

POLITECHNIKA WARSZAWSKA

DYSCYPLINA NAUKOWA NAUK O ZARZĄDZANIU I JAKOŚCI

DZIEDZINA NAUK SPOŁECZNYCH

Rozprawa doktorska

mgr inż. Aron Witkowski

**Model dojrzałości w wykorzystaniu rozwiązań generatywnej
sztucznej inteligencji w procesie rozwoju nowego produktu**

Promotor

dr hab. Andrzej Wodecki, prof. uczelni

WARSZAWA 2025

Podziękowania

Serdecznie dziękuję

Mojemu promotorowi dr hab. Andrzejowi Wodeckiemu, prof. uczelni, za współpracę,
wskazywanie drogi, zrozumienie i swobodę eksploracji świata nauki.

Kadrze naukowej Wydziału Zarządzania Politechniki Warszawskiej
za życzliwość i liczne cenne wskazówki dotyczące rozprawy doktorskiej i pracy naukowej.

W szczególności dziękuję Pani dr hab. inż. Agacie Pierścieniak, prof. uczelni,

Panu dr hab. inż. Januszowi Zawile-Niedźwieckiemu, prof. uczelni oraz

Pani dr hab. Agnieszce Skali-Gosk, prof. uczelni.

Wszystkim osobom, które zgodziły się wziąć udział w badaniach i przyczyniły się do powstania
tej pracy.

Moim Rodzicom za otwartość, zrozumienie i nieocenioną pomoc, dzięki której mogłem podążać
za swoimi celami.

Moim najbliższym za optymizm i wsparcie mentalne.

Na koniec chciałbym osobno podziękować mojej żonie Magdalenie, bez której ta praca by nie
powstała. Dziękuję Jej za motywację, za dawanie mi powodów, by iść naprzód i za nieugiętą
wiarę we mnie.

Streszczenie

Niniejsza rozprawa koncentrowała się na badaniu dojrzałości organizacji w kontekście wykorzystania rozwiązań generatywnej sztucznej inteligencji (*Generative Artificial Intelligence – GenAI*) w procesie rozwoju nowego produktu (*New Product Development – NPD*). Głównym celem pracy było opracowanie preskryptywnego modelu, który umożliwi przedsiębiorstwom ocenę i doskonalenie integracji rozwiązań GenAI w procesie rozwoju produktu. W badaniach zastosowano podejście nauk o projektowaniu (*Design Science Research – DSR*), łącząc dogłębną analizę literatury, wywiady z ekspertami oraz studia przypadków. Na podstawie przeglądu istniejących modeli dojrzałości oraz analizy specyfiki zastosowań GenAI w NPD, opracowano zintegrowany model CLIMB2-OLIMP. Model ten poddano walidacji poprzez wywiady z ekspertami oraz analizę przypadków wdrożeniowych. Badania wykazały, że organizacje mają zróżnicowany poziom dojrzałości w zakresie NPD, a integracja GenAI pozostaje na wczesnym etapie. Główne bariery obejmowały niską jakość danych, brak kompetencji pracowników oraz niejednolite procesy. Model CLIMB2-OLIMP umożliwia diagnozę poziomu dojrzałości organizacji oraz wskazuje rekomendacje dotyczące ścieżek rozwoju.

Rozprawa wnosi wkład w nauki o zarządzaniu, poszerzając metodologię badań nad dojrzałością o obszary związane z nowymi technologiami o wysokim potencjale transformacyjnym, poprzez opracowanie zintegrowanego modelu dojrzałości łączącego ocenę procesów NPD z dojrzałością organizacji w zakresie GenAI. W przeciwieństwie do wcześniejszych modeli, CLIMB2-OLIMP posiada komponent preskryptywny, oparty o duże modele językowe (*Large Language Models – LLM*), który nie tylko ocenia stan organizacji, ale także wskazuje konkretne kroki poprawy. Opracowany model dostarcza praktycznego narzędzia dla menedżerów produktu, wspierając podejmowanie decyzji strategicznych w zakresie wdrażania AI w procesach innowacyjnych. Jednocześnie praca wskazuje na ograniczenia, takie jak ograniczona liczba badanych przypadków oraz dynamiczny charakter rozwoju technologii, co stanowi impuls do dalszych badań w zakresie adaptacji i optymalizacji modeli dojrzałości w kontekście generatywnej AI oraz badań podłużnych w celu oceny długoterminowych efektów wdrażania generatywnej sztucznej inteligencji.

Słowa kluczowe: Proces rozwoju nowego produktu; Generatywna sztuczna inteligencja; Modele dojrzałości; Podejście nauk o projektowaniu; Studium przypadku

Abstract

This dissertation has focused on examining organizational maturity in the context of integrating Generative Artificial Intelligence (GenAI) solutions into the New Product Development (NPD) process. The primary objective was to develop a prescriptive model that enables enterprises to assess and enhance the integration of GenAI into product development. The study employed a Design Science Research (DSR) approach, combining an in-depth literature review, expert interviews, and case studies. Based on a review of existing maturity models and an analysis of the specific applications of GenAI in NPD, an integrated model – CLIMB2-OLIMP – was developed. This model was validated through expert interviews and an analysis of real-world implementation scenarios. The findings revealed that organizations exhibit varying levels of maturity in NPD, while the integration of GenAI remains in its early stages. The main barriers identified include low data quality, lack of employee competencies, and inconsistent processes. The CLIMB2-OLIMP model facilitates the diagnosis of an organization's maturity level and provides prescriptive recommendations for development pathways.

This dissertation contributes to management science by extending maturity research methodologies to areas related to emerging technologies with high transformational potential. It achieves this by developing an integrated maturity model that assesses both NPD processes and the organization's maturity for GenAI adoption. Unlike previous models, CLIMB2-OLIMP includes a prescriptive component, leveraging Large Language Models (LLMs) not only to evaluate an organization's current state but also propose specific improvement steps.

The developed model serves as a practical tool for product managers, supporting strategic decision-making regarding AI implementation in innovation processes. At the same time, the study highlights certain limitations, such as the limited number of case studies and the dynamic nature of technological advancements, which signal the need for further research on the adaptation and optimization of maturity models in the context of GenAI. Additionally, longitudinal studies are recommended to assess the long-term impact of Generative AI adoption on organizational innovation and efficiency.

Keywords: New Product Development; Generative Artificial Intelligence; Maturity models; Design Science Research approach; Case studies

Spis treści

Wykaz skrótów i pojęć.....	13
Wprowadzenie.....	18
Rozdział 1. Przegląd istotnych komponentów tworzących domenę badawczą pracy	29
1.1. Zarys badań nad procesem rozwoju nowego produktu	29
1.2. Sztuczna inteligencja w zarządzaniu produktem	38
1.3. Dojrzałość i modele dojrzałości w literaturze naukowej.....	52
1.4. Podsumowanie przeglądu istotnych komponentów tworzących domenę badawczą pracy	75
Rozdział 2. Badania literaturowe	76
2.1. Proces przeglądu literatury dla modeli dojrzałości.....	76
2.2. Wyniki przeglądu literatury dla modeli dojrzałości procesowej	80
2.3. Dyskusja modeli dojrzałości procesowej.....	97
2.4. Wyniki przeglądu literatury dla modeli dojrzałości AI	104
2.5. Dyskusja modeli dojrzałości AI.....	113
2.6. Analiza bibliometryczna i przegląd literatury w celu identyfikacji elementów modelu	121
2.7. Wyniki przeglądu literatury identyfikującego elementy modelu	126
2.8. Dyskusja wyników przeglądu literatury identyfikującego elementy modelu.....	134
2.9. Podsumowanie badań literaturowych	140
Rozdział 3. Wywiady – zastosowania, wyzwania i czynniki sukcesu wprowadzenia rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju nowego produktu	143
3.1. Wywiady – podejście badawcze	143
3.2. Wywiady – rezultaty badań	146
3.3. Wywiady – dyskusja wyników	155
3.4. Podsumowanie zidentyfikowanych zastosowań, wyzwań i czynników sukcesu	161
Rozdział 4. Opracowanie modelu dojrzałości w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju nowego produktu	163
4.1. Podejście badawcze	163
4.2. Definicja problemu	164
4.3. Określenie strategii budowy modelu	165
4.4. Iteracyjny rozwój modelu	170
4.5. Koncepcja transferu i ewaluacji oraz implementacja mediów	189
4.6. Podsumowanie opracowania modelu dojrzałości.....	190
Rozdział 5. Ewaluacja modelu dojrzałości w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju nowego produktu	192
5.1. Dobór i opis organizacji.....	192

5.2.	Wyniki oceny dojrzałości	193
5.3.	Dyskusja wyników oceny dojrzałości	209
5.4.	Podsumowanie oceny dojrzałości.....	220
Podsumowanie		222
Bibliografia		230
Spis rysunków i tabel		251
Spis rysunków		251
Spis tabel		251
Spis załączników.....		252
Załączniki.....		252

Wykaz skrótów i pojęć

(w kolejności alfabetycznej)

AI – Sztuczna inteligencja (*Artificial Intelligence*)

AIMM – Model dojrzałości w wykorzystaniu sztucznej inteligencji (*Artificial Intelligence Maturity Model*)

BERT – Jeden z modeli językowych (*Bidirectional Encoder Representations from Transformers*)

BPM – Zarządzanie procesami biznesowymi (*Business Process Management*)

BPMM – Model dojrzałości procesu biznesowego (*Business Process Maturity Model*)

BPMMM – Model dojrzałości zarządzania procesami biznesowymi (*Business Process Management Maturity Models*)

BPO – Zorientowanie organizacji na zarządzanie procesowe (*Business Process Orientation*)

CAD – Projektowanie wspomagane komputerowo (*Computer Aided Design*)

CAE – Prace inżynierskie wspomagane komputerowo (*Computer Aided Engineering*)

CAI – Jeden z modeli dojrzałości procesowej w procesie rozwoju nowego produktu

CAM – Wytwarzanie wspomagane komputerowo (*Computer Aided Manufacturing*)

CAPP – Komputerowe wspomaganie planowania procesów (*Computer Aided Process Planning*)

CAS – Stylizacja wspomagana komputerowo (*Computer Aided Styling*)

CDM – System zarządzania danymi klientów (*Customer Data Management*)

CFD – Obliczeniowa dynamika płynów (*Computational Fluid Dynamics*)

ChatGPT – Jeden z najpopularniejszych chatbotów, opartych na modelu GPT

CLIMB – Jeden z modeli dojrzałości procesowej w procesie rozwoju nowego produktu

CLIP – Jeden z modeli multimodalnych (*Contrastive Language-Image Pretraining*)

CMM – Jeden z modeli dojrzałości, wczesna wersja modeli CMMI (*Capability Maturity Model*)

CMMI – Jeden z najpopularniejszych modeli dojrzałości (*Capability Maturity Model Integration*)

CMMS – Skomputeryzowany system zarządzania konserwacją (*Computerized Maintenance Management System*)

CPI – Jeden z modeli dojrzałości procesowej w procesie rozwoju nowego produktu

CRM – Systemy zarządzania relacjami z klientami (*Customer Relationships Management*)

CSAT – Skala satysfakcji klienta (*Customer SATisfaction*)

CTR – Współczynnik klikalności (*Click-Through Rate*)

CV – Rozwiązania wizji komputerowej / widzenia maszynowego (*Computer Vision*)

CX – Zarządzanie doświadczeniem klienta (*Customer eXperience*)

DALL-E – Model służący do generacji obrazów

DES – Symulacja zdarzeń dyskretnych (*Discrete Event Simulation*)

DFX – Projektowanie dla wybranej zmiennej X (*Design for X*)

DL – Uczenie Głębokie (*Deep Learning*)

DMS – Systemy zarządzania dokumentami (*Document Management Systems*)

DMU – Cyfrowa makieta / cyfrowy opis produktu (*Digital Mock-Up*)

DoD – Departament Obrony Stanów Zjednoczonych (*Department of Defense*)

DREAMY – Jeden z modeli dojrzałości cyfrowej

DSR – Metodologia nauk o projektowaniu (*Design Science Research*)

DTC – Systematyczne podejście do kontrolowania kosztów rozwoju i wytwarzania produktu (*Design-To-Cost*)

EBIT – Zysk operacyjny (*Earnings Before Interests and Taxes*)

ERP – Systemy planowania zasobów przedsiębiorstwa (*Enterprise Resource Planning*)

FEA/FEM – Metoda analizy elementów skończonych (*Finite Element Analysis / Method*)

FFE – Określenie aktywności poprzedzających proces projektowania i wytwarzania produktu (*Fuzzy Front-End*)

FID – Jedna z metryk oceny modeli generatywnych (*Fréchet Inception Distance*)

FMEA/FMECA – Analiza rodzajów i skutków możliwych błędów (*FMEA – Failure Mode and Effects Analysis / FMECA – Failure Mode, Effects and Criticality Analysis*)

GAN – Generatywne sieci przeciwstawne (*Generative Adversarial Networks*)

GenAI – Generatywna sztuczna inteligencja (*Generative Artificial Intelligence*)

GMM – Modele Mieszanin Rozkładów Gaussa (*Gaussian Mixture Models*)

GPT – Jeden z modeli językowych (*Generative Pre-trained Transformer*)

GRU – Bramkowane jednostki rekurencyjne (*Gated Recurrent Units*)

HITL – Model wymagający interakcji człowieka (*Human-In-The-Loop*)

HMM – Ukryte Modele Markova (*Hidden Markov Models*)

IoT – Internet Rzeczy (*Internet of Things*)

IS – Jedna z metryk oceny modeli generatywnych (*Inception Score*)

KBE – Zastosowanie technologii systemów opartych na wiedzy w dziedzinie projektowania i produkcji (*Knowledge-Based Engineering*)

KM – Zarządzanie wiedzą (*Knowledge Management*)

KPI – Kluczowe wskaźniki efektywności (*Key Performance Indicator*)

LCA – Oprogramowanie do analizy cyklu życia (*Lifecycle Analysis Software*)

LCA&E – Metodologia oceny (*Life-Cycle Assessment/Analysis*) lub inżynierska (*Life-Cycle Engineering*) wpływu na środowisko związanego ze wszystkimi etapami cyklu życia produktu

LCC – Koszt posiadania w całym okresie życia danego produktu (*Life-Cycle Cost*)

LDA – Jedna z metod modelowania tematów (*Latent Dirichlet Allocation*)

LLM – Duże modele językowe (*Large Language Models*)

LSTM – Długa pamięć krótkotrwała (*Long Short-Term Memory*)

ML – Uczenie Maszynowe (*Machine Learning*)

MLOps – Paradygmat wdrażania i utrzymywania modeli uczenia maszynowego w produkcji (*Machine Learning Operations*)

MM – Model dojrzałości (*Maturity Model*)

MVP – Produkt o kluczowej funkcjonalności (*Minimum Viable Product*)

NLP – Rozwiązania przetwarzania języka naturalnego (*Natural Language Processing*)

NPD – Proces rozwoju nowego produktu (*New Product Development*)

NPS – Narzędzie pomiaru lojalności klientów (*Net Promoter Score*)

OMG – Organizacja, która stworzyła model OMG-BPM (*Object Management Group*)

PARP – Polska Agencja Rozwoju Przedsiębiorczości

PDM – Systemy zarządzania danymi produktowymi (*Product Data Management*)

PDMA – Amerykańskie stowarzyszenie rozwoju i zarządzania produktami (*Product Development and Management Association*)

PLM – Zarządzanie cyklem życia produktu (*Product Lifecycle Management*)

QFD – Metoda identyfikowania wartości dla konsumentów i przekładania ich na cechy produktu/usługi przy wprowadzaniu nowych produktów na rynek (*Quality Function Deployment*)

RL – Uczenie ze wzmocnieniem (*Reinforcement Learning*)

RNN – Rekurencyjne sieci neuronowe (*Recurrent Neural Networks*)

ROI – Zwrot z inwestycji (*Return On Investment*)

RPA – Zrobotyzowana automatyzacja procesów (*Robotic Process Automation*)

SCM – Systemy zarządzania łańcuchem dostaw (*Supply Chain Management*)

SEI – Centrum badawczo-rozwojowe prowadzone przez Carnegie Mellon University, odpowiadające za budowę modeli CMM/CMMI (*Software Engineering Institute*)

SRM – Systemy zarządzania relacjami z dostawcami (*Supplier Relationship Management*)

TCM – Proces stosowania umiejętności i wiedzy z zakresu inżynierii kosztów (*Total Cost Management*)

TCO – Oszacowanie finansowe, które ma pomóc określić koszty produktu lub usługi (*Total Cost of Ownership*)

TTM – Czas, jaki upływa od powstania produktu do jego udostępnienia do sprzedaży (*Time-To-Market*)

TRIZ – Jedna z metod tworzenia innowacyjnych pomysłów i rozwiązywania problemów (ros. *Teoria Reszenija Izobretatielskich Zadacz*)

UGC – Treści generowane przez użytkowników (*User Generated Content*)

VAE – Autoenkodery wariacyjne (*Variational Autoencoders*)

VA&E – Analiza wartości / Inżynieria wartości (*Value Analysis/Value Engineering*)

VR/AR – Rzeczywistość wirtualna / rozszerzona (*Virtual / Augmented Reality*)

WMS – Systemy zarządzania przepływem pracy (*Workflow Management Systems*)

Wprowadzenie

Obszar problemowy – przesłanki i uzasadnienie

Tematyka doktoratu koncentruje się na wykorzystaniu rozwiązań generatywnej sztucznej inteligencji (*Generative Artificial Intelligence – GenAI*) w procesach rozwoju nowego produktu (*New Product Development – NPD*), w szczególności na pomiarze dojrzałości organizacji w wykorzystaniu rozwiązań GenAI w tych procesach. Problematyka ta jest silnie związana z innymi kwestiami z zakresu nauki o zarządzaniu i jakości i jest umiejscowiona w subdyscyplinie zarządzania procesami i projektami w obszarze badań związanym z metodami doskonalenia procesów i dojrzałością organizacji.

Istnieje wiele przesłanek do podjęcia powyższej tematyki, związanych z wpływem, jaki rozwiązywanie sztucznej inteligencji, w szczególności generatywnej sztucznej inteligencji, wywierają zarówno na poziomie mikro (organizacje, procesy) oraz makro (gospodarka), a także z podejściem ludzi do tych rozwiązań. Z perspektywy Polski, obszar badań związany z wykorzystaniem rozwiązań sztucznej inteligencji jest na tyle istotny, że Rada Ministrów 28 grudnia 2020 roku uchwaliła „Politykę rozwoju AI w Polsce” (M.P. poz. 23 2021). W polityce opisany jest wykaz programów finansujących projekty związane z rozwojem i wdrażaniem rozwiązań AI. Jedną z instytucji finansujących jest Polska Agencja Rozwoju Przedsiębiorczości, której celem programu jest „opracowanie i wprowadzenie na rynek nowych lub znacząco ulepszonych produktów lub usług opartych na nowoczesnych technologiach”. Inną instytucją jest Fundacja Platforma Przemysłu Przyszłości, której celem programu jest działanie na rzecz wzrostu konkurencyjności przedsiębiorców, co ma być osiągnięte przez „wsparcie ich transformacji cyfrowej w zakresie procesów, produktów i modeli biznesowych, wykorzystujących najnowsze osiągnięcia z dziedziny automatyzacji, sztucznej inteligencji, technologii teleinformatycznych oraz komunikacji między maszynami oraz człowiekiem a maszynami”. Cele i narzędzia polityki są podzielone na sześć obszarów: „AI i społeczeństwo”, „AI i innowacyjne firmy”, „AI i nauka”, „AI i edukacja”, „AI i współpraca międzynarodowa” oraz „AI i sektor publiczny”. W ramach celu AI i nauka jest opracowywanie inicjatyw wspierających środowisko naukowe i badawcze w Polsce w zakresie projektowania rozwiązań interdyscyplinarnych związanych ze sztuczną inteligencją. Te działania obejmują uwzględnianie aspektów nauk humanistycznych i społecznych, zakładanie katedr AI,

prowadzenie programów edukacyjnych dla doktorantów, przyznawanie grantów badawczych oraz podejmowanie innych działań mających na celu przygotowanie specjalistów zdolnych do opracowywania rozwiązań opartych na sztucznej inteligencji, przy jednoczesnym uwzględnieniu etycznych i bezpiecznych ram korzystania z tej technologii.

Inną z niezwykle istotnych przesłanek do podjęcia tematu rozprawy doktorskiej jest powstanie ChatGPT. Aplikacja bazująca na zaawansowanej architekturze GPT (*Generative Pre-Trained Transformer*), reprezentuje wybitny przykład, jak zaawansowane modele generatywne mogą zmieniać sposób, w jaki ludzie komunikują się z technologią. Sama aplikacja przyciągnęła 1 milion użytkowników w ciągu 5 dni i 100 milionów w ciągu 2 miesięcy od powstania (Duarte, 2024; Hu, 2023). Przełomowy charakter tego modelu stwarza fascynujące możliwości zastosowania GenAI w obszarze rozwoju produktu, gdzie interakcje między ludźmi a technologią są kluczowe. Rozprawa doktorska w tym zakresie miałaby potencjał nie tylko do przyczynienia się do teoretycznego rozwinięcia dziedziny, ale także do wypracowania praktycznych wskazówek dotyczących skutecznego wykorzystania rozwiązań generatywnej sztucznej inteligencji w środowisku biznesowym.

Wspomniana wcześniej Polska Agencja Rozwoju Przedsiębiorczości stworzyła raport „Zastosowania sztucznej inteligencji w gospodarce. Przegląd wybranych inicjatyw i technologii z rekomendacjami dla przedsiębiorców” (Polska Agencja Rozwoju Przedsiębiorczości, 2023). W raporcie wskazano rozwój technologii generatywnych jako jeden z najważniejszych trendów w obszarze sztucznej inteligencji. Według raportu, w roku 2022 światowy rynek generatywnej sztucznej inteligencji, przed premierą aplikacji ChatGPT, oceniano na 10,63 miliarda dolarów amerykańskich, przewidując jego wzrost o około 34,2% do 2030 roku. Aktualna sytuacja na rynku technologii sztucznej inteligencji jest na tyle dynamiczna, że nie można jednoznacznie potwierdzić tych wcześniejszych prognoz, a przewiduje się, że wzrosty te mogą być wielokrotnie wyższe. Raport pokazuje wiele polskich i zagranicznych firm korzystających z rozwiązań AI, w tym GenAI, na przykład brytyjską firmę Stability AI Ltd., której rozwiązanie pozwala na generowanie obrazu na podstawie tekstu czy polską spółkę SentiOne Sp. z o.o., która opracowała boty konwersacyjne oparte na rozwiązaniach AI.

Nad badaniami na temat wykorzystania rozwiązań AI w obszarze rozwoju produktu skupia się w swoich najnowszych badaniach dr Robert G. Cooper¹, który jest twórcą światowej sławy procesu *Stage-Gate®* i międzynarodowo uznawanym ekspertem w dziedzinie zarządzania produktami. Według dr. Coopera, wykorzystanie sztucznej inteligencji stanie się kolejnym kamieniem milowym procesu rozwoju nowego produktu (*New Product Development – NPD*) i zmieni krajobraz rozwoju nowego produktu. Zdaniem naukowca, liczne zastosowania AI w procesie NPD już przyniosły drastyczne zmiany, zwiększając szybkość, efektywność i jakość NPD dla tych firm, które wcześniej zaadaptowały rozwiązania AI, jednocześnie wskazując, że ta adaptacja w organizacjach nie może odbywać się kawałkami, a musi to być całościowa transformacja, prowadzona odważną, przedsiębiorczą strategią, stworzoną i popieraną przez zespół kierowniczy danej organizacji (Cooper, 2023a).

Wybór tematyki rozprawy w obszarze wykorzystania rozwiązań generatywnej sztucznej inteligencji w procesach rozwoju produktu jest także podyktowany doświadczeniami naukowymi i zawodowymi autora niniejszej rozprawy (w dalszej części rozprawy także jako „Autor”). Autor od ponad 8 lat zajmuje się zarządzaniem produktem, w ostatniej roli jako globalny kierownik produktu, wprowadzający produkty technologiczne na rynki europejski, amerykański i azjatycki, a także doskonaleniem tych procesów, biorąc udział w testach pilotażowych wdrażania nowych rozwiązań, w tym rozwiązań generatywnej sztucznej inteligencji.

Podsumowując: sytuacja problemowa (Nowak, 2012), będąca punktem wyjścia do tego, aby sformułować problem badawczy jest motywacją do podjęcia badań teoretycznych i empirycznych umożliwiających zrozumienie wykorzystania rozwiązań GenAI w procesie rozwoju nowego produktu oraz opracowanie narzędzi, które mogłyby zwiększyć efektywność tych procesów. Uzasadnienie do przeprowadzenia owych jest oparte na sformułowanych przesłankach, które potwierdzają zapotrzebowanie naukowe i społeczno-gospodarcze na przeprowadzenie tego rodzaju prac badawczych.

¹ Dr. Robert G. Cooper został uznany za najwybitniejszego naukowca ds. zarządzania innowacjami na świecie przez prestiżowy amerykański *Journal of Product Innovation Management* oraz zdobył tytuł najlepszego lidera seminarium roku w *Chalmers Institute* w Göteborgu w Szwecji. Jest również członkiem Stowarzyszenia Rozwoju i Zarządzania Produktem (PDMA). Przez wiele lat łączył praktyczne doradztwo z pionierskimi badaniami, opublikował dwie książki i ponad 130 artykułów na temat zarządzania badaniami i rozwojem oraz zarządzania produktami i innowacjami.

Eksploracja problemu badawczego – wnioski z badań wstępnych i luka badawcza

Aby zweryfikować problem badawczy i uzyskać bardziej szczegółowe zrozumienie sytuacji związanej z wykorzystaniem rozwiązań generatywnej sztucznej inteligencji (GenAI) w procesie rozwoju nowego produktu, przeprowadzono własne badania wstępne, które skupiły się na eksploracji tego zagadnienia.

Pierwszym elementem badań wstępnych była analiza wywiadów pogłębionych (n=7) z kierownikami produktu i inżynierami zajmującymi się wdrożeniami rozwiązań sztucznej inteligencji. Respondentom zadano pytanie, co byłoby dla nich najbardziej interesujące z perspektywy wykorzystania rozwiązań sztucznej inteligencji w procesie rozwoju nowego produktu. Wyróżniono dwie odpowiedzi:

- *„Sztuczna inteligencja to jest duży temat, może warto by to jakoś zawęzić? Z perspektywy wdrożeń rozwiązań AI, najciekawszym tematem w najbliższej przyszłości będą rozwiązania generatywnej sztucznej inteligencji – myślę, że to jest coś nad czym można się zastanowić. (...) Gdyby zapytać kierowników produktu jakie widzą zastosowania AI wspomagające ich pracę, to daję głowę, że większość wskaże rozwiązania GenAI, czasem nie zdając sobie nawet sprawy, że właśnie je wskazują. Można by też pokazać im takie rozwiązanie, jak to działa w praktyce i poprosić ich, żeby ocenili potencjał tego rozwiązania – na ile oceniają, że takie rozwiązanie poprawiłoby efektywność ich pracy.”*
- *„Przy takich wdrożeniach rozwiązań sztucznej inteligencji, które wspomagają procesy, ważna jest kwestia w jakim stopniu firma jest dojrzała, jeśli chodzi o takie wdrożenie. Często brak jest świadomości albo infrastruktury albo obu tych rzeczy. Myślę, że warto by było podpytać firmy, jakie największe wyzwania widzą lub jakie mieli w przeszłości, jeśli chodzi o wdrażanie rozwiązań AI w danym procesie. Każda firma jest w innym stadium zaawansowania i każda będzie wymagała nieco innego podejścia.”*

Z wywiadów wynikają dwie istotne implikacje: kilkoro respondentów wskazało na rozwiązania generatywnej sztucznej inteligencji jako jeden z najbardziej interesujących tematów w kontekście wsparcia procesu rozwoju nowego produktu oraz na pomiar dojrzałości, jeśli chodzi o wdrażanie takich rozwiązań.

Drugim elementem badań wstępnych był systematyczny przegląd literatury w zakresie modeli dojrzałości procesowej i dojrzałości w wykorzystaniu sztucznej inteligencji (AI), omówiony szerzej w rozdziale trzecim. Zidentyfikowano 15 modeli dojrzałości AI oraz 28 związanych z dojrzałością procesu rozwoju produktu. Analiza tych koncepcji pozwoliła wskazać pewne prawidłowości. Pierwsze modele dojrzałości AI zostały opracowane stosunkowo niedawno, a jedynie jeden z piętnastu dotyczył dojrzałości GenAI i jest on ukierunkowany na procesy kształcenia online i kształcenia dorosłych. Można dostrzec **lukę badawczą** związaną z brakiem ogólnego lub ukierunkowanego na proces rozwoju produktu modelu dojrzałości w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji. Inną prawidłowością zidentyfikowaną w procesie systematycznego przeglądu literatury była obserwacja dotycząca preskryptywności modeli – większość przedstawionych modeli to modele opisowe, czyli pokazujące stan organizacji na danym poziomie dojrzałości. Brak jest modeli preskryptywnych, czyli takich, które pokazują w jaki sposób przejść z niższego poziomu dojrzałości na wyższy. Niektóre modele można uznać za częściowo preskryptywne, gdyż proponują pewne kroki przejścia na wyższy poziom dojrzałości, ale nie uwzględniają na przykład alternatyw w dojściu do wyższego poziomu dojrzałości lub analizy kosztu i korzyści (Röglinger, Pöppelbuß i Becker 2012). Zauważalna jest także krytyka modeli dojrzałości w literaturze, którą wskazują także sami autorzy opracowywanych modeli dojrzałości, często jednak nie odnosząc się do tej krytyki podczas budowy własnego modelu. Jeśli chodzi o wymiary modeli dojrzałości, można zauważyć podobieństwa między modelami dojrzałości AI i modelami dojrzałości procesu rozwoju produktu. Autor przyjmuje założenie, że organizacja powinna być już na pewnym poziomie dojrzałości, jeśli chodzi o dojrzałość procesu rozwoju produktu, zanim zbadana zostanie dojrzałość w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w tym procesie. Innymi słowy, pewien stopień dojrzałości procesu rozwoju produktu warunkuje pomiar dojrzałości w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji.

Podsumowując: wyniki badań wstępnych wskazały na zainteresowanie tematem użycia generatywnej sztucznej inteligencji w procesie rozwoju nowego produktu i na potrzebę oceny dojrzałości organizacji w wykorzystaniu tych rozwiązań.

Sformułowanie problemu badawczego

Po przeanalizowaniu wyników badań wstępnych, wyłania się potrzeba określenia, w jaki sposób organizacje są w stanie wykorzystać rozwiązania generatywnej sztucznej inteligencji w procesach rozwoju nowego produktu, biorąc pod uwagę dojrzałość wykorzystania tych rozwiązań.

Według Nowaka (2012) każdy problem badawczy daje się opisać odpowiedzią na pytanie „jakie i na ile ogólne relacje między jakimi własnościami jakich przedmiotów czy też zdarzeń i procesów, którym te przedmioty podlegają, chcielibyśmy uchwycić i wykryć w naszych badaniach oraz opisać czy wyjaśnić w naszych twierdzeniach, prawach i teoriach”. Stąd celem Autora było uchwycenie relacji między rozwiązaniami generatywnej sztucznej inteligencji a procesami rozwoju nowego produktu, biorąc pod uwagę dojrzałość organizacji w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w tych procesach. W związku z tym problem badawczy został ujęty w formie następującego głównego pytania badawczego:

Główne pytanie badawcze: W jaki sposób można zmierzyć dojrzałość organizacji w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesach rozwoju nowego produktu oraz opracować narzędzie wspierające działania rozwojowe na podstawie tej oceny?

Zadane pytanie badawcze zostało doprecyzowane poprzez sformułowanie szczegółowych pytań badawczych, których treści i uzasadnienia zostały opisane w Tabeli 1.

Cel główny pracy oraz cele szczegółowe

Główne pytanie badawcze, które wyraża problem badawczy, wskazuje na konieczność opracowania sposobu pomiaru dojrzałości w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji. Cel główny pracy przyjmuje zatem następującą formę:

Cel główny: Opracowanie preskryptywnego modelu dojrzałości organizacji w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju nowego produktu i metodyki jej pomiaru.

Cel główny został podzielony na cel poznawczy, cel metodyczny i cel aplikacyjny. Poniżej zaprezentowane są cele szczegółowe oraz zastosowane metody, techniki i narzędzia badawcze.

Tabela 1. Szczegółowe pytania badawcze wraz z uzasadnieniem (PB – pytanie badawcze).

Nr i treść pytania	Uzasadnienie i cel
PB1. W jaki sposób mierzona jest dojrzałość procesu rozwoju nowego produktu i dojrzałość w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji?	Pytanie badawcze wpisuje się w cel poznawczy rozprawy. Odpowiedź na pytanie będzie podstawą do budowy własnego modelu dojrzałości.
PB2. Jakie są potencjalne i aktualne zastosowania generatywnej sztucznej inteligencji w procesach rozwoju nowego produktu oraz wyzwania i czynniki sukcesu wdrożeń (np. najlepsze praktyki) tego typu rozwiązań w organizacjach?	Pytanie badawcze wpisuje się w cel poznawczy rozprawy. Identyfikacja i analiza zastosowań, wyzwań i czynników sukcesu (np. najlepszych praktyk) pomoże określić elementy, poziomy i przynależność praktyk do poziomów modelu dojrzałości.
PB3. W jaki sposób można zaprojektować (uwzględniając aktualną krytykę modeli) model dojrzałości w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesach rozwoju nowego produktu, tak, aby uzależnić dojrzałość organizacji w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji od dojrzałości procesu rozwoju produktu?	Pytanie badawcze wpisuje się w cel metodyczny rozprawy. Opracowanie modelu dojrzałości pomoże zmierzyć poziom dojrzałości organizacji w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesach rozwoju nowego produktu.
PB4. W jaki sposób zaprojektować część preskryptywną modelu dojrzałości w oparciu o duże modele językowe?	Pytanie badawcze wpisuje się w cel metodyczny rozprawy. Opracowanie części preskryptywnej modelu pozwoli organizacjom wskazać kroki, jakie powinny zostać wykonane, żeby osiągnąć wyższy poziom dojrzałości, uwzględniając różne alternatywy i analizę kosztów i korzyści.
PB5. Jaki jest poziom dojrzałości wybranych organizacji w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesach rozwoju nowego produktu?	Pytanie badawcze wpisuje się szczególnie w cel aplikacyjny rozprawy. Pomiar poziomu dojrzałości organizacji w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesach rozwoju nowego produktu umożliwi diagnozę tego poziomu i ocenę użyteczności modelu jako narzędzia do pomiaru dojrzałości i wskazania możliwości rozwoju.

Źródło: opracowanie własne.

1. **Cel poznawczy:** Identyfikacja relacji między rozwiązaniami generatywnej sztucznej inteligencji a procesami rozwoju nowego produktu.
 - **Cel poznawczy 1:** Identyfikacja cech modeli dojrzałości sztucznej inteligencji i modeli dojrzałości procesu rozwoju produktu.
 - **Metody, techniki i narzędzia badawcze:** Systematyczny przegląd literatury.

- **Cel poznawczy 2:** Identyfikacja aktualnych i potencjalnych zastosowań generatywnej sztucznej inteligencji w procesach rozwoju nowego produktu oraz wyzwań i czynników sukcesu (najlepszych praktyk) wdrożeń tych rozwiązań.
 - **Metody, techniki i narzędzia badawcze:** Systematyczny przegląd literatury, wywiady częściowo ustrukturyzowane, analiza tematyczna.
- 2. **Cel metodyczny:** Opracowanie modelu dojrzałości organizacji w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju nowego produktu, w tym narzędzia opartego o rozwiązania generatywnej sztucznej inteligencji, odpowiadającego za część preskryptywną modelu.
 - **Cel metodyczny 1:** Opracowanie części opisowej modelu dojrzałości organizacji w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju nowego produktu.
 - **Metody, techniki i narzędzia badawcze:** Podejście nauk o projektowaniu, walidacja z wybraną grupą odbiorczą.
 - **Cel metodyczny 2:** Opracowanie narzędzia opartego o duże modele językowe, odpowiadającego za część preskryptywną modelu.
 - **Metody, techniki i narzędzia badawcze:** Opracowany kod programu.
- 3. **Cel aplikacyjny:** Empiryczna weryfikacja przygotowanego modelu dojrzałości w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju nowego produktu w wybranych organizacjach.
 - **Cel aplikacyjny 1:** Zbadanie dojrzałości organizacji w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju produktu przy użyciu opracowanego modelu.
 - **Metody, techniki i narzędzia badawcze:** Wywiady częściowo ustrukturyzowane, kwestionariusz.
 - **Cel aplikacyjny 2:** Empiryczna weryfikacja opracowanego narzędzia opartego o rozwiązania generatywnej sztucznej inteligencji odpowiadającego za część preskryptywną modelu.

- **Metody, techniki i narzędzia badawcze:** Wywiady częściowo ustrukturyzowane.

Podsumowaniem tych rozważań jest sformułowanie głównej **tezy pracy**, którą jest twierdzenie, że możliwe jest opracowanie modelu dojrzałości organizacji w wykorzystaniu generatywnej sztucznej inteligencji w procesie rozwoju produktu, uwzględniając aktualną krytykę modeli, część preskryptywną modelu oraz dojrzałość samego procesu rozwoju produktu.

Sposób realizacji procesu badawczego

W kontekście postawionego problemu badawczego, przedmiotem badania są procesy rozwoju produktu. Opracowano strukturalny plan procesu badawczego, zawierający następujące etapy:

1. Opis istotnych komponentów tworzących domenę badawczą pracy (rozdział 1).
2. Przeprowadzenie systematycznego przeglądu literatury w obszarze modeli dojrzałości procesowej procesu rozwoju nowego produktu oraz modeli dojrzałości AI w celu znalezienia odpowiedzi na pytanie badawcze 1 i realizacji celu poznawczego 1 (rozdział 2).
3. Przeprowadzenie systematycznego przeglądu literatury w obszarze relacji rozwiązań generatywnej sztucznej inteligencji i procesu rozwoju nowego produktu w celu znalezienia odpowiedzi na pytanie badawcze 2 i częściowej realizacji celu poznawczego 2 (rozdział 2).
4. Realizacja wywiadów częściowo ustrukturyzowanych na próbie 12 respondentów i zakodowanie zebranych danych z wywiadów oraz późniejsza analiza tych danych (szczegółowy opis badania i procedury doboru próby badawczej dostępny w rozdziale 3) w celu pogłębienia odpowiedzi na pytanie badawcze 2, realizacji celu poznawczego 2 oraz częściowej realizacji celu metodycznego 1.
5. Opracowanie części deskryptywnej modelu dojrzałości w wykorzystaniu rozwiązań GenAI w procesie rozwoju nowego produktu oraz walidacja tego modelu (rozdział 4) w celu znalezienia odpowiedzi na pytanie badawcze 3 oraz realizacji celu metodycznego 1.
6. Opracowanie narzędzia opartego o rozwiązania dużych modeli językowych, odpowiadającego za część preskryptywną modelu (rozdział 4) w celu znalezienia odpowiedzi na pytanie badawcze 4 oraz realizacji celu metodycznego 2.

7. Realizacja badań empirycznych – ocena dojrzałości organizacji (rozdział 5) w celu znalezienia odpowiedzi na pytanie badawcze 5 oraz realizacji celu aplikacyjnego.
8. Odpowiedź na szczegółowe pytania badawcze (Podsumowanie).
9. Opracowanie wniosków z badań oraz wskazania implikacji dla przyszłych badań (Podsumowanie).

Działania zostały więc podzielone na etapy – od sprawdzenia aktualnej wiedzy na temat modeli dojrzałości w badanej dziedzinie, przez zbadanie relacji pomiędzy rozwiązaniami generatywnej sztucznej inteligencji oraz procesu rozwoju nowego produktu (w formie systematycznego przeglądu literatury i wywiadów), opracowanie modelu dojrzałości w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju nowego produktu łącznie z narzędziem odpowiadającym za część preskryptywną, aż do weryfikacji przygotowanego modelu i badań organizacyjnych.

Struktura rozprawy doktorskiej

Sposób realizacji procesu badawczego jest odzwierciedlony w strukturze niniejszej rozprawy doktorskiej.

W rozdziale pierwszym o charakterze teoretyczno – poznawczym dokonano analizy terminologicznej systematyzującej i formalizującej opis procesu rozwoju produktu, rozwiązań sztucznej inteligencji oraz dojrzałości, definiując podstawowe pojęcia stosowane w rozprawie.

W rozdziale drugim przeprowadzono systematyczny przegląd literatury dotyczący modeli dojrzałości procesowej związanych z rozwojem nowego produktu i modeli dojrzałości AI organizacji. Kolejno przeprowadzono także systematyczny przegląd literatury w celu rozpoznania potencjalnych elementów konstruowanego modelu.

W rozdziale trzecim przeprowadzono wywiady częściowo ustrukturyzowane w celu eksploracji zastosowań, wyzwań i czynników sukcesu związanych z wdrożeniem rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju nowego produktu. Szczegółowo podsumowano i przedyskutowano wyniki.

W rozdziale czwartym opracowano model dojrzałości w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju nowego produktu, uwzględniając część preskryptywną modelu, opartą o rozwiązania generatywnej sztucznej inteligencji, w celu określenia wytycznych dla organizacji, w zależności od poziomu, na którym dana organizacja obecnie się znajduje.

W rozdziale piątym zaprezentowano wyniki badań empirycznych oraz oceniono użyteczność modelu jako narzędzia do pomiaru dojrzałości organizacji oraz do wskazania rekomendacji dotyczących rozwoju.

W ostatniej części pracy udzielono odpowiedzi na konkretne pytania badawcze i odniesiono się do głównego celu badawczego. Autor rozprawy przedstawił również swój wkład w nauki o zarządzaniu i jakości, wskazując ograniczenia oraz potencjalne obszary do dalszych badań w dziedzinie wykorzystania generatywnej sztucznej inteligencji w procesie rozwoju nowego produktu.

Rozdział 1. Przegląd istotnych komponentów tworzących domenę badawczą pracy

Niniejszy rozdział analizuje punkty styku trzech kluczowych obszarów: procesu rozwoju nowych produktów (w rozprawie także jako „proces rozwoju produktu”, *New Product Development – NPD*), sztucznej inteligencji (*Artificial Intelligence – AI*) oraz teorii dojrzałości. Poprzez integrację perspektyw historycznych i współczesnych badań, celem jest dostarczenie kompleksowego zrozumienia, w jaki sposób te dziedziny wzajemnie na siebie oddziałują.

1.1. Zarys badań nad procesem rozwoju nowego produktu

W literaturze naukowej występuje bardzo wiele definicji słowa „produkt”, np. „w szerokim rozumieniu pojęcie „produktu” odnosi się jednak nie tylko do fizycznego towaru, ale również do różnorodnych usług, koncepcji i idei, projektów, czynności, umiejętności i zdolności człowieka oraz wszelkich projektów stanowiący wytwór człowieka lub też natury” (P. Rutkowski, 2011). Korzystając z definicji Kotlera (2006), produkt to "cokolwiek, co może być zaoferowane na rynek w celu przyciągnięcia uwagi, nabycia, użytkowania lub konsumpcji, co może zaspokoić chęć lub potrzebę. Obejmuje to przedmioty fizyczne, usługi, osoby, miejsca, organizacje i pomysły". Najczęściej jednak przez produkt rozumiany jest fizyczny, "tradycyjny" obiekt jak np. rower, biurko, lodówka; obiekt wirtualny (oprogramowanie), np. aplikacja mobilna czy gra internetowa albo połączenie obu, czyli inteligentny, połączony produkt, który oprócz fizycznych komponentów (części mechaniczne i elektryczne) posiada także inteligentne komponenty (czujniki, pamięć danych, oprogramowanie, system operacyjny) i komponenty łączności (porty, anteny, sieć umożliwiającą komunikację między produktem a chmurą produktu) (Porter i Heppelmann, 2015). Ze względu na fakt, że powyższe definicje bardzo szeroko opisują produkt, Autor zdecydował się na zawężenie definicji i w niniejszych badaniach jest to dobro fizyczne (oraz ewentualne towarzyszące dobru fizycznemu usługi), spełniające określoną potrzebę klienta.

W rzeczywistości rynkowej, skoncentrowane zarządzanie produktem obejmuje cztery kluczowe obszary (Mello, 2002). Pierwszym z nich jest proces tworzenia i wprowadzania na rynek produktów, które adekwatnie odpowiadają zgłaszanym potrzebom klientów. Kolejnym istotnym

aspektem jest dostosowanie modelu biznesowego do struktur i reguł funkcjonowania rynku, przy uwzględnieniu różnych segmentów docelowych. Dodatkowo konieczne jest precyzyjne dostosowanie reguł i zasad konkurencji w celu wypracowania silnej pozycji konkurencyjnej. Warto również aktywnie poszukiwać nowych rozwiązań, pomysłów i produktów, które nie tylko budują, ale także wzmacniają pozycję rynkową przedsiębiorstwa (Mello, 2002). Obserwując literaturę naukową, badania nad zarządzaniem produktem skupiają się w dużej mierze na dwóch obszarach: rozwoju nowego produktu (NPD) oraz zarządzaniu cyklem życia produktu (*Product Lifecycle Management – PLM*).

Proces rozwoju nowego produktu (NPD)

Proces rozwoju nowego produktu (NPD) obejmuje kompletny proces wprowadzania nowego produktu na rynek (uwzględniając wszystkie fazy procesu od pomysłu do wdrożenia), odnawiania istniejącego oraz wprowadzania rozwiązania na nowy rynek. Centralnym aspektem procesu rozwoju nowego produktu jest jego projektowanie wraz z różnymi względami biznesowymi. Proces ten jest szeroko opisywany jako transformacja możliwości rynkowych w produkt dostępny w sprzedaży (Law, 2009). Inaczej jest to „proces, w którym pomysł jest przekształcany w produkt komercyjny” (Crawford i Di Benedetto, 2010). W niniejszych badaniach Autor korzysta z ostatniej definicji.

Aby zacząć rozważać proces NPD, należy odnieść się do definicji nowego produktu. Według Crawforda i Di Benedetto (2010), wśród nowych produktów można wyróżnić:

- Produkty nowe dla świata - produkty, które są wynalazkami tworzącymi nowe rynki;
- Produkty nowe dla firmy lub nowe linie produktów - produkty, dzięki którym organizacja znajduje się na nowym rynku, wcześniej nie było takiego typu produktu w organizacji;
- Dodatki do istniejących linii produktów - produkty, które mają rozszerzyć obecne portfolio firmy na danym rynku;
- Ulepszenia i rewizje istniejących produktów - aktualne produkty, ale poddane różnym poprawkom w celu lepszego działania;
- Repozycjonowania - aktualne produkty, ale takie, które zmieniły docelowe zastosowanie, docelowego użytkownika albo docelowy rynek; oraz

- Redukcje kosztów - nowe produkty, które zastępują aktualne, dając użytkownikowi podobną jakość, ale o niższym koszcie.

Co ciekawe, a widać to bezpośrednio w powyższym podziale, nowe produkty to niekoniecznie innowacje. Czasami są to jedynie rozszerzenia obecnych linii lub gam produktów, np. o nowe kształty, smaki czy zapachy (Crawford i Di Benedetto, 2010).

Zarządzanie innowacją jest tematem przenikającym się z zarządzaniem produktem, jednak w przypadku innowacji mówi się o ciągu działań prowadzących do wytworzenia nie tylko nowych produktów, ale także usług, procesów czy systemów. W związku z tym innowacją może być wprowadzenie nowych sposobów dystrybucji, technik wytwarzania, pozyskanie nieznanych wcześniej komponentów lub unowocześnione systemy organizacyjne czy marketingowe (Gaubinger i in., 2015).

Strategia innowacji organizacji może obejmować proces powstawania nowych, innowacyjnych produktów, lecz koncentruje się raczej na tym, jakie innowacje można wprowadzić w procesie NPD, aby uzyskać innowacyjny produkt. Zazwyczaj kończy się ona na wdrożeniu produktu, ewentualnie uwzględniając fazę po wdrożeniu jako fazę nauki – w jaki sposób można poprawić proces innowacji, mniej skupiając się na późniejszym utrzymaniu i aktywnościach po wdrożeniu (np. marketingowych) (Eveleens, 2010). W niniejszej pracy Autor koncentruje się na procesie rozwoju nowego produktu, stąd w dalszej części rozprawy termin zarządzania innowacją jest rozpatrywany jedynie, jeśli odnosi się bezpośrednio do rozwoju nowego produktu.

Jednym z najpopularniejszych modeli rozwoju nowego produktu jest model *stage-gate* (lub *phase-gate*), stworzony przez Roberta G. Coopera, stosowany z powodzeniem od lat 80. Zakłada on podział procesu na poszczególne fazy, w których wykonywana jest praca, oraz bramki lub punkty decyzyjne pomiędzy tymi fazami, w których sprawdzana jest jakość wykonania poprzedniej fazy i podejmowana zostaje decyzja, czy kolejna faza ma zostać rozpoczęta (Rao i in., 1999).

Model *stage-gate* nie jest jedynym podejściem do rozwoju nowego produktu. W 2001 powstał manifest *agile* (*Agile manifesto, Manifesto for agile software development*), prezentujący zasady dotyczące zwinnych metod wytwarzania oprogramowania. Koncepcja *agile* ewoluowała z wąskiej, specjalistycznej koncepcji w zakresie rozwoju oprogramowania do szerszego podejścia, które można stosować w różnych branżach w tym w zarządzaniu produktami (Madsen, 2020).

Tradycyjny model *stage-gate* jest linearnym podejściem do rozwoju produktu, podczas gdy *agile* charakteryzuje się cyklami iteracyjnymi (Sommer i in., 2015). Procesy w modelu *stage-gate* są znane z ich sztywności i przewidywalności, podczas gdy procesy *agile* są bardziej elastyczne i dobrze przystosowane do innowacji w dynamicznych ustawieniach (Sarangee i in., 2022).

Obserwuje się integrację metod *agile* w etapy istniejącego systemu *stage-gate* w firmach produkcyjnych, prowadząc do modelu hybrydowego (czasami nazywanego *agile-stage-gate*) (Cooper, 2016; Cooper i Furst, 2023b). Organizacje, które produkują produkty fizyczne i przyjmują podejście hybrydowe, mogą się spodziewać, na przykład, skrócenia czasów rozwoju i wyższego poziomu innowacji (Salvato i Laplume, 2020). Niezależnie od podejścia, dokładne zdefiniowanie zawartości poszczególnych faz może być bardziej wymagającym zadaniem. W literaturze naukowej istnieje wiele różnych podziałów, a proces rozwoju nowego produktu jest elastyczny, co pozwala na pomijanie lub łączenie etapów i punktów decyzyjnych w zależności od charakteru projektu. Wielu badaczy wskazuje, że produkt musi być przede wszystkim zaprojektowany (faza projektowania produktu) i rzeczywiście wytworzony (faza budowy lub utworzenia produktu), a wszystkie działania na początku i końcu procesu można określić mianem tzw. rozmytego początku (*fuzzy front end*) (Reid i de Brentani, 2004) lub rozmytej fazy końcowej (*fuzzy back end*). Wybrane różne podejścia do podziału procesu w ostatnich dekadach przedstawiono w Tabeli 2. Analizując rozwiązania z tabeli pochodzące z różnych dekad, można dostrzec pewne podobieństwa i różnice między fazami, jednak same nazwy faz mogą być niejednoznaczne, dlatego warto przyjrzeć się aktywnościom realizowanym w danej fazie.

Pierwsze etapy procesu NPD obejmują dwie podstawowe aktywności – generowanie pomysłów, selekcję oraz wewnętrzną strategię i ocenę. Pierwsza aktywność – generowanie pomysłów, znana także jako ideacja (*ideation*) (Cooper i Edgett, 2008), zarządzanie ideami, pozyskiwanie pomysłów, odkrywanie produktów, rozwijanie koncepcji – jest kluczową częścią procesu i dotyczy systematycznego poszukiwania nowych pomysłów na produkty. Pomysły mogą być pozyskiwane wewnętrznie, od klientów, konkurencji lub dostawców (Cooper i Edgett, 2008; Kotler, 2006). Po zebraniu wielu pomysłów, konieczne jest ich selekcja (*screening*), czyli redukcja i zachowanie tylko tych najlepszych. W niektórych źródłach literaturowych jest to uznawane za fazę procesu NPD (Kotler, 2006; Ozcan i in., 2021; Trott, 2017), a w innych jako bramka pomiędzy

Tabela 2. Wybrane podejścia do procesu NPD na przestrzeni dekad (na żółto zaznaczono fazy związane z fuzzy front end, a na zielono fazę związaną z projektowaniem i budowaniem produktu).

Nr fazy	Noori i in. (1997)	Griffin (1997)	Annacchino (2003)	Kotler (2006)	Cooper (2010)	Crawford i Di Benedetto (2010)	Trott (2017)	H. Zhang, Zhang i Song (2021)
Faza 1	Planowanie strategiczne	Generowanie pomysłów / koncepcji	Ocena rynku i ocena wewnętrzna	Strategia nowego produktu	Odkrycie	Identyfikacja i wybór możliwości	Generowanie pomysłów	Rozwój pomysłów
Faza 2	Identyfikacja możliwości	Weryfikacja pomysłów	Prototypowanie	Generowanie pomysłów	Określanie zakresu	Tworzenie koncepcji	Sprawdzanie pomysłów	Analiza biznesowa
Faza 3	Rozwój możliwości	Analiza biznesowa	Podstawowy rozwój i testowanie	Przegląd pomysłów	Tworzenie uzasadnienia biznesowego	Ocena koncepcji / projektu	Testowanie koncepcji	Projektowanie produktu
Faza 4	Budowa produktu / usługi	Budowa produktu	Industrializacja	Rozwój i testowanie koncepcji	Budowa produktu	Budowa produktu	Analiza biznesowa	Testowanie produktu
Faza 5	Wprowadzenie produktu / usługi	Testy i walidacja	Komercjalizacja	Strategia marketingowa	Testowanie i walidacja	Wdrożenie	Budowa produktu	Komercjalizacja
Faza 6	Zarządzanie cyklem życia	Komercjalizacja	Optymalizacja	Analiza biznesowa	Wdrożenie		Marketing testowy	Po komercjalizacji
Faza 7				Budowa produktu			Komercjalizacja	Zarządzanie operacyjne
Faza 8				Marketing testowy			Monitorowanie i ocena	
Faza 9				Komercjalizacja				

Źródło: opracowanie własne.

etapami (Cooper, 2010). Niektóre źródła wskazują również, że przed wszystkimi działaniami związanymi z generowaniem pomysłów, organizacje powinny mieć wewnętrzne strategie dotyczące tworzenia nowych produktów, w ramach których kontynuowane jest badanie dynamiki rynku (Annacchino, 2003). W ten sposób w tej fazie sprawdzane jest także, jak nowe pomysły na produkty wpisują się w strategię organizacji oraz rzeczywistość rynkową.

Po zebraniu najlepszych pomysłów, organizacje tworzą uzasadnienie biznesowe (*business case*) – przygotowują opis, czy też definicję produktu, czasem zwaną protokołem produktu, i oceniają potencjalne wskaźniki sprzedaży nowego produktu, koszty oraz możliwe korzyści, aby sprawdzić, czy stworzenie nowego produktu jest opłacalne i zgodne z celami organizacji. W tej fazie część artykułów wskazuje również na testowanie koncepcji (Cooper, 2010; Crawford i Di Benedetto, 2010), czyli prezentowanie koncepcji produktu grupie docelowych klientów. Do przeprowadzenia takiego testu często wystarczy prosty opis rozwiązania, jednak im bardziej szczegółowa i konkretna jest prezentacja koncepcji dla klientów, tym większa pewność, że produkt odniesie sukces.

Po pierwszych etapach, które można określić, jak wspomniano wcześniej, jako rozmyty początek (*fuzzy front end*), następnym etapem jest projektowanie i wytwarzanie produktu, czyli przekształcenie koncepcji w działający produkt o przewidywalnym działaniu. W tej fazie powstaje prototyp lub produkt o kluczowej funkcjonalności (*Minimal Viable Product – MVP*), specyfikacja produktu, plany wdrożenia, a niektóre źródła wskazują także na opracowanie w tej fazie planu marketingowego (Crawford i Di Benedetto, 2010).

Kolejnym etapem jest faza testowania i walidacji – produkt, program marketingowy i operacje związane ze sprzedażą (Cooper, 2010) są testowane w prawdziwych warunkach rynkowych. W tej fazie mogą być prowadzone próby sprzedaży, sprawdzana jest strategia pozycjonowania, reklama produktu, ustalanie cen. Organizacje sprawdzają, jakie będą pierwsze reakcje klientów i jak będą oni używać produktu. Wszystkie te informacje mogą przyczynić się do lepszych wyników sprzedaży i bardziej precyzyjnego prognozowania zysków. Jeśli koszty stworzenia produktu są niskie lub jeśli zarząd jest pewny, że produkt odniesie sukces, faza ta może być skrócona do minimum lub zupełnie pominięta (Kotler, 2006).

W wielu podejściach i modelach faza wprowadzenia na rynek, czyli komercjalizacji, jest ostatnim etapem procesu NPD, w którym produkt jest wdrażany w pełną produkcję, marketing i sprzedaż

(Cooper, 2010; Crawford i Di Benedetto, 2010; Griffin, 1997; Kotler, 2006). Podstawowe pytania, jakie organizacje sobie zadają podczas wprowadzania produktu na rynek, to kiedy go wdrożyć – na przykład, aby nie kolidował z innymi produktami z portfolio; gdzie go wdrożyć – na przykład, czy w określonym regionie, kraju czy na całym świecie; dla kogo – choć docelowi klienci często są wybierani już na wcześniejszych etapach; jak – jakie działania i akcje będą towarzyszyć wprowadzeniu produktu.

Po wprowadzeniu produktu na rynek nadchodzi czas jego monitorowania i oceny, jak radzi sobie na rynku, a także ewentualnej implementacji poprawek. W tym czasie poszukiwana jest optymalizacja całego procesu NPD i związanych z nim operacji. Część badaczy zajmujących się produktami uznaje tę fazę za ostatnią fazę NPD (np. Noori i in. (1997), Annacchino (2003), Trott (2017), H. Zhang, Zhang i Song (2021)) a część nie uwzględnia jej w procesie w ogóle (np. Griffin (1997), Crawford i Di Benedetto (2010)).

Zarządzanie cyklem życia produktu (PLM)

Podjęcia do procesu NPD są różne, ale jak wcześniej wspomniano, wszystkie koncentrują się na rozmytym początku, obejmującym wstępne fazy związane z generowaniem pomysłów, analizą biznesową i testowaniem koncepcji, kolejno na projektowaniu i budowie produktu, a następnie na rozmytej fazie końcowej, która zazwyczaj obejmuje testowanie i wdrożenie produktu. Do zarządzania cyklem życia produktu (*Product Lifecycle Management – PLM*) można podejść na wiele różnych sposobów. PLM można zdefiniować jako działalność biznesową polegającą na zarządzaniu w najbardziej efektywny sposób produktami firmy na wszystkich etapach ich cykli życia (Stark, 2016). W latach 1960. powstał pierwszy model cyklu życia produktu, inspirowany biologią, który dzieli go na 4 fazy (H. Cao i Folan, 2012; Kotler, 2006):

- Wprowadzenie (*Introduction*) – faza powolnego wzrostu sprzedaży, bez zysków, ze względu na duże koszty wprowadzenia nowego produktu na rynek;
- Wzrost (*Growth*) – etap szybkiej akceptacji rynku i wzrastających zysków;
- Dojrzałość (*Maturity*) – etap spowolnienia sprzedaży, ponieważ produkt dotarł do wszystkich potencjalnych klientów, z obniżonymi również zyskami, ze względu na duże koszty marketingu, aby obronić produkt przed konkurencją; i

- Spadek (*Decline*) – faza wycofywania, kiedy sprzedaż i zyski spadają.

Cztery fazy opisane powyżej są w literaturze opisywane jako model cyklu życia produktu w marketingu (*Marketing Product LifeCycle – M-PLC*), w porównaniu do modelu cyklu życia produktu w inżynierii (*Engineering Product LifeCycle – E-PLC*), na temat, na który badania rozpoczęły się pod koniec lat 1980. i obejmowały następujące etapy (H. Cao i Folan, 2012):

- Koncepcja produktu;
- Projektowanie;
- Produkcja;
- Sprzedaż;
- Użycie i obsługa przez klienta;
- Usuwanie (ponowne wykorzystanie / recykling / utylizacja).

W literaturze istnieje kilka wariantów tego podejścia. Na przykład Terzi i in. (2010) wspominają o fazach kolejno: projektowanie, produkcja, dystrybucja, użytkowanie, wsparcie, wycofanie, natomiast Stark (2016) podaje: wymyślenie, zdefiniowanie, realizacja, wsparcie/użycie, wycofanie/usunięcie. Wiele opracowań (H. Cao i Folan, 2012; J. Li i in., 2015; Terzi i in., 2010) dodatkowo dzieli te etapy na:

- Początek Życia (*Beginning-Of-Life – BOL*) – pierwsze fazy związane z projektowaniem i produkcją;
- Środek Życia (*Middle-Of-Life – MOL*) – fazy związane z sprzedażą, dystrybucją, obsługą, użytkowaniem, wsparciem; oraz
- Koniec Życia (*End-Of-Life – EOL*) – faza związana z wycofaniem, recyklingiem, usunięciem.

Podział na te sześć etapów (lub skrócenie do trzech, jak powyżej) jest problematyczny ze względu na wcześniejszy podział NPD – mieszają się tutaj między innymi fazy związane z koncepcją produktu, projektowaniem czy wytwarzaniem. Dodatkowo, niektóre opracowania jako pierwszą fazę, przed wprowadzeniem, dodają proces NPD jako całość bez podziału na poszczególne etapy (Kotler, 2006), a niektóre opracowania dodają PLM jako całość, bez podziału na etapy, jako ostatnią fazę w procesie NPD (Noori i in., 1997).

We współczesnej literaturze, zwłaszcza w tzw. literaturze szarej (*grey literature*) lub wśród białych ksiąg (*white paper*) organizacji, PLM jest rozumiane zupełnie inaczej – jako narzędzia komputerowe ukierunkowane na projektowanie i szeroko pojęte zarządzanie produktem (H. Cao i Folan, 2012). Patrząc na to w ten sposób, historia PLM sięga lat 1970. i 1980. i rozwoju narzędzi komputerowych wspomagających projektowanie produktów – projektowanie wspomagane komputerowo (*Computer Aided Design - CAD*), wytwarzanie wspomagane komputerowo (*Computer Aided Manufacturing - CAM*) oraz prace inżynierskie wspomagane komputerowo (*Computer Aided Engineering - CAE*), wraz z rozwojem systemów zarządzania danymi produktowymi (*Product Data Management - PDM*) do kontroli i zarządzania danymi i informacjami związanymi z produktami. Do tego grona z czasem dołączyły systemy planowania zasobów przedsiębiorstwa (*Enterprise Resource Planning – ERP*), zarządzania relacjami z klientami (*Customer Relationships Management – CRM*) oraz zarządzania łańcuchem dostaw (*Supply Chain Management – SCM*), każde ukierunkowane na pewien proces w cyklu życia produktu (Ameri i Dutta, 2005; H. Cao i Folan, 2012). Połączenie tych wszystkich odrębnych systemów i narzędzi w jeden system PLM jest specjalnością obecnych producentów, co wpływa również na aktualne badania w tym zakresie. W takim rozumieniu PLM, w literaturze pojawiają się artykuły dotyczące tego, jak wykorzystać PLM w procesie NPD, aby osiągnąć sukces w danej branży (Pinna i in., 2018; Tai, 2017; Vezzetti i in., 2017).

Wskazano występujący w literaturze brak uporządkowania pojęć i wspomniany wcześniej brak systematyzacji dotyczący podziału pomiędzy NPD, a PLM, natomiast rozwiązanie niniejszego problemu nie jest przedmiotem rozprawy. W dalszej części pracy, skupiono się głównie na procesie rozwoju produktu z fazami tego rozwoju (niezależnie od tego czy jest on definiowany w literaturze jako PLM czy NPD – Autor używa skrótu NPD). Zarys faz produktowych tworzy kontekst dla roli sztucznej inteligencji, której zastosowania omówiono w sekcji 1.2.

1.2. Sztuczna inteligencja w zarządzaniu produktem

Zarys badań nad sztuczną inteligencją

Jest wiele różnych definicji sztucznej inteligencji (*Artificial Intelligence – AI*). Według jednej z nich, sztuczna inteligencja to dziedzina badań starająca się wyjaśnić oraz wdrożyć zachowania inteligentne poprzez wykorzystanie procesów obliczeniowych (Schalkoff, 1990). Według innej definicji sztuczna inteligencja odnosi się do zestawu koncepcji, metod i narzędzi, które mają na celu lepsze zrozumienie inteligencji i wyposażenie maszyn w zdolności, które są kwalifikowane jako inteligentne, gdy są wykonywane przez ludzi lub inne żywe istoty (Loisel i in., 2021). W badaniach wykorzystano ostatnią definicję. W niniejszym podrozdziale przedstawiony zostanie historyczny zarys badań nad sztuczną inteligencją, uwzględniając także wybrane zastosowania rozwiązań AI w biznesie ogólnie i skupiając się na procesie rozwoju nowego produktu.

Russell i Norvig (2016) w swojej książce, która jest jedną z bardziej gruntownych pozycji, jeśli chodzi o opis rozwiązań sztucznej inteligencji, prezentują zarówno klasyczne podejście (tzw. *Good Old Fashioned AI*), jak i współczesne rozwiązania. Sztuczna inteligencja jest na tyle dużym obszarem, że istnieje potrzeba dokonania pewnego podziału. Korzystając z pracy Russella i Norviga (2016) oraz Finlaya i Dixona (2002) można by wyróżnić podział na następujące podobszary:

- Przetwarzanie Języka Naturalnego (*Natural Language Processing – NLP*) – podobszar związany z przetwarzaniem języka naturalnego, komunikacją, wyszukiwaniem informacji, tłumaczeniem maszynowym;
- Reprezentacja Wiedzy (*Knowledge Representation*) – podobszar związany z przechowywaniem informacji, ontologiami, odkrywaniem wiedzy, logiką, regułami;
- Rozumowanie / Wyciąganie Wniosków (*Reasoning*) – podobszar związany z wyciąganiem wniosków, indukcją, dedukcją, rozumowaniem rozmytym, rozumowaniem opartym na przypadkach;
- Uczenie Maszynowe (*Machine Learning – ML*) – pole związane z adaptacją do nowych okoliczności, predykcją, detekcją wzorców, uczeniem indukcyjnym, uczeniem dedukcyjnym, uczeniem opartym na wyjaśnieniach;
- Wizja Komputerowa / Widzenie Maszynowe (*Computer Vision – CV*) – pole związane z percepcją, wizualną identyfikacją obiektów, rozumieniem obrazów; oraz

- Robotyka (*Robotics*) – pole związane z ruchem, manipulacją.

Taki podział ma jednak kilka wad. Po pierwsze, sztuczna inteligencja jest na tyle szerokim obszarem nauki, że powyższy podział nie obejmuje wszystkich podobszarów – występują chociażby takie dziedziny jak planowanie (*planning*) wspomniane w Finlay i Dix (2002), natomiast planowanie jest tam jednak wspomniane w jednym rozdziale z robotyką (nie można poruszyć czymś, jeżeli się tego wcześniej nie zaplanuje). Po drugie, gdyby, zamiast na powyższych podobszarach sztucznej inteligencji, skoncentrować się na konkretnych metodach czy rozwiązaniach, wiele z nich jest połączonych, np. Finlay i Dix (2002) przywołują w jednym rozdziale systemy eksperckie, jako połączenie obszarów reprezentacji wiedzy i rozumowania. Bezpośrednio z powyższym związany jest kolejny problem – zarówno Russell i Norvig (2016) i Finlay i Dix (2002) odwołują się do klasycznego podziału sztucznej inteligencji sprzed 2010 roku. Bernijazov i in. (2021) zauważają, że w latach 2010-2020 była zauważalna tendencja do korzystania z metod skupionych na danych, opartych, na przykład, na głębokim uczeniu (*Deep Learning – DL*), niż z tradycyjnych metod opartych na wiedzy (*knowledge-based methods*). Przyczyną jest zwiększona dostępność danych połączona z większą mocą obliczeniową komputerów. To spowodowało, że obecnie rozwiązania ML, czy DL są niejako kanwą do stosowania w innych obszarach np. algorytm YOLO (Redmon i in., 2016), używany do detekcji obiektów, który można by uznać za rozwiązanie z zakresu wizji komputerowej jako podstawy algorytmu używa sieci konwolucyjnych, które są rozwiązaniem z zakresu uczenia głębokiego.

Powyższe obserwacje skłaniają do znalezienia innego, bardziej współczesnego podziału AI. Gdyby odwoływać się do procesu rozwoju nowego produktu, H. Zhang, Zhang i Song (2021) po przeprowadzeniu serii wywiadów, zidentyfikowali sześć najczęściej używanych typów sztucznej inteligencji w organizacjach przy procesie rozwoju nowego produktu (NPD):

- Analityczna AI (*Analytic AI*) z rozwiązaniami prognozowania popytu, oceny ryzyka i analizy sentymentu (*demand forecasting, risk assessment, and sentiment analysis*);
- Funkcjonalna AI (*Functional AI*) z rozwiązaniami Internetu Rzeczy i robotyką (*Internet of Things solutions and robotics*);
- Interaktywna AI (*Interactive AI*) z rozwiązaniami inteligentnych osobistych asystentów i chatbotów (*smart personal assistants and chatbots*);

- Tekstowa AI (*Text AI*) z rozwiązaniami konwersji mowy na tekst, rozpoznawania tekstu i tłumaczeń maszynowych (*speech-to-text conversion, text recognition, and machine translation*);
- Wizualna AI (*Visual AI*) z rozwiązaniami wizji komputerowej i rozszerzonej rzeczywistości (*computer vision and augmented reality*); oraz
- Robotyczna AI (*Robotic AI*) z rozwiązaniami zrobotyzowanej automatyzacji procesów (*robotic process automation*).

Takie podejście skłania do kilku refleksji. Po pierwsze, taka nomenklatura używa w kilku przypadkach dość ogólnych nazw, np. słysząc termin „*Funkcjonalna AI*” ciężko jest utożsamić ją z rozwiązaniami Internetu Rzeczy i robotyką, nie wiedząc wcześniej, jakie rozwiązania się w jej ramach zawierają. Nie oznacza to, że taka nomenklatura jest zła, ale niejako implikuje, że podział na obszary lub typy jest niewystarczający i konieczny jest dodatkowy podział na rozwiązania lub uszczegółowienie opisu obszarów o te rozwiązania. Dodatkowo, można sobie wyobrazić więcej stosowanych rozwiązań, zarówno mieszczących się w określonym obszarze, jak i takich, które mogą być na pograniczu danych obszarów (np. robot segregujący dany materiał jako wadliwy lub nie na podstawie przetworzenia obrazu z kamery i przesuwający go do odpowiedniej przegrody to rozwiązanie z zakresu Funkcjonalnej AI czy Wizualnej AI?). Stąd założono, że konieczne jest dokładniejsze opisanie rozwiązań z powyższych kategorii. Poniżej opisane są wybrane rozwiązania występujące w literaturze naukowej z każdego obszaru, w odniesieniu do procesu rozwoju nowego produktu.

1. Rozwiązania Analitycznej AI

W literaturze naukowej metodę prognozowania popytu ściśle łączy się z zarządzaniem łańcuchem dostaw (*Supply Chain Management*), na przykład w branżach elektronicznej, opieki zdrowotnej czy hotelarskiej (Dombi i in., 2018; HajMirzaei i in., 2020; N. Li i in., 2021). Jak napisali Van Steenberghe i Mes (2020): „Dokładne prognozowanie popytu na rynek produktu jest istotne dla jego projektowania, dystrybucji, promocji i strategii cenowej”. Metoda ta będzie miała więc największe znaczenie w fazach związanych z komercjalizacją produktu oraz jego późniejszym zarządzaniem. Prognozowanie popytu przy użyciu sztucznej inteligencji jest opisywane w takich branżach jak moda (Jin i Shin, 2020; Ren i in., 2017), żywność (Gružauskas i in., 2019), czy uroda

(Souza i in., 2020) i może pomóc w odpowiednim rozmieszczeniu produktów w sklepach stacjonarnych, co przekłada się na brak nadmiernych zapasów magazynowych, większą satysfakcję i retencję klientów. Ponadto, prognozowanie popytu może być również używane do przewidywania zapotrzebowania na części zamienne do regularnie sprzedawanych produktów (Gonçalves i in., 2021).

Niektóre badania (X. Cao i Zhang, 2021; Kharfan i in., 2021; X. Li i in., 2021; van Steenbergen i Mes, 2020) wskazują na podział prognozowania popytu, który obejmuje istniejące produkty na rynku, od prognozowania nowych produktów, dla których brak danych historycznych pomagających w określeniu przyszłego zapotrzebowania. Aby sprostać takiemu zadaniu, proponowane są różne metody oparte na sztucznej inteligencji, na przykład bazujące na danych historycznych podobnych produktów, do tych, które są wprowadzane po raz pierwszy (van Steenbergen i Mes, 2020).

Część badań wspomina również o prognozowaniu popytu na produkty pochodzące z przemysłowej regeneracji zużytego sprzętu (*remanufacturing*) (Tsiliyannis, 2018; Van Nguyen i in., 2020). Stało się to bardzo ważną gałęzią przemysłu ze względu na korzyści zarówno ekonomiczne, jak i środowiskowe. Określenie popytu wiąże się jednak w tym przypadku z dużą niepewnością, ponieważ nie wiadomo, kiedy i w jakim stanie produkt wróci do producenta, co prowadzi z kolei do trudności w oszacowaniu procesu rozmieszczenia produktu, inspekcji i testowania. Co więcej, istnieje także niepewność klientów, którzy, pomimo niższej ceny produktu, obawiają się jego jakości.

Kolejną metodą wykorzystywaną w procesie rozwoju nowego produktu jest analiza sentymentu (nazywana również eksploracją opinii – *opinion mining*). H. Zhang, Zhang i Song (2021) zakwalifikowali analizę sentymentu w ramach obszaru Analitycznej AI, natomiast jest to rozwiązanie związane z przetwarzaniem języka naturalnego (akcja bazująca na rozpoznaniu tekstu), więc mogłoby także zostać sklasyfikowane jako Tekstowa AI. W ostatnich latach powstało wiele przeglądowych artykułów opisujących aktualny stan badań dotyczących analizy sentymentu, jej algorytmów oraz zastosowań w różnych dziedzinach (Birjali i in., 2021; J. Choi, Yoon, i in., 2020; Mukhopadhyay, 2018; Verma i Yadav, 2021). Analiza sentymentu wymaga źródeł danych, takich jak na przykład media społecznościowe, strony z recenzjami, blogi, fora czy transkrypcje z wywiadów, a do pozyskania tych danych wykorzystuje się różne podejścia. Metoda ta jest

rozwijana, aby nie tylko rozróżniać komentarze na pozytywne i negatywne, ale także wprowadzić poziom rozmycia negatywności i pozytywności, co może prowadzić do lepszych wyników (Aguwa i in., 2017) lub uzupełnić informacje o sentymencie o dodatkowe dane, który konkretnie aspekt jest pozytywnie lub negatywnie oceniany przez klienta (X. Li i in., 2019).

Analiza sentymentu jest użyteczna w fazie generowania pomysłów na produkt (Escoffier i in., 2018; H. Lee i in., 2018; W. Zhang i in., 2018). Badania potwierdzają, że jest ona stosowana zarówno w społecznościach innowacji otwartej (czyli wewnętrznych źródłach organizacji oraz czasami przyjaźnie nastawionej konkurencji), jak i w *crowdsourcingu* (źródła zewnętrzne, głównie klienci), aby zbadać opinie innych na temat danego pomysłu na produkt. Jest to istotne, ponieważ nowe produkty często kończą się niepowodzeniem z powodu braku rynku. Co więcej, przy poszukiwaniu pomysłów na produkty często wykorzystuje się wspomniane wcześniej media społecznościowe, gdzie analiza sentymentu jest łączona z modelowaniem tematów (*topic modeling*), a konkretnie z metodą LDA (*Latent Dirichlet Allocation*). Modelowanie tematów odpowiada za określenie, jak ważny jest temat dotyczący produktu, a analiza sentymentu odpowiada za określenie ilościowej satysfakcji z jego wprowadzenia (Jeong i in., 2019).

W literaturze można również znaleźć liczne badania dotyczące wpływu analizy sentymentu na projektowanie produktów (Akbari i in., 2020; Giannakis i in., 2022; Y. Wang i in., 2018; Yagci i Das, 2018; B. Yang i in., 2019), wytwarzanie produktów (J. Choi, Oh i in. 2020; Yoon i in. 2020), czy ulepszanie produktów (C. Yang i in., 2021). Większość z nich wskazuje, że wzrost treści generowanych przez użytkowników (*user generated content – UGC*) w mediach społecznościowych wpływa na to, że projektanci sięgają po opinie ludzi, którzy są obecnie, lub w przyszłości mogą stać się, użytkownikami ich produktów. Warto jednak zauważyć, że w ten sposób można poznać tylko opinie użytkowników, którzy są przedmiotem analizy sentymentu, ale nie sposób przewidzieć, jak zwiększyć popularność produktu, aby odniósł sukces (Akbari i in., 2020). Badanie UGC umożliwia nie tylko poznanie sentymentu użytkowników dotyczącego jednego produktu, ale także identyfikację zalet (lub wad), jakie dany produkt ma w porównaniu z konkurencją (Y. Liu i in., 2019).

Istnieją również inne rozwiązania, które, zdaniem Autora, można zakwalifikować do obszaru Analitycznej AI, które są interesujące z perspektywy niniejszej pracy, a które nie znalazły się w pierwotnym ujęciu według H. Zhanga, Zhanga i Songa (2021). Jednym z takich rozwiązań są

systemy rekomendacyjne (*recommendation systems*). Przeładowanie informacyjne wygenerowało potrzebę pojawienia się systemów rekomendacyjnych, które z natłoku danych zaczęły proponować te, które są najbardziej interesujące dla użytkownika. W literaturze naukowej większość podejść koncentruje się na tym, który system rekomendacyjny jest najlepszy pod względem technicznym (X. Chen i in., 2019; Cunha i in., 2018; Sánchez i Bellogín, 2019), przywiązując wagę do takich parametrów jak dokładność, różnorodność czy efektywność. Jednakże niewiele jest podejść, które analizują rozwiązanie z perspektywy biznesowej, uwzględniając różne uwarunkowania biznesowe, które mają bezpośredni wpływ na postrzeganie organizacji przez użytkowników i w konsekwencji na sprzedaż produktów (Gorgoglione i in., 2019). Odpowiednia strategia rekomendowania produktów jest zatem kluczowa. Niemniej jednak nawet najlepiej dopasowane systemy rekomendacyjne mogą napotykać na wyzwania, takie jak spadek różnorodności sprzedaży (w porównaniu z organizacjami, które w ogóle nie korzystają z systemów rekomendacyjnych) (D. Lee i Hosanagar, 2019) lub tzw. problem zimnego startu, gdzie na początku swojego istnienia system rekomendacyjny nie dysponuje danymi, które mógłby wykorzystać do rekomendacji (Q. Zhang i in., 2017), czy nawet fakt, że użytkownicy mogą po prostu być zniechęceni do korzystania z systemów rekomendacyjnych (C. Yin i in., 2018). Pewnym rozwiązaniem dla wymienionych wyżej problemów może być połączenie sieci społecznościowych i systemów rekomendacyjnych (X. Deng i in., 2017), co może pozytywnie wpłynąć między innymi na różnorodność sprzedaży i okres zimnego startu.

Systemy rekomendacyjne mogą być również wykorzystane w połączeniu z innymi metodami, na przykład z wcześniej wspomnianą analizą sentymentu w fazie generowania pomysłów (H. Lee i in., 2018). Znając sentyment użytkowników z setek recenzji, nadal jest to dużo informacji do przetworzenia, więc system rekomendacyjny pozwala wybrać te, które są najbardziej wartościowe, zwiększając efektywność całego procesu.

Inne rozwiązania, które mogłyby się znaleźć w obszarze Analitycznej AI, są związane z predykcją i optymalizacją. Artykuły dotyczące analizy predykcyjnej w zarządzaniu produktem skupiają się nawet bardziej na zagadnieniu analizy preskryptywnej (*prescriptive analytics*) (Viswanandhne i in., 2019), czyli nie na tym, co wydarzy się w przyszłości, ale na tym, jaką akcję należy podjąć teraz, aby wyeliminować problem w przyszłości. Jest to istotne zwłaszcza w kontekście optymalizacji produktów oraz kosztów czy kampanii produktowych skierowanych do klientów.

Rozwiązania AI zapewniają również wsparcie w optymalizacji procesów, które zachodzą nie bezpośrednio, ale w obrębie tworzenia produktów, na przykład podczas kontaktów z dostawcami (Allal-Chérif i in., 2021). Już po wdrożeniu produktu na rynek, wiele działań związanych z zarządzaniem produktem jest wspieranych przez rozwiązania oparte na uczeniu maszynowym. Jednym z przykładów jest klasyfikacja układu produktów w sklepie lub lokalizacji sklepu w celu maksymalizacji sprzedaży produktów (Huang i in., 2019; I. Lee i Shin, 2020). Innym przykładem są zastosowania związane z optymalizacją ceny produktu czy predykcją cen (Ferreira i in., 2018; Greenstein-Messica i Rokach, 2020; Simchi-Levi i Wu, 2018), takie jak dynamiczny algorytm ceny oparty na próbkowaniu Thompsona (Ferreira i in., 2018), ale także badania dotyczące wpływu ceny produktu na zachowanie klientów (Wolkenfelt i Situmeang, 2020). Inne badania związane z zachowaniem klientów dotyczą na przykład reakcji klienta w sklepie po obejrzeniu danego produktu online (Dzyabura i in., 2019) lub przewidywania rezygnacji klientów (*churn prediction*) (Pustokhina i in., 2021). Rozwiązania oparte na uczeniu ze wzmocnieniem (*reinforcement learning* – *RL*) również znajdują zastosowanie, na przykład w uczeniu się na podstawie doświadczeń konkurencji (Luoma i in., 2017) lub w wyzwaniach związanych z personalizacją usług dla każdego klienta (Byrd i Darrow, 2021). Powiązane z powyższymi są również ciekawe badania z zakresu modelowania wyboru (*choice modeling*) z dziedziny nauk społecznych, związane z analizą przyczynową (*causal analysis*), próbujące odpowiedzieć na pytania „Jakiego rodzaju produkty preferują konsumenci? Ile są skłonni zapłacić za nowe produkty lub cechy produktów?” (Liebe i Meyerhoff, 2021).

2. Rozwiązania Wizualnej AI

Badania dotyczące zagadnień wizyjnych opierają się głównie na wytwarzaniu produktu oraz testowaniu i zarządzaniu jakością (T. Jain i in., 2020; Liao i in., 2021; Zhao i in., 2022), co jest związane z wykorzystaniem robotów w procesie tworzenia produktów, o czym będzie wspomniane w kolejnym punkcie. Ponadto, w badaniach przedstawiano także użycie rozwiązań wizyjnych w procesie wcześniej wspomnianej przemysłowej regeneracji zużytego sprzętu (*remanufacturing*), do identyfikacji części na miejscu, aby zaoszczędzić czas potrzebny na znalezienie odpowiednich części zamiennych do produktu (Lehr i in., 2020). Jednym z rozwiązań używanych przy zagadnieniach wizyjnych jest detekcja anomalii (*anomaly detection*), której celem jest analiza

określonego obrazu w celu wykrycia w nim nietypowych zjawisk. Detekcja anomalii znajduje zastosowanie w przemyśle w procesie zarządzania jakością produktów (Garg i in., 2021; Langone i in., 2020).

Oprócz badania defektów w produktach, rozwiązania w zakresie wizji komputerowej są również wykorzystywane do analizy zachowań ludzkich (Micu i in., 2022; Rutter i in., 2021; Schwenzow i in., 2021). Analiza obrazów z mediów społecznościowych (Rutter i in., 2021) oraz wydobywanie informacji z wideo (Schwenzow i in., 2021) są stosowane w celu zrozumienia zaangażowania konsumentów z produktem na platformach innych niż producent, który go wprowadził na rynek. Takie analizy mogą pomóc w lepszym umiejscowieniu produktu i opracowaniu odpowiednich strategii reklamowych. Inne badania sięgają jeszcze dalej i zamiast koncentrować się na platformach społecznościowych, prowadzą profilowanie klientów na miejscu, bezpośrednio w sklepie (Micu i in., 2022), aby jeszcze bardziej dostosować produkty do oczekiwań docelowych odbiorców.

3. Rozwiązania Funkcjonalnej AI i Robotycznej AI

W literaturze naukowej zastosowanie rozwiązań Internetu Rzeczy czy robotyki w procesie rozwoju nowego produktu jest ograniczone, tym bardziej, że same roboty można uznać za produkt (Bertolini i Aiello, 2018). Najczęściej wspomina się wykorzystanie robotów jako współpracowników ludzi w procesie tworzenia produktów lub nawet zamiast ludzi, wykonując proste, automatyczne zadania, podczas gdy ludzie mogą skupić się na bardziej skomplikowanych, wymagających podejmowania decyzji (Dalmarco i in., 2019; Kose i Sakata, 2019; Shukla i in., 2017). Niemniej jednak, w połączeniu z innymi metodami z zakresu przetwarzania języka naturalnego (*Natural Language Processing – NLP*), widzenia maszynowego (*Computer Vision – CV*) czy systemów eksperckich są w stanie osiągnąć wysoki stopień autonomii i pomagać również w bardziej zaawansowanych zadaniach niż czysto mechaniczne, takie jak planowanie czy prognozowanie (Blöcher i Alt, 2021). W rezultacie część badań traktuje roboty cyfrowe (*software robots*), znane pod nazwą zrobotyzowanej automatyzacji procesów (*Robotic Process Automation – RPA*), jako część robotyki (Shukla i in., 2017), ponieważ usprawniają one proste, rutynowe zadania.

4. Rozwiązania Interaktywnej AI i Tekstowej AI

Zdecydowano się na opisanie rozwiązań Interaktywnej AI i Tekstowej AI we wspólnym paragrafie ze względu na fakt, że zarówno rozwiązania osobistych asystentów, jak i te związane z konwersją tekstu bazują na przetwarzaniu języka naturalnego (*NLP*). Konwersacyjna sztuczna inteligencja (*conversational AI*) jest tematem badawczym, który w literaturze naukowej skupia się głównie na wykorzystaniu chatbotów. Są one najczęściej stosowane do oceny doświadczenia klienta oraz satysfakcji klienta (J.-S. Chen i in., 2021; Eren, 2021; Sidaoui i in., 2020) lub bezpośrednio w procesie sprzedaży (X. Luo i in., 2019). Łączenie chatbotów z analizą sentymentu (Sidaoui i in., 2020) pozwala na poznanie sentymentu ludzi względem danego produktu bezpośrednio z bardzo wielu interakcji, bez udziału człowieka po stronie producenta. Ich użycie wiąże się jednak z szeregiem wyzwań. Według X. Luo i in. (2019) tego typu rozwiązania mogą być tak samo skuteczne w procesie sprzedaży jak doświadczeni pracownicy, a nawet cztery razy lepsze od ich mniej doświadczonych kolegów. Kluczowym czynnikiem sukcesu jest jednak sposób ich prezentacji – jeśli użytkownik od początku rozmowy zostanie poinformowany, że rozmawia z programem, efektywność sprzedaży może drastycznie spaść. Wynika to z powszechnego postrzegania tych rozwiązań jako mniej kompetentnych i pozbawionych empatii. Co więcej, ocena użyteczności danego chatbota w konkretnym biznesie może być trudna (Borsci i in., 2022) ze względu na stopień skomplikowania wdrożenia rozwiązania, które musi być dostosowane do stylu pisania odbiorcy czy charakteru jego wypowiedzi.

Rozważając rozwiązania konwersacyjnej sztucznej inteligencji, należy również wspomnieć o systemach eksperckich, które najczęściej służą jako wsparcie przy projektowaniu, wytwarzaniu i doskonaleniu produktów (Chakraborty i Boral, 2017; Shafiee i in., 2021), a także w zarządzaniu jakością (Mouludi i in., 2019). Jednym z ciekawszych zastosowań systemów eksperckich jest ich wykorzystanie jako technologii stojącej za konfiguratorem produktu, czyli narzędziem wspomagającym projektowanie i dostosowywanie produktów (Shafiee i in., 2021). Systemy eksperckie mogą również pomóc w fazie generowania pomysłów, poprzez pobudzanie kreatywności zespołów i proponowanie odpowiednich technik twórczych i innowacyjnych do zastosowania w konkretnych przypadkach (Botega i da Silva, 2020).

Jeżeli chodzi o rozwiązania związane z tekstem, większość z nich dotyczy rozpoznania tekstu, wydobycia z niego kluczowych informacji i jego przetworzenia. Algorytmy ekstrakcji wiedzy (lub

ekstrakcji informacji, *knowledge extraction*) to jedna z metod należących do obszaru NLP, silnie powiązana z analizą sentymentu oraz modelowaniem tematów. W literaturze naukowej często występuje ona w kontekście terminów „zarządzanie wiedzą”, „eksploracja tekstu” (*text mining*) czy „eksploracja danych” (*data mining*). Algorytmy ekstrakcji wiedzy, podobnie jak analiza sentymentu, ma zastosowanie w fazie generowania pomysłów. Nadal mogą to być opinie online (Z. Luo i in., 2019; M. Zhang i in., 2021), dane patentowe (Nikabadi i Sani-Varjovi, 2021) lub społeczności crowdsourcingowe (Hwang i in., 2019), ale informacje wydobywane są bardziej szczegółowe, ponieważ dotyczą nie tylko sentymentu użytkownika, lecz na przykład mogą zawierać konkretne innowacyjne pomysły na produkt. Co więcej, ekstrakcja wiedzy może pomóc również w ocenie pomysłów wewnątrz organizacji, aby upewnić się, że potencjalnie wartościowe możliwości nie zostaną pominięte (Yaakobi i in., 2019). W późniejszych fazach rozwoju nowego produktu, ekstrakcja wiedzy może być również używana do projektowania produktu (Lai i in., 2019), analizy konkurencji (Guo i in., 2017), czy przewidywania odejść klientów (Jamjoom, 2021).

Wspomniana wcześniej przy rozwiązaniach wizyjnych detekcja anomalii może być wykorzystywana nie tylko przy obrazach, ale również przy tekście. Metoda ta jest używana na przykład do analizy logów procesów biznesowych (Ko i Comuzzi, 2021; Sarno i in., 2020), ale może być również stosowana do analizy mediów społecznościowych (Mahmood i Alanezi, 2021), na przykład do wykrywania użytkowników w określonym zbiorze, którzy nie odpowiadają opisowi docelowego klienta, do którego skierowany jest dedykowany produkt.

Opis rozwiązań wskazuje więc, że przy wykorzystaniu rozwiązań AI w procesie rozwoju nowego produktu, większość zagadnień skupia się na predykcji i optymalizacji, automatyzacji, przetwarzaniu języka naturalnego oraz przetwarzaniu obrazów i wideo. Jak w te zagadnienia wpisują się rozwiązania generatywnej sztucznej inteligencji (*Generative Artificial Intelligence – GenAI*)?

Zarys badań nad generatywną sztuczną inteligencją

Generatywna sztuczna inteligencja „to narzędzie, które pozwala na tworzenie nowych, unikalnych treści, takich jak tekst, obrazy, muzyka czy filmy” (Przegalińska i Jemieliński, 2023). W odróżnieniu od tradycyjnych rozwiązań sztucznej inteligencji, które – jak wspomniano powyżej –

koncentrują się na przetwarzaniu, predykcji lub automatyzacji, rozwiązania generatywnej sztucznej inteligencji, ukierunkowane na generowanie nowych instancji danych, wykorzystują modele do tworzenia treści, które mogą naśladować rzeczywiste obiekty lub kreować zupełnie nowe, wcześniej niewidziane instancje (Benbya i in., 2024). Zastosowania tych rozwiązań obejmują tworzenie obrazów, muzyki, tekstów, augmentację danych, a także symulację i modelowanie złożonych systemów.

Historia modeli generatywnych sięga lat 50. XX wieku, kiedy powstały Ukryte Modele Markowa (*Hidden Markov Models – HMM*) (Knill i Young, 1997) oraz Modele Mieszanin Rozkładów Gaussa (*Gaussian Mixture Models – GMM*) (Reynolds, 2009), które stosowano do generowania danych sekwencyjnych, takich jak mowa czy szeregi czasowe. W 1966 roku Joseph Weizenbaum stworzył pierwszego chatbota o nazwie ELIZA, który symulował psychoanalityka i wydawał się zachęcać użytkowników do angażującej konwersacji. W początkowej fazie rozwoju chatbotów stosowano techniki dopasowywania wzorców, polegające na definiowaniu reguł i szablonów mapujących frazy wejściowe na odpowiedzi. Chatbot analizował dane wejściowe, wyszukując wcześniej zdefiniowane słowa kluczowe, struktury lub wzorce. W przypadku dopasowania odpowiedź generowano na podstawie przygotowanego szablonu wyjściowego. ELIZA była pionierskim rozwiązaniem, które wykorzystywało algorytmy rozpoznawania wzorców. Znaczący postęp w wydajności modeli generatywnych nastąpił dopiero wraz z nadejściem uczenia głębokiego. W początkowych latach rozwoju głębokich modeli generatywnych poszczególne dziedziny rzadko się ze sobą krzyżowały (Adamopoulou i Moussiades, 2020).

W przetwarzaniu języka naturalnego (*Natural Language Processing – NLP*) tradycyjnym podejściem do generowania zdań było modelowanie języka za pomocą rozkładu słów w oparciu o modele N-gramowe, a następnie wyszukiwanie najlepszej sekwencji (Bengio i in., 2003). Jednak metoda ta nie była efektywna w przypadku dłuższych zdań. Aby rozwiązać ten problem, wprowadzono rekurencyjne sieci neuronowe (*Recurrent Neural Networks – RNN*) do zadań modelowania języka, co umożliwiała uwzględnienie relatywnie długich zależności (Mikolov i in., 2010). Następnie opracowano bardziej zaawansowane sieci rekurencyjne, takie jak długa pamięć krótkotrwała (*Long Short-Term Memory – LSTM*) (Graves, 2012) oraz bramkowane jednostki rekurencyjne (*Gated Recurrent Units – GRU*) (Dey i Salem, 2017), które wykorzystywały mechanizmy bramkowania do kontroli pamięci podczas procesu uczenia. Te rozwiązania

umożliwiają modelowanie około 200 tokenów (części) w próbce, co stanowi znaczną poprawę w porównaniu z modelami N-gramowymi. W dziedzinie wizji komputerowej (*Computer Vision – CV*) przed wprowadzeniem metod opartych na głębokim uczeniu tradycyjne algorytmy generowania obrazów wykorzystywały techniki takie jak synteza tekstur (Efros i Leung, 1999) oraz mapowanie tekstur (Heckbert, 1986). Algorytmy te opierały się na ręcznie zaprojektowanych cechach i charakteryzowały się ograniczonymi możliwościami generowania złożonych i różnorodnych obrazów.

W 2014 roku Ian Goodfellow i jego współpracownicy po raz pierwszy zaproponowali sieci GAN (Goodfellow i in., 2014), nazywane generatywnymi sieci przeciwnymi lub generatywnymi sieciami kontrykcyjnymi (*Generative Adversarial Networks – GAN*), co stanowiło istotny postęp w dziedzinie generatywnej sztucznej inteligencji dzięki imponującym rezultatom w różnych zastosowaniach. Opracowano także autoenkodery wariacyjne (*Variational Autoencoders – VAE*) oraz inne metody, które umożliwiły bardziej precyzyjną kontrolę nad procesem generowania obrazów (Pinheiro Cinelli i in., 2021). Postęp w modelach generatywnych doprowadził do opracowania architektury Transformer, wprowadzonej przez Vaswaniego i jego współpracowników w 2017 roku w kontekście zadań NLP (Vaswani i in., 2017). Architektura Transformer została później zastosowana w CV, stając się dominującym trzonem dla wielu modeli generatywnych (takich jak wprowadzony w 2021 roku DALL-E) w różnych dziedzinach. W dziedzinie NLP wiele wybitnych dużych modeli językowych (*Large Language Models – LLM*), takich jak BERT i GPT, przyjmuje architekturę Transformer jako swój podstawowy element konstrukcyjny, oferując przewagi nad poprzednimi modelami, tj. LSTM i GRU. Architektura Transformer, oprócz poprawy wyników w pojedynczych modalnościach (tekst, obrazy, dźwięk, wideo), umożliwiła łączenie modeli z różnych dziedzin w celu realizacji zadań multimodalnych. Jednym z przykładów takich modeli multimodalnych jest CLIP (Radford i in., 2021), który łączy język i wizję, wykorzystując architekturę Transformer w połączeniu z komponentami wizualnymi. Dzięki szkoleniu na dużej ilości danych tekstowych i obrazowych, CLIP otworzył nowe możliwości w zakresie przetwarzania danych multimodalnych. Pojawienie się modeli opartych na architekturze Transformer zrewolucjonizowało generatywną sztuczną inteligencję, umożliwiając szkolenie modeli na dużą skalę oraz znacznie zwiększając ich możliwości w różnych dziedzinach.

Jednym z najbardziej znaczących rozwiązań w dziedzinie generatywnej sztucznej inteligencji jest ChatGPT, chatbot oparty na modelu GPT, udostępniony 30 listopada 2022 roku przez firmę OpenAI. Narzędzie to szybko przyciągnęło uwagę zarówno użytkowników, jak i naukowców. Liczne publikacje wskazują na zalety ChatGPT, podkreślając jego zdolność do generowania wszechstronnych, kreatywnych i obiektywnych odpowiedzi. Niemniej jednak zwrócono uwagę na istotne ograniczenia. Model miewa trudności ze zrozumieniem pytań i nie zawsze potrafi poprawnie korzystać z dostępnej wiedzy, co prowadzi do generowania niepoprawnych odpowiedzi (X. Wang i in., 2023). W niektórych przypadkach ChatGPT tworzy nieistniejące zasady lub równania, a jego odpowiedzi nie są w pełni wiarygodne, ani możliwe do śledzenia, ani weryfikowalne. Kreatywność ChatGPT może nie dorównywać doświadczeniu i intuicji wykwalifikowanych inżynierów, a proces podejmowania decyzji przez model jest często nieprzejrzysty. W analizach jakościowych użytkownicy mają trudności ze zrozumieniem priorytetyzacji konkurencyjnych czynników, np. kosztów, skuteczności czy opłacalności. W analizach ilościowych ChatGPT często stosuje niewłaściwe formuły lub pomija kroki pośrednie w złożonych obliczeniach (X. Wang i in., 2023). Pomimo tych ograniczeń, modele językowe oparte na architekturze Transformer, takie jak GPT, są potężnym narzędziem wspierającym zespoły innowacyjne, umożliwiając eksplorację szerszego zakresu problemów i rozwiązań (Bouschery i in., 2023). Dzięki zdolnościom w zakresie rozumienia, generowania i adaptacji języka, modele te mają potencjał do transformacji przyszłych praktyk opartych na wiedzy, zwiększając efektywność procesów innowacyjnych. Modele językowe powinny być jednak postrzegane jako komponent inteligencji hybrydowej, współdziałający z ludźmi w ramach zespołów innowacyjnych. Bouschery, Blazevic i Piller (2023) zachęcają jednocześnie do dalszych badań nad współpracą człowieka i AI w rzeczywistych kontekstach oraz do eksperymentów mających na celu lepsze zrozumienie efektywności takiej współpracy. Zgodnie z sugestiami Cubric (2020), przyszłe badania nad sztuczną inteligencją w biznesie powinny koncentrować się na ulepszeniach metodologicznych, opracowaniu lepszych metod oceny i podejściu interdyscyplinarnym. Aby w pełni wykorzystać potencjał sztucznej inteligencji w rozwoju nowych produktów, organizacje muszą opracować modele skutecznie adresujące te wyzwania.

Jednym z najnowszych trendów, jeśli chodzi o rozwiązania generatywnej sztucznej inteligencji, są systemy agentowe i wieloagentowe (*Multi-Agent Systems – MAS*), które umożliwiają rozwiązywanie złożonych problemów poprzez ich dekompozycję na mniejsze, łatwiejsze do

zarządzania zadania (Dorri i in., 2018). Są one oparte na interakcji wielu autonomicznych podmiotów, określanych jako agenci, które funkcjonują w określonym środowisku w celu realizacji wspólnych lub potencjalnie sprzecznych celów. Podstawową cechą systemów wieloagentowych jest ich autonomia, co oznacza, że agenci działają niezależnie od bezpośredniej interwencji człowieka, podejmując decyzje na podstawie własnych algorytmów oraz interakcji z otoczeniem (Aref i in., 2022). Dzięki rozproszonej naturze, zadania mogą być efektywnie dzielone pomiędzy agentów, co pozwala na równoległe przetwarzanie informacji oraz zwiększa zdolność systemu do skalowania w przypadku bardziej złożonych problemów. Kolejnym kluczowym aspektem jest interakcja i współpraca między agentami, które mogą wymieniać informacje oraz koordynować działania w celu osiągnięcia zamierzonych efektów (Dorri i in., 2018). Ponadto, systemy wieloagentowe charakteryzują się zdolnością do uczenia się i adaptacji, co oznacza, że agenci mogą doskonalić swoje strategie działania na podstawie wcześniejszych doświadczeń, co prowadzi do optymalizacji ich funkcjonowania (Goonatilleke i Hettige, 2022). Pomimo licznych korzyści, systemy wieloagentowe napotykają istotne wyzwania związane z ich implementacją i efektywnością działania. Jednym z kluczowych problemów jest koordynacja i synchronizacja działań agentów, zwłaszcza w systemach o dużej skali, gdzie efektywna komunikacja staje się wyzwaniem. Skalowalność również pozostaje istotnym wyzwaniem, ponieważ rozwój systemów wieloagentowych wymaga opracowania architektur umożliwiających ich efektywne działanie w warunkach rosnącej liczby agentów i złożoności procesów decyzyjnych (Boutyour i Idrissi, 2024). Dodatkowo, przydzielanie zadań w sposób dynamiczny i optymalny wciąż jest przedmiotem badań, ponieważ zapewnienie efektywnego podziału pracy pomiędzy agentami w czasie rzeczywistym jest skomplikowanym problemem obliczeniowym (Dorri i in., 2018). Pomimo powyższych wyzwań, ich dalszy rozwój i udoskonalanie mogą prowadzić do jeszcze bardziej efektywnego wykorzystania ich potencjału w przyszłości. Skoro GenAI wnosi nową wartość do NPD, kluczowe staje się pytanie, jak mierzyć dojrzałość organizacji w jej wykorzystaniu – zagadnienie to rozwija sekcja 1.3.

1.3. Dojrzałość i modele dojrzałości w literaturze naukowej

Terminy gotowości, dojrzałości, zdolności oraz modelu i siatki dojrzałości

Dojrzałość (w kontekście zjawiska) może być definiowana jako „w pełni ukształtowane, mające wszystkie typowe cechy” (SJP PWN, 2024). Warto jednak zauważyć, że w literaturze przedmiotu często pojawia się również termin „gotowość” (*readiness*), który w niektórych badaniach stosowany jest zamiennie z terminem „dojrzałość” (jak wskazują na przykład Schumacher, Erol i Sihn (2016)) lub wręcz definiując dojrzałość jako gotowość (Weidemann, 2017). Należy jednak podkreślić różnice między tymi pojęciami. Schumacher, Erol i Sihn (2016) wskazali, że gotowość poprzedza proces dojrzewania, co oznacza, że gotowość określa, czy organizacja jest przygotowana do rozpoczęcia procesu rozwoju, podczas gdy dojrzałość opisuje poziom zaawansowania i zorganizowania w odniesieniu do określonego procesu. Według słownika PWN, gotowość to „stan należytego przygotowania do czegoś” (SJP PWN, 2024). W literaturze naukowej pojawiają się także definicje innych pokrewnych koncepcji, takich jak gotowość do zmiany (*change readiness*), która koncentruje się na uwarunkowaniach poprzedzających zmiany oraz ich skutkach (Rafferty i in., 2013; Wybrańczyk i in., 2018), gotowość wobec technologii (*technology readiness*) odnosząca się do akceptacji i wykorzystania technologii przez ludzi (Blut i Wang, 2020; Clausing i Holmes, 2010; Rudnicka i in., 2016), czy dojrzałość projektowa (*project maturity*) analizująca zdolność organizacji do zarządzania projektami (Andersen i Jessen, 2003; Weidemann, 2017).

W literaturze funkcjonuje także termin „zdolności” (*capability*), jednakże terminy takie jak „dojrzałość” i „zdolność” nie są konsekwentnie stosowane w kontekście zarządzania procesami biznesowymi (*Business Process Management – BPM*). Na przykład model CMMI (*Capability Maturity Model Integration*), który omówiony zostanie dokładniej w dalszej części pracy, jednoznacznie odnosi się zarówno do poziomów dojrzałości, jak i zdolności, podczas gdy kolejny z modeli – OMG-BPM (Object Management Group – Business Process Maturity Model) uwzględnia jedynie poziom dojrzałości. W modelu OMG-BPM zdolność procesu jest mierzona pośrednio przez poziom dojrzałości, co podkreśla bliską zależność między tymi dwoma pojęciami. Niektóre modele konsekwentnie posługują się terminem „dojrzałość”, nawet w kontekstach, które bardziej odpowiadałyby definicji zdolności (Rohloff, 2009). Na ogół modele definiują poziom

zdolności jako osiągnięcie poprawy procesu w odniesieniu do konkretnego obszaru procesowego lub zestawu atrybutów procesu. W teorii zwiększenie zdolności jednego komponentu może prowadzić do wzrostu ogólnej dojrzałości, jednak zależy to od konkretnego modelu dojrzałości, czy ten wzrost wystarczy do osiągnięcia wyższego poziomu dojrzałości. W szczególności wzrost zdolności jednego komponentu nie wpływa bezpośrednio na inne komponenty ani nie musi stanowić kolejnego kroku w osiągnięciu wyższego poziomu dojrzałości. W praktyce architektura konkretnego modelu określa, w jaki sposób wpływ zdolności na dojrzałość jest mierzalny, zwłaszcza gdy komponenty są doskonalone indywidualnie (Van Looy i in., 2011). W niniejszej rozprawie podążono za podejściem przyjętym przez twórców modeli dojrzałości procesowej i dojrzałości w wykorzystaniu sztucznej inteligencji, zidentyfikowanych w przeglądzie literatury, koncentrując się na koncepcji dojrzałości.

Model dojrzałości jest zestawem różnorodnych narzędzi i praktyk, które umożliwiają ocenę zdolności organizacji do skutecznego zarządzania (Kosieradzka i Smagowicz, 2016). W innym ujęciu, modele dojrzałości stanowią proces ewolucyjny, w którym wprowadza się kluczowe praktyki w jednej lub wielu dziedzinach funkcjonowania przedsiębiorstwa. Stopnie dojrzałości, które są przyjęte, pozwalają organizacji na doskonalenie praktyk, począwszy od tych nieokreślonych i niespójnych, aż do praktyk powtarzalnych na poziomie komórek organizacyjnych, a następnie kompleksowo zdefiniowanych procesów biznesowych (przewidywalnych i zarządzanych statystycznie). Proces ten prowadzi ostatecznie do ciągłego wprowadzania innowacji i optymalizacji (Kosieradzka i Smagowicz, 2016; OMG, 2008). W literaturze naukowej funkcjonują zarówno terminy „model dojrzałości” (*maturity model*), jak i „siatka (lub macierz) dojrzałości” (*maturity grid*). Pomimo istniejących podobieństw, Maier, Moultrie i Clarkson (2012) wskazują na kluczowe różnice między siatką dojrzałości a modelem dojrzałości, które dotyczą aspektów zorientowania, sposobu oceny oraz celu zastosowania. W zakresie zorientowania, siatka dojrzałości charakteryzuje się uniwersalnością, umożliwiając jej zastosowanie w przedsiębiorstwach z różnych sektorów, podczas gdy model dojrzałości jest bardziej specyficzny i skoncentrowany na wybranych procesach. W odniesieniu do sposobu oceny, modele dojrzałości zazwyczaj opierają się na listach kontrolnych i kwestionariuszach, natomiast siatki dojrzałości opisują oczekiwane zachowania na każdym poziomie w formie komórek macierzy. Pod względem celu zastosowania, narzędzia te również różnią się funkcjonalnością: siatki dojrzałości są prostsze i mają bardziej uniwersalne zastosowanie, podczas gdy modele

dojrzałości mogą być wykorzystywane m.in. do celów certyfikacyjnych, oceniając efektywność organizacji w sposób bardziej kompleksowy. Siatka dojrzałości zazwyczaj zawiera tekstowe opisy czynności przypisanych do poszczególnych poziomów dojrzałości i może być przedstawiona w formie kilku stron tekstu (Fraser i in., 2002). W niniejszej rozprawie skoncentrowano się na opracowaniu modelu dojrzałości.

Najpopularniejsze modele dojrzałości

Początki modeli dojrzałości są powszechnie wiązane z Philipem B. Crosby'ym oraz jego Siatką Dojrzałości Zarządzania Jakością (*Quality Management Maturity Grid – QMMG*) (Crosby, 1979), obejmującą pięć etapów: niepewność, przebudzenie, oświecenie, mądrość i pewność. Koncepcja Crosby'ego znacząco wpłynęła na rozwój innych modeli dojrzałości. Historycznie, model dojrzałości zdolności (*Capability Maturity Model – CMM*) oraz jego rozszerzenie, kompleksowy model dojrzałości organizacyjnej (*Capability Maturity Model Integration – CMMI*), zaprojektowane dla sektora wytwarzania oprogramowania, osiągnęły największą popularność i stały się jednymi z najczęściej stosowanych modeli dojrzałości (Berg i in., 2006; Wendler, 2012). Pierwsza edycja CMM została opracowana w 1987 roku przez zespół programistów działających w Software Engineering Institute (SEI) przy Carnegie Mellon University w Pittsburghu, finansowanym przez Departament Obrony Stanów Zjednoczonych (*Department of Defense – DoD*).

Głównym celem SEI było stworzenie metodologii usprawniających realizację projektów informatycznych zlecanych przez DoD, tak aby były one ukończone w terminie, w ramach ustalonego budżetu, spełniając jednocześnie oczekiwania klientów bez obniżania funkcjonalności. W ramach tych działań opracowano Kwestionariusz Oceny Dojrzałości Procesów (*Maturity Questionnaire*), zawierający 85 pytań dotyczących kluczowych aspektów projektów IT, takich jak planowanie, monitorowanie postępów, zarządzanie harmonogramem, wymaganiami, konfiguracją, zapewnianie jakości oraz ciągłe doskonalenie procesów. Analizy przeprowadzone z wykorzystaniem tego kwestionariusza wśród dostawców DoD ujawniły powtarzające się wzorce w procesach wytwarzania oprogramowania, które były wspólne dla wszystkich badanych przypadków. Na podstawie tych obserwacji oraz zidentyfikowanych najlepszych praktyk w 1991

roku stworzono pierwszą wersję modelu *Capability Maturity Model for Software (SW-CMM)* (Chrissis i in., 2011). Model CMM stał się podstawą do opracowywania kolejnych modeli, zorientowanych na specyficzne obszary, takie jak akwizycja czy proces rozwoju nowych produktów. Chociaż modele z rodziny CMM cieszyły się dużą popularnością, każde z tych narzędzi miało nieco inne zastosowanie. Jednoczesne wdrażanie kilku modeli okazało się kosztowne dla organizacji dążących do doskonalenia procesów w różnych obszarach działalności. W odpowiedzi na tę sytuację, w 1997 roku *Software Engineering Institute* rozpoczął prace nad kompleksowym modelem integracyjnym. Efektem tych prac było powstanie modelu *Capability Maturity Model Integration (CMMI)* w wersji 1.1, który zdobył szerokie uznanie, stając się podstawą dla opracowywania kolejnych wersji.

Innym popularnym modelem dojrzałości omawianym w literaturze jest model BPMM, opracowany w 2002 roku przez organizację Object Management Group, Inc. (OMG). Jego celem jest osiągnięcie wysokiego poziomu sukcesu biznesowego poprzez zwiększenie dojrzałości procesów (Raschke i Ingraham, 2010). Autorzy modelu zakładają, że OMG-BPMM może być stosowany zarówno jako samodzielny model procesowy, jak i jako ramy dla działań doskonalących opartych na innych modelach (OMG, 2008). Model OMG-BPMM bazuje na koncepcji CMM i obejmuje pięć poziomów dojrzałości oraz 30 obszarów procesowych. Dokumentacja OMG-BPMM jest bardzo obszerna i liczy 496 stron, co wyróżnia go na tle innych modeli, które najczęściej są prezentowane w formie artykułów naukowych lub rozdziałów książek.

OMG-BPMM posiada dwie kluczowe zalety: po pierwsze, wspiera proces uczenia się w organizacji, między innymi poprzez analizę i wnioskowanie z popełnionych błędów; po drugie, promuje innowacyjne usprawnienia oraz zapobieganie problemom (Röglinger i in., 2012). W kontekście wcześniej wspomnianych typów modeli dojrzałości, Albliwi, Antony i Arshed (2014) zauważają, że niektóre modele, takie jak OMG-BPMM, zostały opracowane do oceny dojrzałości procesów (ogólnego stanu procesu), podczas gdy inne, takie jak CMM czy CMMI, skupiają się na ocenie dojrzałości organizacyjnej (zdolności organizacji do zarządzania procesami biznesowymi). W literaturze istnieje jednak niewiele modeli łączących cechy obu tych typów. Poza wspomnianymi modelami CMM, CMMI i OMG-BPMM, opracowano wiele innych modeli dojrzałości dostosowanych do różnych celów i obszarów, takich jak zarządzanie łańcuchem dostaw

(Lockamy i McCormack, 2004), zarządzanie ludźmi (Schiraldi i in., 2021), zarządzanie wiedzą (Khatibian i in., 2010), zarządzanie projektami (Ibbs i Kwak, 2000) i inne.


Budowa i cele modeli dojrzałości

W ostatnich latach obserwuje się wzrost liczby publikacji dotyczących modeli dojrzałości (Păunescu i Acatrinei 2012; Tarhan i in. 2016). Większość popularnych modeli opiera się na pięciopoziomowych systemach, które mogą mieć charakter etapowy lub ciągły. Modele te różnią się w zakresie swoich celów: jedne służą opisowi bieżącego stanu organizacji (opisowe, deskryptywne), inne wskazują ścieżkę doskonalenia (preskryptywne – *prescriptive*), a jeszcze inne umożliwiają porównywanie organizacji wewnątrz lub między sektorami na podstawie podobieństw praktyk (porównawcze) (García-Mireles i in., 2012). Jedną z popularnych metod opracowywania modeli dojrzałości są nauki o projektowaniu (*Design Science Research – DSR*). Podejście DSR, przedstawione przez Hevnera i in. (2004), wywodzi się z dziedziny systemów informacyjnych (*Information Systems – IS*), którą Hevner i in. (2004) definiują szeroko jako połączenie ludzi, organizacji biznesowych i technologii. Systemy informacyjne są wdrażane w organizacjach w celu zwiększenia ich efektywności i wydajności. Skuteczność tych wdrożeń zależy zarówno od możliwości samego systemu, jak i od cech organizacji, jej struktur pracy, personelu oraz stosowanych metod rozwoju i implementacji (Silver i in., 1995). Badania w dziedzinie systemów informacyjnych powinny koncentrować się m.in. na rozwijaniu i przekazywaniu wiedzy dotyczącej zarządzania technologią informacyjną oraz jej zastosowań do celów zarządczych i organizacyjnych. Pozyskiwanie takiej wiedzy opiera się na dwóch uzupełniających się paradygmatach: nauce behawioralnej i nauce projektowej (March i Smith, 1995).

Paradygmat nauki behawioralnej wywodzi się z metod badawczych nauk przyrodniczych i dąży do tworzenia oraz uzasadniania teorii (tj. zasad i praw), które wyjaśniają lub przewidują zjawiska organizacyjne i ludzkie związane z analizą, projektowaniem, wdrażaniem, zarządzaniem i użytkowaniem systemów informacyjnych. Teorie te dostarczają badaczom i praktykom wiedzy na temat interakcji między ludźmi, technologią i organizacjami, które należy odpowiednio zarządzać, aby system informacyjny mógł osiągnąć zakładane cele, takie jak poprawa efektywności i wydajności organizacji. Paradygmat nauki projektowej wywodzi się z inżynierii i zasadniczo jest

paradygmatem rozwiązywania problemów, który dąży do tworzenia innowacji definiujących idee, praktyki, możliwości techniczne i produkty umożliwiające efektywną i wydajną analizę, projektowanie, wdrażanie, zarządzanie i użytkowanie systemów informacyjnych (Denning, 1997). Innymi słowy, badania w obszarze nauki projektowej zajmują się rozwiązywaniem istotnych, nierozwiązanych problemów w unikalny lub innowacyjny sposób bądź rozwiązywaniem znanych problemów w sposób bardziej efektywny lub wydajny (Hevner i in., 2004).

Zwiększenie zdolności rozwiązywania problemów w obszarze nauk o projektowaniu odbywa się poprzez tworzenie innowacyjnych artefaktów, takich jak konstrukty, modele, metody i instancje (March i Smith, 1995). Becker, Knackstedt i Pöppelbuß (2009) wykorzystali powyższy opis, uznając, że modele dojrzałości są artefaktami służącymi rozwiązywaniu problemów związanych z określaniem aktualnego stanu zdolności przedsiębiorstwa oraz wyprowadzaniem z tego działań doskonalących oraz osadzili opracowywanie modeli dojrzałości w ramach wytycznych opracowanych przez Hevnera i in. (2004). Podkreślili jednak, że nie przypisują opracowywania modeli dojrzałości wyłącznie obszarowi nauk o projektowaniu, z wykluczeniem innych paradygmatów, lecz zaznaczyli, że bazowanie na kryteriach Hevnera i in. (2004) jest, ich zdaniem, wystarczające do opracowania modeli dojrzałości. Na podstawie tych wytycznych opracowali model procedury tworzenia modeli dojrzałości, przedstawiony na Rysunku 1.



Rysunek 1. Model procedury opracowywania modeli dojrzałości.

Źródło: opracowanie własne, bazując na pracy Beckera, Knackstedta i Pöppelbußa (2009).

W kontekście projektowania artefaktów, takich jak modele dojrzałości, wcześniejsze badania (Becker i in., 2009; De Bruin i in., 2005; Hevner i in., 2004) wskazują różne podejścia do procesu projektowego (Röglinger i Pöppelbuß, 2011). Praca De Bruin i in. (2005)² proponuje sześć etapów rozwojowych, które wspierają tworzenie modelu dojrzałości i dostosowanie go do specyficznych, złożonych zadań (Röglinger i Pöppelbuß, 2011). Z kolei Becker, Knackstedt i Pöppelbuß (2009) w odniesieniu do projektowania modeli dojrzałości, bazują na wytycznych nauki projektowania autorstwa Hevner i in. (2004) i definiują siedem kluczowych wymagań, jakie powinien spełniać użyteczny model dojrzałości: identyfikacja problemu, porównanie istniejących modeli dojrzałości, określenie strategii budowy modelu, iteracyjny rozwój modelu, koncepcja transferu i ewaluacji, implementacja mediów oraz ewaluacja modelu. Identyfikacja problemu skupia się na zdefiniowaniu problemu lub określeniu jego istotności dla badaczy i/lub praktyków, np. poprzez wywiady z potencjalnymi użytkownikami modelu dojrzałości. Porównanie z istniejącymi modelami dojrzałości jest konieczne, aby uzasadnić opracowanie nowego modelu (który może być również ulepszeniem już istniejącego modelu). Określenie strategii budowy modelu koncentruje się na wyborze strategii, gdzie najpopularniejsze opcje to: opracowanie całkowicie nowego modelu, ulepszenie istniejącego modelu, połączenie kilku modeli w nowy oraz transfer struktur lub treści z istniejących modeli do nowych obszarów zastosowań. Centralnym krokiem modelu procedury jest iteracyjny rozwój modelu dojrzałości, który składa się z kilku mniejszych kroków, takich jak wybór podejścia i testowanie uzyskanych wyników, powtarzane iteracyjnie. Wybierając podejście i opracowując wszystkie elementy modelu (tj. wymiary i elementy w tych wymiarach), należy dobrać odpowiednie metody, np. analizę literatury, z której możliwe jest wyodrębnienie kryteriów oceny dojrzałości z czynników sukcesu lub innych opracowań modeli. Następnym etapem jest koncepcja transferu i ewaluacji, w której należy określić, w jakiej formie model zostanie przekazany (np. kwestionariusz lub zamieszczenie narzędzia w Internecie) społeczności akademickiej oraz użytkownikom (należy również określić, kim będą użytkownicy). Na etapie implementacji mediów model należy udostępnić w zaplanowany sposób wszystkim wcześniej zdefiniowanym użytkownikom. Ostatnim krokiem jest ewaluacja modelu, podczas której najczęściej przeprowadzane są studia przypadków w określonych organizacjach. Wyniki ewaluacji mogą prowadzić do przeprojektowania modelu, odrzucenia go lub pozostawienia modelu

² Praca dr Toni de Bruin, wspomniana powyżej, była cytowana ponad 1500 razy. Rozprawa doktorska dr de Bruin dotycząca rozwoju dojrzałości procesów została uznana najlepszą rozprawą doktorską w Australii w 2010 roku w dziedzinie systemów informacyjnych.

niezmienionego, przy czym np. koncepcja transferu i ewaluacji może ulec modyfikacji. Modele dojrzałości mogą również stać się przestarzałe w danym obszarze problemowym, co powoduje konieczność regularnej weryfikacji i modyfikacji.

W literaturze wyróżnia się dwa podejścia do definiowania etapów dojrzałości. Podejście *top-down* (Becker i in., 2009; De Bruin i in., 2005) polega na wstępnym określeniu liczby poziomów lub etapów dojrzałości oraz wymiarów, a następnie definiowaniu warunków i kryteriów niezbędnych do konstrukcji modelu. Z kolei podejście *bottom-up* (Lehmkuhl i in., 2013; Mettler i in., 2010) rozpoczyna się od zestawu konkretnych cech lub czynników, a dopiero potem określa poziomy i wymiary odzwierciedlające te elementy (Lasrado i in., 2015). Podejście *bottom-up* jest częściej stosowane w dobrze rozwiniętych dziedzinach, gdzie aspekty dojrzałości są już zdefiniowane i rozpoznane. Natomiast podejście *top-down* sprawdza się w nowych obszarach, w których brakuje jasnych dowodów definiujących dojrzałość (De Bruin i in., 2005). Pomimo tych różnic, oba podejścia obejmują podobne etapy, różniące się głównie kolejnością realizacji (Mettler, 2011).

Păunescu i Acatrinei (2012) wskazują, że zastosowanie modeli dojrzałości powinno umożliwić organizacjom długoterminowe utrzymanie oraz rozwój wydajności procesów, zwiększenie poziomu dojrzałości kluczowych oraz pozostałych procesów, co przyczynia się do utrzymania konkurencyjności i osiągnięcia zrównoważonego rozwoju. Dojrzałość procesów może być postrzegana jako wskaźnik określający stopień zbliżenia procesu do stanu idealnego. Cronemyr i Danielsson (2013) zauważyli, że organizacje wdrażające zarządzanie procesami często rozpoczynają na zbyt zaawansowanym poziomie, co uwydatnia znaczenie precyzyjnego pomiaru aktualnego poziomu dojrzałości procesów. Wzrost poziomu dojrzałości generuje różnorodne korzyści, w tym zdobycie przewagi konkurencyjnej (Forstner i in., 2014), poprawę zarządzania procesami (Cronemyr i Danielsson, 2013), zwiększenie wydajności (Iii i in., 2008; Willems i in., 2012), podniesienie efektywności (Ahmed i in., 2008), wyższą jakość oraz zwiększenie inwestycji w rozwój (Harter i in., 2000).

Preskryptywność modeli dojrzałości

Röglinger, Pöppelbuß i Becker (2012) zauważają, że większość analizowanych przez nich modeli dojrzałości w literaturze ma charakter deskryptywny, co oznacza, że są one wykorzystywane

głównie do oceny bieżącego stanu organizacji w zakresie zarządzania procesami biznesowymi. Autorzy podkreślają trzy kluczowe zasady tworzenia modeli o charakterze preskryptywnym:

- A.** Modele dojrzałości przeznaczone do zastosowania preskryptywnego muszą uwzględniać środki poprawy poprzez wskazanie najlepszych praktyk, które powinny być wdrożone na danym poziomie.
- B.** Preskryptywne modele dojrzałości powinny zawierać rachunek decyzyjny, umożliwiający decydentom ocenić różne alternatywy, tj. różne zestawy środków poprawy – w odniesieniu do określonych celów organizacji i relacji kosztów i korzyści oraz zidentyfikować, która alternatywa najlepiej spełnia te cele.
- C.** Należy opracować metodologię wdrażania, która obejmuje procedurę, porady dotyczące dostosowania środków poprawy oraz rachunku decyzyjnego. Powinna być ona przystępna i zrozumiała dla grupy docelowej modelu oraz – jeśli to możliwe – uwzględniać wiedzę zdobytą na podstawie wcześniejszych zastosowań.

Autorzy tego badania zauważają, że spośród badanych modeli preskryptywnych większość spełnia jedynie pierwszy z powyższych warunków, nie uwzględniając w pełni dwóch pozostałych zasad lub traktując je bardzo ogólnikowo. Preskryptywne podejście umożliwia nie tylko diagnozę stanu organizacji, lecz także aktywne wspieranie jej w procesie doskonalenia, co zwiększa szanse na osiągnięcie lepszych wyników i adaptację do zmieniających się warunków rynkowych.

W późniejszych badaniach Linhart, Klaus i Röglinger (2017) bazując na modelu decyzyjnym Forstnera, Kampratha i Röglingera (2014) zaproponowali metodologiczne rozszerzenie, które może być wykorzystane do rozbudowania modeli dojrzałości o część preskryptywną. Rozszerzenie to wykorzystuje metodę porównań parami, umożliwiając ocenę istotności różnych elementów modelu z perspektywy realizacji celów organizacji (takich jak, na przykład, skrócenie czasu procesu). W tym celu autorzy rozszerzenia posługują się dziewięciostopniową skalą, gdzie 1 oznacza to, że dwa elementy modelu w równym stopniu przyczyniają się do osiągnięcia celu przez organizację, 3 oznacza to, że doświadczenie i osąd nieznacznie faworyzują jeden element nad drugim, 5 oznacza to, że doświadczenie i osąd zdecydowanie faworyzują jeden element nad drugim, 7 oznacza to, że jeden z elementów jest silnie faworyzowany, a jego dominacja jest widoczna w praktyce, 9 oznacza to, że są klarowne dowody potwierdzające faworyzowanie jednego elementu nad drugim, a liczby 2, 4, 6 i 8 oznaczają wartości pośrednie między

powyższymi. Mimo że Linhart, Klaus i Röglinger (2017) odwołują się do kryteriów prowadzących do celu organizacji (np. dotyczących czasu lub elastyczności), brak jest jednoznacznego odniesienia do relacji koszt – korzyść. Również złożoność zaproponowanego przez autorów rozwiązania może ograniczać jego przystępność – budowa macierzy i użycie przedstawionych wzorów może być niezrozumiałe lub zniechęcające dla grupy docelowej. Te ograniczenia wskazują na konieczność poszukiwania innych sposobów na uzupełnienie modeli o komponent preskryptywny.

Rozwój dużych modeli językowych (*Large Language Models – LLM*) może stanowić nową alternatywę dla zaprezentowanej powyżej oceny istotności. Systemy sztucznej inteligencji można sklasyfikować na dwa główne typy: modele ogólne oraz modele eksperckie, zaprojektowane do realizacji konkretnych zadań. Modele ogólne są trenowane na obszernych i różnorodnych zbiorach danych (na przykład danych pochodzących z Internetu z ostatnich dwóch dekad). Taka różnorodność pozwala platformom AI na wszechstronne i elastyczne funkcjonowanie poprzez inteligentne łączenie informacji z wielu dziedzin. Chociaż generowane przez te systemy odpowiedzi często wydają się przekonujące dzięki wysokiej płynności językowej, to jednak nie zawsze są wystarczająco wiarygodne, by wspierać podejmowanie decyzji w obszarach wymagających dużej precyzji i specjalistycznej wiedzy, takich jak projektowanie innowacji czy tworzenie strategii biznesowych na zaawansowanych etapach rozwoju. Modele eksperckie mają za zadanie wypełnić lukę między pozorną wiarygodnością a rzeczywistą rzetelnością informacji. Zostały stworzone z myślą o radzeniu sobie z dodatkowymi złożonościami wynikającymi z unikalnych wymagań konkretnych dziedzin lub organizacji. Przejście do tego rodzaju modeli odbywa się zazwyczaj poprzez integrację specjalistycznych danych z dużymi modelami językowymi. Tego typu modele eksperckie mogą być tworzone od podstaw poprzez dostrajanie istniejących systemów LLM z wykorzystaniem danych specyficznych dla danej branży lub poprzez precyzyjne dostrajanie przy pomocy specjalistycznych *promptów* w ramach dostępnych komercyjnie dużych modeli językowych (Piller i in., 2024). Coraz popularniejszym kierunkiem w rozwoju modeli eksperckich jest tworzenie tzw. agentów AI (Xi i in., 2023). Agenci ci generują wyspecjalizowane informacje i współpracują z innymi modelami, przyczyniając się do powstania bardziej zintegrowanego i efektywnego ekosystemu sztucznej inteligencji (Piller i in., 2024). Współdziałanie pomiędzy agentami AI zwiększa precyzję i specyfikę wygenerowanych danych,

czyniąc je niezwykle przydatnymi narzędziami w złożonych procesach decyzyjnych wymagających szczegółowych i dokładnych informacji (W. Chen i in., 2024).

Krytyka modeli dojrzałości

Modele dojrzałości w literaturze naukowej spotykają się z różnorodną krytyką. Po pierwsze, wskazuje się na problem nadmiernej liczby modeli. Röglinger, Pöppelbuß i Becker (2012) zauważają, że tak duża liczba modeli może prowadzić do dezorientacji zarówno wśród badaczy, jak i praktyków. Tarhan, Turetken i Reijers (2016) zwracają uwagę, że pomimo licznych propozycji modeli dojrzałości, wciąż brakuje empirycznych dowodów potwierdzających ich skuteczność i praktyczną użyteczność. Wendler (2012) potwierdza ten brak, wskazując na niedostatek walidacji i oceny modeli w literaturze naukowej. Kolejną kwestią krytyczną jest struktura modeli. Zamiast koncentrować się na czynnikach wpływających na proces ewolucji i doskonalenia, większość modeli zakłada osiągnięcie z góry określonego końcowego stanu jako ostatecznego celu (Röglinger i in., 2012). Modele często dostarczają ograniczonych wskazówek dotyczących konkretnych działań, które należy podjąć w celu poprawy poziomu dojrzałości, co stanowi istotną lukę metodologiczną (Röglinger i in., 2012). Z tego względu istnieje potrzeba opracowania kryteriów umożliwiających użytkownikom lepsze zrozumienie, jak skutecznie przechodzić na wyższe poziomy dojrzałości (Cronemyr i Danielsson, 2013). Dodatkowo, organizacje powinny w pełni wdrożyć praktyki charakterystyczne dla aktualnego poziomu, zanim przejdą do praktyk związanych z wyższymi poziomami (Dooley i in., 2001). Pomijanie poziomów dojrzałości jest uznawane za nieefektywne, ponieważ każdy poziom stanowi fundament dla następnego (Rae i in., 2014).

Albliwi, Antony i Arshed (2014) zwrócili uwagę na fakt, że ograniczona liczba modeli dojrzałości została opracowana w oparciu o naukowe wytyczne, co powoduje, że większość dostępnych modeli bazuje głównie na praktycznych doświadczeniach badaczy, a nie na solidnych podstawach teoretycznych. Innym aspektem krytyki jest uniwersalność modeli. W literaturze dotyczącej zarządzania cyklem życia produktu podkreśla się, że z jednej strony modele dojrzałości powinny być uniwersalne, aby umożliwiać porównania pomiędzy różnymi firmami lub branżami (R. Batenburg i in., 2005). Z drugiej strony, modele powinny być dostosowane do specyfiki danej

firmy lub branży, uwzględniając jej logikę biznesową, co pozwala na tworzenie konkretnych planów działania opartych na wynikach oceny dojrzałości dla pojedynczej organizacji (Dayan i Evans, 2006). Dodatkowo, wśród uwag krytycznych dotyczących modeli dojrzałości wskazuje się na liczne podobieństwa pomiędzy istniejącymi modelami, niewystarczającą dokumentację, bezkrytyczne stosowanie szablonu Capability Maturity Model oraz brak ekonomicznych podstaw (Albliwi i in., 2014).

W literaturze podkreślane są również braki i ograniczenia związane z wdrażaniem niektórych popularnych modeli dojrzałości. Na przykład, dla wielu organizacji modele takie jak CMM czy CMMI okazały się zbyt skomplikowane w implementacji. Badania sugerują, że rozbudowane struktury poprawy procesów wytwarzania oprogramowania, takie jak CMMI, są zbyt obszerne, aby mogły zostać efektywnie wdrożone i zrozumiane (Kuiliboer i Ashrafi, 2000; Reifer, 2000). Typowy cykl wdrażania CMM dla usprawniania procesów może trwać od roku do dwóch lat, wymagając znacznych zasobów oraz długoterminowego zaangażowania. Stanowi to wyzwanie, zwłaszcza dla małych i średnich przedsiębiorstw, które często nie dysponują wystarczającymi zasobami ani nie mogą zastosować wielu praktyk przewidzianych w modelu CMM (van de Weerd i in., 2010). Dodatkowo, model CMMI jest krytykowany za brak elastyczności w dostosowywaniu go do specyficznych procesów, takich jak rozwój produktów mechatronicznych. Wyższe poziomy dojrzałości w CMMI są często trudne do osiągnięcia z powodu nieprzewidywalności samego procesu (Hollauer i in., 2016). Model ten jest krytykowany także za koncentrację na procesach, pomijając istotne aspekty, takie jak ludzie, kultura organizacyjna czy struktura organizacji, które są kluczowe dla sukcesu projektu. Wymaga również specyficznego rodzaju szkolenia i doświadczenia, co jest dodatkowym wyzwaniem (Höggerl i in., 2006). Model OMG-BPM z kolei został na przykład skrytykowany za brak uwzględnienia ważnej roli wsparcia IT (Röglinger i in., 2012).

Dojrzałość procesowa w procesie rozwoju nowego produktu

Dojrzałość w odniesieniu do procesów jest najczęściej definiowana jako zdolność organizacji oraz realizowanych przez nią procesów do systematycznego dostarczania coraz lepszych rezultatów działalności (Kalinowski, 2011). Inaczej dojrzałość procesowa to „stopień, w jakim wszystkie

zasoby organizacji są optymalnie alokowane w stabilnych i opomiarowanych procesach, które umożliwiają realizację celów strategicznych organizacji” (Grela, 2013). Według innej definicji dojrzałość procesowa to „stan, w którym możliwe jest powtarzalne osiągnięcie tego samego rezultatu procesów (lub charakteryzującego się niewielkim, dopuszczalnym odchyleniem) w odniesieniu do wcześniej zdefiniowanych, kluczowych czynników” (Brajer-Marczak, 2014). W niniejszych badaniach wykorzystano ostatnią definicję.

Zarządzanie procesami biznesowymi (*Business Process Management – BPM*) jest definiowane jako osiągnięcie celów organizacji poprzez doskonalenie, zarządzanie i kontrolę kluczowych procesów biznesowych (Jeston, 2014). Kluczowe procesy, które często mają charakter międzywydziałowy, odpowiadają za zaspokajanie potrzeb klientów, zamiast skupiania się na działaniach poszczególnych działów. Organizacja w tym ujęciu staje się zbiorem procesów biznesowych, które wymagają modelowania, zarządzania i ciągłego doskonalenia. W obszarze BPM wyróżnia się dwa główne typy modeli dojrzałości: modele dojrzałości procesów oraz modele dojrzałości organizacyjnej (czy też zdolności organizacji do zarządzania procesami biznesowymi, *Business Process Management Maturity Models – BPMMM*) (Albliwi i in., 2014; Rosemann i vom Brocke, 2015). Modele dojrzałości procesów oceniają stan konkretnych procesów lub procesów ogólnie, natomiast BPMMM koncentrują się na zdolnościach organizacji w zakresie zarządzania procesami biznesowymi (Hammer, 2007; J. Lee i in., 2007; Rosemann i De Bruin, 2005). W literaturze pojawia się również koncepcja zorientowania na procesy biznesowe (*Business Process Orientation – BPO*). Jest ono definiowane jako podejście organizacyjne, które kładzie nacisk na procesy, procesowe myślenie, rezultaty i potrzeby klientów zamiast hierarchicznych struktur (Van Looy i in., 2011). W odróżnieniu od BPM, BPO wykracza poza zasady zarządzania i modelowania procesów, promując rozwijanie świadomości procesowej i podejścia zorientowanego na procesy. Przykładowo, właściele procesów ustalają cele wydajności dla zespołów procesowych, uwzględniając strategię organizacyjną (Hammer i Stanton, 1999). Niemniej jednak, stosowanie strategii BPM nie gwarantuje pełnego zorientowania na procesy biznesowe ani ewolucji w kierunku BPO (Van Looy i in., 2011). Przykładem może być organizacja zarządzająca i optymalizująca proces w sposób statystyczny, ale ograniczająca działania do jednego działu, bez zapewnienia międzydziałowego autorytetu właściciela procesu lub odpowiedniego poziomu zaufania między działami. Niektórzy autorzy traktują BPM i BPO jako tożsame (Rosemann i De Bruin, 2005), jednak inni wskazują, że BPM jest jedynie częścią BPO, gdzie BPO dodatkowo

obejmuje struktury organizacyjne dopasowane do procesów, płaską hierarchię, międzydziałowe zespoły procesowe oraz kulturę procesów, przenikającą wszystkie elementy organizacji. Kultura ta opiera się na wartościach i przekonaniach, takich jak orientacja na klienta, usamodzielnianie pracowników i ciągłe doskonalenie (Van Looy i in., 2011).

Zakładając wcześniej wspomnianą definicję dojrzałości procesowej oraz przyjmując, że analizowanym procesem jest proces rozwoju nowego produktu (*New Product Development – NPD*), kluczowe staje się określenie kluczowych czynników, względem których mierzona jest dojrzałość procesu. Model dojrzałości procesowej w kontekście procesu rozwoju nowego produktu będzie więc zestawem kluczowych narzędzi i praktyk stosowanych w tym procesie, umożliwiającym ocenę zdolności organizacji do efektywnego zarządzania rozwojem nowych produktów.

Liczba praktyk stosowanych w procesach NPD jest znaczna, a ich występowanie rozciąga się na różne poziomy rozwoju produktu, co sprawia, że niewielu autorów podjęło się ich systematycznej klasyfikacji w wielowymiarowej perspektywie. Niektórzy badacze przedstawiają różne grupowania praktyk, które odzwierciedlają różne aspekty procesu rozwoju nowego produktu. Barczak, Griffin i Kahn (2009) proponują osiem kategorii najlepszych praktyk obejmujących takie aspekty jak proces NPD, rozmyty początek (*fuzzy front end – FFE*), zarządzanie portfelem, organizacja NPD, narzędzia badania rynku, narzędzia projektowania inżynierskiego oraz narzędzia technologiczne i organizacyjne wspierające NPD. W podobnym duchu, wyniki badań prowadzonych przez amerykańskie stowarzyszenie rozwoju i zarządzania produktami (*Product Development and Management Association – PDMA*) umożliwiły wyróżnienie takich obszarów jak strategia, badania, komercjalizacja, proces, klimat projektu, kultura firmy oraz metryki i pomiar wydajności (Barczak i Kahn, 2012; Kahn i in., 2012). Kolejną próbę klasyfikacji zasad i praktyk rozwoju produktów przedstawiono w literaturze poświęconej *lean product development*, gdzie Morgan i Liker (2006) zaproponowali trzy główne obszary: ludzie, proces oraz narzędzia i technologie.

Rossi i Terzi (2017), bazując na powyższych klasyfikacjach (Barczak i in., 2009; Barczak i Kahn, 2012; Kahn i in., 2012; Morgan i Liker, 2006), przeprowadzili mapowanie najlepszych praktyk w rozwoju produktów, które zostały zidentyfikowane na podstawie literatury oraz wkładu praktyków.

Efektem tych działań było opracowanie modelu najlepszych praktyk w rozwoju produktów, który został szczegółowo zaprezentowany w Tabeli 3.

W ramach badania autorzy zidentyfikowali 107 najlepszych praktyk szeroko uznawanych w literaturze naukowej, które zostały zaproponowane przez różnych badaczy. Na tej podstawie, w połączeniu z wynikami serii grup fokusowych z udziałem ekspertów, opracowano najbardziej aktualne ramy identyfikacji i kategoryzacji najlepszych praktyk w zakresie rozwoju produktów. Grupy fokusowe składały się z członków rady doradczej inicjatywy badawczej dotyczącej projektowania i rozwoju produktów, prowadzonej przez Szkołę Zarządzania Politechniki Mediolańskiej we Włoszech. Sugestie praktyków, bazujące na ich doświadczeniach, były wykorzystywane do rozwijania, ulepszania oraz walidacji ostatecznej wersji modelu. Zawodowe tło uczestników miało ścisły związek z analizowaną dziedziną – w skład rady doradczej wchodziła między innymi kierownictwo projektów oraz dyrektorzy techniczni ds. projektowania i rozwoju produktów. Wszyscy uczestnicy posiadali co najmniej pięcioletnie doświadczenie na aktualnym stanowisku oraz minimum dziesięcioletnie doświadczenie zawodowe w przedsiębiorstwach. Choć wszystkie praktyki uwzględnione w modelu pochodziły z literatury – w tym sensie, że praktycy nie wprowadzili nowych praktyk bezpośrednio – to nie wszystkie z nich były dotąd uwzględnione w istniejących klasyfikacjach. Autorzy podkreślają, że wkład praktyków był kluczowy, gdyż zwrócili oni uwagę na pewne praktyki uznawane za najlepsze w literaturze, ale pomijane w dotychczasowych klasyfikacjach. Z powyższego wynikają dwie kwestie: po pierwsze, identyfikacja w ten sposób opracowanych najlepszych praktyk może stanowić podstawę do stworzenia modelu dojrzałości. Po drugie, doświadczenia zgromadzone i opisane przez badaczy podczas tworzenia modelu stanowią cenne wskazówki dla naukowców opracowujących własne modele dojrzałości.

Dojrzałość AI

Sztuczna inteligencja (*Artificial Intelligence – AI*) nie jest technologią łatwą do zastosowania ani wdrożenia w porównaniu z innymi technologiami cyfrowymi. Wyzwania związane z jej implementacją i funkcjonowaniem (zarówno techniczne, jak i społeczne) wymagają, aby

Tabela 3. Model najlepszych praktyk w rozwoju produktów.

Kategoria	Obszar	Najlepsze praktyki
Ludzie	Role i współpraca	Zespół międzyfunkcyjny; Wszyscy interesariusze są zaangażowani w zespół projektowy, nawet gdy są rozproszeni globalnie; Jasne określenie ról i obowiązków dla każdej osoby; Wysoka elastyczność w wykonywaniu zadań; Istnieje ogólny odpowiedzialny kierownik produktu z technicznym zapleczem; Pełne zaangażowanie klienta w rozwój; Zaangażowanie doświadczonych projektantów od najwcześniejszych etapów projektów
Ludzie	Szkolenie	Formalne programy wspierające rozwój umiejętności interdyscyplinarnych; Indywidualne korepetycje; KPI* do oceny wyników szkolenia
Proces	Działania i przepływ	Formalny model rozwoju produktu, właściwie przestrzegany i dokumentowany przez zaangażowanych aktorów; Silnie współpracujący proces rozwoju; Złożony zestaw KPI* do pomiaru wydajności rozwoju produktu; Frontloading procesu rozwoju produktu; Inicjatywy ciągłego doskonalenia; Wiele rozwiązań jest projektowanych i gorsze rozwiązania są stopniowo odrzucane w miarę pojawiania się nowych informacji; Pełne skupienie na wartości dla klienta; Sformalizowany proces analizy konkurencji (inżynieria odwrotna – <i>reverse engineering</i>)
Proces	Podjmowanie decyzji	Wizja z perspektywy cyklu życia. Uwzględnienie wszystkich faz życia produktu podczas jego rozwoju (dziesięć faz): projektowanie i industrializacja części i modułów; produkcja komponentów i półproduktów; montaż komponentów; testowanie i eksperymentowanie; pakowanie i magazynowanie; dostawa i dystrybucja; użytkowanie przez klienta; konserwacja i usługi posprzedażowe; demontaż, recykling i utylizacja; kontrola, ponowne użycie, aktualizacja, odnowienie. Opieranie procesu podejmowania decyzji na czynnikach strategicznych (12 czynników): końcowy koszt produktu/cena produktu; koszty rozwoju/ROI*; koszty związane z użytkowaniem i cyklem życia (np. konserwacja, usługi, recykling, utylizacja itp.); TTM*/zachowanie terminu dostawy; liczba różnych produktów; poziom dostosowania; poziom innowacyjności; wizerunek marki; wydajność funkcjonalna (np. produktywność, prędkość, dokładność, użyteczność, bezpieczeństwo, łatwość konserwacji itp.) odczuwalna i nie przez klientów; wydajność jakościowa (np. wytrzymałość, niezawodność, dostępność, trwałość itp.) odczuwalna przez klientów; zgodność wydajności z przepisami i normami dostarczanych klientom; inne wydajności odczuwalne przez klientów (np. zrównoważony rozwój środowiskowy, estetyka, aspekty społeczne i moralne itp.)

Kategoria	Obszar	Najlepsze praktyki
Zarządzanie wiedzą (KM)	Procesy KM	Poprzednia wiedza jest odzyskiwana przez poszczególne osoby na różnych etapach rozwoju produktu (pięć etapów): projekt koncepcyjny; studium wykonalności; szczegółowe projektowanie produktu i jego komponentów; testowanie, prototypowanie, eksperymentowanie; końcowa weryfikacja projektu. Formalny ogólny plan KM; Główne źródło wiedzy pochodzi ze środków formalnych, takich jak zasady projektowania zdefiniowane przez firmę/interesariuszy w celu zapewnienia, że czynniki strategiczne są brane pod uwagę w procesie rozwoju produktu (12 czynników): ostateczny koszt produktu/cena produktu; koszty rozwoju/ROI*; koszty związane z użytkowaniem i koszty cyklu życia (np. konserwacja, usługi, recykling, utylizacja itp.); TTM*/zgodność z terminem dostawy; liczba różnych produktów; poziom dostosowania; poziom innowacyjności; wizerunek marki; parametry funkcjonalne (np. produktywność, prędkość, dokładność, użyteczność, bezpieczeństwo, łatwość konserwacji itp.) dostrzegalne lub nie przez klientów; parametry jakościowe (np. solidność, niezawodność, dostępność, trwałość itp.) dostrzegalne przez klientów; zgodność osiągnięć z przepisami prawa i regulacjami, zapewniona klientom; inne parametry dostrzegalne przez klientów (np. zrównoważony rozwój środowiskowy, estetyka, aspekty społeczne i moralne itp.). Formalne źródła wiedzy są stale aktualizowane i przeglądane (trzy formalne źródła): pisemne zasady projektowania zdefiniowane przez firmę; pisemne podręczniki/standardy projektowania; pisemne zasady określone przez zewnętrzne strony (np. klientów, dostawców itp.); Opieranie się na poprzedniej wiedzy dla projektów rozwoju produktów
Zarządzanie wiedzą (KM)	Techniki KM	Strukturalne narzędzia i techniki formalnie wykorzystywane do przechwytywania, udostępniania i ponownego wykorzystywania wiedzy (11 różnych technik): werbalna komunikacja z kolegami; dokumenty z wnioskami wyciągniętymi z lekcji; dokumenty specyfikacji projektów; kwestionariusze/listy kontrolne; pokoje do obrad, plakaty i zarządzanie wizualne; wspólne foldery sieciowe; intranet; Wiki; blogi, fora, tablice ogłoszeń; systemy PDM/PLM*; oprogramowanie KBE* i automatyzacja projektowania
Narzędzia	Metody	Formalne metody inżynierskie/projektowe (11 metod): zasady modularyzacji i standaryzacji części (projektowanie modułowe, platformowe, klastrowe itp.); projektowanie dla X (DFX*) dla wydajności funkcjonalnej (np. projektowanie pod kątem produkcji, montażu, projektowanie odporne itp.); projektowanie dla X (DFX*) dla wydajności jakościowej (np. projektowanie dla Six Sigma, dla konserwacji itp.); projektowanie dla X (DFX*) dla innych wydajności odczuwalnych przez klienta (projektowanie pod kątem estetyki, środowiska, eko-projektowanie itp.); projektowanie pod kątem kosztów

Kategoria	Obszar	Najlepsze praktyki
		(DTC*)/zarządzanie kosztami docelowymi (TCM*); analiza kosztów cyklu życia (LCC*)/całkowity koszt posiadania (TCO*); analiza cyklu życia i inżynieria (LCA&E*); analiza wartości i inżynieria (VA&E*); wdrażanie funkcji jakości (QFD*); analiza ryzyka i awarii, analiza skutków awarii (FMEA/FMECA*); metody systematycznej innowacji (np. TRIZ*)
Narzędzia	Komputerowe i oprogramowanie	Rozwój produktu jest silnie wspierany przez platformy programowe (23 programy): automatyzacja biura (arkusze kalkulacyjne, edytory tekstu itp.); CAD* 2D; CAD* 3D; cyfrowe modele (DMU*); komputerowe wspomaganie stylizacji (CAS*); komputerowe wspomaganie inżynierii (CAE*); metoda analizy elementów skończonych (FEA/FEM*); obliczeniowa dynamika płynów (CFD*); KBE* i automatyzacja projektowania; komputerowe wspomaganie produkcji (CAM*); komputerowe planowanie procesów (CAPP*)/cyfrowa produkcja i fabryka; symulacja zdarzeń dyskretnych (DES*); rzeczywistość wirtualna/rozszerzona (V/AR*); zarządzanie danymi produktu (PDM/PLM*); systemy zarządzania dokumentami (DMS*); system zarządzania przepływem pracy (WMS*); planowanie zasobów przedsiębiorstwa (ERP*); zarządzanie łańcuchem dostaw (SCM*); zarządzanie relacjami z klientami (CRM*); zarządzanie relacjami z dostawcami (SRM*); skomputeryzowany system zarządzania konserwacją (CMMS*); oprogramowanie do analizy cyklu życia (LCA*); oprogramowanie do zarządzania projektami

Źródło: opracowanie własne, bazując na pracy Rossi i Terziego (2017).

**patrz: wykaz skrótów i pojęć*

organizacje były na nie odpowiednio przygotowane poprzez rozwój dojrzałości (lub gotowości) w obszarze AI (Jöhnk i in., 2021; Lokuge i in., 2019). Ocena dojrzałości AI w firmach ilustruje znaczenie opartego na inteligencji spojrzenia na wyniki firm (A. Kumar i in., 2020; Lichtenthaler, 2019). Różne poziomy dojrzałości pomagają wyjaśnić wyzwania wielu firm w zarządzaniu inicjatywami AI i czerpaniu korzyści z tych inicjatyw poprzez wzmocnienie ich pozycji konkurencyjnej (Datta, 2018; Overgoor i in., 2019). W niniejszych badaniach zakłada się, że dojrzałość w wykorzystaniu rozwiązań sztucznej inteligencji (w dalszej części pracy w skrócie: dojrzałość AI) skupia się na wykorzystaniu rozwiązań sztucznej inteligencji do budowania sukcesu rynkowego organizacji oraz zdobywania przewagi konkurencyjnej, natomiast dojrzałość AI w

procesie rozwoju nowego produktu to zdolność do wykorzystania rozwiązań sztucznej inteligencji w procesie rozwoju nowego produktu, w celu poprawy efektywności procesu.

Narzędzia służące ocenie dojrzałości i gotowości mogą wspierać organizacje w identyfikowaniu luk w ich zdolnościach do wdrażania AI, przyspieszać proces implementacji oraz pomagać w realizacji założonych celów związanych ze sztuczną inteligencją (Molla i in., 2009). Pojęcie gotowości AI odnosi się do przygotowania organizacji do wdrażania zmian związanych z zastosowaniami i technologiami AI (Alsheibani i in., 2018). W literaturze naukowej terminy takie jak dojrzałość AI i gotowość AI często stosowane są zamiennie. Ponadto, pojawia się również termin adopcji (przyjęcia) AI (*AI adoption*), odnoszący się do decyzji o przyjęciu innowacji, takich jak produkt, usługa, proces czy technologia (Frambach i Schillewaert, 2002). W niniejszej rozprawie skoncentrowano się na pojęciu dojrzałości.

Modele dojrzałości AI mogą być wykorzystywane do oceny zdolności organizacji w zakresie wykorzystania AI (Coates i Martin, 2019), prowadzenia organizacji w jej drodze do wykorzystania AI (Burgess, 2018) oraz porównywania wykorzystania AI w organizacji z innymi, bardziej zaawansowanymi organizacjami (Alsheibani i in., 2019). Aby ocenić dojrzałość AI, konieczna jest analiza wszystkich istotnych wymiarów AI (np. danych, kultury organizacji w odniesieniu do AI itp.) w różnych obszarach działalności organizacji (np. automatyzacja, marketing itp.), co pozwala uzyskać pełny obraz całkowitego poziomu możliwości AI (Mikalef i in., 2019). Co więcej, modele dojrzałości powinny opierać się na solidnych podstawach teoretycznych, ponieważ ich konceptualizacja może być uzależniona od różnorodnych perspektyw teoretycznych (Lasrado i in., 2015).

Dojrzałość AI coraz częściej pojawia się w publikacjach jako odrębny temat naukowy, jednakże sztuczna inteligencja występuje również w modelach dojrzałości cyfrowej (*digital maturity models*) lub modelach dojrzałości Przemysłu 4.0 (*Industry 4.0 maturity models*). Pomimo braku spójnej i powszechnie uznanej definicji terminu Przemysł 4.0 (Y. Lu, 2017), jest on używany do opisywania szerokiej integracji technologii informacyjno-komunikacyjnych w produkcji przemysłowej i obejmuje zintegrowany zbiór inteligentnych systemów produkcyjnych i zaawansowanych technologii informacyjnych, które opierają się na zestawach zintegrowanych systemów oprogramowania (Dilberoglu i in., 2017; Mosterman i Zander, 2016). Modele dojrzałości Przemysłu 4.0 mają na celu zmierzenie, w jakim stopniu obecny stan jednostki

organizacyjnej umożliwia przyjęcie i wdrożenie koncepcji Przemysłu 4.0 w przyszłości (Angreani i in., 2020). W przypadku dojrzałości cyfrowej, może być ona definiowana jako status transformacji cyfrowej przedsiębiorstwa (Thordsen i Bick, 2020), rozumianej jako głęboka transformacja działań organizacyjnych, granic i celów w celu wykorzystania możliwości technologii cyfrowych (Matt i in., 2015; Vial, 2019). Organizacje korzystają z modeli dojrzałości cyfrowej, które pomagają określić bieżący stan transformacji cyfrowej oraz wyznaczyć i ustalić priorytety działań (Chanas i Hess, 2016). Według Kupilasa i in. (2021) pojęcia dojrzałości cyfrowej i Przemysłu 4.0 są ściśle powiązane w kontekście produkcyjnym – dojrzałość cyfrowa może być oceniana we wszystkich branżach, podczas gdy Przemysł 4.0 odnosi się głównie do firm produkcyjnych.

Liczba modeli jest tak wysoka, że powstało bardzo wiele przeglądów literatury dotyczących zarówno modeli dojrzałości cyfrowej (Alsufyani i Gill, 2021; Ochoa-Urrego i Peña-Reyes, 2021; Teichert, 2019; Thordsen i in., 2020; Thordsen i Bick, 2020), jak i modeli dojrzałości Przemysłu 4.0 (Angreani i in., 2020; Basl, 2018; Elibal i Özceylan, 2020; Hajoary i in., 2023; Pacchini i in., 2019; Schumacher i in., 2016; Şener i Eren, 2017). Niezależnie od tego, czy są to modele dojrzałości cyfrowej, czy Przemysłu 4.0, w obu w obszarze technologii czasem pojawia się sztuczna inteligencja. Co ciekawe, na przykład w przeglądzie literatury mającym na celu znalezienie technologii rozwijających Przemysł 4.0, sztuczna inteligencja była wskazywana jedynie w 6 z 19 znalezionych artykułów (Pacchini i in., 2019). W związku z tym autorzy początkowo ją odrzucili, wybierając tylko technologie najczęściej cytowane. Jednak później skonsultowali swój wybór z ekspertami, którzy jednogłośnie stwierdzili, że sztuczna inteligencja powinna zostać dodana do listy. Autor niniejszej pracy jest świadomy występowania sztucznej inteligencji w niektórych modelach dojrzałości cyfrowej i modelach dojrzałości Przemysłu 4.0, jednak dojrzałość AI rozwinęła się w literaturze naukowej w na tyle dużym stopniu jako odrębny temat badawczy, że w niniejszej rozprawie skoncentrowano się właśnie na dojrzałości AI i modelach dojrzałości AI.

Jeśli chodzi o wymiary dotyczące dojrzałości w wykorzystaniu rozwiązań sztucznej inteligencji, Fukas i Thomas (2023) przygotowali uniwersalny model referencyjny zarządzania AI, odpowiedni dla różnych branż. Model ten został opracowany na podstawie przeglądu literatury, a jego wiarygodność była sprawdzana w konsultacjach z ekspertami oraz za pomocą obliczeń

statystycznych w celu oceny istotności poszczególnych wymiarów. Model obejmuje osiem wymiarów: „Technologie i Infrastrukturę”, „Dane”, „Ludzi i Kompetencje”, „Organizację i Procesy”, „Strategię i Zarządzanie”, „Budżet i Inwestycje”, „Produkty i Usługi” oraz „Etykę i Regulacje”, które zostały przyporządkowane do czterech głównych kategorii: aktywności wspierające, aktywności wartościowe, aktywności zarządcze oraz aktywności kluczowe. Aktywności wspierające i wartościowe definiują, dlaczego organizacja powinna wdrażać AI z punktu widzenia ekonomicznego. Na początku konieczne jest przeznaczenie budżetu i inwestycje w różne zasoby, takie jak technologie, dane i personel, aby rozwijać innowacyjne produkty i usługi oparte na AI, które powinny przynosić zwrot z inwestycji (*Return On Investment – ROI*) i dodawać wartość organizacji. Aktywności wspierające, takie jak planowanie budżetu, kalkulacja kosztów i alokacja zasobów, są zawarte w obszarze „Budżet i Inwestycje”. Aby AI generowało wartość biznesową, jego zastosowanie musi wpływać na produkty i usługi oferowane przez organizację. Aktywności wartościowe, takie jak projektowanie produktów opartych na AI, ocena wkładu AI w tworzenie wartości, marketing i sprzedaż produktów, należą do obszaru „Produkty i Usługi”. Dla skutecznego wykorzystania AI wymagane są kluczowe aktywności, które obejmują cztery główne obszary działania. Implementacja technologii związanych z AI oraz stworzenie odpowiedniej infrastruktury wspierającej efektywne zbieranie, przetwarzanie i analizę danych należą do obszaru „Technologie i Infrastruktura”. Obszar „Dane” dotyczy działań zarządczych zapewniających odpowiednią ilość, jakość oraz bezpieczeństwo danych, co jest niezbędne dla funkcjonowania systemów AI w organizacji. Obszar „Ludzie i Kompetencje” obejmuje identyfikację wymaganych kompetencji, szkolenie pracowników oraz rekrutację specjalistów posiadających wiedzę i umiejętności z zakresu AI. Wdrożenie AI w działalność organizacji często wymaga zmian w procesach i strukturach biznesowych. Zarządzanie tymi zmianami, w tym modelowanie procesów napędzanych AI, jest przypisane do obszaru „Organizacja i Procesy”. Aktywności wspierające, kluczowe i wartościowe muszą być spójne z centralną strategią AI. Dlatego aktywności zarządcze, takie jak tworzenie strategii AI, jej integracja ze strategią biznesową, zarządzanie projektami AI, to działania przypisane do obszaru „Strategia i Zarządzanie”. Dodatkowo, wdrażanie AI musi być zgodne z wytycznymi etycznymi i regulacjami, aby budować zaufanie do tych technologii. Obszar „Etyka i Regulacje” obejmuje ustanawianie zasad etycznych dotyczących AI oraz zapewnienie zgodności z wewnętrznymi i zewnętrznymi normami prawnymi. Model referencyjny został przedstawiony w Tabeli 4.

Tabela 4. Model referencyjny zarządzania sztuczną inteligencją.

Aktywności	Obszary	Opis
Aktywności wspierające	Budżet i Inwestycje	Aby umożliwić tworzenie wartości za pomocą AI, organizacje muszą przeznaczać budżety i inwestować w różne zasoby, takie jak technologie, dane i pracownicy. Kalkulacje, takie jak ROI, powinny zapewniać propozycję wartości biznesowej oraz trwały, ekonomiczny, zrównoważony rozwój AI.
Aktywności zarządcze	Strategia i Zarządzanie	Cele i strategie dotyczące zastosowania AI w kontekście, zakresie oraz odniesieniu czasowym i przestrzennym muszą zostać zaplanowane i sformułowane (dopasowanie AI do biznesu). Należy zdefiniować, jak organizacje mogą umożliwić wykorzystanie AI.
	Etyka i Regulacje	Rozwój i stosowanie AI musi być zgodne z wewnętrznymi i zewnętrznymi regulacjami. W organizacji muszą zostać ustalone wartości etyczne oraz standardy dotyczące AI, takie jak ochrona danych, przejrzystość i uczciwość.
Aktywności kluczowe	Technologie i Infrastruktura	Technologie (AI i inne) muszą być zintegrowane z odpowiednią infrastrukturą IT, aby AI mogła być rozwijana i wdrażana na dużą skalę.
	Dane	Ilość i jakość danych oraz efektywne przetwarzanie są kluczowe dla osiągnięcia wartości biznesowej za pomocą AI.
	Ludzie i Kompetencje	Kompetencje, które pracownicy muszą posiadać, aby rozwijać, doskonalić i stosować AI, muszą być zidentyfikowane, rozwijane, a jeśli potrzeba – pozyskiwane z zewnątrz.
	Organizacja i Procesy	Aby AI zostało efektywnie zintegrowane z działalnością organizacji (integracja AI z biznesem), procesy i struktury biznesowe muszą być elastyczne, przejrzyste i łatwo dostosowywalne.
Aktywności wartościowe	Produkty i Usługi	Aby tworzyć wartość biznesową, AI musi pozytywnie wpływać na produkty i usługi. Wkład AI w produkty i usługi oferowane klientom, jak również jej wpływ na sprzedaż i marketing, musi być oceniany oraz mierzalny dla kalkulacji ROI.

Źródło: opracowanie własne, bazując na pracy Fukasa i Thomasa (2023).

Wykorzystanie generatywnej sztucznej inteligencji (*Generative Artificial Intelligence – GenAI*) w biznesie stanowi dynamicznie rozwijające się pole badawcze. Jednakże w literaturze naukowej wciąż brakuje szczegółowych informacji dotyczących dojrzałości w wykorzystaniu rozwiązań

generatywnej sztucznej inteligencji (w skrócie: dojrzałość GenAI). Reznikov (2024) omawia różnorodne podejścia strategiczne do adopcji rozwiązań generatywnej AI. Jednym z takich podejść jest stopniowa integracja, w ramach której przedsiębiorstwa wprowadzają generatywną AI w sposób stopniowy, minimalizując zakłócenia w funkcjonowaniu organizacji. Podejście to umożliwia systematyczną ocenę i dostosowywanie rozwiązań, co pozwala na ich lepsze dopasowanie do celów biznesowych i wymogów regulacyjnych. Kolejną strategią jest transformacyjna integracja. W tym przypadku firmy decydują się na radykalne przeprojektowanie modeli biznesowych oraz procesów operacyjnych, bazując na potencjale generatywnej AI. Takie podejście jest charakterystyczne dla organizacji technologicznych, które chcą uzyskać przewagę konkurencyjną poprzez tworzenie innowacyjnych produktów lub usług opartych na zaawansowanych analizach generowanych przez AI. Trzecim omawianym podejściem jest współpraca poprzez partnerstwa. Wiele przedsiębiorstw decyduje się na strategiczne partnerstwa z dostawcami technologii AI, instytucjami badawczymi oraz innymi interesariuszami, co umożliwia wspólne opracowywanie i wdrażanie rozwiązań generatywnej AI. Dzięki takiej współpracy organizacje zyskują dostęp do zaawansowanych technologii i wiedzy specjalistycznej, co przyspiesza proces wdrażania AI oraz zwiększa jego efektywność. Brak jest jednak omówienia kwestii dojrzałości po adopcji tych rozwiązań.

Jak zauważa Chukhlomin (2024), doświadczenia wynikające z modeli dojrzałości AI mogą stanowić wartościowy punkt wyjścia dla tworzenia modeli dojrzałości GenAI. Analiza kluczowych komponentów modeli dojrzałości AI pozwala zidentyfikować elementy, które należy dostosować lub rozszerzyć w celu uwzględnienia specyficznych wyzwań i możliwości generatywnej sztucznej inteligencji. Jednocześnie generatywna AI wprowadza nowe aspekty i poziomy złożoności, które mogą nie być wystarczająco odzwierciedlone w istniejących modelach dojrzałości AI. Powstaje więc pytanie, w jaki sposób powinny być definiowane praktyki oraz poziomy dojrzałości w modelach dojrzałości GenAI, aby skutecznie odpowiadały na te specyficzne wymagania.

Opisane wcześniej podejście nauk o projektowaniu (*Design Science Research – DSR*) zostało wykorzystane w niniejszej rozprawie w celu opracowania modelu dojrzałości w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju nowego produktu. Aplikacje generatywnej sztucznej inteligencji można traktować jako systemy informacyjne, które wykorzystują technologię generatywnej AI do wspomagania zdolności człowieka w realizacji

określonych zadań (Feuerriegel i in., 2024). Podczas gdy wiele badań prowadzonych jest już w dziedzinach technologicznych, takich jak informatyka, badacze z obszarów biznesu czy projektowania systemów informacyjnych mogą wносить istotny wkład, analizując projektowanie z perspektywy socjotechnicznej. Angażowanie jednostek, zespołów, organizacji oraz grup społecznych w procesy projektowe pozwala na wzbogacenie wiedzy i przyczynia się do dalszego rozwoju tej interdyscyplinarnej dziedziny (Maedche i in., 2019).

1.4. Podsumowanie przeglądu istotnych komponentów tworzących domenę badawczą pracy

W rozdziale pierwszym przedstawiono szerzej relacje między podstawowymi komponentami pracy – procesem rozwoju nowych produktów, zastosowaniami (generatywnej) sztucznej inteligencji oraz aspektami związanymi z dojrzałością. Omawiane zagadnienia są osadzone w kontekście zarządzania i technologii, podkreślając interdyscyplinarne podejścia w badaniach i praktyce.

Odwołano się do podstawowych definicji zarządzania produktem, przywołując literaturę, która opisuje poszczególne fazy rozwoju produktu. Przeanalizowano także, w jaki sposób rozwiązania sztucznej inteligencji mogą wspierać efektywność procesu rozwoju nowego produktu oraz jaki potencjał mają rozwiązania generatywnej sztucznej inteligencji, biorąc pod uwagę tempo rozwoju tych rozwiązań w ostatnich latach. Dodatkowo, rozdział ten zgłębia zagadnienia związane z dojrzałością, obejmując przegląd historii modeli dojrzałości, ich konstrukcji, celów i preskryptywnego charakteru, a także krytycznych uwag na ich temat zawartych w literaturze. Pokazano także, na czym skupiają się badania dotyczące dojrzałości procesowej w procesie rozwoju nowego produktu oraz dojrzałości w wykorzystaniu rozwiązań sztucznej inteligencji.

Podsumowując, badania są pozycjonowane w obszarze synergii między procesem rozwoju nowego produktu a wykorzystaniem rozwiązań generatywnej sztucznej inteligencji, podkreślając istotność aspektu dojrzałości oraz wskazując na potrzebę dalszej eksploracji zastosowań, najlepszych praktyk czy barier wdrożeniowych.

Rozdział 2. Badania literaturowe

Celem niniejszego rozdziału jest przeprowadzenie badań literaturowych, które w rozprawie pełnią dwie kluczowe funkcje. Pierwsze badanie to przeprowadzenie przeglądu istniejących modeli dojrzałości procesowej obejmujących proces rozwoju nowego produktu (*New Product Development – NPD*) oraz modeli dojrzałości w wykorzystaniu sztucznej inteligencji (*Artificial Intelligence – AI*) (krok 2 w modelu procedury według Beckera, Knackstedta i Pöppelbußa (2009) opisanego w poprzednim rozdziale). Zidentyfikowane modele mają stanowić podstawę do opracowania konceptualnego modelu dojrzałości organizacyjnej w zakresie zastosowania rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju nowych produktów. Drugie badanie to przegląd zastosowań, wyzwań oraz czynników sukcesu związanych z wdrożeniami rozwiązań generatywnej sztucznej inteligencji, ukierunkowanymi na proces rozwoju nowego produktu, w celu wsparcia opracowania wymiarów i elementów modelu (jako część kroku 4 w modelu procedury z poprzedniego rozdziału).

2.1. Proces przeglądu literatury dla modeli dojrzałości

Systematyczny przegląd literatury został przeprowadzony w oparciu o ustrukturyzowany proces wyszukiwania i identyfikacji, oparty na metodologiach zaproponowanych przez Webster i Watsona (2002), tj. wyszukiwanie w wielu bazach, uzupełnione o tzw. *backward* i *forward search* oraz konceptualnie zorientowaną syntezę (*concept – centric*) – oraz Brocke i in. (2009)³ – tj. transparentność słów kluczowych, kryteriów włączenia / wykluczenia i ścieżki selekcji. Systematyczny przegląd literatury zapewnia transparentny proces identyfikacji i oceny literatury, redukuje stroniczość typową dla przeglądów narracyjnych i umożliwia konceptualną syntezę wymaganą do budowy ram teoretycznych dla modeli dojrzałości (Okoli i Schabram, 2010). Zakres pokrycia literatury określono zgodnie z taksonomią Coopera (Brocke i in. 2009) jako „wyczerpujący z selektywnym cytowaniem” (*exhaustive with selective citation*) – dążono do możliwie pełnego uchwycenia prac na styku dojrzałości procesowej i procesu rozwoju nowego

³ Praca Webster i Watsona (2002), dotycząca przeprowadzania przeglądów literatury, była cytowana ponad 15000 razy, a praca Brocke i in. (2009) prawie 3500 razy.


produktu, raportując finalnie te pozycje, które spełniły z góry ustalone kryteria włączenia i wyłączenia.

W pierwszym kroku dobrano słowa kluczowe związane z dojrzałością procesową w kontekście procesu rozwoju nowego produktu. Na początku uwzględniono słowa kluczowe obejmujące wszystkie fazy procesu rozwoju nowego produktu (takie jak *ideation*, *idea generation*, *business case analysis*, *product commercialization*, *market assessment* itp.), jednak generowały one nadmierną liczbę artykułów, co skłoniło do zawężenia do fraz „NPD”, „*product development*” (aby uwzględnić zarówno „*product development*”, jak i „*new product development*”), „*product management*” (dla szerszego zakresu) oraz wyrażen „*process maturity*” i „*maturity model*” w celu identyfikacji modeli dojrzałości procesowej. Wyszukiwanie oparto na tytułach, streszczeniach i słowach kluczowych w bazach takich jak Scopus, Web of Science, EbscoHost, ProQuest, ACM Digital Library, Wiley Online Library i ScienceDirect, które zgodnie z kryteriami Gusenbauera i Haddawaya (2020) spełniają standardy jakości wymagane od akademickich systemów wyszukiwania. Zdecydowano się również na uzupełnienie ich o bazy IEEE Xplore i SpringerLink (ze względu na ujęcie w tych bazach kluczowych serii konferencyjnych oraz w celu redukcji ryzyka pominięcia literatury) oraz analizę źródeł cytowanych w odnalezionych publikacjach oraz źródeł cytujących te publikacje (tzw. *backward* i *forward search*) (Webster i Watson, 2002). Uzupełniając wykorzystano wyszukiwarkę Google Scholar (Google Scholar zwiększa czułość i pomaga wychwytywać pozycje nieuwzględnione w bazach selektywnych (Martín-Martín i in., 2018), ale ze względu na ograniczoną powtarzalność nie był stosowany jako system główny).

Zastosowano następujące kryteria włączenia: (i) skupienie na modelach dojrzałości w tematyce procesu rozwoju nowego produktu, (ii) zawężenie zakresu publikacji do ostatnich 10 lat (2014-2024), w celu uwzględnienia najnowszych badań (starsze, fundamentalne prace identyfikowano metodą *backward / forward search*), (iii) wybór prac z zakresu nauk o zarządzaniu (najczęściej w wyszukiwarkach są to kategorie takie jak *Business i Management* oraz *Social Sciences i Decision Sciences*), (iv) ograniczenie do publikacji napisanych w języku angielskim. Uwzględniono także kryteria wykluczenia, które obejmowały: (i) brak pełnego tekstu artykułu, (ii) publikacje „fałszywie pozytywne” (na przykład, gdy akronim NPD oznaczał coś innego, niż proces rozwoju nowego produktu) oraz (iii) artykuły niezwiązane z tematem dojrzałości procesowej w procesie rozwoju nowego produktu – odrzucono modele dojrzałości Przemysłu 4.0, modele dojrzałości

cyfrowej, praktyk SCRUM, modele dojrzałości zarządzania jedynie oprogramowaniem, rozwoju nowych usług (tylko usług, a nie produktów, tzw. *New Service Development*), dojrzałości projektowej, dojrzałości zrównoważonego rozwoju, dojrzałości współpracy, dojrzałości pomysłów (*idea maturity*), dojrzałości technologii, dojrzałości innowacji (jeśli nie dotyczyła w żadnym stopniu produktu), modele dojrzałości produktu (danego produktu, a nie procesu rozwoju produktu), dojrzałości zarządzania zapotrzebowaniem, dojrzałości dostawców, dojrzałości zarządzania ryzykiem, dojrzałości roadmapy produktowej, dojrzałości serwityzacji oraz te zbyt ogólne, które nie odnosiły się w żadnym stopniu do procesów rozwoju produktów lub które zawierały modele w temacie rozwoju produktów, ale nie były to modele dojrzałości, a także modele komercyjne bez podstaw naukowych i niedostępne publicznie. W celu zapewnienia odpowiedniej jakości wybranych artykułów zastosowano następujące kryteria: (i) uwzględniono jedynie publikacje w czasopismach naukowych lub materiały z konferencji oraz (ii) brano pod uwagę wyłącznie prace poddane procesowi recenzji naukowej.

Kryteria selekcji zastosowano najpierw do tytułów i streszczeń w fazie wstępnej, a następnie do pełnych tekstów w etapie oceny kwalifikacyjnej. Początkowe wyszukiwanie przy użyciu fraz kluczowych przyniosło łącznie 1041 wyników (stan na dzień 20 kwietnia 2024 roku). Selekcji dokonał jeden recenzent (Autor niniejszej rozprawy). Po usunięciu duplikatów, analizie tytułów i abstraktów oraz odrzuceniu publikacji niespełniających określonych kryteriów, do szczegółowej analizy pełnych tekstów zakwalifikowano 77 artykułów. Następnie, w wyniku dokładniejszej weryfikacji, wykluczono 67 prac badawczych, co pozostawiło ostatecznie 10 publikacji. Najczęstszymi powodami odrzucenia były brak bezpośredniego powiązania z tematyką dojrzałości procesowej w procesie rozwoju nowego produktu oraz brak dostępu do pełnych tekstów publikacji. Następnie przeprowadzono analizę źródeł, które były cytowane w znalezionych publikacjach oraz tych, które cytowały znalezione publikacje, w ramach której zidentyfikowano 17 istotnych artykułów (znalezione artykuły cytowały istotne dla tego przeglądu literatury prace opublikowane przed 2014 rokiem). Kolejną jedną istotną publikację odnaleziono w wyniku dodatkowego wyszukiwania przy użyciu bazy Google Scholar i wybranych słów kluczowych. W efekcie tego procesu selekcji utworzono końcową bazę danych składającą się z 28 artykułów. Graficzny schemat procesu systematycznego przeglądu literatury przedstawiono na Rysunku 2. Matryca koncepcji w formie tabeli ze zidentyfikowanymi modelami dojrzałości i ich elementami została



Rysunek 2. Proces systematycznego przeglądu literatury – modele dojrzałości procesowej.

Źródło: opracowanie własne.


przedstawiona w kolejnym podrozdziale. Dyskusja modeli została przeprowadzona w podrozdziale 2.3. Następnie rozpoczęto proces identyfikacji modeli dojrzałości w wykorzystaniu sztucznej inteligencji. Wybrano słowa kluczowe „maturity model” oraz „AI” lub „artificial intelligence” (tak, aby uwzględnić także potencjalne modele dojrzałości w wykorzystaniu generatywnej sztucznej inteligencji). Podobnie jak w przypadku wyszukiwania modeli dojrzałości procesowej, przeszukano bazy danych Scopus, Web of Science, EbscoHost, ProQuest, ACM Digital Library, Wiley Online Library, ScienceDirect, IEEE Xplore oraz SpringerLink. Dodatkowo przeprowadzono analizę źródeł cytowanych w znalezionych publikacjach oraz tych, które cytowały znalezione artykuły, jak również wykonano dodatkowe wyszukiwanie w bazie Google Scholar. Zastosowano te same kryteria włączenia, co w przypadku modeli dojrzałości procesu rozwoju nowego produktu, tym razem koncentrując się na modelach związanych z wykorzystaniem rozwiązań AI. Kryteria wykluczenia obejmowały artykuły bez dostępu do pełnego tekstu, prace „fałszywie pozytywne” oraz te, które nie były związane z tematem

dojrzałości AI – odrzucono takie modele jak modele dojrzałości technologii, modele dojrzałości w użytkowaniu narzędzi wspieranych przez AI, białe księgi organizacji (tzw. *whitepapers*), raporty organizacyjne, internetowe narzędzia różnych organizacji, a także prace inżynierskie lub magisterskie.

Wstępne wyszukiwanie za pomocą słów kluczowych przyniosło łącznie 494 wyniki (stan na dzień 28 kwietnia 2024 roku). Selekcji dokonał jeden recenzent (Autor niniejszej rozprawy). Po usunięciu duplikatów, analizie tytułów i abstraktów oraz wykluczeniu artykułów niespełniających określonych kryteriów, do szczegółowej analizy zakwalifikowano 31 artykułów. Następnie wykluczono 19 prac badawczych, co pozwoliło wybrać 12 publikacji. Dalsza analiza źródeł cytowanych w znalezionych artykułach oraz tych, które je cytowały, umożliwiła zidentyfikowanie kolejnych dwóch istotnych artykułów. Dodatkowo, w wyniku wyszukiwania w Google Scholar, odnaleziono jeszcze jedną publikację. Na podstawie tego procesu selekcji utworzono ostateczną bazę danych składającą się z 15 artykułów. Proces systematycznego przeglądu literatury przedstawiono graficznie na Rysunku 3. Matryca koncepcji w formie tabeli ze zidentyfikowanymi modelami dojrzałości i ich elementami została przedstawiona w podrozdziale 2.4, a dyskusja modeli została przeprowadzona w podrozdziale 2.5.

2.2. Wyniki przeglądu literatury dla modeli dojrzałości procesowej

Wyniki systematycznego przeglądu literatury dotyczącego modeli dojrzałości procesowej w procesie rozwoju nowego produktu obejmują 28 modeli, które zostały sklasyfikowane i przedstawione w Tabeli 5. Tabela zawiera kluczowe informacje, takie jak liczba i nazwy poziomów oraz „elementów” modeli. Ze względu na różnorodność terminologii stosowanej przez autorów (m.in. „wymiary”, „elementy”, „wskaźniki”, „motywy”, „fazy”, „obszary”), zdecydowano się na użycie ogólnego terminu „elementy” do opisu tych części modeli (Autor zdecydował się na pozostawienie nazw poziomów i elementów w oryginalnej, angielskiej formie ze względu na fakt, iż, zdaniem Autora, lepiej oddają one znaczenie danego poziomu lub elementu). Tabela zawiera także domenę, dla której autorzy konstruowali modele, sugerowany sposób oceny dojrzałości według przygotowanego modelu, liczbę i charakterystykę badanej grupy podmiotów (jeśli



Rysunek 3. Proces systematycznego przeglądu literatury – modele dojrzałości AI.

Źródło: opracowanie własne.

przeprowadzono badania empiryczne) oraz typ modelu (wyłącznie opisowy lub preskryptywny). Poniżej znajduje się krótki opis 28 przeglądanych badań, uporządkowanych według roku ich publikacji.

Model dojrzałości procesu biznesowego (Business Process Maturity Model – BPMM) 1: Sharma (2005) przedstawił model dojrzałości dotyczący połączenia innowacji, rozwoju produktu i współpracy (*Collaborative Product Innovation – CPI*), składający się z trzech poziomów (*Intra-enterprise CPI, Inter-enterprise CPI, Just-in-time CPI*). Następnie przedstawili model zarządzania cyklem życia produktu (PLM) dla typowej organizacji z sektora produkcyjnego, składający się z 6 poziomów (*Manual/Ad-hoc, Standardization, Visibility, Business Activity Reinvention, Real time Track & Trace, Collective Optimization*). Według autorów modelu, CPI jest podzbiorem zarządzania cyklem życia produktu (*Product Lifecycle Management – PLM*), dlatego poziomy CPI mogą być naniesione na model PLM. Autorzy nie wskazują wprost, w jaki sposób poziomy są naniesione, lecz analizując rysunek modelu, można przypuszczać, że poziomy 1, 2 i 3 modelu CPI

Tabela 5. Modele dojrzałości uwzględniające proces rozwoju nowego produktu.

Autorzy	Nazwa / akronim	Domena	Poziomy	Elementy	Sposób oceny	Badana grupa	Typ modelu
Sharma (2005)	Collaborative Product Innovation (CPI)	Sektor produkcyjny	3 (<i>Intra-enterprise CPI, Inter-enterprise CPI, Just-in-time CPI</i>)	3 wymiary (<i>People, Process, Information</i>)	Brak danych	Brak	Opisowy
R. S. Batenburg, Helms i Versendaal (2006)	PLM Maturity Model	Ogólna	4 (<i>Ad hoc, Departmental, Organizational, Inter-organizational</i>)	5 wymiarów (<i>Strategy and policy, Monitoring and control, Organisation and processes, People and culture, Information technology</i>)	Kwestionariusz	23 organizacje (transport, dostawcy usług IT, wytwarzanie oprogramowanie, finanse)	Opisowy
Nicholas i Ledwith (2006)	NPD Maturity Model	Ogólna (małe i średnie przedsiębiorstwa)	5 (<i>Initial, Under Development, Defined, Managed, Optimised</i>)	6 wymiarów (<i>Strategy, Process, Metrics and Performance Evaluation, People, Portfolio Management, Market Research</i>)	Brak danych	Brak	Opisowy
Amaral i Rozenfeld (2007)	PDPNet (NPD Maturity Model)	Ogólna	5 (<i>Basic, Intermediate, Measurable, Controlled, Continuous Improvement</i>)	30 aktywności	Kwestionariusz	1 organizacja (produkcja maszyn dla sektora rolniczego)	Częściowo preskryptywny
OMG (2008)	OMG-BPMM	Ogólna	5 (<i>Initial, Managed, Standardized, Predictable, Innovating</i>)	30 wymiarów	Samoocena lub ocena zewnętrzna wg praktyk	Brak	Opisowy
Pels i Simons (2008)	PLM Maturity Model	Ogólna	4 (<i>Ad hoc, Departmental, Organizational, Inter-organizational</i>)	5 wymiarów (<i>Strategy and policy, Monitoring and control, Organisation and processes, People and culture, Information technology</i>)	Kwestionariusz	23 oceny dojrzałości (transport, elektronika, mechatronika)	Opisowy
Saaksvuori i Immonen (2008)	PLM Maturity Model	Ogólna	5 (<i>Unstructured, Repeatable but intuitive, Defined, Managed and measurable, Optimal</i>)	Brak wymiarów	Brak danych	1 organizacja (sektor dostawców usług IT)	Opisowy
Wieder, Le Dain i Blanco (2009)	NPD Agility Maturity Model	Sektor produkcyjny	4 (<i>Rigid, Frontal Responsive, Planned Responsive, Agile</i>)	4 obszary (<i>Multiple Valuations Management, Uncertainty Management, Knowledge and Learning Management, Collaboration Management</i>)	Kwestionariusz	Brak	Opisowy
Paula i in. (2010)	Product Development Process Management (PDPM)	Ogólna	5 (<i>Maturity Level 1, Maturity Level 2, Maturity Level 3, Maturity Level 4, Maturity Level 5</i>)	10 obszarów wiedzy (<i>Corporate Strategy, Project/Product Strategy, Portfolio Management, Marketing and consumer's research, Systematized Process, Gates, Personnel, Structure and organization for PDP, Innovation culture</i>)	Model procedury	1 organizacja (sektor IT)	Częściowo preskryptywny

				<i>and climate, Performance evaluation and metrics)</i>			
Chrissis i in. (2011)	CMMI-DEV V1.3	Ogólna (skoncentrowany początkowo na IT)	5 (<i>Initial, Managed, Defined, Quantitatively Managed, Optimizing</i>)	22 wymiary	Samooocena lub ocena zewnętrzna wg praktyk	Brak	Opisowy
Hüsig (2011)	NPD-CAI Maturity Model	Ogólna	6 (<i>No NPD Process, Phased Review Process, Stage-Gate Systems, Flexible NPD System, Flexible NPD System & FFE-OI, Holistic NPD System</i>) + 6 poziomów modelu CAI	Brak wymiarów	Brak danych	Brak	Opisowy
Savino, Mazza i Ouzrout (2012)	PLM Maturity Model	Ogólna	5 (<i>Lowest, Low, Medium, High, Top</i>)	15 komponentów (<i>People, Relationship, Technology, Organizational, Organizational interoperability, Process, Process Management Maturity Assessment, Product, PDM, Product Data, Techniques & Practices, PLM applications, Financial management, Measurement, Metrics</i>)	Kwestionariusz	250 organizacji (sektor elektromechaniczny i prefabrykatów)	Częściowo preskryptywny
Oliveira i Kaminski (2012)	Tech. Innovation Factors in NPD Maturity Model	Sektor przemysłowy	4 poziomy (<i>First, Second, Third, Fourth</i>)	4 elementy (<i>Effective information channels, Product differentiation strategy, Capacity to implement innovations, New product launch</i>)	Kwestionariusz	1 organizacja (sektor metalurgiczny – mechaniczny)	Opisowy
Kärkkäinen, Pels i Silventoinen (2012)	Customer Dimension of PLM Maturity	Ogólna	5 (<i>Chaotic, Conscientious, Managed, Advanced and Integration</i>)	4 motywy (<i>Level of proactivity, Extent of coordination, Extent of integration, Quality and type of customer knowledge</i>)	Brak danych	Brak	Opisowy
Wei i in. (2013)	CMM-IPD	Sektor przemysłowy	6 (<i>CMM-IPD0, CMM-IPD1, CMM-IPD2, CMM-IPD3, CMM-IPD4, CMM-IPD5</i>)	3 wymiary (<i>Organizational Support Capability – OSC, Technology Development Capability – TDC and Project Management Capability – PMC</i>)	Kwestionariusz	Brak	Opisowy
Walton, Tomovic i Grieves (2013)	Product Lifecycle Implementation on MM	Ogólna	5 (<i>Inputs, Processes, Outputs, Outcomes, Impact</i>)	1 wymiar (<i>Metrics</i>)	Lista metryk	Brak	Opisowy
Pigosso, Rozenfeld i McAloone (2013)	Ecodesign Maturity Model	Ogólna	5 (<i>Evolution Level 1 – Evolution Level 5</i>)	3 obszary (<i>Ecodesign management practices, Ecodesign operational practices, Ecodesign techniques and tools</i>)	Wywiady	1 organizacja (sektor transportowy)	Częściowo preskryptywny

Hynds i in. (2014)	Sustainability in NPD Maturity Model	Ogólna	4 (<i>Beginning, Improving, Succeeding, Leading</i>)	14 wymiarów (<i>Corporate Sustainability Policy, Overall Sustainability Strategy, Government Policy & Regulation, Impact of Trends, Supply Chain (CSR), Green labeling, Sustainability Design for Environment (DfE), Specifications/Customer Insights, Life Cycle Assessment (LCA) Process, DfE–Material and Part Selection, DfE–Supply Chain, DfE–Manufacturing Impact, DfE–Use Phase Impact, DfE–End of Life Impact</i>)	Kwestionariusz	21 organizacji (m.in. sektor motoryzacyjny, chemiczny, produkty konsumenckie i elektronika)	Opisowy
Moultrie, Sutcliffe i Maier (2016)	Ecodesign Maturity Grid for NPD	Sektor urządzeń medycznych	6 (<i>Level 0 – Level 5</i>)	5 faz (<i>raw material sourcing, manufacturing, distribution, use, end of life</i>)	Kwestionariusz (forma siatki)	5 organizacji (projektowanie urządzeń medycznych)	Opisowy
Vezzetti, Alemanni i Morelli (2017)	PLM implementation in NPD Maturity Model	Sektor dóbr luksusowych	5 (<i>Non-existing, Ad hoc, Departmental, Organizational, Inter-organizational</i>)	5 wymiarów (<i>Strategy and policy, Monitoring and control, Organisation and processes, People and culture, Information technology</i>)	Kwestionariusz	1 organizacja (sektor dóbr luksusowych)	Opisowy
Rossi i Terzi (2017)	CLIMB	Sektor produkcyjny	5 (<i>Chaos, Low, Intermediate, Mature, Best Practice</i>)	8 wymiarów (<i>Activities and flow, Decision making, Training, Roles and Collaboration, Knowledge management process, Knowledge management techniques, Methods, Computerisation and software</i>)	Kwestionariusz	103 organizacje (sektor produkcyjny)	Opisowy
Paavel, Karjust i Majak (2017)	PLM Maturity Model	Ogólna (małe i średnie przedsiębiorstwa)	5 (<i>Unstructured, Repeatable but intuitive, Defined, Managed and measurable, Optimal</i>)	5 wymiarów (<i>Strategy and policy, Monitoring and control, Organisation and processes, People and culture, Information technology</i>)	Kwestionariusz	1 (sektor produkcyjny)	Opisowy
Rutkowski (2017)	PIPMIGR	Ogólna	6 (<i>Default, Initiating, Enabling, Integrating, Optimising, Pioneering</i>)	2 wymiary (<i>Smart Grid, Product Innovation</i>)	Kwestionariusz (forma siatki)	Brak	Częściowo preskryptywny
Demir (2018)	Strategic Management MMI for Innovation (S3M-i)	Ogólna	6 (<i>Undefined, Initial, Planned, Performed, Optimized, Excellent</i>)	7 wymiarów (<i>Leadership, Planning & Executing, Processes & Tools, Structure & Model, People & Culture, Performance Management, Innovation</i>)	Kwestionariusz (forma siatki)	Brak	Opisowy
Exner, Balder i Stark (2018)	PSS Maturity Model	Sektor przemysłowy	5 (<i>Novice, Beginner, Advanced, Experienced, Expert</i>)	4 wymiary (<i>Value proposition, Business processes, Customer, Sustainability</i>)	Kwestionariusz, narzędzie Internetowe	1 organizacja (produkcja maszyn i systemów analitycznych)	Częściowo preskryptywny

Mattei i in. (2019)	Innovation Maturity Model for NPD	Ogólna	3 (przestrzeń operacyjna: <i>Beginner, Professional, Master</i> ; przestrzeń strategiczna: <i>Fearless, Conservative, Visionary</i>)	8 wymiarów (w przestrzeni strategicznej: <i>Strategy, Mega-trend innovation, Culture and organizational system, Openness to external</i> ; w przestrzeni operacyjnej: <i>Opportunity management (idea management), Technology management, Product and service development, Intellectual property</i>)	Brak danych	Brak	Opisowy
Pfenning i in. (2020)	PLM Maturity Model	Sektor przemysłowy	5 (<i>Reactive, Repeatable, Integrated, Collaborative, Adaptive</i>)	6 wymiarów (<i>Process, Organization, Collaboration, Data, Application, Technology</i>)	Model oceny	189 organizacji (sektor przemysłowy)	Częściowo preskryptywny
Aguiar i Jugend (2022)	CPDM2	Ogólna	5 (<i>Inert, Conversant, Applied, Monitored, Optimized</i>)	11 wymiarów (<i>Narrowing - Design for resources conservation, Regenerating - Design for regenerative systems, Slowing - Design to slow the resources loop, Closing - Design to close the resources loop, Informing - Information technologies supporting CPD, Use of data in CPD, CPD Impact Assessment, CPD and CBM Alignment, Circular User Engagement, CPD Collaboration, CPD Communication</i>)	Kwestionariusz (forma siatki)	4 organizacje (sektor produkcji żywności, produkcji środków chemicznych i plastiku, sektora motoryzacyjny i sektor modowy)	Opisowy

Źródło: opracowanie własne.

odpowiadają poziomom 4, 5, 6 modelu PLM. W modelu nie wymieniono bezpośrednio jego wymiarów, ale autorzy podkreślają, że model CPI nawiązuje do trzech aspektów (ludzie, procesy, informacje/dane) i jak efektywne zarządzanie nimi przynosi korzyści organizacjom. Autorzy nie przeprowadzili badań empirycznych, a także nie przedstawili metody oceny organizacji za pomocą tego modelu.

BPMM 2: R. S. Batenburg, Helms i Versendaal (2006) przedstawili model dojrzałości dotyczący zarządzania cyklem życia produktu (*PLM*) koncentrujący się na połączeniu dojrzałości procesów PLM i wdrażania systemów PLM ze współpracą między biznesem i IT. Należy do częściej cytowanych modeli z zakresu PLM. Autorzy wykorzystują pięć wymiarów (*Strategy and policy, Monitoring and control, Organisation and processes, People and culture, Information technology*) oraz cztery poziomy dojrzałości (*ad hoc level, departmental level, organisational level, inter-organisational level*), uwzględniając dodatkowo poziom 0, czyli brak działań w danym obszarze. Autorzy opracowali kwestionariusz składający się z 40 zagadnień (po osiem na wymiar), które uznali za istotne z perspektywy PLM. Kwestionariusz został wykorzystany do badania 23 holenderskich średnich i dużych organizacji z sektorów transportowego, wyposażenia, dostawców usług IT, wytwarzania oprogramowania oraz usług finansowych. Średnio wszystkie organizacje znajdowały się między pierwszym a drugim poziomem.

BPMM 3: Nicholas i Ledwith (2006) przedstawili model dojrzałości procesu rozwoju nowego produktu, ukierunkowany przede wszystkim na małe i średnie przedsiębiorstwa. Model zawiera sześć wymiarów (*Strategy, Process, Metrics and Performance Evaluation, People, Portfolio Management, Market Research*) oraz pięć poziomów (*Initial, Under Development, Defined, Managed, Optimised*). Autorzy przedstawili model (wraz z praktykami) sześciu ekspertom, pytając ich o przesunięcie praktyki na poziom wyższy, niższy lub usunięcie jej całkowicie z danego wymiaru, a następnie opracowali ostateczną wersję modelu z tabelami praktyk dla każdego poziomu w każdym wymiarze. Ponadto zadali ekspertom dwa dodatkowe pytania – czy duże organizacje oraz małe i średnie przedsiębiorstwa mogą korzystać z tego samego modelu oraz czy przedsiębiorstwa powinny zawsze dążyć do osiągnięcia najwyższego, piątego poziomu dojrzałości, czy też istnieje punkt, który byłby dla tych przedsiębiorstw optymalnym poziomem. Ekspertci byli podzieleni – połowa uznała, że model może być zastosowany do obu typów organizacji, podczas gdy druga połowa była przeciwnego zdania. Ponadto pięciu z sześciu ekspertów uznało, że małe i

średnie przedsiębiorstwa powinny starać się osiągnąć najwyższy poziom dojrzałości, natomiast jeden ekspert stwierdził, że korzyści z osiągnięcia najwyższego poziomu nie są proporcjonalne do kosztów jego realizacji. Autorzy nie przeprowadzili badań empirycznych w organizacjach.

BPMM 4: Amaral i Rozenfeld (2007) zaprezentowali model dojrzałości procesu rozwoju nowego produktu. Model obejmuje pięć poziomów dojrzałości (*Basic, Intermediate, Measurable, Controlled, Continuous Improvement*) oraz 30 aktywności. Autorzy opisali również, że poziomy dojrzałości dzielą się na podpoziomy, a aktywności są podzielone na zadania odpowiadające najlepszym praktykom wraz z opisami. Brak jednak szczegółowych informacji dotyczących wszystkich podpoziomów, zadań, praktyk i ich opisów. Zadania są przyporządkowane do jednego z dziewięciu obszarów wiedzy (zarządzanie projektami, środowisko, marketing, inżynieria produktu, inżynieria procesów, produkcja, zaopatrzenie, jakość, koszty). Model dojrzałości jest częścią większego modelu autorów o nazwie PDPNet, który obejmuje również model referencyjny procesu (opisujący fazy procesu rozwoju produktu) oraz model zarządzania zmianą (sugerujący, jak zarządzać zmianami i projektami w celu osiągnięcia wyższego poziomu dojrzałości). Autorzy przeprowadzili studium przypadku w jednej z brazylijskich organizacji z sektora małych i średnich przedsiębiorstw zajmującej się produkcją maszyn dla przemysłu rolniczego. Organizacja została oceniona jako nieosiągająca nawet pierwszego poziomu z powodu braku formalnego procesu rozwoju nowego produktu. Autorzy zauważyli jednak, że dzięki zmianom w organizacji mającym na celu formalizację procesu, firma w ciągu roku osiągnęła poziom pierwszy.

BPMM 5: OMG-BPMM (OMG, 2008) to jeden z wcześniej omawianych modeli, stworzony przez organizację OMG i skupiający się na różnych dziedzinach. Składa się z 5 poziomów dojrzałości (*Initial, Managed, Standardized, Predictable, Innovating*), 30 wymiarów i ponad 350 praktyk. Model został oparty na regułach budowania modeli CMM i CMMI. Uwzględniono go w zestawieniu z dwóch powodów. Po pierwsze, autorzy modelu zauważają, że w wielu dziedzinach podstawowy model procesu przedstawia rozwój i dostarczanie produktów oraz usług – na przykład w dziale finansowym organizacji byłoby to dostarczanie produktów (baz danych, formularzy) użytkownikom (menedżerom i innym pracownikom). W związku z tym według autorów ten podstawowy model procesu stanowi fundament ich modelu dojrzałości. Po drugie, autorzy przyznają, że model jest bardzo ogólny i organizacje mogą potrzebować opracowania bardziej szczegółowych, domenowych modeli dojrzałości. W tym celu przedstawiają wskazówki dotyczące

budowania takich domenowych modeli na podstawie OMG-BPMM, wskazując, że większość obszarów procesowych można uznać za rdzenne komponenty do tworzenia nowych modeli. Wyjątkiem jest sześć obszarów procesowych związanych z produktami i usługami (*Product and Service Business Management, Product and Service Work Management, Product and Service Preparation, Product and Service Deployment, Product and Service Operations, Product and Service Support*), co również sugeruje, że model przygotowany przez autorów koncentruje się głównie na produktach i usługach.

BPMM 6: Pels i Simons (2008) skorzystali z wcześniej omawianego modelu R. S. Batenburga, Helmsa i Versendaala (2006), rozszerzając go o dwa dodatkowe pytania – jedno dotyczące względnej liczby użytkowników zarządzania cyklem życia produktu (*PLM*) na dział, a drugie liczby aktywnych użytkowników PLM na funkcję systemu PLM. Przeprowadzili 23 oceny dojrzałości organizacji (przebadanych firm było mniej, ponieważ autorzy wykonywali również oceny dojrzałości poszczególnych działów w ramach jednej organizacji, lecz nie podano łącznej liczby organizacji). Badania objęły organizacje z sektora technologicznego (transport, elektronika, mechatronika). Średni wynik dojrzałości wynosił 2,5, przy czym zauważalne były różnice między średnią dla średnich organizacji (poziom dojrzałości bliski 2 we wszystkich wymiarach) a średnią dla dużych organizacji (poziom dojrzałości bliski 3 we wszystkich wymiarach). Autorzy opisali również badanie dużej organizacji z sektora motoryzacyjnego, gdzie wszystkie wymiary były powyżej poziomu 3, a dwa z nich (*Monitoring & Control* oraz *Organization & Processes*) osiągnęły pełną dojrzałość (najwyższy poziom 4 w modelu R. S. Batenburga, Helmsa i Versendaala (2006)). Wyniki wskazują, że organizacja uznaje swój proces rozwoju produktu za wyjątkowo dobrze zorganizowany.

BPMM 7: Saaksvuori i Immonen (2008) zaprezentowali model dojrzałości zarządzania cyklem życia produktu (*PLM*), rozumianym nie tylko jako proces produktowy (projektowanie i rozwój nowego produktu czy marketing produktowy), ale uwzględniający także proces zamówienia i dostawy produktu. Model zawiera pięć poziomów dojrzałości (*Unstructured, Repeatable but intuitive, Defined, Managed and measurable, Optimal*) i nie zawiera wymiarów. Autorzy zbadali jedną organizację z sektora dostawców usług IT, która znajdowała się na pierwszym poziomie (*Unstructured*). Brak kwestionariusza lub informacji o tym, w jaki sposób dokładnie przeprowadzono badania.

BPMM 8: Wieder, Le Dain i Blanco (2009) przedstawili model dojrzałości zwinności procesu rozwoju produktu (*NPD agility*), mający na celu określenie, jak zwinny powinien być proces rozwoju produktu, aby wdrożenie innowacji nie obniżało jego wydajności. Zaproponowany model składa się z czterech obszarów procesowych (*Multiple Valuations Management, Uncertainty Management, Knowledge and Learning Management, Collaboration Management*), które są podzielone łącznie na 12 praktyk, oraz czterech poziomów dojrzałości (*Rigid, Frontal Responsive, Planned Responsive, Agile*). Autorzy adaptują model dostępny w literaturze, lecz nie przedstawiają pełnego kwestionariusza. Jako docelową formę badania dojrzałości organizacji wskazują wywiady, jednak nie przeprowadzili badań empirycznych.

BPMM 9: Paula i in. (2010) zaprezentowali model dojrzałości zarządzania procesem rozwoju produktu (*Product Development Process Management – PDPM*). Model składa się z trzech obszarów (*Strategic, Tactical / Operational* oraz *Support*), które podzielone są na łącznie 10 obszarów wiedzy (*Corporate Strategy, Project/Product Strategy, Portfolio Management, Marketing and consumer's research, Systematized Process, Gates, Personnel, Structure and organization for PDP, Innovation culture and climate, Performance evaluation and metrics*). Obszary wiedzy dzielą się dalej na 30 zdolności, zawierających 95 najlepszych praktyk (odnalezionych w literaturze i podręcznikach organizacji zajmujących się zarządzaniem produktami i projektami) oraz 302 opisy części procesu. Autorzy zaproponowali procedurę identyfikacji częstotliwości występowania problemów w procesie rozwoju produktu (1 – występuje w 0–10% projektów, do 9 – występuje w 90–100% projektów) oraz ocenę, w jakim stopniu dana najlepsza praktyka może zminimalizować problem. W tym celu zaadaptowali dostępny w literaturze kwestionariusz najczęściej występujących problemów w organizacjach do procesu rozwoju produktu. Końcowy kwestionariusz zawierał 52 problemy i 95 najlepszych praktyk, tworząc macierz 4940 elementów. Autorzy przeprowadzili grupy fokusowe z ekspertami w celu stworzenia macierzy relacji. Na podstawie tej macierzy oraz częstotliwości występowania problemów autorzy przyporządkowali firmy do jednego z pięciu poziomów dojrzałości. Artykuł zawiera również propozycje ulepszeń, określając wagi (istotność) ulepszeń z perspektywy organizacji. W połączeniu z macierzą relacji powstała lista najważniejszych najlepszych praktyk do wdrożenia w celu podniesienia poziomu dojrzałości. Autorzy przeprowadzili badania empiryczne na jednej organizacji z Brazylii z sektora małych i średnich przedsiębiorstw zajmującej się produkcją oprogramowania. Organizacja została oceniona na drugi poziom dojrzałości.

BPMM 10: CMMI-DEV 1.3 (Chrissis i in., 2011) to jedna z wersji wcześniej omawianego modelu CMMI, opracowanego przez Carnegie Mellon University, skupiającego się na ulepszaniu procesów rozwoju produktów i usług. Początkowo CMMI dotyczył rozwoju oprogramowania, jednak wersja DEV została uwzględniona ze względu na ogólne skupienie na produktach i usługach, a nie jedynie na oprogramowaniu, oraz na fakt, że jest to jedna z wersji najbardziej znanego na świecie modelu dojrzałości procesowej CMMI, na podstawie którego powstało w literaturze wiele innych modeli. Model składa się z pięciu poziomów dojrzałości (*Initial, Managed, Defined, Quantitatively Managed, Optimizing*) oraz 22 obszarów procesowych (zawierających ponad 160 praktyk) i przedstawia metodologię wdrażania modelu.

BPMM 11: Hüsigg (2011) przedstawił model łączący dojrzałość procesu rozwoju nowego produktu z dojrzałością komputerowego wspomaganie innowacyjności (*Computer-Aided Innovation – CAI*). Oba modele zawierają 5 poziomów dojrzałości oraz poziom zerowy (w modelu dojrzałości CAI są to: *No CAI Tools, Focused CAI 1.0 Tools, Integrated CAI 1.0 Systems, Enterprise CAI 1.0 Solutions, Enterprise CAI 1.0 & Open CAI 2.0, Holistic CAI 2.0 Solutions*, a w modelu dojrzałości NPD: *No NPD Process, Phased Review Process, Stage-Gate Systems, Flexible NPD System, Flexible NPD System & FFE-OI, Holistic NPD System*). Model koncentruje się na przejściu z podejścia CAI opartego na zamkniętych innowacjach (określanych jako CAI 1.0) do podejścia opartego na otwartych innowacjach (określanych jako CAI 2.0). Opisywany jest także wpływ różnych metod i technologii (np. przetwarzanie w chmurze) na CAI, ale nie przedstawia wymiarów modelu ani metod oceny organizacji na jego podstawie. Brak jest także badań empirycznych.

BPMM 12: Savino, Mazza i Ouzrout (2012) przedstawili model zarządzania cyklem życia produktu. Model zawiera 5 poziomów (*Lowest, Low, Medium, High, Top*) oraz 15 zidentyfikowanych komponentów (*People, Relationship, Technology, Organizational, Organizational interoperability, Process, Process Management Maturity Assessment, Product, PDM, Product Data, Techniques & Practices, PLM applications, Financial management, Measurement, Metrics*). Brak jest informacji, w jaki sposób autorzy zidentyfikowali komponenty; w artykule znajdują się opisy praktyk jedynie dla dwóch spośród 15 komponentów na każdym z pięciu poziomów. Model można uznać za częściowo preskryptywny, ponieważ autorzy stosują wagi do określenia mniej dojrzałych elementów modelu wymagających poprawy. Autorzy przeprowadzili badania empiryczne na próbie 250 małych i średnich przedsiębiorstwach z

sektorów elektromechanicznego i prefabrykatów w południowych Włoszech. Wyniki badań wskazały, że większość organizacji we wszystkich 15 komponentach znajdowała się na poziomie trzecim lub czwartym, wskazując wysoką świadomość w kontekście zarządzania cyklem życia produktu.

BPMM 13: Oliveira i Kaminski (2012) zaprezentowali model dojrzałości procesu rozwoju produktu w małych i średnich przedsiębiorstwach przemysłowych. Model zawiera cztery poziomy dojrzałości (*First, Second, Third, Fourth*) oraz cztery elementy (*Effective information channels, Product differentiation strategy, Capacity to implement innovations, New product launch*). Autorzy zidentyfikowali 45 czynników innowacyjności technologicznej, które przypisali do wcześniej wymienionych elementów. Do każdego elementu przypisano sześć pytań, a do każdej odpowiedzi współczynnik wagowy oparty na wcześniejszych badaniach. Dzięki temu każdy element ma inne progi przejścia między poziomami dojrzałości. Autorzy wskazali, że modelem przebadano wiele przedsiębiorstw, jednak szczegółowo opisano jedynie jeden przypadek organizacji z Brazylii z sektora przemysłowego (metalurgia, mechanika). W badaniu dwa elementy osiągnęły poziom pierwszy, jeden – poziom drugi, a jeden – poziom trzeci.

BPMM 14: Kärkkäinen, Pels i Silventoinen (2012) uznali model R. S. Batenburga, Helmsa i Versendaala (2006) za najlepiej zbudowany pod kątem teoretycznym i przebadany empirycznie. Jednocześnie stwierdzili, że w aktualnych modelach PLM brakuje uwzględnienia potrzeb klientów, dlatego zaproponowali rozszerzenie modelu o ten jeden wymiar. Rozszerzenie posiada pięć poziomów dojrzałości (*Chaotic, Conscientious, Managed, Advanced and Integration*), a autorzy wspominają także o czterech motywach przewodnich w wymienionych wymiarach (*Level of proactivity, Extent of coordination, Extent of integration, Quality and type of customer knowledge*). Brak jest kwestionariusza oraz badań empirycznych dotyczących zaproponowanego rozszerzenia.

BPMM 15: Wei i in. (2013) zaprezentowali model dojrzałości dedykowany rozwojowi produktów przemysłowych. Model składa się z trzech wymiarów (*Organizational Support Capability – OSC, Technology Development Capability – TDC and Project Management Capability – PMC*), które podzielono łącznie na 18 kluczowych obszarów procesowych, 52 cele i ponad 300 kluczowych praktyk. Model uwzględnia pięć poziomów dojrzałości (*CMM-IPD1, CMM-IPD2, CMM-IPD3, CMM-IPD4, CMM-IPD5*), a także poziom zerowy (*CMM-IPD0*). Brak szczegółowych informacji na temat wszystkich celów i praktyk. Autorzy zastosowali system wag dla kluczowych obszarów

procesowych, gdzie wagi są przypisywane przez ekspertów. Nie przeprowadzono badań empirycznych, jednak autorzy przedstawili teoretyczny przykład zastosowania modelu do oceny organizacji.

BPMM 16: Walton, Tomovic i Grieves (2013) zaprezentowali model dojrzałości dedykowany wdrożeniu cyklu życia produktu (*PLM*). Na podstawie przeprowadzonych wcześniej ankiet autorzy stworzyli listę metryk służących do oceny wydajności zarządzania cyklem życia produktu. Metryki zostały przypisane do jednego z pięciu poziomów dojrzałości (*Inputs, Processes, Outputs, Outcomes, Impact*). Brak szczegółowych informacji o wartościach metryk, które wskazywałyby na wysoką wydajność zarządzania cyklem życia produktu. Nie przeprowadzono także badań empirycznych organizacji.

BPMM 17: Pigosso, Rozenfeld i McAloone (2013) zaprezentowali model dojrzałości dedykowany wdrożeniu praktyk eko – projektowania w procesie rozwoju produktu. Model opracowano na podstawie przeglądu literatury, wywiadów z 14 ekspertami oraz badań w działaniu (*action research*). Model składa się z praktyk zarządzania eko – projektowaniem (62 praktyki zidentyfikowane we wcześniejszych badaniach), praktyk operacyjnych eko – projektowania (480 opcji projektowania, sklasyfikowanych w obrębie 35 wskazówek i 6 strategii, zaadaptowanych z literatury) oraz technik i narzędzi eko – projektowania (106 technik i narzędzi zidentyfikowanych we wcześniejszych badaniach). Model obejmuje pięć poziomów dojrzałości (*Evolution Level 1 – Evolution Level 5*) oraz kroki procedury przejścia na wyższy poziom dojrzałości. Autorzy zaprezentowali studium przypadku, bazujące na jednej z większych międzynarodowych firm z sektora transportu. Organizacja znajdowała się na najniższym poziomie dojrzałości, ale określiła drugi poziom jako swój cel. Zidentyfikowano osiem projektów ukierunkowanych na poprawę dojrzałości organizacji, szczególnie w obszarach, gdzie obecna dojrzałość była na najniższym poziomie.

BPMM 18: Hynds i in. (2014) przedstawili model dojrzałości dedykowany zrównoważonemu rozwojowi procesu rozwoju produktu. Model składa się z czternastu wymiarów przypisanych do dwóch obszarów – *Strategy* (wymiarzy *Corporate Sustainability Policy, Overall Sustainability Strategy, Government Policy & Regulation, Impact of Trends, Supply Chain (CSR), Green labeling, Sustainability Design for Environment (DfE)*) oraz *Design Tools* (wymiarzy *Specifications/Customer Insights, Life Cycle Assessment (LCA) Process, DfE–Material and Part*

Selection, DfE–Supply Chain, DfE–Manufacturing Impact, DfE–Use Phase Impact, DfE–End of Life Impact). Model obejmuje cztery poziomy dojrzałości (*Beginning, Improving, Succeeding, Leading*). Autorzy przygotowali kwestionariusz składający się z 171 pytań, ale przedstawili jedynie przykładowe pytania. Przeprowadzono także badania empiryczne na 21 organizacjach z sektora wytwórczego (m.in. rynek motoryzacyjny, chemiczny, produkty konsumenckie i elektronika). Średnio organizacje znajdowały się pomiędzy pierwszym a trzecim poziomem dojrzałości. Najlepsza organizacja osiągnęła czwarty poziom (najwyższy) w 11 z 14 wymiarów.

BPMM 19: Moultrie, Sutcliffe i Maier (2016) opracowali model składający się z pięciu siatek dojrzałości dedykowanych eko – projektowaniu w sektorze urządzeń medycznych. Każda siatka dojrzałości przypisana jest jednej z pięciu faz cyklu życia produktu (*raw material sourcing, manufacturing, distribution, use, end of life*). Każda siatka zawiera od 6 do 9 zagadnień związanych z eko-projektowaniem, a każde zagadnienie można przypisać jednemu z pięciu poziomów dojrzałości (czasami dostępny jest również poziom zerowy). Autorzy udostępniają każdą siatkę i podają źródła dotyczące zagadnień w danej siatce. Przeprowadzono badania empiryczne w pięciu organizacjach projektujących urządzenia medyczne (trzy duże organizacje, jedna mała firma i jeden start-up). Przeprowadzono również wywiady dotyczące przydatności narzędzia. Nie przedstawiono jednak wszystkich odpowiedzi organizacji – autorzy zaprezentowali jedynie przykład wypełnionej siatki przez jedną z organizacji.

BPMM 20: Vezzetti, Alemanni i Morelli (2017) zaprezentowali model dojrzałości dla procesu NPD w firmach rodzinnych z sektora dóbr luksusowych. Autorzy skupili się na systemach używanych w procesie rozwoju nowego produktu (systemy PLM, ERP, CRM, CDM) i ich wpływie na wsparcie tego procesu w kontekście biznesów rodzinnych. Zidentyfikowali potrzeby użytkowników i przełożyli je na niezbędne aktywności procesowe, którym przypisano poziomy istotności. Wypisano właściwości systemów PLM, ERP, CRM i CDM, porównując je z aktywnościami procesowymi. Wyniki wskazały, że system PLM jest najbardziej istotny i ma największy wpływ na zysk i markę biznesu rodzinnego. Autorzy następnie porównali cztery modele pod kątem dopasowania do domeny biznesów rodzinnych i wybrali model R. S. Batenburga, Helmsa i Versendaala (2006), używając jednak skali 5-poziomowej (*Non-existing (0), Ad hoc (1), Departmental (2), Organizational (3), and Inter-organizational (4)*). Przyjęto te same wymiary, co w modelu pierwotnym, wskazując jednak wymagane zdolności i aktywności

procesowe dla domeny biznesów rodzinnych. Przygotowano kwestionariusz składający się z 40 pytań, jednak nie przedstawiono go w artykule. Przeprowadzono badania empiryczne w jednej organizacji, która osiągnęła wyniki od 1,9 do 2,5 (w skali od 0 do 4) w każdym wymiarze.

BPMM 21: Rossi i Terzi (2017) zaproponowali model dojrzałości procesu NPD, skoncentrowany głównie na firmach z sektora produkcyjnego. Model bazuje na przygotowanym przez autorów, omawianym wcześniej, modelu najlepszych praktyk w procesie NPD. Model obejmuje pięć poziomów dojrzałości (*Chaos, Low, Intermediate, Mature, Best Practice*) oraz 107 praktyk w 8 obszarach (*Activities and flow, Decision making, Training, Roles and Collaboration, Knowledge management process, Knowledge management techniques, Methods, Computerisation and software*). Autorzy przygotowali kwestionariusz, ale zaprezentowali jedynie jedno przykładowe pytanie dotyczące jednej z praktyk. Przeprowadzono badania empiryczne na 103 włoskich przedsiębiorstwach różnej wielkości z sektora produkcyjnego. Nie przedstawiono wyników dla każdej organizacji, ale średnio organizacje osiągnęły poziom 2 lub 3.

BPMM 22: Paavel, Karjust i Majak (2017) przedstawili model dojrzałości zarządzania cyklem życia produktu dla małych i średnich przedsiębiorstw. Model wykorzystuje wymiary z modelu R. S. Batenburga, Helmsa i Versendaala (2006) oraz poziomy dojrzałości z modelu Saaksvuoriego i Immonena (2008), ale bazując na wywiadach, stworzyli 26 własnych elementów (subkategorii) modelu, w ramach wymiarów. Opracowano również kwestionariusz składający się z ponad 120 pytań, choć nie został on w pełni zaprezentowany – autorzy pokazali jedynie 21 pytań dotyczących jednej z subkategorii (wizja PLM). Model uwzględnia na początku oczekiwania organizacji – korzyści, jakie organizacja może uzyskać, poprawiając swoją dojrzałość, przypisane do jednej z czterech kategorii (*Financial performance, Time reduction, Quality improvement, Business improvement*). Przeprowadzono badania empiryczne na jednej organizacji z Estonii z sektora produkcyjnego – średnio organizacja we wszystkich wymiarach znajdowała się na pierwszym lub drugim poziomie dojrzałości.

BPMM 23: Rutkowski (2017) zaproponował macierz dojrzałości procesu innowacji i inteligentnej sieci relacji (*Product Innovation Process Maturity and Intelligent Grid of Relationships – PIPMIGR*). Macierz zawiera dwa wymiary – poziom dojrzałości inteligentnej sieci relacji oraz poziom dojrzałości procesu innowacji i wprowadzenia nowego produktu na rynek. Dla obu wymiarów przewidziano skale od 0 do 5 (0 – *Default*, 1 – *Initiating*, 2 – *Enabling*, 3 – *Integrating*,

4 – *Optimising*, 5 – *Pioneering*), co daje macierz złożoną z 25 obszarów. Każdy obszar macierzy definiuje strategię aktywności, które organizacja powinna podjąć, będąc umiejscowiona w danym obszarze macierzy. W artykule brak informacji o przeprowadzonych badaniach empirycznych.

BPMM 24: Demir (2018) zaprezentował model dojrzałości zarządzania strategicznego dla innowacji. Model został uwzględniony w zestawieniu ze względu na fakt, że zarządzanie strategiczne postrzegane przez autorów jest powiązane z radykalnie nowym produktem lub usługą wdrożonymi na nowym rynku. Model obejmuje siedem wymiarów (*Leadership, Planning & Executing, Processes & Tools, Structure & Model, People & Culture, Performance Management, Innovation*) oraz sześć poziomów dojrzałości (*Undefined, Initial, Planned, Performed, Optimized, Excellent*). Autorzy przedstawiają tabelę z praktykami dla każdego z poziomów w każdym wymiarze. Nie przeprowadzono badań empirycznych – zaproponowano jedynie sposób mierzenia poziomu dojrzałości organizacji. Poziom ten wyznaczany jest jako średnia poziomów we wszystkich wymiarach, zaokrąglana do najbliższej liczby całkowitej (na przykład średnia 2,7 dla wszystkich wymiarów daje poziom 3).

BPMM 25: Exner, Balder i Stark (2018) przedstawili model dojrzałości dedykowany systemom produktowo – usługowym (*Product-Service Systems – PSS*). Model składa się z czterech wymiarów, z których każdy posiada dwa kryteria: *Value proposition* (kryteria *Degree of individualisation* oraz *Service degree*), *Business processes* (kryteria *PSS management* oraz *PSS orientation*), *Customer* (kryteria *Customer demands* oraz *Customer integration*), *Sustainability* (kryteria *Sustainable management* oraz *End-of-life responsibility*). Dla każdego kryterium definiowany jest jeden z pięciu poziomów dojrzałości (*0 – novice, 1 – beginner, 2 – advanced, 3 – experienced, 4 – expert*). Autorzy zaproponowali również rekomendowane działania, które mogą zostać wdrożone w celu przejścia na wyższy poziom dojrzałości. Bazując na przykładzie dla jednego z kryteriów, są to krótkie sugestie, składające się z jednego lub dwóch działań do podjęcia. Autorzy przygotowali także kwestionariusz, prezentując pytania dla jednego kryterium. Na jego podstawie zbudowano internetowe narzędzie do samooceny dojrzałości dla organizacji, choć brak jest linku do narzędzia. Przeprowadzono studium przypadku na jednej organizacji z sektora małych i średnich przedsiębiorstw, zajmującej się produkcją maszyn i systemów analitycznych dla elektrowni oraz przemysłu chemicznego. Organizacja osiągnęła wyniki od 2 (dla trzech kryteriów) do 4 (dla kryterium *PSS management*) w skali od 0 do 4. Autorzy ocenili także użyteczność

narzędzia wśród badanej organizacji, uwzględniając jego łatwość użycia i atrakcyjność. Użyteczność narzędzia oceniono na 70%, głównie ze względu na niewystarczającą szczegółowość rekomendowanych działań.

BPMM 26: Mattei i in. (2019) przedstawili model dojrzałości dotyczący innowacji w rozwoju nowych produktów i usług. Model podzielono na dwie przestrzenie – strategiczną i operacyjną, z których każda zawiera cztery wymiary (łącznie osiem wymiarów – w przestrzeni strategicznej: *Strategy, Mega-trend innovation, Culture and organizational system, Openness to external*, a w przestrzeni operacyjnej: *Opportunity management (idea management), Technology management, Product and service development, Intellectual property*). Każda z przestrzeni posiada trzy oddzielne poziomy dojrzałości (przestrzeń operacyjna: *Beginner, Professional, Master*; przestrzeń strategiczna: *Fearless, Conservative, Visionary*). Model obejmuje także 24 podwymiarów, które dzielą się dodatkowo na narzędzia i metody. Autorzy przedstawiają przykłady jedynie dla dwóch z ośmiu wymiarów. Nie zaprezentowano kwestionariusza ani nie przeprowadzono badań empirycznych.

BPMM 27: Pfenning i in. (2020) przedstawili model dojrzałości dedykowany cyklowi życia produktu. Model składa się z pięciu poziomów (*reactive, repeatable, integrated, collaborative, adaptive*) oraz sześciu wymiarów zmiany (*Process, Organization, Collaboration, Data, Application, Technology*). W modelu uwzględniono również konieczność opisu organizacji oraz pięć domen wiedzy (*plan, define, verify, build, operate*), w ramach których zidentyfikowano 50 zdolności (wraz z opisem). Dodatkowo wprowadzono docelowy stan (poziom dojrzałości) oraz ustalanie priorytetów każdej zdolności z wykorzystaniem modelu MoSCoW (*Must – Should – Could – Won't*). Brak jednak szczegółowych opisów zdolności. Autorzy przebadali 189 organizacji z sektora przemysłowego, lecz w celu wskazania istotności niektórych zdolności w danych sektorach (korzystając z ustalania priorytetów), a nie w celu oceny poziomu dojrzałości.

BPMM 28: Aguiar i Jugend (2022) zaprezentowali siatkę dojrzałości CPDM2 (*Circular Product Design Maturity Matrix*) dedykowaną włączaniu aspektów gospodarki cyrkularnej (*circular economy – CE*) w proces rozwoju nowego produktu (NPD). Siatka zawiera pięć poziomów dojrzałości (*Inert, Conversant, Applied, Monitored, Optimized*) oraz 11 wymiarów (*Narrowing - Design for resources conservation, Regenerating - Design for regenerative systems, Slowing - Design to slow the resources loop, Closing - Design to close the resources loop, Informing -*

Information technologies supporting CPD, Use of data in CPD, CPD Impact Assessment, CPD and CBM Alignment, Circular User Engagement, CPD Collaboration, CPD Communication). Autorzy przeprowadzili przegląd literatury w celu zidentyfikowania elementów zawartych w wymiarach modelu oraz dokonali walidacji z ekspertami. Zaprezentowano tabelę opisującą zachowania organizacji na każdym poziomie dojrzałości dla każdego wymiaru, na podstawie której przeprowadzono badania empiryczne. Przebadano cztery organizacje z sektorów: produkcji żywności, chemicznego i plastikowego, motoryzacyjnego oraz modowego. Jedna firma osiągnęła drugi poziom dojrzałości, dwie trzeci, a jedna piąty.

2.3. Dyskusja modeli dojrzałości procesowej

Bazując na systematycznym przeglądzie literatury dotyczącej modeli dojrzałości procesowej zorientowanych na rozwój produktu, można zauważyć wspomniany wcześniej w rozdziale pierwszym brak systematyzacji w stosowaniu pojęć. Modele dojrzałości związane z rozwojem produktu bywają określane jako modele zarządzania cyklem życia produktu, modele procesów rozwoju nowego produktu, modele rozwoju lub projektowania produktu, a także jako modele innowacyjności. Tę niejednoznaczność widać również w przeglądach modeli przedstawianych w różnych artykułach naukowych. Można wyróżnić następujące nurty:

- **Nurt związany z zarządzaniem cyklem życia produktu (PLM)**, przedstawiony w dziewięciu modelach: BPMM 2, 6, 7, 12, 14, 16, 20, 22, 27). PLM jest rozumiany na różne sposoby w literaturze związanej z modelami dojrzałości. R. S. Batenburg, Helms i Versendaal (2006) określają PLM jako działalność polegającą na zarządzaniu produktami firmy na każdym etapie cyklu życia, od wczesnej koncepcji po ostateczną utylizację lub recykling produktu. Jednak ich model dojrzałości koncentruje się na PLM jako programie komputerowym wspomagającym proces rozwoju produktu, ale jednocześnie uwzględniając konieczność dojrzałości procesów biznesowych wokół zarządzania cyklem życia produktu. Saaksvuori i Immonen (2008) nazywają PLM koncepcją zarządzania i rozwoju produktów oraz związanych z nimi informacji. Poza procesem rozwoju produktu i marketingiem produktowym, uwzględniają także proces realizacji zamówień i dostaw (*order-delivery process*). Autorzy dodają, że PLM odnosi się również do systemów informatycznych wspierających zarządzanie cyklem życia produktu oraz zarządzanie

danymi związanymi z produktem. Vezzetti, Alemanni i Morelli (2017) postrzegają PLM typowo jako system informatyczny, którego wdrożenie w procesie NPD analizują, uwzględniając dwa powyżej wymienione modele. Pels i Simons (2008) uważają PLM za strategię maksymalizacji wartości oferty produktowej poprzez elastyczne reagowanie na indywidualne potrzeby klientów, wychodząc poza definicję samego oprogramowania. Walton, Tomovic i Grieves (2013) definiują PLM jako zintegrowane, oparte na informacji podejście, które obejmuje ludzi, procesy (lub praktyki) oraz technologie. Ich celem jest integracja informacji na wszystkich etapach cyklu życia produktu, od pomysłu na produkt, przez projektowanie, produkcję, dystrybucję, wsparcie, aż po wycofanie produktu z użytkowania.

- **Nurt związany w największym stopniu z procesem rozwoju** (najczęściej nowego) produktu (w sześciu modelach BPMM: 3, 4, 9, 11, 15, 21). Cztery z sześciu modeli sklasyfikowanych w tej kategorii koncentrują się na identyfikacji najlepszych praktyk i aktywności wykonywanych podczas procesu rozwoju produktu. Do tej kategorii zaliczono również model CMM-IPD (Wei i in., 2013), który przedstawia model dojrzałości dla rozwoju produktów przemysłowych, oraz model CAI-NPD (Hüsig, 2011), który łączy dojrzałość procesu rozwoju nowego produktu z dojrzałością komputerowego wspomagania innowacyjności.
- **Nurt związany z innowacyjnością i perspektywą włączenia innowacji w proces rozwoju produktu** (w sześciu modelach BPMM: 1, 8, 13, 23, 24, 26). Autorzy podejmują temat innowacyjności w procesie rozwoju produktu na różne sposoby. Oliveira i Kaminski (2012) definiują 45 czynników innowacyjności technologicznej wpływających na proces rozwoju produktu. Z kolei Mattei i in. (2019) dzielą model innowacji dla rozwoju nowego produktu na przestrzeń strategiczną i operacyjną. Demir (2018) opracował model zarządzania strategicznego dla innowacji, podkreślając, że zarządzanie strategiczne koncentruje się na dostarczaniu radykalnie nowego produktu lub usługi na nowy rynek. Wieder, Le Dain i Blanco (2009) zbadali wprowadzenie innowacji w proces rozwoju produktu z perspektywy zwinności tego procesu. Sharma (2005) zaprezentował model łączący innowacyjność, rozwój produktu i współpracę, a Rutkowski (2017) opracował model, który łączy dojrzałość procesu innowacji i wprowadzenia nowego produktu na

rynek z dojrzałością sieci relacji, stanowiącej przestrzeń funkcjonowania zespołu odpowiedzialnego za proces rozwoju nowego produktu.

- **Nurt związany z eko – projektowaniem i zrównoważonym rozwojem w procesie rozwoju produktu** (reprezentowany przez cztery modele: BPMM 17, 18, 19, 28). Wszystkie cztery modele koncentrują się w największym stopniu na etapie projektowania produktu.
- **Inne** (3 modele: BPMM 5, 10, 25). W tej kategorii sklasyfikowano modele OMG-BPMM oraz CMMI-DEV 1.3, a także model Exnera, Baldera i Starka (2018), który reprezentuje dojrzałość systemów produktowo – usługowych, podejścia skoncentrowanego na dostarczaniu kompleksowych rozwiązań, a nie pojedynczych produktów lub usług.

Niektóre modele można przypisać do więcej niż jednej kategorii. Na przykład modele Hüsiga (2011) czy Wiedera, Le Daina i Blanco (2009) można przypisać zarówno do nurtu związanego z rozwojem nowego produktu, jak i do nurtu związanego z innowacyjnością, a wskazane modele PLM opisują częściowo proces rozwoju nowego produktu. Modele zostały zaklasyfikowane do dominującego nurtu, który, według Autora pracy, w największym stopniu odpowiada ich charakterystyce.

Kolejnym istotnym aspektem była metodologia. W wielu modelach widoczne są braki metodologiczne. Pierwszą kwestią jest brak informacji o źródłach danych wykorzystanych do budowy modelu. W artykułach najczęściej brakuje przeglądu literatury (nie tylko szczegółowych kroków, ale samego przeprowadzenia przeglądu). Na przykład w modelu R. S. Batenburga, Helmsa i Versendaala (2006) brak jest informacji, w jaki sposób autorzy pozyskali zagadnienia użyte do budowy kwestionariusza. Podobny problem występuje w modelu Pfenninga i in. (2020), gdzie autorzy przedstawili model zawierający 50 zdolności, lecz nie wyjaśnili, w jaki sposób zdolności te zostały zidentyfikowane. W modelu Sharmy (2005) wprowadzono sześciostopniowy model dojrzałości PLM, określając go jako typowy dla sektora produkcyjnego, jednak nie wskazuje źródła tego modelu. Następnie zasugerowano, że opracowany model CPI można zmapować na model dojrzałości PLM, ale nie opisuje, w jaki sposób przeprowadzić to mapowanie. W modelu Kärkkäinenena, Pelsa i Silventoinena (2012), autorzy, dodając wymiar kliencki, podają kilka źródeł, jednak nie przeprowadzają przeglądu literatury.

Drugą kwestią jest brak możliwości odtworzenia badań. Autorzy, mimo przygotowania kwestionariuszy lub list praktyk, często nie podają ich w pełni, co uniemożliwia ponowne wykorzystanie (np. w BPMM 8, 9, 11, 12, 14, 15, 18, 22, 25, 26, 27). W modelu Paavela, Karjusta i Majaka (2017), przykładowe pytania z kwestionariusza zawierają pytania otwarte, co budzi wątpliwości dotyczące porównywalności wyników między różnymi organizacjami. Exner, Balder i Stark (2018) przygotowali narzędzie internetowe (określane przez Beckera, Knackstedta i Pöppelbußa (2009) jako dodana wartość modelu), lecz link do narzędzia nie działa. Czasami problemem jest stopień uogólnienia lub skomplikowania modelu. Modele CMMI i OMG-BPMM, uwzględnione w przeglądzie, zostały krótko omówione w poprzednim rozdziale. Chociaż modele CMMI-DEV 1.3 i OMG-BPMM są ukierunkowane na rozwój produktów i usług, wciąż są modelami bardzo ogólnymi i jednocześnie skomplikowanymi (krytyka obu modeli została omówiona w poprzednim rozdziale).

Kolejną kwestią, powiązaną z powyższymi, jest brak teoretycznego fundamentu. Większość autorów nie odnosi się do konkretnej metodologii badań w zakresie tworzenia modeli dojrzałości. Na przykład, jedynym modelem opartym na wcześniej wspomnianej pracy De Bruin i in. (2005) był model zaprezentowany przez Rossi i Terziego (2017). Model ten wyróżnia się bazowaniem na walidowanym modelu najlepszych praktyk w rozwoju produktów, przedstawiając wszystkie praktyki w artykule. Dodatkowo, jedną z najlepszych praktyk w rozwoju produktów w tym modelu jest wdrożenie systemu PLM, podczas gdy niektóre modele z przeglądu koncentrują się wyłącznie na wdrożeniu systemu PLM, a procesy rozwoju produktów traktują jako drugorzędne.

W poprzednim rozdziale wspomniano krytykę Röglingera, Pöppelbußa i Beckera (2012) dotyczącą nadmiernej liczby modeli. Warto jednak zauważyć, że nie wszystkie badania dotyczące dojrzałości rozwoju produktu wiązały się z opracowaniem nowego modelu. Vezzetti, Alemanni i Morelli (2017) oraz Pels i Simons (2008) wykorzystali w swoich badaniach model R. S. Batenburga, Helmsa i Versendaala (2006), wprowadzając w nim modyfikacje lub rozbudowując go. Kärkkäinen, Pels i Silventoinen (2012), bazując na modelu R. S. Batenburga, Helmsa i Versendaala (2006), zaproponowali nowy wymiar kliencki dla modeli PLM. Z kolei Paavel, Karjust i Majak (2017) połączyli modele Saaksvuoriego i Immonena (2008) i R. S. Batenburga, Helmsa i Versendaala (2006) wykorzystując strukturę poziomów z jednego modelu i wymiary z drugiego. To pokazuje, że nie zawsze konieczne jest opracowanie nowego modelu od podstaw, jeśli istnieje

już dostępny w literaturze model spełniający dane potrzeby. Można także wybrać istniejący model i go rozbudować lub połączyć kilka modeli w jeden. Problemem przy analizie dużej liczby modeli jest jednak, jak wcześniej wspomniano, brak przeglądu literatury, który mógłby skierować autorów do już istniejących modeli.

Ze względu na różne nurty, w jakich opracowywane są modele, trudno jest bezpośrednio porównać poziomy i wymiary pomiędzy nimi. Liczba poziomów w modelach wahała się od 3 do 6, przy czym najczęściej występowało pięć poziomów (w 16 modelach). W modelach pięcio- i sześciopoziomowych często pojawiał się poziom zerowy, oznaczający brak działań w danym obszarze. Oznacza to, że faktycznie w modelach pięciopoziomowych ostatnim poziomem dojrzałości był poziom 4, a w sześciopoziomowych – poziom 5. Porównanie wymiarów między modelami jest jeszcze trudniejsze. Niektóre modele stosują wielostopniowy podział (np. najpierw na obszary lub przestrzenie, a następnie na kolejne elementy modelu), co sprawia, że trudno określić, które części porównywać między modelami. Nazewnictwo elementów również jest różne (czynniki, wymiary, praktyki, opisy, obszary procesowe, przestrzenie, komponenty, fazy i inne). Często autorzy nie odnoszą się bezpośrednio do tych elementów, a można je rozpoznać jedynie na podstawie przygotowanych tabel. Liczba wymiarów w modelach waha się od 0 nawet do 30, przy czym średnia dla wszystkich 28 modeli wynosi około 8 wymiarów. Porównując wymiary między modelami, można zauważyć powtarzające się motywy:

- **Ludzie i kompetencje** – wymiar skupiający się na ludziach, ich kulturze, umiejętnościach, rolach, strukturach zespołów oraz jednostkach organizacyjnych (np. w BPMM 1, 2, 3, 6, 8, 9, 12, 15, 20, 21, 22, 24, 26, 27).
- **Procesy i organizacja** – wymiar koncentrujący się na strukturze organizacji i procesów, sposobie realizacji działań i ich kolejności, zasadach, które są przestrzegane, oraz uzyskiwanych wynikach (np. w BPMM 1, 2, 3, 6, 9, 12, 13, 15, 17, 20, 21, 22, 24, 25, 26, 27).
- **Dane i technologia** (w tym różnego rodzaju narzędzia i techniki) – wymiar skupiający się na treści, strukturze, relacjach i zasadach biznesowych dotyczących danych używanych w procesach biznesowych. Uwzględnia także przekształcanie danych w informacje i wiedzę, które firma może wykorzystać, a także infrastrukturę sprzętową, oprogramowanie i infrastrukturę komunikacyjną. Obejmuje również narzędzia, techniki, metody i aplikacje

wspierające rozwój produktu (np. w BPMM 1, 2, 6, 12, 13, 15, 17, 18, 20, 21, 22, 26, 27, 28).

- **Strategia i regulacje** – wymiar zajmujący się wizją i strategią firmy (w tym strategią innowacji), zarządzaniem portfelem projektów, ryzykiem i finansami (np. w BPMM 2, 3, 6, 8, 9, 12, 13, 17, 18, 20, 21, 22, 24, 25, 26).
- **Współpraca z klientem i współpraca zewnętrzna** – wymiar skupiający się na relacjach z klientem (np. włączenie klienta w proces rozwoju produktu) oraz na relacjach z otoczeniem zewnętrznym, np. z dostawcami (np. w BPMM 12, 13, 14, 18, 25, 26, 27, 28).
- **Metryki i ocena wydajności** – wymiar koncentrujący się na zestawie wskaźników i miar wydajności (np. w BPMM 3, 9, 12, 16, 24).

Analizując powyższe wymiary, można zauważyć kilka istotnych kwestii. Po pierwsze, wymiary powtarzają się między modelami, mimo że modele pochodzą z różnych nurtów (PLM, eko-projektowanie, innowacje, NPD, inne). Po drugie, dokładne przypisanie danego obszaru do konkretnej kategorii jest wymagające – wymiar związany ze współpracą z klientem i współpracą zewnętrzną mógłby być przypisany do wymiaru ludzi i kompetencji (w niektórych modelach ludzie i współpraca to jeden wymiar) albo do strategii (np. strategia dotycząca współpracy zewnętrznej) albo do procesów (włączanie klienta w proces rozwoju). Podobnie wymiar związany z metrykami i oceną wydajności mógłby być częścią wymiaru strategicznego (strategiczne określenie kluczowych wskaźników), a wymiar danych i technologii można by podzielić na kategorie dotyczące danych i narzędzi. Po trzecie, analiza ta jest przeprowadzana na poziomie wymiarów, a te są zbiorami praktyk. Nie wszystkie praktyki są dostępne w każdym modelu, ale np. w modelu najlepszych praktyk opracowanym przez Rossi i Terziego (2017), na podstawie którego powstał ich model dojrzałości, można zauważyć praktyki związane z eko-projektowaniem (w wymiarze Metody), użyciem programów i narzędzi (np. CAD, ERP, SCM), a także procesami, strategią, kompetencjami czy współpracą z klientem. Część tych praktyk, opisanych innymi słowami lub inaczej przyporządkowanych, można znaleźć także w innych modelach (np. u Oliveiry i Kaminskiego (2012)). Z tego powodu istnieje możliwość (do pewnego stopnia) porównania wyników organizacji ocenianych różnymi modelami.

Ponad połowa analizowanych artykułów wskazywała na przeprowadzenie badań empirycznych. Badano organizacje z różnych sektorów, takich jak transport, chemia, moda, motoryzacja,

produkcja czy przemysł ogólnie. Połowa autorów, którzy przeprowadzili badania empiryczne, skupiła się na jednej wybranej organizacji. Na tle innych wyróżniają się badania, w których przebadano 103 (Rossi i Terzi, 2017), 189 (Pfenning i in., 2020) oraz 250 (Savino i in., 2012) organizacji. Organizacje najczęściej znajdowały się na początkowym (pierwszym lub drugim) poziomie dojrzałości w skali pięciostopniowej. Zaskakująco wysoką dojrzałość osiągały organizacje przebadane przez Savino, Mazzę i Ouzrouta (2012). Spośród 250 organizacji większość znajdowała się na poziomie 3 lub 4 (w skali pięciostopniowej) we wszystkich 15 komponentach modelu. Podobnie wysokie wyniki osiągnęła organizacja badana przez Exnera, Baldera i Starka (2018). Osiągnięcie przez organizacje najwyższych poziomów dojrzałości rodzi pytanie, czy kryteria potrzebne do spełnienia wymagań najwyższego poziomu dojrzałości nie były zbyt niskie. W niektórych badaniach najwyższy poziom dojrzałości jest zarezerwowany dla liderów lub pionierów w danym sektorze. Interesujące poznawczo byłoby badanie porównujące kryteria osiągania poziomów w różnych modelach dojrzałości (np. czy poziom 5 w jednym modelu nie odpowiada poziomowi 3 w innym modelu). Potencjalnego kierunku przyszłych badań dostarczyły również badania Nicholasa i Ledwitha (2006), którzy zapytali ekspertów, czy duże i małe firmy mogą być oceniane przy użyciu tego samego modelu oraz czy małe firmy powinny dążyć do osiągnięcia najwyższego poziomu dojrzałości, czy też celować w niższy poziom. Opinie respondentów były podzielone, jeśli chodzi o zastosowanie tego samego modelu dla małych i dużych firm. Natomiast jedynie jeden respondent był przeciwny dążeniu małych firm do najwyższego poziomu, sugerując, że osiągnięcie tego poziomu nie przyniosłoby proporcjonalnych korzyści w stosunku do nakładów pracy. Warto jednak zauważyć, że grupa ekspertów była mało liczna (sześciu respondentów). Sposób wyliczania poziomu dojrzałości także różnił się między modelami. W modelach dojrzałości organizacji (niekoniecznie związanych z rozwojem produktu) za poziom dojrzałości przyjmowany jest najniższy poziom osiągnięty w różnych wymiarach. W modelu Demira (2018) poziom ten jest wyliczany jako średnia z wymiarów, zaokrąglana do najbliższej liczby całkowitej.

Siedem modeli można uznać za częściowo preskryptywne. Żaden z nich jednak nie spełnia w pełni wymagań dla modeli preskryptywnych według Röglingera, Pöppelbußa i Beckera (2012). Modele te skupiają się głównie na określonych czynnikach doskonalenia lub rekomendowanych działaniach, jednak często brakuje alternatywnych ścieżek osiągania wyższego poziomu dojrzałości czy analizy kosztów i korzyści. Amaral i Rozenfeld (2007) poza modelem dojrzałości

przedstawili także model zarządzania zmianą, wspierający definiowanie i wdrażanie projektów zmian. Exner, Balder i Stark (2018) zaproponowali rekomendowane działania, lecz badania nad użytecznością modelu wykazały, że zbyt ogólnikowe rekomendacje były głównym powodem zaniżonej oceny. To wskazuje na potencjał do stworzenia modelu o większej szczegółowości w części preskryptywnej.

2.4. Wyniki przeglądu literatury dla modeli dojrzałości AI

Poniżej przedstawiono wyniki systematycznego przeglądu literatury dotyczącego modeli dojrzałości AI. Piętnaście zidentyfikowanych modeli zostało sklasyfikowanych i przedstawionych w Tabeli 6. W tabeli zawarto liczbę oraz nazwy poziomów i „elementów” modelu. Ze względu na fakt, że autorzy stosują różne określenia dla elementów modelu (takie jak „wymiar”, „element”, „wskaźnik” i inne, lub nie używają ich wcale), wybrano termin „elementy” do opisu tych części modelu (ponownie zdecydowano się na pozostawienie nazw poziomów i elementów w oryginalnej, angielskiej formie ze względu na fakt, iż, zdaniem Autora pracy, lepiej oddają one znaczenie danego poziomu lub elementu). Tabela zawiera również informacje na temat domeny, dla której modele zostały skonstruowane, sugerowanego sposobu oceny dojrzałości według danego modelu, liczby oraz charakterystyki podmiotów badanych (jeśli przeprowadzono badanie) oraz typu modelu (opisowy lub preskryptywny). Piętnaście przeglądanych badań zostało krótko omówionych poniżej w kolejności chronologicznej według roku powstania.

Model dojrzałości sztucznej inteligencji (AI Maturity Model – AIMM) 1: Alsheibani, Cheung i Messom (2019) zaproponowali model, który, zdaniem autora niniejszej rozprawy, był jednym z pierwszych modeli dojrzałości AI w literaturze naukowej. Składa się z pięciu poziomów dojrzałości: *Initial* (Początkowy), *Assessing* (Poddawany ocenie), *Determined* (Określony), *Managed* (Zarządzany), *Optimised* (Zoptymalizowany). Autorzy wykorzystali podejście nauk o projektowaniu (*Design Science Research – DSR*), opisując cztery pierwsze kroki w podejściu Beckera, Knackstedta i Pöppelbußa (2009). W przeglądzie literatury zauważyli, że głównymi modelami dostępnymi w tamtym czasie były modele stworzone przez organizacje (np. Gartner czy Ovum), które jednak nie posiadały teoretycznego fundamentu. Model zawiera cztery elementy: *AI*

Tabela 6. Modele dojrzałości AI.

Autorzy	Nazwa / akronim	Domena	Poziomy	Elementy	Sposób oceny	Badana grupa	Typ modelu
Alsheibani, Cheung i Messom (2019)	Brak	Ogólna	5 (<i>Initial, Assessing, Determined, Managed, Optimised</i>)	4 (<i>AI functions, Data structure, People, Organisational</i>)	Brak	Brak	Opisowy
Yablonsky (2019)	Data-Driven AI Innovation Maturity Framework	Zarządzanie innowacjami	5 (<i>Human Led; Human Led, Machine Supported; Machine Led, Human Supported; Machine Led, Human Governed; Machine Controlled</i>)	4 (<i>Who produces insights, Who decides and how, Who acts based on decision, Advanced Analytics/Big Data Level</i>)	Brak	Brak	Opisowy
Ellefsen i in. (2019)	Brak	Procesy logistyczne	4 (<i>AI Novice; AI Ready; AI Proficient; AI Advanced</i>)	5 (<i>Strategy, Organisation, Data, Technology, Operations</i>)	Kwestionariusz	Cztery firmy z sektora logistyki	Opisowy
Lichtenthaler (2020)	Brak	Ogólna (zarządzanie sztuczną inteligencją)	5 (<i>Initial Intent, Independent Initiative, Interactive Implementation, Interdependent Innovation, Integrated Intelligence</i>) lub 7 (uwzględniając dodatkowo Poziom 0: <i>Isolated Ignorance</i> oraz Poziom +: <i>Intuitive Ingenuity</i>)	3 (<i>Various types of AI, Various types of human intelligence, Meta-intelligence</i>)	Brak	Brak	Opisowy
Fukas i in. (2021)	Auditing AI Maturity Model (A-AIMM)	Firmy audytorskie	5 (<i>Initial, Assessing, Determined, Managed, Optimised</i>)	8 (<i>Technologies, Data, People & Competencies, Organisation & Processes, Strategy & Management, Budget, Products & Services, Ethics & Regulations</i>)	Brak	Brak	Opisowy
Yams i in. (2021)	AI Innovation Maturity Index (AIMI)	Zarządzanie innowacjami	5 (<i>Foundational, Experimenting, Operational, Inquiring, Integrated</i>)	7 (<i>Data, Technologies, Organisation, Strategy, Ecosystems, Mindset, Trustworthy Integrated AI</i>)	Brak	Brak	Opisowy
Holmström (2021)	AI Readiness Framework	Ogólna	5 (<i>None, Low, Moderate, High, Excellent</i>)	4 (<i>Technologies, Goals, Activities, Boundaries</i>)	Kwestionariusz	Firma z sektora ubezpieczeń	Opisowy
Schuster, Waidelich i Volz (2021)	SME focused AIMM	Małe i średnie przedsiębiorstwa	5 (<i>Novice, Explorer, User, Translator, Pioneer</i>)	7 (<i>Culture/mindset, Data, Ethics, Organization, Privacy, Strategy, Technology</i>)	Brak	Brak	Opisowy
W. Chen i in. (2021)	I-AI Maturity Model	Inteligentne systemy produkcyjne i procesy przemysłowe	5 (<i>Planning Level; Specification Level; Integration Level; Optimization Level; Leading Level</i>)	2 (<i>Industry, Artificial Intelligence</i>)	Kwestionariusz	Brak	Częściowo preskryptywny
Schreckenberga i Moroff (2021)	AI Maturity Model for ML application implementation	Ogólna (ukierunkowana na sektor produkcyjny)	4 (<i>AI-new, AI-enabled, AI-experienced, AI-advanced</i>)	5 (<i>Strategy, Organisation & People, Technology, Data, Process</i>)	Brak	Brak	Opisowy
Noymancee, Iewwongcharoen i	AI MM for Government	Organizacje rządowe i sektora publicznego	5 (<i>Rookie Level, Beginner Level, Operational Level, Expert Level, Mastery Level</i>)	4 (<i>Strategy, Organization, Information, Technology</i>)	Brak	Brak	Opisowy

Theeramunkong (2022)	Administration and Service						
Colangelo i in. (2022)	AI MM for Production Planning and Control	Organizacje z sektora produkcyjnego	5 (<i>Initialization Phase, Definition Phase, Preparation Phase, Implementation Phase, Optimization Phase</i>)	5 (<i>General conditions, Data, Production Planning & Control (PPC), Technology, Organization</i>)	Brak	Brak	Opisowy
Das, Bala i Mishra (2023)	Trustworthy AI System MM (TAS-MM)	Ogólna	4 (<i>Level 0, Level 1, Level 2, Level 3</i>)	4 (<i>Auditability, Explainability, Fairness, Safety</i>)	Brak	Brak	Opisowy
Sonntag i in. (2024)	SMMT Maturity Model	Organizacje z sektora produkcyjnego	5 (<i>Initial, Experimental, Practicing, Integrated, Transformed</i>)	5 (<i>Culture & Competencies, Strategy, Data, Organization & Processes, Technology</i>)	Kwestionariusz	Trzy dywizje jednej firmy z sektora produkcyjnego	Częściowo preskryptywny
Chukhlomin (2024)	EMERALD-GenAI-CMM-OAL	Kształcenie online i kształcenie dorosłych	5 (<i>Pre-generative AI Level, Foundational Level, Intermediate Level, Advanced Level, Expert Level</i>)	5 (<i>(E) External (workplace) environments and Expectations for graduate capabilities, (M) Technological Means, tools, and platforms, (E) Essential tasks and use cases, (RA) Required Abilities, skills, and competencies, (LD) Learning Designs and strategies</i>)	Brak	Brak	Opisowy

Źródło: opracowanie własne.

Functions (Funkcje sztucznej inteligencji), *Data structure* (Struktura danych), *People* (Ludzie) oraz *Organisational* (Organizacyjne). Autorzy modelu wyszukali te elementy w dostępnej literaturze jako kluczowe czynniki przy wprowadzaniu rozwiązań opartych na sztucznej inteligencji. W pracy podkreślono również konieczność walidacji modelu z ekspertami z zakresu IT i sztucznej inteligencji, jednak brak szczegółów dotyczących realizacji tego zadania.

AIMM 2: Yablonsky (2019) zaproponował model dojrzałości innowacji przedsiębiorstw opartych na rozwiązaniach AI, który wykorzystuje wcześniejszy model automatyzacji AI oraz model wartości AI/Big Data/Zaawansowanej Analityki. Model ten wspiera strategiczne planowanie innowacji oraz podejmowanie decyzji inwestycyjnych w zakresie automatyzacji opartej na AI. Model koncentruje się na relacjach człowiek – maszyna opartych na danych oraz wdrażaniu AI i składa się z pięciu poziomów: *Human Led* (Prowadzony przez człowieka); *Human Led, Machine Supported* (Prowadzony przez człowieka, wspierany przez maszynę); *Machine Led, Human Supported* (Prowadzony przez maszynę, wspierany przez człowieka); *Machine Led, Human Governed* (Prowadzony przez maszynę, zarządzany (kontrolowany) przez człowieka); *Machine Controlled* (Kontrolowany przez maszynę). Budowa modelu oparta na wcześniejszych modelach automatyzacji i wartości bazuje na badaniach dotyczących tworzenia taksonomii, zapożyczonych z pracy Nickersona, Varshney i Muntermanna (2013). Przeprowadzono przegląd literatury oraz wywiady w celu walidacji elementów modelu. Model zawiera cztery wymiary: *Who produces insights* (Kto tworzy wgląd), *Who decides and how* (Kto decyduje i w jaki sposób), *Who acts based on decision* (Kto działa w oparciu o decyzję), *Advanced Analytics/Big Data Level* (Poziom zaawansowanej analityki i Big Data). Brak jednak metodologii oceny, która pozwoliłaby na jednoznaczne określenie poziomu dojrzałości w tym modelu.

AIMM 3: Ellefsen i in. (2019) zaprezentowali model oceny gotowości AI w firmach logistycznych. Do oceny wykorzystano cztery poziomy dojrzałości AI dla dostawców usług komunikacyjnych opracowane przez firmę Ovum: *AI Novice* (Nowicjusz w AI), *AI Ready* (Gotowy na AI), *AI Proficient* (Biegly w AI), *AI Advanced* (Zaawansowany w AI). Model posiada również pięć wymiarów: *Strategy* (Strategia), *Organisation* (Organizacja), *Data* (Dane), *Technology* (Technologia), *Operations* (Operacje). Autorzy nie opisują tych wymiarów szczegółowo – ich definicje można znaleźć w oryginalnym artykule organizacji Ovum. W artykule zamieszczono jedynie krótki, jednozdaniowy opis poziomów. Autorzy opracowali narzędzie badawcze (listę

pytań) mające na celu zrozumienie i ocenę obecnej sytuacji w zakresie wdrożeń Logistyki 4.0 oraz AI w firmach logistycznych. Przeprowadzili także badania empiryczne, których wyniki ujawniły, że wszystkie cztery badane firmy wciąż znajdują się na pierwszym poziomie dojrzałości.

AIMM 4: Lichtenthaler (2020) zaproponował model opisujący pięć poziomów dojrzałości w zarządzaniu sztuczną inteligencją w organizacji: *Initial Intent* (Początkowa intencja), *Independent Initiative* (Niezależna inicjatywa), *Interactive Implementation* (Interaktywne wdrożenie), *Interdependent Innovation* (Współzależna innowacja), *Integrated Intelligence* (Zintegrowana inteligencja). Dodatkowo wprowadził dwa dodatkowe poziomy – wstępny poziom 0: *Isolated Ignorance* (Izolowana ignorancja), czyli brak aktywności w zarządzaniu sztuczną inteligencją oraz poziom +: *Intuitive Ingenuity* (Intuicyjna pomysłowość), nawiązujący do poziomu w przyszłości, z systemami samoświadomości, gdzie rozwiązania sztucznej inteligencji wykonywałyby większą część czynności, które nadal wymagają unikalnych ludzkich umiejętności. Model został zbudowany w oparciu o koncepcję inteligencji w ocenie wydajności organizacji. Brakuje jednak szczegółowego opisu procesu budowy modelu, przeglądu literatury istniejących modeli oraz walidacji. Stwierdzono, że działania związane z AI stanowią część architektury inteligencji organizacji, składającej się z różnych typów AI, różnych rodzajów inteligencji ludzkiej oraz meta-inteligencji. Meta-inteligencja pełni funkcję integratora, odnawiającego i łączącego różne typy inteligencji oraz ich interfejsy. Choć autor modelu nie klasyfikuje tych działań jako wymiary ani elementy modelu, są one istotne w opisie poziomów modelu, dlatego zostały uznane w niniejszej pracy za elementy składowe modelu. Brakuje walidacji modelu, struktury oceny dojrzałości organizacji według tego modelu oraz badań empirycznych.

AIMM 5: Fukas i in. (2021) zaproponowali model, który ocenia dojrzałość zarządzania sztuczną inteligencją w firmach audytorskich. Obejmuje pięć poziomów dojrzałości: *Initial* (Początkowy), *Assessing* (Poddawany ocenie), *Determined* (Określony), *Managed* (Zarządzany), *Optimised* (Zoptymalizowany). Wymiary modelu obejmują: *Technologies* (Technologie), *Data* (Dane), *People & Competencies* (Ludzi i kompetencje), *Organisation & Processes* (Organizację i procesy), *Strategy & Management* (Strategię i zarządzanie), *Budget* (Budżet), *Products & Services* (Produkty i usługi) oraz *Ethics & Regulations* (Etykę i regulacje). Model wykorzystuje metodologię DSR, opierając się na podejściu Beckera, Knackstedta i Pöppelbußa (2009), szczegółowo opisując kroki

powstawania modelu. Model został także poddany walidacji przez ekspertów, brak jest jednak badań empirycznych i informacji, w jaki sposób przeprowadzić takie badania.

AIMM 6: Yams i in. (2021) zbudowali model dojrzałości AI, aby sprawdzić, jak rozwiązania AI mogą zmienić i wesprzeć różne aspekty zarządzania innowacją. Model składa się z pięciu poziomów: *Foundational* (Fundamentalny), *Experimenting* (Eksperymentalny), *Operational* (Operacyjny), *Inquiring* (Dociekliwy/Pytający), *Integrated* (Zintegrowany). Autorzy modelu przeprowadzili przegląd literatury i nie znaleźli modeli opisujących bezpośrednio dojrzałość AI, stąd w budowaniu modelu wspierali się pracami praktyków. Opisują wybranie podejścia top-down, bazując na pracy De Bruin i in. (2005), uwzględniając walidację modelu przez czternastu ekspertów. Model zawiera siedem wymiarów: *Data* (Dane), *Technologies* (Technologie), *Organisation* (Organizacja), *Strategy* (Strategia), *Ecosystems* (Ekosystemy), *Mindset* (Sposób myślenia) i *Trustworthy Integrated AI* (Wiarygodna AI). Brak jest badań empirycznych ani sposobu oceny organizacji na podstawie zaprezentowanego modelu.

AIMM 7: Holmström (2021) zbudował model gotowości organizacji do wykorzystania rozwiązań sztucznej inteligencji. Model składa się z pięciu poziomów: *None* (Brak), *Low* (Niski), *Moderate* (Średni), *High* (Wysoki), *Excellent* (Doskonały). Zawiera cztery wymiary – *Technologies* (Technologie), *Activities* (Aktywności), *Boundaries* (Granice/Ograniczenia) oraz *Goals* (Cele), a także jednostronicowy scenariusz z dwoma pytaniami do każdego z wymiarów. Brak przeglądu literatury dotyczącej aktualnych modeli. Autor modelu przebadł kwestionariuszem firmę z sektora ubezpieczeń i zawarł odpowiedzi firmy w artykule. Brak jest jednoznacznej informacji o metodologii budowania modelu – wspomniano jedynie, po przeprowadzaniu badań empirycznych, o trzech wymaganiach dobrego modelu, bazując na pracy Crossana, Lane'a i White'a (1999) – identyfikacja zjawiska będącego przedmiotem zainteresowania, określenie kluczowych założeń leżących u podstaw modelu, opisanie relacji między elementami modelu – potwierdzając, że zbudowany model spełnia te założenia.

AIMM 8: Schuster, Waidelich i Volz (2021) zaproponowali model dojrzałości skupiający się na małych i średnich przedsiębiorstwach. Autorzy również zaproponowali pięć poziomów dojrzałości: *Novice* (Nowicjusz), *Explorer* (Odkrywca), *User* (Użytkownik), *Translator* (Tłumacz), *Pioneer* (Pionier). Model został zbudowany za pomocą podejścia DSR, przedstawionego przez Beckera, Knackstedta i Pöppelbußa (2009), opierając się na czterech

pierwszych jego krokach, nie poddając modelu np. walidacji przez ekspertów ani badaniom empirycznym. Po porównaniu obecnych modeli autorzy skupiają się na trzech modelach (oznaczonych wcześniej w tej pracy jako AIMM 1, AIMM 6 oraz AIMM 7), uznając je za najbardziej holistyczne. Model składa się z siedmiu wymiarów: *Culture / mindset* (Kultura / sposób myślenia), *Data* (Dane), *Ethics* (Etyka), *Organization* (Organizacja), *Privacy* (Prywatność), *Strategy* (Strategia), *Technology* (Technologia).

AIMM 9: W. Chen i in. (2021) zaproponowali model dojrzałości przemysłowej AI, który ma pomóc firmom produkcyjnym ocenić ich postępy w drodze do wdrażania przemysłowej AI i wskazać kierunki przyszłych ulepszeń. Model zawiera pięć poziomów dojrzałości: *Planning Level* (Poziom planowania), *Specification Level* (Poziom specyfikacji), *Integration Level* (Poziom integracji), *Optimization Level* (Poziom optymalizacji), *Leading Level* (Poziom kierowania / przywództwa). Model zawiera także dwa wymiary: *Industry* (Przemysł) i *AI* (Sztuczna inteligencja), a także 12 wskaźników pierwszego rodzaju i 35 wskaźników drugiego rodzaju, które wyjaśniają koncepty i komponenty modelu. Autorzy modelu bazowali częściowo na wytycznych Beckera, Knackstedta i Pöppelbußa (2009), łącząc je z wytycznymi budowy modelu według Felcha i Asdeckera (2020). Model oferuje bardzo szczegółową dokumentację, uwzględniając kwestionariusz z pytaniami. Jest to jedyny model w zestawieniu, który nosi znamiona modelu preskryptywnego. Autorzy modelu odwołują się bezpośrednio do wytycznych Röglingera, Pöppelbußa i Beckera (2012) dotyczących budowania modeli preskryptywnych, sugerując, że ich model dostarcza organizacjom referencyjne ścieżki i strategie kalkulacji decyzji na ich drodze do inteligentnej produkcji. W artykule brak jest badań empirycznych.

AIMM 10: Schreckenberga i Moroff (2021) przedstawili model dojrzałości AI, który połączyli z procedurą rozwoju i implementacji aplikacji uczenia maszynowego. Dojrzałość organizacji w wykorzystaniu sztucznej inteligencji jest oceniana przed rozpoczęciem projektu rozwoju aplikacji. Autorzy bazują na podejściu Beckera, Knackstedta i Pöppelbußa (2009) podczas tworzenia modelu, przeprowadzając przegląd literatury, jednak nie omawiają procesu przeglądu, a jedynie przedstawiają wnioski. Model składa się z pięciu wymiarów: *Strategy* (Strategia), *Organisation & People* (Organizacja i ludzie), *Technology* (Technologia), *Data* (Dane) i *Process* (Proces) oraz z pięciu poziomów dojrzałości: *AI-new* (Nowy w AI), *AI-enabled* (Obsługujący AI), *AI-experienced*

(Doświadczony w AI), *AI-advanced* (Zaawansowany w AI). Autorzy wspominają o kwestionariuszu, ale nie został on zamieszczony w artykule. Brak jest także badań empirycznych.

AIMM 11: Noymanee, Iewwongcharoen i Theeramunkong (2022) zaprezentowali model dojrzałości AI dla organizacji administracji rządowej i usług publicznych. Mimo że autorzy przy budowie modelu nie odwołują się do tego wprost, to przyjęto podejście DSR zaadaptowane przez Beckera, Knackstedta i Pöppelbußa (2009). Autorzy modelu przeprowadzili jednak przegląd literatury dla modeli dotyczących zarządzania danymi i modeli analityki biznesowej (*Business Intelligence – BI*). Model składa się z czterech wymiarów: *Strategy* (Strategia), *Organization* (Organizacja), *Information* (Informacja), *Technology* (Technologia). Model zawiera także pięć poziomów dojrzałości: *Rookie Level* (Poziom debiutancki), *Beginner Level* (Poziom początkujący), *Operational Level* (Poziom operacyjny), *Expert Level* (Poziom ekspercki), *Mastery Level* (Poziom mistrzowski). Brak jest sposobu oceny dojrzałości organizacji oraz badań empirycznych.

AIMM 12: Colangelo i in. (2022) przedstawili model dojrzałości AI dedykowany procesowi kontroli i planowaniu produkcji. Autorzy bazowali na podejściu Beckera, Knackstedta i Pöppelbußa (2009), przeprowadzając przegląd literatury modeli oraz ankiety z 18 firmami z Niemiec i Węgier, aby poznać zdanie ekspertów na temat tego, jak rozwiązania AI mogą wspomóc kontrolę i planowanie produkcji. Wyniki pomogły autorom zbudować model złożony z pięciu wymiarów (podzielonych na łącznie osiemnaście elementów): *General conditions* (Warunki ogólne), *Data* (Dane), *Production Planning & Control* (Kontrola i planowanie produkcji), *Technology* (Technologia), *Organization* (Organizacja) oraz pięciu poziomów dojrzałości: *Initialization Phase* (Faza inicjalizacji), *Definition Phase* (Faza definicji), *Preparation Phase* (Faza przygotowania), *Implementation Phase* (Faza implementacji) oraz *Optimization Phase* (Faza optymalizacji). Autorzy nie wskazali sposobu oceny dojrzałości dla modelu, brak jest również badań empirycznych.

AIMM 13: Das, Bala i Mishra (2023) zaproponowali model dojrzałości rozwoju systemów AI, który pomoże firmom ocenić, na jakim etapie znajdują się w procesie tworzenia godnej zaufania platformy AI. Autorzy modelu bazowali na podejściu DSR, na podstawie pracy Peffersa i in. (2006), którzy spełnili wszystkie wymagania DSR zaproponowane przez Hevnera i in. (2004). Model składa się z czterech poziomów dojrzałości: *Level 0* (Poziom 0), *Level 1* (Poziom 1), *Level 2* (Poziom 2), *Level 3* (Poziom 3), przy czym dwa pierwsze poziomy to poziomy zaufania

początkowego (*initial trust*), a dwa kolejne to poziomy zaufania ciągłego, trwałego (*continuous trust*). Model zawiera także cztery wymiary: *Auditability* (Możliwość kontroli), *Explainability* (Możliwość wyjaśnienia), *Fairness* (Uczciwość), *Safety* (Bezpieczeństwo). Model został poddany walidacji przez ekspertów, lecz brak jest sposobu oceny dojrzałości na podstawie tego modelu i badań empirycznych.

AIMM 14: Sonntag i in. (2024) zaproponowali model dojrzałości w zakresie zdolności wdrażania sztucznej inteligencji w firmach produkcyjnych. Autorzy bazowali na podejściu DSR, zaadaptowanym przez Beckera, Knackstedta i Pöppelbußa (2009), przeprowadzając przegląd literatury obecnych modeli, wybierając elementy modelu z literatury, walidując model i wykonując badania empiryczne. Model składa się z pięciu wymiarów: *Culture & Competencies* (Kultura i kompetencje), *Strategy* (Strategia), *Data* (Dane), *Organization & Processes* (Organizacja i procesy), *Technology* (Technologia) oraz pięciu poziomów: *Initial* (Początkowy), *Experimental* (Eksperymentalny), *Practicing* (Praktykujący), *Integrated* (Zintegrowany), *Transformed* (Przekształcony / Poddany transformacji). Każdy z wymiarów jest dodatkowo podzielony na pięć do siedmiu wskaźników (łącznie 29 wskaźników). Autorzy wprowadzają dodatkowo system wag dla wskaźników, wskazując, że nie każdy wskaźnik jest równie ważny w kontekście wprowadzenia rozwiązań AI z sukcesem. Badania empiryczne zostały przeprowadzone na trzech różnych dywizjach jednej firmy z sektora produkcyjnego – autorzy przeprowadzali wywiady z ekspertami z danych dywizji, bazując na przygotowanym kwestionariuszu z listą pytań, aby uzyskać odpowiedzi dotyczące każdego ze wskaźników.

AIMM 15: Chukhlomin (2024) zaproponował model mający pomóc instytucjom edukacyjnym w ocenie i poprawie ich zdolności do wykorzystania generatywnej sztucznej inteligencji w kształceniu online i kształceniu dorosłych. Jest to jedyny model dojrzałości znaleziony w literaturze, skupiający się na dojrzałości w wykorzystaniu generatywnej sztucznej inteligencji, a nie sztucznej inteligencji ogólnie. Model ten obejmuje pięć kluczowych obszarów procesowych: *External (workplace) environments and Expectations for graduate capabilities* (Środowisko zewnętrzne i oczekiwania dotyczące umiejętności absolwentów), *Technological Means, tools, and platforms* (Środki, narzędzia i platformy technologiczne), *Essential tasks and use cases* (Podstawowe zadania i przypadki użycia), *Required Abilities, skills, and competencies* (Wymagane zdolności, umiejętności i kompetencje), *Learning Designs and strategies* (Projekty i strategie

uczenia się). Autor modelu jest świadomy istnienia różnych modeli dojrzałości AI i uważa, że mogą być one podstawą do zbudowania modelu dotyczącego wykorzystania generatywnej AI, ale nie wspomina o przeprowadzeniu przeglądu literatury. Brak jest także informacji o doborze kluczowych obszarów procesowych (wymiarów modelu). Model proponuje pięć poziomów dojrzałości: *Pre-generative AI Level* (Poziom przed generatywną AI), *Foundational Level* (Poziom podstawowy), *Intermediate Level* (Poziom średniozaawansowany), *Advanced Level* (Poziom zaawansowany), *Expert Level* (Poziom ekspercki).

2.5. Dyskusja modeli dojrzałości AI

Na podstawie systematycznego przeglądu literatury można zauważyć, że modele dojrzałości AI są stosunkowo nowym tematem w literaturze naukowej, ponieważ pierwsze modele zaczęły pojawiać się dopiero na przełomie lat 2018 i 2019, podchodząc do dojrzałości AI z różnych perspektyw, często opierając się na dostępnej wówczas literaturze branżowej. Na przykład firma Microsoft zaproponowała w 2018 roku czteropoziomowy model dojrzałości, podobnie jak firma Ovum (również czteropoziomowy model, wykorzystany przez Ellefsen i in. (2019)) czy firma Gartner w 2019 roku (pięciopoziomowy model dojrzałości). Niektórzy autorzy krytykowali podejście oparte na modelach organizacyjnych, wskazując na brak informacji, czy te modele opierają się na naukowych wytycznych oraz podkreślając niewystarczającą dokumentację i niemożliwość odtworzenia procedury tworzenia modelu (np. Alsheibani, Cheung i Messom (2019) i Schuster, Waidelich i Volz (2021)). Yams i in. (2021) jako jedyni wskazali na wybór podejścia top-down, bazując na pracy De Bruin i in. (2005), uzasadniając ten wybór (słusznie zdaniem Autora niniejszej rozprawy) tym, że jest on zalecany dla nowych dziedzin, gdzie nie jest jasne, co oznacza dojrzałość. Dziewięć z piętnastu modeli w pewnym stopniu opierało się na podejściu nauk o projektowaniu (*Design Science Research – DSR*), korzystając z prac Hevnera i in. (2004) lub Beckera, Knackstedta i Pöppelbußa (2009), którzy rozwinęli podejście DSR dla modeli dojrzałości. Warto wspomnieć, że w przypadku wcześniej omawianych modeli dojrzałości procesu rozwoju produktu jedynie jeden model nawiązywał do fundamentu teoretycznego na podstawie wcześniej przedstawionych podejść (model Rossi i Terziego (2017) – podejście De Bruin i in. (2005)). Modele dojrzałości procesu rozwoju produktu powstawały jednak w większości dużo wcześniej niż modele dojrzałości AI (choć praca Hevnera i in. (2004) została opublikowana już w 2004

roku, a pierwszy z omawianych modeli dojrzałości procesu rozwoju produktu został opublikowany w roku 2005).

Bazując na sposobie, w jaki modele w literaturze są aktualnie budowane, można wyróżnić trzy podejścia:

- Podejście, które można nazwać **pojedynczym** lub **wysokopoziomowym** – jest to model dojrzałości AI dla np. całej organizacji (bez rozróżnienia na typy organizacji (Lichtenthaler, 2020)), wybranej wielkości organizacji (np. małe i średnie przedsiębiorstwa (Schuster i in., 2021)) czy wybranego typu / sektora, z którego pochodzi organizacja (np. firmy audytorskie (Fukas i in., 2021)). Takie podejście wyróżnia się tym, że jest bardzo szerokie i może być niekiedy zbyt skomplikowane, zwłaszcza w kontekście preskryptywności i wskazania co należy w danym momencie zrobić, żeby przejść na wyższy poziom dojrzałości. Ponadto organizacja składa się z wielu komórek organizacyjnych i procesów, stąd, jeśli są spełniane kryteria z wyższego poziomu tylko dla jednej z komórek, organizacja wciąż pozostanie na niższym poziomie dojrzałości. Problematiczne może być także zbadanie wszystkich komórek i zasugerowanie zmian w kierunku podwyższenia poziomu dojrzałości. Te modele najczęściej także wskazują, że różnice między jednym z poziomów a kolejnym opierają się na tym, że w jednym z poziomów „niektóre procesy korzystają ze wsparcia rozwiązań AI”, a w kolejnym „wszystkie procesy opierają się o rozwiązania AI” (np. w pracy Fukasa i in. (2021)). Taki krok dla organizacji może oznaczać wielomiesięczne lub wieloletnie zmiany, gdzie modele nie wskazują w jaki sposób do tego podejść. Ponadto, w takich modelach zakładane jest często, że infrastruktura jest taka sama w całej organizacji tj. w każdej komórce organizacyjnej, przy każdym procesie oraz np. to, że zbieranie danych odbywa się w ten sam sposób w całej organizacji. Ustalenie jednej infrastruktury i jednego słownika danych w organizacji może być dużym wyzwaniem, czego obecne modele również nie biorą pod uwagę. Dobrym pomysłem może być skupienie modelu na jednym procesie (na przykład model dojrzałości AI w procesie logistycznym), który może się wpisywać w model organizacyjny – np. jeśli dana organizacja jest na poziomie 2 we wszystkich modelach danych procesów, to jest też na poziomie 2 w modelu całej organizacji lub na poziomie 2 w wymiarze związanym z procesami w modelu całej organizacji.

- Podejście, które można nazwać **wielokrotnym** lub **łączonym**, czyli dwa oddzielne modele dojrzałości sprawdzające dojrzałość organizacji z różnych perspektyw, po czym następuje synteza wyników (najbliżej takiego podejścia jest model Yablonsky'ego (2019)). Według wiedzy Autora istnieje jedno badanie, które łączy w sobie różne modele ze zbliżonych do tej rozprawy dziedzin, w którym przeprowadzono badania empiryczne oraz wyciągnięto wnioski z połączenia modeli – Sassanelli, Rossi i Terzi (2020) wykorzystują wspomniany w tej pracy model CLIMB razem z modelem dojrzałości cyfrowej DREAMY (oraz dwoma innymi metodami do oceny czasu spędzanego na różnych aktywnościach w procesie i oceny przeszkód występujących w procesie), aby przeprowadzić holistyczne badanie organizacji. Z badania można wyciągnąć dwa wnioski ogólne, istotne z perspektywy tej pracy. Pierwszym wnioskiem jest pomyślnie połączenie tych podejść w jedno, bardziej kompleksowe, zintegrowane podejście. Modele DREAMY i CLIMB wydawały się kompatybilne, ponieważ są zbudowane na tych samych czterech filarach: procesie, monitorowaniu i kontroli (wspieranych przez praktyki zarządzania wiedzą), technologii (obejmującej narzędzia, metody i poziom komputeryzacji) oraz organizacji (dotyczącej ról, współpracy i szkolenia pracowników). To pozwoliło autorom na porównanie wyników pochodzących z obu modeli i uzyskanie pełniejszej perspektywy dla każdego z tych czterech wymiarów oraz zidentyfikowanie związanych z nimi głównych problemów. Drugi wniosek odnosi się do metody badawczej – podejście opierało się w całości na wywiadach, które wymagały wielu godzin, zarówno ze strony organizacji, jak i badaczy i w zależności od modelu dotyczyło innych jednostek organizacji. W wywiadach dotyczących modelu DREAMY uczestniczyli przedstawiciele produkcji, łańcucha dostaw, operacji i IT, natomiast model CLIMB wymagał udziału dyrektora technicznego, kierowników produktu, IT, badań i rozwoju, serwisu, działu elektrycznego i działu mechanicznego. Na podstawie tych dwóch wnioskach, można określić, że połączenie dwóch modeli zapewnia bardziej kompleksowe podejście niż użycie tylko jednego z nich. Wymaga jednak większej liczby zasobów (wywiady), więc potencjalnie można by ograniczyć zakres zasobów poprzez zastosowanie innej metody badawczej.
- Podejście, które można nazwać **hybrydowym** lub **niskopoziomowym** – takie podejście w swoim artykule reprezentuje W. Chen i in. (2021). Zaprezentowany przez autorów model ma dwa wymiary, które są na tyle rozbudowane (zwłaszcza w przypadku wymiaru

Przemysł, który dzieli się na: Badania i Rozwój, Wytwarzanie/produkcję, Łańcuch dostaw, Marketing oraz Wsparcie projektowe), że mogłyby zostać podzielone na kilka różnych modeli (np. model dojrzałości AI dla badań i rozwoju, model dojrzałości AI dla marketingu itd.). Takie podejście charakteryzuje się tym, że jest jeden kwestionariusz (w odróżnieniu od dwóch w podejściu łączonym od dwóch różnych modeli) i w kwestionariuszu są pytania do każdego wiersza i każdej kolumny. Tworzy to macierz o wymiarach 12 x 5 dla każdego z pięciu podwymiarów wymiaru *Przemysł* (12 podwymiarów wymiaru *Sztuczna inteligencja* x 5 poziomów dojrzałości), gdzie w każdej z komórek macierzy znajduje się od 1 do 3 pytań, a ponadto uwzględniono dodatkową, szóstą macierz o wymiarach 10 x 5 zawierającą podwymiary wymiaru *Sztuczna inteligencja*, które mają zastosowanie dla każdego z podwymiarów wymiaru *Przemysł*, gdzie w każdej z komórek macierzy znajduje się od 1 do nawet 5 pytań. Łącznie jest to 637 pytań, w tym 140 pytań dla poziomu pierwszego (24 pytania dla każdego z podwymiarów oraz 20 pytań ogólnych, które mają zastosowanie dla każdego z podwymiarów). Według Autora rozprawy, nie jest to jednak wyzwanie, gdyż na pytania będą najprawdopodobniej odpowiadały osoby z różnych działów, co znacząco redukuje ich liczbę dla każdego działu. Tym samym, niewiele różni się od podejścia łączonego w tym aspekcie, że badane są różne jednostki w organizacji, stąd konieczne jest istotne zaangażowanie ze strony badanej organizacji. W takim podejściu organizacja badana jest jednak na wyższym poziomie szczegółowości niż w modelu pojedynczym (oddzielnie rozpatrywane są pojedyncze komórki organizacyjne i procesy).

Dominująca liczba poziomów dojrzałości w modelach to pięć, co stało się standardem w modelach dojrzałości z różnych dziedzin, prawdopodobnie bazując na efekcie modelu CMMI. Tylko trzy modele – model Ellefsen i in. (2019) (oparty na modelu organizacyjnym Ovum) i modele Dasa, Bali i Mishry (2023) oraz Schreckenberga i Moroffa (2021) – mają cztery poziomy dojrzałości. Inaczej wygląda sytuacja w przypadku liczby elementów – modele zawierają od dwóch do nawet ośmiu elementów, przy czym średnia wynosi między cztery a pięć elementów (zarówno cztery, jak i pięć są dominantami tego zbioru). Wśród poziomów wskazywanych w artykułach można wyróżnić:

- **Poziom 0** – występujący w niektórych modelach dojrzałości, wskazujący na brak jakiegokolwiek aktywności związanej z wdrażaniem rozwiązań AI. Może wynikać z braku

otwartości firmy na nowe technologie albo być świadomą decyzją o skupieniu się na innych priorytetach.

- **Poziom 1** – często nazywany początkującym, nowicjuszem, fundamentalnym, niskim lub poziomem planowania. Na tym poziomie brakuje inicjatywy w kierunku wdrażania rozwiązań AI (co może czynić go tożsamym z poziomem 0), lub podejmowane działania są mocno ograniczone i skupiają się na przygotowaniu podstawowej infrastruktury IT oraz zrozumieniu potencjalnych zastosowań AI. Niekiedy pojawiają się działania ad hoc, bez ustalonej strategii.
- **Poziom 2** – określany jako poddawany ocenie, eksperymentalny, gotowy na AI lub poziom odkrywcy. Na tym poziomie organizacja zaczyna zmieniać sposób myślenia w kierunku tworzenia pierwszych eksperymentalnych procesów wdrażania rozwiązań AI. Zakres tych działań jest jednak ograniczony i są one najczęściej inicjowane przez pojedyncze jednostki organizacyjne bez koordynacji między nimi, zazwyczaj z niewielkim budżetem na przetestowanie pewnych rozwiązań. Infrastruktura IT na tym etapie jest na ogół gotowa, mogą pojawić się początki budowania strategii AI oraz pierwsze szkolenia.
- **Poziom 3** – określany jako zdefiniowany, operacyjny, praktykujący, średniozaawansowany lub poziom użytkownika. Na tym poziomie pracownicy organizacji są świadomi możliwości i korzyści, jakie rozwiązania AI mogą przynieść organizacji. Powstaje pierwsza strategia dotycząca rozwiązań AI lub istniejąca od niedawna strategia ma wsparcie kierownictwa, a struktury danych i zasady ich przetwarzania są zdefiniowane. Tworzone i testowane są pierwsze rozwiązania AI, a organizacja ustala wymagania dotyczące ochrony i etyki danych.
- **Poziom 4** – często nazywany zarządzanym, zoptymalizowanym lub zaawansowanym. Na tym poziomie organizacje dobrze rozumieją, jak rozwiązania AI mogą przyczynić się do rozwoju organizacji, a strategia jest jasno określona i ukierunkowana na wykorzystanie AI. Organizacje na tym poziomie mogą łączyć wprowadzenie rozwiązań AI z tworzeniem nowych modeli biznesowych. Rozwiązania AI mają dedykowane zasoby (ludzkie i technologiczne), a dane są systematycznie zbierane i wykorzystywane do potrzeb tych rozwiązań. Zasady dotyczące etyki danych są ustalone i przestrzegane.

- **Poziom 5** – nazywany mistrzowskim, pionierskim, przekształconym, doskonałym lub poziomem przywództwa. Na tym poziomie pracownicy organizacji wykazują biegłość we wdrażaniu i korzystaniu z rozwiązań AI. Organizacja posiada długoterminową strategię i wizję, która jest proaktywnie zarządzana. Wiedza z danych jest wykorzystywana operacyjnie i strategicznie. Rozwiązania AI są stale optymalizowane, osiągając wysoki stopień automatyzacji. Organizacja ma udokumentowane sukcesy we wdrażaniu AI, a etyka i regulacje są integralną częścią praktyk organizacyjnych. Wdrożone są certyfikowane standardy jakości użycia AI.

Na podstawie nazw i krótkich opisów, wśród najczęściej pojawiających się w modelach elementów można wyróżnić takie jak:

- **Technologia** (w 11 modelach; również jako Środki, narzędzia i platformy technologiczne oraz Funkcje sztucznej inteligencji)
- **Strategia** (w 10 modelach; również jako Strategia i zarządzanie, Projekty i strategię uczenia się, Cele lub Warunki ogólne)
- **Dane** (w 9 modelach; również jako Informacja lub Struktura danych)
- **Organizacja** (w 8 modelach; czasem jako Organizacja i procesy)
- **Ludzie / Kultura / Kompetencje** (w 7 modelach; czasem jako Ludzie i kompetencje, Kultura i kompetencje, Wymagane zdolności, umiejętności i kompetencje, Sposób myślenia lub Organizacja i ludzie)
- **Przypadki użycia sztucznej inteligencji** (w 6 modelach; jako Operacje, Produkty i usługi, Podstawowe zadania i przypadki użycia, Aktywności, Proces lub Kontrola i planowanie produkcji)
- **Etyka** (w 3 modelach; również jako Etyka i regulacje oraz Wiarygodność)

Warto dodać, że wymiary związane z danymi, technologią, strategią, organizacją i procesami oraz ludźmi pojawiały się także w modelach dojrzałości procesu rozwoju produktu. Wskazanie wszystkich powtarzających się w modelach elementów jest jednak wyzwaniem z dwóch powodów. Po pierwsze, autorzy różnie podchodzili do określania elementów modelu, co utrudnia

jednoznaczną klasyfikację. Na przykład, żaden element z czterech poniższych modeli nie został uwzględniony w powyższym zestawieniu:

- W modelu Yablonsky'ego (2019) występują 4 elementy: Kto tworzy wgląd, Kto decyduje i w jaki sposób, Kto działa na podstawie decyzji, Zaawansowana analityka. Elementy te obejmują pracę nad danymi, budowanie infrastruktury danych oraz wsparcie decyzji strategicznych, ale autorzy nie wskazują ich bezpośrednio.
- W modelu Lichtenthalera (2020) wskazane są 3 elementy: różne rodzaje AI, różne rodzaje inteligencji ludzkiej, meta-inteligencja łącząca różne typy inteligencji. Sam model jednak zawiera elementy budowania odpowiedniej technologii, przyjęcia strategii dotyczącej AI oraz osiągnięcia wzrostu i innowacji.
- Model W. Chena i in. (2021) jest najbardziej rozbudowanym modelem w zestawieniu – zawiera dwa wymiary: Przemysł i Sztuczną inteligencję, które są dodatkowo podzielone na wskaźniki. W ramach wymiaru Przemysł znajdują się wskaźniki: Badania i Rozwój, Wytwarzanie/produkcja, Łańcuch dostaw, Marketing oraz Wsparcie projektowe. Wymiar Sztuczna inteligencja obejmuje wskaźniki takie jak: jakość Big Data, inteligentne pozyskiwanie danych, inteligentna analiza danych, inteligentne podejmowanie decyzji, bezpieczeństwo Big Data, zarządzanie Big Data oraz inteligentne przechowywanie w chmurze. Model zawiera ponadto 35 wskaźników drugiego poziomu i jest na tyle rozbudowany, że można by go nazwać hybrydowym modelem dojrzałości, łączącym kilka dziedzin w ramach jednego modelu. Wskaźniki dotyczące sztucznej inteligencji w modelu w dużej mierze opierają się na pracy nad danymi i infrastrukturą oraz odpowiednią strategią.
- Model Dasa, Bali i Mishry (2023) z założenia koncentruje się w całości na etyce, a wszystkie cztery wymiary modelu – Możliwość kontroli, Możliwość wyjaśnienia, Uczciwość, Bezpieczeństwo – są aspektami dotyczącymi etyki sztucznej inteligencji.

Po drugie, nazwy elementów nie zawsze odzwierciedlają, co faktycznie znajduje się w danym elemencie. Na przykład element Organizacja w modelu Yamsa i in. (2021) zawiera także zasoby ludzkie i umiejętności, co w wielu modelach jest wymieniane jako osobny punkt, lub elementy etyki, które czasem zawierają się w wymiarze Dane lub Organizacja. Z innych niewymienionych

dotychczas elementów pozostają takie jak Budżet (czasami uwzględniany w wymiarze Strategia), Prywatność (danych – która w modelu Schustera, Waidelicha i Volza (2021) jest oddzielona jako osobny wymiar), Ekosystemy (skupiające się na współpracy i komunikacji), Granice/Ograniczenia (które firma może przesuwać za pomocą rozwiązań AI) czy Środowisko zewnętrzne i oczekiwania dotyczące umiejętności absolwentów (co jest wymiarem stricte domenowym – edukacyjnym, koncentrującym się na umiejętnościach studentów).

Model W. Chena i in. (2021) jako jedyny bezpośrednio odnosi się do kwestii preskryptywności modelu według Röglingera, Pöppelbuşa i Beckera (2012) (także uwzględniając omawiane wcześniej modele dojrzałości procesu rozwoju produktu), sugerując, że przygotowane przez autorów narzędzie częściowo spełnia cel preskryptywny, ale podkreślając, że w badaniu mogły nie zostać pokazane konkretne środki poprawy w kierunku oczekiwanych poziomów dojrzałości w formie szczegółowej specyfikacji. Zdaniem Autora rozprawy, w tym podejściu (opartym na pracy Röglingera, Pöppelbuşa i Beckera (2012)) brakuje między innymi rachunku decyzyjnego – czyli podkreślenia alternatyw w dojściu do kolejnego poziomu dojrzałości. Stąd określono ten model jako częściowo preskryptywny – niespełniający wszystkich zasad budowy modeli preskryptywnych (Röglinger i in., 2012). Mimo że Sonntag i in. (2024) nie odnoszą się bezpośrednio do preskryptywności w swoim artykule, ich model można również uznać za częściowo preskryptywny. Autorzy, bazując na wcześniejszych badaniach w tej dziedzinie, stwierdzili, że pewne wskaźniki w danych wymiarach są istotniejsze od innych i wprowadzili wagi dla każdego z wymiarów. Taki zabieg może być określony jako pewna forma rachunku decyzyjnego – niektóre elementy są wskazywane jako bardziej priorytetowe niż inne. Brakuje jednak relacji koszt-korzyść oraz pełnej procedury z dostosowaniem środków poprawy.

Jeśli chodzi o sposób oceny organizacji na podstawie zbudowanego modelu dojrzałości, tylko cztery artykuły oferują taki sposób. W każdym przypadku jest to kwestionariusz w różnej formie z listą pytań lub skonstruowany w formie tabeli, gdzie należy zaznaczyć, czy spełnia się dany punkt. Kwestionariusze są przygotowane dla organizacji jako forma samooceny lub opisywane jest przeprowadzenie wywiadu w celu uzyskania bardziej szczegółowych informacji. Tylko trzy artykuły z czterech, w których opracowano kwestionariusze (i przy tym tylko trzy ze wszystkich piętnastu artykułów), opisują wykonanie badań empirycznych. W jednym przypadku są to cztery firmy z sektora logistyki (AIMM 3), w drugim jedna firma z sektora ubezpieczeń (AIMM 7), a w

trzecim trzy dywizje jednej firmy z sektora produkcyjnego (AIMM 14). Wszystkie badania wskazują, że mimo iż w niektórych wymiarach badane firmy (lub dywizje) radzą sobie lepiej niż w innych (wykazując wyższy poziom dojrzałości w danym wymiarze), to patrząc na wszystkie wymiary jednocześnie, wszystkie badane organizacje wciąż byłyby na poziomie pierwszym (najniższym).

Analiza modeli dojrzałości w obszarze AI pokazuje, że chociaż istnieje kilka ogólnych modeli, które wspierają ocenę zaawansowania w obszarze sztucznej inteligencji, to wyraźnie brakuje dedykowanych modeli dotyczących generatywnej AI. Generatywna AI, która odgrywa coraz większą rolę w innowacyjnych zastosowaniach biznesowych i technologicznych, wymaga nowych podejść do oceny dojrzałości, uwzględniających specyficzne wyzwania i możliwości tej technologii. Kluczowe wyzwania, takie jak zgodność z regulacjami czy integracja z procesami organizacyjnymi, nie są wystarczająco uwzględniane w istniejących modelach. Stąd w kolejnych częściach pracy przeprowadzono badania, mające na celu identyfikację elementów modelu dojrzałości w wykorzystaniu rozwiązań generatywnej AI w procesie rozwoju nowego produktu.

2.6. Analiza bibliometryczna i przegląd literatury w celu identyfikacji elementów modelu

Przeprowadzono systematyczny przegląd literatury, poprzedzony kontekstową analizą bibliometryczną w celu osadzenia przeglądu literatury w krajobrazie badań. Skupiono się na analizie wydajności (*performance analysis*) (Donthu i in., 2021), zakładając dwie metryki – liczbę publikacji ogółem w kolejnych latach oraz rozkład liczby publikacji według dziedziny badań (Klincewicz i in., 2012). Te dwie metryki pozwalają uchwycić dynamikę i etap rozwoju pola (identyfikacja skoków publikacyjnych, uzasadnienie zakresu lat w przeglądzie literatury) oraz określić profil dyscyplinarny i potencjalne luki pokrycia, co uzasadnia dobór baz i fokus przeglądu. Analizę przeprowadzono wykorzystując informacje uzyskane z międzynarodowej bazy Scopus, która jest uznawana za reprezentatywną dla dziedziny nauk o zarządzaniu i jakości (Żemigala, 2018). Pierwszym krokiem było wyszukanie słów kluczowych z zakresu generatywnej sztucznej inteligencji i rozwoju nowego produktu jak w Tabeli 7 (w tytułach, streszczeniach i słowach


Tabela 7. Słowa kluczowe z obszarów generatywnej sztucznej inteligencji i rozwoju nowego produktu do analizy bibliometrycznej i przeglądu literatury w celu identyfikacji elementów modelu.

Obszar	Słowa kluczowe
Zarządzanie produktem	<i>New Product Development, NPD, Product management</i>
GenAI	<i>Generative Artificial Intelligence, GenAI, Generative AI</i> <i>Large language model, LLM, Transformer</i> <i>GPT, BERT, DALL-E, CLIP</i>

Źródło: opracowanie własne.


kluczowych). W przypadku obszaru rozwoju nowego produktu, zdecydowano się na zawężenie wyszukiwania do słów kluczowych *product management*, *New Product Development* oraz *NPD* (podobnie jak przy przeglądzie literatury z początku tego rozdziału, słowa kluczowe uwzględniające poszczególne fazy procesu rozwoju produktu generowały zbyt dużą liczbę wyników). W przypadku obszaru generatywnej sztucznej inteligencji (GenAI), słowa kluczowe zbudowano warstwowo: ogólne (sama nazwa generatywnej AI w trzech najczęściej widzianych odmianach), architektoniczne (*Large language model/LLM, Transformer*) oraz nazwy kilku najczęściej występujących modeli (*GPT, DALL-E, BERT, CLIP* – traktowane także jako komponenty ekosystemu i wykluczane w pełnym tekście, jeśli występują bez elementu generatywnego). Celowo nie włączano ogólnych rodzin (np. *foundation / diffusion / GAN / VAE / text-to-image / text-to-video / multimodal*), ponieważ pilotaże pokazały znaczny spadek trafności (duży udział publikacji czysto algorytmicznych bez związku z wdrożeniami w NPD). Dodatkowo wykonane zostało oczyszczenie zbioru – wykluczono takie dokumenty jak notatki edytorskie czy recenzje ze względu na fakt ich mniejszego znaczenia w określaniu trendów w obszarze badań. W bazie indeksowanych było 1190 publikacji na dzień 06.01.2025.

W przypadku tak sprecyzowanego wyszukiwania, liczba publikacji utrzymywała się na stałym poziomie ok. 30 publikacji w latach 2004-2018, natomiast w 2024 roku liczba publikacji wynosiła ponad 260 i była ponad dwukrotnie większa niż w 2023, a niemal czterokrotnie większa niż w 2022 roku (Rysunek 4). Łącznie liczba publikacji z 2023 i 2024 roku odpowiadała za jedną trzecią wszystkich publikacji w zbiorze. Obserwując koncentrację według obszarów nauk (Rysunek 5), można zauważyć, że pierwsze trzy dziedziny z największą liczbą publikacji to dziedziny techniczne – *Computer Science, Engineering* oraz *Mathematics*, które odpowiadają za ponad



Rysunek 4. Liczba publikacji z bazy Scopus dla wybranych słów kluczowych z obszarów generatywnej sztucznej inteligencji oraz rozwoju nowego produktu z Tabeli 7 w latach 1973 – 2024.

Źródło: opracowanie własne.



Rysunek 5. Liczba publikacji według dziedziny badań (top 10 dziedzin) dla wybranych słów kluczowych z obszarów generatywnej sztucznej inteligencji oraz rozwoju nowego produktu z Tabeli 7.

Źródło: opracowanie własne.


połowę wszystkich publikacji (55,9%). Niecałe 12% znajduje się w obszarach bliższych naukom o zarządzaniu i jakości oraz naukom społecznym – *Business, Management and Accounting, Decision Sciences* oraz *Social Sciences*. Bazując na analizie liczby publikacji zdecydowano się na ograniczenie zakresu publikacji w przeglądzie literatury do ostatnich pięciu lat. Ponadto kontekst bibliometryczny potwierdził techniczne zdominowanie pola, co uzasadniło fokus systematycznego przeglądu literatury na literaturze zarządczej – celem nie było poszerzenie przeglądu literatury o kolejne platformy techniczne, lecz trafne wyłapanie dowodów wdrożeniowych istotnych dla praktyki procesu rozwoju nowego produktu.

Systematyczny przegląd literatury został przeprowadzony, podobnie jak wcześniej, na podstawie ustrukturyzowanego procesu wyszukiwania i identyfikacji, opartego na metodologiach zaproponowanych przez Webster i Watsona (2002) oraz Brocke i in. (2009). Syntezę przeprowadzono tematycznie, grupując wyniki w trzy kategorie: zastosowania, wyzwania i czynniki sukcesu. Zakres pokrycia literatury, podobnie jak przy wcześniejszym przeglądzie, określono zgodnie z taksonomią Coopera (Brocke i in. 2009) jako „wyczerpujący z selektywnym cytowaniem” (*exhaustive with selective citation*). Skorzystano z wcześniej dobranych słów kluczowych z Tabeli 7. Słowa kluczowe wyszukiwano w bazach Scopus, Web of Science, ProQuest, ACM Digital Library, Wiley Online Library i ScienceDirect, które zgodnie z kryteriami Gusenbauera i Haddawaya (2020) spełniają standardy jakości wymagane od akademickich systemów wyszukiwania (świadomie nie przeszukiwano platform o profilu technicznym, np. IEEE Xplore, ponieważ wstępne rekonesanse wskazywały na duży udział publikacji czysto algorytmicznych bez powiązania z wdrożeniami w procesie rozwoju nowego produktu, co prowadziłoby do istotnego wzrostu „szumu”). Zdecydowano się także na analizę źródeł cytowanych w odnalezionych publikacjach oraz źródeł cytujących te publikacje (Webster i Watson, 2002) oraz wykorzystanie uzupełniająco wyszukiwarki Google Scholar (podobnie jak w poprzednim przeglądzie literatury z początku tego rozdziału).

Zastosowano następujące kryteria włączenia: (i) skupienie na zastosowaniach, wyzwaniach i czynnikach sukcesu wdrażania rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju nowego produktu, (ii) zawężenie zakresu publikacji do ostatnich pięciu lat (2020-2024), w celu uwzględnienia najnowszych badań (bazując na analizie bibliometrycznej; starsze, istotne prace identyfikowano metodą *backward / forward search*), (iii) wybór prac z zakresu nauk o zarządzaniu

(najczęściej w wyszukiwarkach są to kategorie takie jak *Business & Management* oraz *Social Sciences* i *Decision Sciences*), (iv) ograniczenie do publikacji napisanych w języku angielskim. Uwzględniono także kryteria wykluczenia, które obejmowały: (i) brak pełnego tekstu artykułu oraz (ii) artykuły niezwiązane z wyszukiwaną tematyką (nieodnoszące się w żadnym stopniu do procesu rozwoju nowego produktu lub nieskupiające się na rozwiązaniach generatywnej sztucznej inteligencji). W celu zapewnienia odpowiedniej jakości wybranych artykułów zastosowano następujące kryteria: (i) uwzględniono jedynie publikacje w czasopismach naukowych lub materiały z konferencji oraz (ii) brano pod uwagę wyłącznie prace poddane procesowi recenzji naukowej.

Początkowe wyszukiwanie przy użyciu fraz kluczowych przyniosło łącznie 1037 wyników (stan na dzień 07.01.2025 roku). Selekcji dokonywał jeden recenzent (Autor niniejszej rozprawy). Po usunięciu duplikatów, analizie streszczeń i kolejno odrzuceniu publikacji, gdzie nie znaleziono pełnego tekstu lub które nie były związane z użyciem rozwiązań GenAI w procesie rozwoju nowego produktu, zidentyfikowano 96 prac uznanych za istotne dla tego przeglądu literatury. Następnie przeprowadzono analizę źródeł, które były cytowane w znalezionych publikacjach oraz tych, które cytowały znalezione publikacje, w ramach której odnaleziono 10 istotnych artykułów. Kolejne pięć prac zidentyfikowano poprzez przeprowadzenie regularnego wyszukiwania w bazie Google Scholar przy użyciu wybranych słów kluczowych. Na podstawie tego procesu selekcji utworzono bazę danych składającą się z 111 artykułów. Graficzny schemat procesu systematycznego przeglądu literatury wskazano na Rysunku 6. Dane z artykułów zestawiono w tabelach ekstrakcyjnych (Popay i in., 2006) w kolejnym podrozdziale (tabele zastępują klasyczną macierz konceptów proponowaną przez Webster i Watsona (2002)). Dyskusja modeli została przeprowadzona w podrozdziale 2.8.



Rysunek 6. Proces systematycznego przeglądu literatury – zastosowania, wyzwania i czynniki sukcesu wdrożeń generatywnej sztucznej inteligencji.

Źródło: opracowanie własne.

2.7. Wyniki przeglądu literatury identyfikującego elementy modelu

Zastosowania rozwiązań generatywnej AI w procesie rozwoju nowego produktu

Jak wcześniej wspomniano, analiza sentymentu, czy też eksploracja opinii, jest użyteczna przy generowaniu pomysłów na nowe produkty lub przy projektowaniu produktów. Rozwiązania kojarzone z generatywną sztuczną inteligencją (GenAI), będące komponentami szerszych rozwiązań sztucznej inteligencji (np. BERT, LSTM czy nawet język N-gramowy) często występują jako części składowe większego rozwiązania służącego analizie sentymentu (H. Li i in. 2023; Lin i in. 2023; Vargas i in. 2022; Troya i in. 2021; M. Zhang i in. 2021; Nuraliza i in. 2023; Santu i in. 2016; Soni 2017; Bouschery i in. 2023; Tang i in. 2024; Chaldun i in. 2024; Işcan i in. 2024; Shahin, Chen, Maghanaki i in. 2024) i są używane na przykład w celu identyfikacji istotniejszych elementów dotyczących wrażeń użytkowników z treści przez nich generowanych (J. Wang i Liu,

2023), do ulepszenia eksploracji opinii poprzez fuzję tekstu i ikon (*emoji*) (Sai i in., 2023), przy detekcji sarkazmu (S. Kumar i in., 2023), żeby ulepszyć przewidywania sprzedaży (Geetha i in., 2023) czy przy detekcji fałszywych informacji (tzw. *fake news* – na przykład aby sprawdzić, czy ktoś nie pisze nieprawdziwych informacji o produkcie) (Peng i Xintong, 2022). W zdecydowanej większości rozwiązań te korzystają z modelu BERT np. przy analizie sentymentu w branży e-commerce, gdzie producenci mogą dowiedzieć się o publicznym sentymencie dotyczącym produktów sprzedawanych na stronach e-commerce (Y. Liu i in., 2020), np. wydobywając treści opisujące główne problemy produktu w celu określenia nowego kierunku rozwoju produktu (M.-F. Li i in., 2022). Narzędzia takie jak ChatGPT są także w stanie same generować idee dotyczące produktu, pomagać we wstępnej burzy mózgów lub wspierać proces zbierania informacji od klientów (Joosten i in. 2024; Bilgram i Laarmann 2023; Bouschery i in. 2023; S. Gupta i in. 2024; Brand i in. 2023; Jetter i in. 2024; Paliwal i in. 2024; Oppenlaender i in. 2023; Shahin, Chen i Hosseinzadeh 2024). Rozwiązania generatywnej sztucznej inteligencji można także zastosować do podsumowań tekstów w różnych kontekstach (Bouschery i in., 2023; Shi i in., 2023). Automatyczne tworzenie streszczeń może wykorzystywać recenzje internetowe jako podstawę analizy (Benham i in., 2022), żeby następnie integrować automatyczne podsumowania w systemach rekomendacyjnych (Bai i in., 2021). Automatyczne podsumowania mogą być też wykorzystywane przy produktach medycznych (Shi i in., 2023) lub żeby zrozumieć skomplikowane niuanse projektowe – według badań zastosowanie BERT może przewyższać w tym zakresie standardowe rozwiązania sztucznej inteligencji (C. Chen i Morkos, 2023).

Rozwiązania generatywnej sztucznej inteligencji znajdują także zastosowanie przy ewaluacji pomysłów, analizie wymagań i ocenie ryzyka w procesie powstawania nowego produktu. Rozwiązania GenAI mogą zwiększyć efektywność procesu oceniania pomysłów, umożliwiając masowe analizowanie pomysłów z różnych punktów widzenia, takich jak innowacyjność, realność wykonania lub ekonomiczna opłacalność (Mesbah i in., 2023; Organisciak i in., 2023). Rozwiązania takie jak Ukryte Modele Markowa (HMM) mogą być użyte do segmentacji słów np. w przemyśle lotniczym, gdzie proces produktowy jest skomplikowany, charakteryzuje się intensywnością technologiczną, interdyscyplinarnością, długim procesem tworzenia, dużymi kosztami i licznymi interesariuszami, z których każdy dostarcza własne wymagania co do powstania samolotu. Liczba wymagań jest więc na tyle duża, że narzędzia oparte na GenAI potrafią znacząco wspomóc proces (J. K. Lu i Hu, 2023). Co więcej, zmiany wymagań w trakcie procesu i

kaskadowe efekty propagacji tych zmian mogą prowadzić do nieefektywności procesu. Również w tym przypadku rozwiązania GenAI mogą wesprzeć proces, wspomagając ocenę wystąpienia potencjalnej zmiany wymagań lub rozszerzając zbiór, generując dodatkowe, sztuczne dane (tzw. *data augmentation*) (C. Chen i in., 2023; Grasler i in., 2022; Gräßler i in., 2022; Subahi, 2023). Dodatkowo mogą wspomóc proces planowania zadań służąc np. do ekstrakcji semantyki z programu Jira, żeby dowiedzieć się kto jest odpowiednią osobą dla danego zadania, jaki powinien być priorytet zadania czy nawet jakie jest aktualne obciążenie pracą zespołu (Diamantopoulos i in., 2023) lub do wygenerowania nowych profili klientów i ich zachowań (S. Gupta i in., 2024; Tkachenko, 2023).

Rozwiązania generatywnej sztucznej inteligencji znajdują swoje zastosowanie także w fazie projektowania i wytwarzania produktów z różnych branż, np. w przemyśle (Bendoly i in., 2024), w branży modowej do projektowania ubrań (W. Choi i in., 2023; Sohn i in., 2020; Yu i Zhang, 2024), w branży meblarskiej do projektowania mebli (Z. Li, Sayuti i in. 2024), w branży kosmetycznej do zwiększenia efektywności procesu powstawania nowych schematów kolorów (W. Zhang i in., 2023), w branży inżynierii biomedycznej do projektowania inspirowanego bioniką (*bionic-inspired design*) wzbogaconego o modele generatywne w celu tworzenia bardziej innowacyjnych i wydajnych konstrukcji (Z. G. Deng i in., 2023), w architekturze np. do projektowania fasad budynków (Heusler i Kadija, 2018), gdzie ludzcy projektanci mogą współpracować z rozwiązaniami GenAI, aby zwiększyć kreatywność (López-Forniés i Asión-Suñer, 2024), w branży medycznej do tworzenia nowych leków (Mahjour i in., 2023; Merk i in., 2018; Schultz i in., 2021), lub modeli zwierząt, dążąc do zmniejszenia testów na zwierzętach (X. Chen i in., 2022), w branży chemicznej do tworzenia nowych materiałów np. barwników czy cukru, przewyższając ludzkie ograniczenia w eksploracji ogromnych przestrzeni kombinatorycznych (Takeda i in., 2020), czy w branży IT do projektowania systemów informatycznych (Ooi i in., 2023; Van Bossuyt i in., 2023), interfejsów użytkownika (S. Gupta i in., 2024) lub gier, aby tworzyć bardziej angażujące i wnikliwe doświadczenia z gry, rozwijając narrację i projektując grafiki (Colado i in., 2023). Jak zauważają Na i Kim (2021): „Projektowanie generatywne jest czymś więcej niż tylko parasolem obejmującym topologię i optymalizację kształtu i może inspirować projektantów do kreatywnego studiowania modeli poprzez celowe wykorzystanie na każdym etapie procesu projektowania produktu”. Rozwiązania GenAI wspomagają nie tylko projektowanie, ale mogą również pomóc przy ocenie projektu (Feng i in., 2020) np. przy analizie

oceny projektów w rozwiązaniach Smart Home (i porównując to z oceną ludzkich ekspertów) (Kuo i Xia, 2023), czy też przy multimodalnej ocenie koncepcji projektu obuwia, włączając analizę opisową i wizualną do informowania o decyzjach opartych na danych (Yuan i in., 2022).

Rozwiązania GenAI są w stanie wspomóc także testowanie produktu i kontrolę jakości. Dzięki generowaniu dodatkowych, sztucznych danych, testowanie produktu może zostać zredukowane z tysięcy godzin do kilku godzin (zanim produkt zostanie wprowadzony na rynek), aby ograniczyć koszty i czas od rozpoczęcia prac do wprowadzenia produktu na rynek (*Time-To-Market – TTM*) (Doanh i in., 2023; Morizet i in., 2023). Younas, Malik i Ignatov (2023) zastosowali BERT w połączeniu z algorytmem word2vec do analizy defektów w telefonach komórkowych, pokazując, jak łączenie różnych rozwiązań AI może zwiększyć zdolności wykrywania. Podobnie, sieci GAN są wykorzystywane do wykrywania anomalii w procesach produkcyjnych stali (C. Zhang i Zhang, 2023). Metody oparte na modelu BERT są również wykorzystywane do wykrywania defektów w samochodach. You i in. (2020) opisują, jak BERT jest wykorzystywany do oceny poziomu ryzyka przypadków wad w przemyśle motoryzacyjnym, przekształcając informacje o defektach w poziomy ryzyka dla pojazdów i tym samym umożliwiając automatyczne prognozy wycofania pojazdów. Badana jest także generacja danych syntetycznych w celu usprawnienia procesu wykrywania defektów (Matuszczyk i in., 2022). Ta metoda oferuje możliwość szkolenia algorytmów wykrywania defektów na danych, które mogą być rzadkie lub trudne do zebrania w rzeczywistym świecie, tym samym poprawiając efektywność i dokładność działań kontrolnych jakości. Kontrola jakości może zostać także usprawniona poprzez zamianę procedur operacyjnych w interaktywne systemy pytań i odpowiedzi, oparte na rozwiązaniach generatywnej AI (S. Jain i in., 2024).

Rozwiązania GenAI sprawdzają się także w marketingu produktowym oraz w optymalizacji produktu i samego procesu produktowego (Amankwah-Amoah i in., 2024; Cillo i Rubera, 2024; Kar i in., 2023; Kshetri i in., 2024). W marketingu GenAI jest wykorzystywana do tworzenia ukierunkowanych reklam i generowania słów kluczowych (Bulut i Mahmoud, 2023), a także do przewidywania wskaźnika klikalności (*click-through rate – CTR*) dla reklam przy użyciu modelu opartego na BERT (Muhammed i in., 2022). Jest również postęp w automatycznym generowaniu obrazów i filmów promocyjnych, co znacznie usprawnia tworzenie treści marketingowych dla produktu (Doanh i in., 2023; R. Gupta i in., 2024; Kshetri i in., 2024; C. Liu i in., 2019; Ooi i in.,

2023; Oppenlaender i in., 2023). W obszarze systemów rekomendacyjnych rozwiązania te są w stanie ulepszać rekomendacje produktowe np. w e-commerce (Chia i in., 2022; Wahsheh i in., 2023), wskazując miejsca dla klientów (Manotumruksa i in., 2017), czy w branży modowej, tworząc bardziej zaawansowane rekomendacje, umożliwiając klientom wizualizację siebie w różnych strojach, stylach i tłach, zwiększając doświadczenie zakupowe (Mohamed i in., 2023). Rozwiązania generatywnej AI są w stanie także optymalizować zarządzanie stanami magazynowymi produktów (Z. Li, Ksibi i in. 2024). Mogą też wspierać obsługę klienta, rekomendując potencjalne rozwiązania dla produktów i usług (Ali Zaidi i in., 2022; Sun i in., 2023) lub wspierać zespół programistów dzięki automatycznej generacji kodu (S. Gupta i in., 2024). Rozwiązania GenAI sprawdzają się także na pograniczu rozwoju nowego produktu i zarządzania wiedzą, usprawniając działanie produktowych baz danych (Abadi i in., 2023; Nasser i in., 2023; Niemir i Mrugalska, 2023; Shin i in., 2022; Su i in., 2021; H. Wang i in., 2023; Zan i in., 2023). Omówione cele wykorzystania rozwiązań generatywnej AI w różnych fazach procesu rozwoju nowego produktu zostały przedstawione w Tabeli 8.

Wyzwania związane z wdrażaniem rozwiązań generatywnej AI

Wdrożenie generatywnej AI w organizacjach wiąże się z wieloma wyzwaniami, które obejmują zarówno aspekty techniczne, jak i społeczne czy etyczne. Po pierwsze, trudności w adopcji wynikają z podejścia pracowników, którzy mogą opierać się technologii, jeśli ogranicza ona ich autonomię i zdolność do wykazania się ekspertyzą (Dwivedi i in., 2023). Profesjonaliści i eksperci sprzeciwiają się wykorzystaniu ich dzieł jako danych treningowych dla rozwiązań GenAI oraz brakowi rekompensaty za ich oryginalne utwory (Samuelson, 2023). Ponadto złożoność i nieprzejrzystość algorytmów GenAI, wynikająca z dużej liczby parametrów i skomplikowanych procesów obliczeniowych, może zniechęcać pracowników do ich wykorzystania, zwłaszcza jeśli nie rozumieją mechanizmów decyzyjnych AI (Rajaram i Tinguely, 2024).

Następnym wyzwaniem jest awersja do algorytmów, polegająca na preferowaniu decyzji podejmowanych przez ludzi, mimo iż prognozy generowane przez sztuczną inteligencję często cechują się wyższą trafnością. Problem ten zyskuje na znaczeniu w przypadku rozwiązań generatywnej sztucznej inteligencji. Zarówno ludzki osąd, jak i osąd rozwiązań GenAI mają

Tabela 8. Cele wykorzystania rozwiązań generatywnej AI w poszczególnych fazach procesu rozwoju nowego produktu.

Faza	Cele wykorzystania
Generowanie pomysłów	Udoskonalenie analizy sentymentu i analizy opinii Generowanie pomysłów związanych z produktem Streszczanie tekstu (redukcja nadmiaru informacji)
Testowanie i ocena koncepcji (zwłaszcza w analizie wymagań i ocenie ryzyka)	Ulepszenie procesu analizy wymagań Antycypacja zmian w wymaganiach Wsparcie dla procesów planowania zadań
Projektowanie i rozwój produktu	Wspomaganie / automatyzacja projektowania Zwiększenie kreatywności Tworzenie nowych elementów i modeli, przewyższanie ludzkich ograniczeń w eksploracji dużych przestrzeni kombinatorycznych Wspomaganie oceny przy projektowaniu
Testowanie i walidacja produktu	Skrócenie czasu testowania Udoskonalenie algorytmów wykrywania anomalii Jakość produktu i testowanie
Marketing produktu (również podczas wprowadzania produktu na rynek)	Tworzenie ukierunkowanych reklam Udoskonalenie przewidywania współczynnika klikalności (<i>Click-Through Rate – CTR</i>) Generowanie słów kluczowych, obrazów i filmów promocyjnych
Ulepszanie i optymalizacja produktu	Udoskonalenie wewnętrznych i zewnętrznych systemów rekomendacji Udoskonalenie działania baz danych produktów

Źródło: opracowanie własne.

tendencję do postrzegania większości informacji jako prawdziwych, ale w rozwiązaniach GenAI ta tendencja jest istotnie większa, co rodzi obawy dotyczące wiarygodności w dokonywaniu oceny tego, co jest prawdziwe (Markowitz i Hancock, 2024). Ponadto rozwiązania GenAI mają tendencję do zachowań urojeniowych (tzw. halucynacje), co wynika często z braku zdolności do weryfikacji faktów w czasie rzeczywistym i prowadzi do tworzenia wprowadzających w błąd lub całkowicie błędnych informacji (Kalam i in., 2024). Istnieje potrzeba holistycznego i systematycznego zrozumienia badań dotyczących jakości i praktyk związanych z wiarygodnością tego typu

rozwiązań, co podkreśla znaczenie interdyscyplinarnej współpracy między ekspertami z różnych dziedzin (m.in. technologii i nauk społecznych) (G.-Y. Li i in., 2023).

Rozwiązania GenAI stwarzają też wyzwania etyczne. Problematiczne są na przykład potencjalne nadużycia związane z rozpowszechnianiem dezinformacji (np. tworząc tzw. *deepfake*) (Samuelson, 2023). Algorytmy GenAI mogą również utrwaląć istniejące uprzedzenia wynikające z danych treningowych, co wymaga dodatkowych działań mających na celu ograniczenie nierówności społecznych w procesach organizacyjnych (Kar i in., 2023). Wyzwaniem etycznym jest również niejasna odpowiedzialność za błędy systemów AI, zwłaszcza w decyzjach biznesowych, gdzie odpowiedzialność dzielona jest między pracowników, twórców GenAI i samą technologię (Al-Busaidi i in., 2024). Brak zaufania i obawy dotyczące autentyczności, zwłaszcza w interakcjach z klientami, dodatkowo komplikują wdrożenie, podobnie jak ryzyko prawne związane z użyciem danych chronionych prawem autorskim w procesach szkoleniowych AI (Bandi i in., 2023; Ebert i Louridas, 2023; Samuelson, 2023). Udostępnianie wiedzy zastrzeżonej niesie także ryzyko zmniejszenia unikalności aktywów rynkowych firmy, co potencjalnie może zagrozić jej zdolności do utrzymania przewagi konkurencyjnej (Cillo i Rubera, 2024).

Kolejnym wyzwaniem jest dobranie odpowiedniej strategii adopcji, uwzględniającej budżet na wdrożenie rozwiązań AI. Na poziomie kadry zarządzającej liderzy technologiczni będą musieli współpracować ze specjalistami od danych przy tworzeniu i rozwijaniu strategii związanych z rozwiązaniami GenAI (Mariani i Dwivedi, 2024). Znaczące koszty początkowe mogą obejmować konieczność nauki nowych umiejętności, takich jak pisanie efektywnych zapytań, co wiąże się z frustracją i stratą czasu, a także korektą błędów wynikających z nieznamomości narzędzi. Istotne są także inwestycje w infrastrukturę technologiczną, aby w pełni wykorzystać potencjał generatywnej AI (Kshetri i in., 2024).

Czynniki sukcesu wdrażania rozwiązań generatywnej AI

Organizacje stosują różne podejścia do pomiaru sukcesu wdrożenia sztucznej inteligencji w procesach rozwoju produktów. Korzyści można sklasyfikować jako niematerialne (trudne do zmierzenia) lub materialne (bezpośrednio przekładalne na wartość liczbową). Korzyści niematerialne obejmują zmianę kultury (sztuczna inteligencja napędza kulturę innowacji

produktowych), przewagę konkurencyjną (zapewniając znaczącą zmianę wartości produktu) i efekt halo (przyciąganie nowych klientów dzięki procesom opartym na sztucznej inteligencji). Uzyskane korzyści obejmują głównie redukcję kosztów (i/lub unikanie kosztów), wzrost przychodów, zadowolenie klientów (mierzone wskaźnikami CSAT i NPS), redukcję ryzyka i zgodność z przepisami (poprzez unikanie kosztów) (Burgess, 2018). Według McKinsey (2021), 69% respondentów ankietowanych w 2020 r., którzy wdrożyli rozwiązania AI w swojej organizacji, zgłosiło spadek kosztów po wdrożeniu AI w rozwoju produktów i/lub usług, przy czym jedna trzecia respondentów wskazała na spadek o ponad 20%. Jeśli chodzi o wzrost przychodów, 70% respondentów zgłosiło wzrost po wdrożeniu rozwiązań AI w rozwoju produktów i/lub usług, przy czym w 40% przypadków wzrost ten przekroczył 6%.

Wśród czynników sukcesu związanych z wdrażaniem rozwiązań generatywnej sztucznej inteligencji można wyróżnić zrozumienie wymagań (sprzętowych, oprogramowania i doświadczenia użytkownika), metryk oceny, a także taksonomię modeli i formatów wejściowo – wyjściowych (Bandi i in., 2023). Dwoma powszechnie stosowanymi metrykami oceny dla modeli generatywnych są *Fréchet Inception Distance (FID)* i *Inception Score (IS)*, które mogą jednak być podatne na uprzedzenia prowadzące do niezupełnie rzetelnych porównań między różnymi modelami, co utrudnia dokładną ocenę ich wydajności (Bandi i in., 2023; Chong i Forsyth, 2020). Stąd kluczowe jest uwzględnienie ograniczeń i uprzedzeń związanych z istniejącymi metrykami oraz eksploracja alternatywnych paradygmatów oceny, które zapewniają bardziej rzetelne i zrozumiałe oceny modeli GenAI (Alaa i in., 2022; Borji, 2019; Cheema i Uner, 2023). Istotne jest także uwzględnienie konkretnych wymagań dziedziny zastosowań i charakterystyki wygenerowanych danych (Bandi i in., 2023; Regenwetter i in., 2023).

Wśród innych czynników można także wyróżnić kulturę organizacyjną i międzyorganizacyjną – w celu osiągnięcia udanych wyników pracownicy muszą dobrze zrozumieć pozytywne konsekwencje dla produktywności i dynamiki przemysłu (Ozkaya, 2023; Sira, 2023). Wspierający wpływ ma jakość liderów, którzy powinni pełnić rolę wizjonerów i agentów zmian, inspirując zespół do przyjęcia innowacyjnych rozwiązań. Relacje z podmiotami zewnętrznymi są kolejnym istotnym czynnikiem. Organizacje mogą korzystać z wiedzy, narzędzi i infrastruktury dostarczanych przez zewnętrznych dostawców rozwiązań GenAI lub instytucje badawcze (Prasad Agrawal, 2024; Rajaram i Tinguely, 2024). Niezależnie od tego, czy wykorzystywane jest rozwiązanie dostarczone przez firmę zewnętrzną, czy opracowane wewnątrz firmy, istotne są także łatwość użytkowania,

możliwość testowania i różnorodność narzędzi (Kshetri i in., 2024). Omówione wyzwania i czynniki sukcesu wdrożeń generatywnej AI zostały przedstawione w Tabeli 9.

2.8. Dyskusja wyników przeglądu literatury identyfikującego elementy modelu

Wnioski z przeprowadzonej analizy są wielowymiarowe i rzucają światło na obecny stan oraz kierunki rozwoju rozwiązań GenAI w procesie rozwoju nowego produktu. Analiza temporalna badanej literatury pokazuje, że większość źródeł pochodzi z lat po 2021 roku, z niewielką liczbą prac opublikowanych wcześniej, co wskazuje na dynamikę rozwoju i rosnące zainteresowanie tematem w ostatnich latach. Warto więc odnotować, że pole GenAI jest jeszcze bardzo młode, a rozwój technologii takich jak na przykład GPT znacznie przyspieszył badania nad ich zastosowaniami. Przeglądowe i bardziej przekrojowe publikacje z niniejszego systematycznego przeglądu literatury w większości zostały opublikowane nie wcześniej niż w drugiej połowie 2023 roku lub w 2024 roku. Dynamika w tej dziedzinie jest więc bardzo wysoka, ale pozostaje wiele miejsca dla innowacji. Analiza dziedzin związanych z publikacjami dla wybranych słów kluczowych wskazuje na interdyscyplinarność zagadnienia – pojawiają się powiązania z dziedzinami dotyczącymi energii, inżynierii materiałowej, IT, medycyny czy zarządzania. Publikacje w dziedzinach nauk technicznych przewyższają jednak te z dziedzin nauk społecznych, co może wskazywać, że wciąż wielu naukowców skupionych jest bardziej na tworzeniu i ulepszaniu rozwiązań generatywnej sztucznej inteligencji niż na wnioskach płynących chociażby z ich implementacji w różnych organizacjach.

W przypadku zastosowań generatywnej AI w procesie rozwoju nowego produktu zauważalny jest znaczący nacisk na generowanie tekstu. BERT wyłania się jako podstawa dla wielu rozwiązań, co świadczy o jego adaptacyjności i potencjale jako fundamentu dla bardziej zaawansowanych systemów. GenAI często stanowi element większego ekosystemu rozwiązań AI, co wskazuje na potrzebę integracji różnorodnych technologii. Generowanie i analiza obrazów czy wideo są mniej reprezentatywne – obserwuje się wciąż niedużą liczbę zastosowań takich narzędzi jak DALL-E czy CLIP (lub innych multimodalnych rozwiązań), szczególnie w kontekście generowania obrazów, co może wskazywać na potencjał do rozwoju w tych obszarach. Zaskakująco mało jest również badań skupiających się na asystentach opartych na rozwiązaniach GenAI w kontekście

Tabela 9. Wyzwania i czynniki sukcesu wdrożeń rozwiązań generatywnej AI.

Elementy	Opis
Wyzwania	Obawy pracowników o ograniczenie autonomii, utratę pracy oraz brak zrozumienia algorytmów generatywnej AI Brak wiarygodności algorytmów generatywnej AI, obawa o halucynacje Wyzwania etyczne – potencjalna dezinformacja, uprzedzenia w danych treningowych Niejasna odpowiedzialność za błędy Wyzwania związane z bezpieczeństwem i ochroną danych w procesach szkoleniowych AI Opracowanie odpowiedniej strategii wdrożenia rozwiązań generatywnej AI Koszty infrastruktury i szkolenia pracowników
Czynniki sukcesu	Zrozumienie wymagań sprzętowych, oprogramowania oraz doświadczenia użytkownika dla danej branży Zrozumienie elementów składowych modeli oraz metryk oceny wydajności Liderzy inspirujący pracowników do przyjęcia zmian związanych z generatywną AI Korzystanie z wiedzy, narzędzi i infrastruktury zewnętrznych dostawców Łatwość użytkowania, możliwość testowania i dostępność różnorodnych narzędzi generatywnej AI

Źródło: opracowanie własne.

rozwoju nowego produktu, co może sugerować niezagospodarowaną niszę badawczą lub aktualnie niewykorzystany potencjał tych technologii.

Rozwiązania GenAI szczególnie dobrze radzą sobie w fazach generowania pomysłów na produkt, projektowania i testowania produktów oraz generowania materiałów marketingowych dotyczących produktu. W dziedzinie analizy opinii klientów, generatywna AI odgrywa kluczową rolę. Dzięki zdolności przetwarzania i analizowania ogromnych ilości danych z różnych źródeł – w tym mediów społecznościowych, recenzji klientów i ankiet – AI może identyfikować trendy i wskazywać obszary do poprawy w produktach i usługach. Ta głęboka analiza wykracza poza

powierzchowne wnioski, zagłębiając się w opinie i preferencje klientów, co może być kluczowe dla ciągłego doskonalenia produktów i procesów. Rozumiejąc opinie klientów na poziomie szczegółowym, firmy mogą podejmować świadome decyzje dotyczące projektowania produktów, ulepszeń funkcji i usprawnień usług. Ta proaktywna metoda analizy opinii klientów pomaga firmom wyprzedzać trendy rynkowe i dostosowywać swoją ofertę bardziej zgodnie z potrzebami klientów, prowadząc do zwiększenia ich satysfakcji i lojalności.

Badania wskazują, że integracja generatywnych algorytmów sztucznej inteligencji do automatycznego projektowania stanowi znaczny postęp w procesie rozwoju produktu. Technologia ta może automatycznie generować różnorodne opcje projektów i prototypów, znacznie przyspieszając proces iteracji. W tradycyjnych metodach, tworzenie wielu prototypów projektowych jest często czasochłonne i wymaga dużej liczby zasobów, ograniczając zakres eksploracji i innowacji. Dzięki rozwiązaniom GenAI, projektanci i inżynierowie mogą szybko generować i oceniać szerokie spektrum alternatywnych rozwiązań projektowych, umożliwiając bardziej efektywną i kreatywną eksplorację możliwości. Ta zdolność do szybkiego prototypowania jest szczególnie cenna w branżach, gdzie innowacje projektowe są kluczowe – takich jak rozpoznane w przeglądzie literatury branża modowa, medyczna czy branża gier. Pozwala zespołom eksplorować bardziej innowacyjne rozwiązania i osiągać optymalne projekty szybciej niż kiedykolwiek wcześniej, znacząco skracając cykl rozwoju produktu i zwiększając potencjał przełomowych innowacji. Ponadto, GenAI ułatwia zwiększoną personalizację i dostosowanie w projektowaniu produktów. Na rynku, gdzie preferencje konsumentów coraz bardziej skłaniają się ku spersonalizowanym produktom, zdolność AI do szybkiego dostosowywania projektów do indywidualnych specyfikacji stanowi znaczącą przewagę. Ta zdolność rozciąga się poza zwykłe dostosowania estetyczne (kolor, kształt), umożliwiając dostosowanie funkcjonalnych aspektów produktu do spełnienia konkretnych potrzeb lub preferencji użytkownika. Ten poziom dostosowania, osiągnięty efektywnie dzięki AI, umożliwia firmom zaspokajanie potrzeb niszowych rynków i indywidualnych potrzeb klientów, zapewniając konkurencyjną przewagę na rynku.

Badania literaturowe wskazują, że zastosowanie GenAI podczas testowania produktu stanowi także znaczący postęp, szczególnie w procesach produkcyjnych i wytwarzania. Systemy GenAI, szczególnie te wyposażone w zdolności wizyjne, mogą być szkolone do inspekcji produktów z

wysoką precyzją, identyfikując defekty i niezgodności z poziomem dokładności i spójności, który znacznie przewyższa możliwości ludzkie. Ten postęp technologiczny jest kluczowy w branżach, gdzie kontrola jakości jest najważniejsza, takich jak produkcja motoryzacyjna, lotnictwo, metalurgia, przemysł ciężki. Poprzez poprawę dokładności i niezawodności procesów kontroli jakości, rozwiązania GenAI pomagają redukować wskaźnik zwrotów produktów lub ich wycofywania, tym samym podnosząc ogólną jakość produktów. Zapewnia to nie tylko satysfakcję klientów, ale także pomaga w utrzymaniu reputacji marki i redukcji kosztów związanych z wadliwymi produktami.

Co więcej, rozwiązania GenAI takie jak ChatGPT mogą także opracowywać treści reklamowe (tekst, zdjęcia i filmy), cyfrowe strategie marketingowe, reklamy czy filmy promocyjne. Dzisiaj klienci mają różnorodność wyboru produktów i usług poprzez różne platformy oraz krótszy czas uwagi na przetwarzanie informacji. W związku z tym, aby przyciągnąć uwagę docelowej publiczności online, personalizacja oferty produktów i usług na platformach online stała się normą w branży. Generatywna sztuczna inteligencja może pomóc w znacznej personalizacji treści poprzez porównanie historii przeglądania i poprzednich zakupów potencjalnego klienta z innymi dostępnymi cyfrowymi śladami. Te dynamiczne oferty w czasie rzeczywistym mogą skutkować wyższą konwersją ofert promocyjnych. Na przykład użytkownicy otrzymują spersonalizowane reklamy i oferty na podstawie wyświetleń, polubień, komentarzy i innych parametrów zaangażowania w czasie rzeczywistym. Może to prowadzić do lepszego doświadczenia klienta (*customer experience – CX*), większej liczby konwersji i poprawy rentowności.

Powyższe wyniki podkreślają, że wdrożenie generatywnej AI w organizacjach stanowi złożone wyzwanie, w którym kluczową rolę odgrywają aspekty techniczne, społeczne, etyczne oraz strategiczne. Dyskusja wyników powinna zatem skoncentrować się na kilku głównych obszarach:

- **Aspekty techniczne i kompetencyjne**

Wyniki wskazują, że złożoność algorytmów generatywnej AI, wynikająca z liczby parametrów i skomplikowanych procesów obliczeniowych, może prowadzić do nieufności wśród pracowników, którzy nie rozumieją mechanizmów decyzyjnych tych systemów. Ta nieprzejrzystość dodatkowo potęguje problem tzw. halucynacji, czyli generowania błędnych lub wprowadzających w błąd informacji. W związku z tym konieczne jest wdrożenie programów rozwoju kompetencji, które umożliwią pracownikom lepsze

zrozumienie technologii oraz zwiększą ich zaangażowanie. Edukacja w zakresie korzystania z narzędzi AI, a także szkolenia dotyczące interpretacji wyników generowanych przez te systemy, mogą stanowić kluczowy element strategii wdrożeniowej.

- **Społeczne i psychologiczne bariery wdrożeniowe**

Istotnym wyzwaniem jest także opór pracowników, którzy mogą postrzegać generatywną AI jako zagrożenie dla ich autonomii i ekspertyzy. Sprzeciw wobec wykorzystania ich twórczości jako danych treningowych bez odpowiedniej rekompensaty świadczy o potrzebie wdrożenia mechanizmów ochrony praw autorskich oraz transparentności procesów wdrożeniowych. Przykładowo, jasne komunikowanie celów i korzyści płynących z zastosowania AI może zmniejszyć lęki związane z utratą kontroli i wpływu na procesy decyzyjne. Konieczne jest także zbudowanie kultury organizacyjnej sprzyjającej współpracy między pracownikami a systemami AI, co wymaga zaangażowania liderów jako agentów zmian.

- **Wyzwania etyczne i prawne**

Dyskusja nad etycznymi aspektami wdrożenia generatywnej AI obejmuje kwestie związane z dezinformacją (np. tworzenie *deepfake* 'ów), utrwalaniem uprzedzeń oraz niejasnościami w zakresie odpowiedzialności za błędy systemów AI. Wskazane jest, aby organizacje opracowały wyraźne zasady etyczne dotyczące korzystania z AI, które będą regulowały kwestie odpowiedzialności oraz zapewniały ochronę danych i praw autorskich. Współpraca interdyscyplinarna między ekspertami z dziedziny technologii, prawa oraz nauk społecznych jest tutaj kluczowa, aby wypracować kompleksowe ramy prawne i etyczne, które ograniczą potencjalne negatywne konsekwencje wdrożeń AI.

- **Strategiczne i finansowe aspekty wdrożenia**

Wdrożenie generatywnej AI wiąże się również z koniecznością opracowania adekwatnej strategii adopcji, uwzględniającej budżet inwestycyjny oraz koszty związane z nauką nowych umiejętności i modernizacją infrastruktury technologicznej. Liderzy technologiczni, współpracując z ekspertami ds. danych, muszą zaprojektować strategię, która nie tylko minimalizuje koszty początkowe, ale także zapewnia długoterminowe korzyści wynikające z optymalizacji procesów biznesowych. W tym kontekście

wyzwaniem pozostaje znalezienie równowagi między inwestycjami w nowoczesne technologie a oczekiwanym zwrotem z inwestycji.

Wyniki wskazują na potrzebę holistycznego podejścia w badaniach nad wdrożeniem generatywnej AI. Konieczne jest dalsze zgłębianie zagadnień związanych z wiarygodnością generowanych informacji, opracowywaniem alternatywnych metryk oceny oraz badaniem mechanizmów adaptacji organizacyjnej w obliczu nowych technologii. Interdyscyplinarne badania, łączące perspektywy technologiczne, etyczne, psychologiczne i ekonomiczne, pozwolą na wypracowanie bardziej kompleksowych modeli wdrożeniowych, które uwzględnią różnorodne wyzwania.

Powyższe wyniki rzucają także światło na złożoność czynników wpływających na sukces wdrożenia rozwiązań generatywnej sztucznej inteligencji w organizacjach. W dyskusji warto podkreślić, że zarówno elementy podstawowe, jak i zaawansowane mają kluczowe znaczenie dla osiągnięcia wysokich wyników ekonomicznych, takich jak wzrost wskaźnika EBIT. Z jednej strony fundamentalne aspekty – w tym myślenie projektowe, jasny model zarządzania AI oraz rozwój kompetencji pracowników – wskazują, że przyjęcie technologii AI nie może ograniczać autonomii zespołów ani pomijać kwestii edukacyjnych. Wdrażanie szkoleń oraz dostarczanie praktycznych narzędzi dla pracowników nietechnicznych stanowi bowiem warunek wstępny do efektywnego wykorzystania potencjału technologicznego.

Z drugiej strony bardziej zaawansowane czynniki, takie jak jednolity słownik danych i zharmonizowane procesy etykietowania, podkreślają wagę spójności i standaryzacji informacji w organizacji. Regularna aktualizacja modeli oraz współpraca z podmiotami zewnętrznymi umożliwiają ciągłe doskonalenie narzędzi AI, co przekłada się na ich praktyczną użyteczność i zdolność adaptacji do zmieniających się warunków rynkowych. Wyniki badań McKinsey (2021) jednoznacznie wskazują na znaczące korzyści materialne, takie jak redukcja kosztów i wzrost przychodów, co sugeruje, że odpowiednio przemyślane strategie wdrożenia AI mogą mieć istotny wpływ na wyniki finansowe przedsiębiorstwa.

W obszarze rozwiązań generatywnej AI dodatkowo istotne jest precyzyjne określenie wymagań technicznych oraz stosowanie właściwych metryk oceny, takich jak FID i IS. Jednakże wskazane ograniczenia tych metryk, wynikające z ich podatności na uprzedzenia, stanowią wyzwanie metodologiczne. Konieczne wydaje się więc dalsze badanie i rozwój alternatywnych paradygmatów oceny, które pozwolą na bardziej rzetelną i obiektywną ocenę wydajności modeli

generatywnych. Ponadto relacje z podmiotami zewnętrznymi, takimi jak dostawcy technologii czy instytucje badawcze, umożliwiają organizacjom dostęp do najnowszych narzędzi i wiedzy, co przyspiesza proces wdrażania oraz podnosi jakość ostatecznych rozwiązań.

Podsumowując, wykorzystanie rozwiązań GenAI w procesie rozwoju nowego produktu jest wciąż bardzo młodą dziedziną badań, z udokumentowanymi publikacjami dotyczącymi szczególnie generowania pomysłów na produkt, projektowania, testowania i marketingu produktowego. Rozwiązania GenAI mogą być wykorzystywane nie tylko do generowania danych, ale także do ulepszania tradycyjnych modeli np. w zadaniach klasyfikacji. Interesującym poznawczo aspektem byłaby większa ilość badań organizacji, weryfikując potencjalne użycia GenAI w praktyce. Wyniki przedstawione w badaniu podkreślają także, że sukces wdrożenia AI zależy od synergii między aspektami technologicznymi, organizacyjnymi i kulturowymi. Wprowadzenie kompleksowej strategii, która łączy rozwój kompetencji wewnętrznych z odpowiednią infrastrukturą technologiczną i otwartością na współpracę z podmiotami zewnętrznymi, może przyczynić się do osiągnięcia przewagi konkurencyjnej. Jednakże ograniczenia obecnych metryk oceny oraz dynamiczny charakter technologii AI wskazują na potrzebę dalszych badań, które pozwolą lepiej zrozumieć i zoptymalizować proces wdrażania tych rozwiązań w różnych kontekstach organizacyjnych.

2.9. Podsumowanie badań literaturowych

Rozdział drugi pracy koncentruje się na analizie literatury przedmiotu i pełni dwojaką funkcję w strukturze rozprawy. Po pierwsze, dokonano systematycznego przeglądu istniejących modeli dojrzałości procesowej, odnoszących się do procesu rozwoju nowego produktu (*New Product Development* – NPD) oraz modeli dojrzałości w zakresie wykorzystania sztucznej inteligencji (*Artificial Intelligence* – AI), w tym generatywnej sztucznej inteligencji. Celem tego etapu było stworzenie podstaw teoretycznych pod opracowanie autorskiego modelu dojrzałości w wykorzystaniu rozwiązań generatywnej AI w procesie rozwoju nowego produktu. Po drugie, przeanalizowano literaturę pod kątem praktycznego zastosowania rozwiązań AI w NPD, identyfikując czynniki sukcesu i wyzwania – działania te wspierają konstrukcję szczegółowych

wymiarów oraz komponentów proponowanego modelu (zgodnie z procedurą badawczą opisaną wcześniej).

Przegląd literatury dotyczący modeli dojrzałości w procesach rozwoju nowych produktów oraz zastosowań sztucznej inteligencji wykazuje szeroki zakres podejść i rozwiązań, które różnią się pod względem poziomów dojrzałości, elementów modeli i domen. W kontekście rozwoju nowych produktów istnieje już wiele modeli dojrzałości, które kompleksowo opisują różne aspekty tego procesu, takie jak zarządzanie projektami, innowacyjność, integracja technologii czy efektywność operacyjna. Ze względu na ich różnorodność i szerokie zastosowanie, wydaje się, że nie ma konieczności tworzenia zupełnie nowych modeli w tej dziedzinie. Lepszym podejściem mogłoby być ulepszanie istniejących narzędzi, dostosowywanie ich do specyficznych potrzeb organizacji lub łączenie najlepszych praktyk z różnych modeli w celu zwiększenia ich użyteczności i skuteczności. Z kolei systematyczny przegląd istniejących modeli dojrzałości w dziedzinie sztucznej inteligencji ujawnia istotną lukę: mimo dostępności kilku uniwersalnych modeli oceniających poziom zaawansowania w AI, zauważalny jest deficyt specjalistycznych narzędzi skupionych na generatywnej sztucznej inteligencji. Generatywna AI, zyskująca na znaczeniu w nowoczesnych aplikacjach biznesowych i technologicznych, potrzebuje odmiennych metod ewaluacji dojrzałości, które uwzględniałyby unikalne charakterystyki i potencjał tej technologii.

W końcowej części rozdziału dokonano systematycznego przeglądu literatury obejmującego zastosowania, wyzwania oraz czynniki sukcesu implementacji rozwiązań generatywnej sztucznej inteligencji w kontekście procesów rozwoju nowego produktu. Badania literaturowe wskazały, że generatywna sztuczna inteligencja znajduje zastosowanie w wielu fazach rozwoju nowego produktu. W fazie generowania pomysłów wspiera analizę sentymentu, eksplorację opinii, tworzenie streszczeń i samodzielne generowanie koncepcji. Na etapie analizy wymagań i oceny ryzyka pozwala na szybszą ocenę pomysłów, przewidywanie zmian oraz automatyzację planowania. W projektowaniu i produkcji GenAI zwiększa kreatywność i pozwala na tworzenie nowych modeli w takich branżach jak moda, meble, medycyna, IT czy architektura. W testowaniu umożliwia generowanie danych syntetycznych, wykrywanie defektów i automatyzację kontroli jakości. W marketingu ułatwia tworzenie treści reklamowych, przewidywanie skuteczności kampanii i personalizację rekomendacji. Wdrożenie GenAI wiąże się jednak z wyzwaniami: oporem pracowników, niskim zaufaniem do algorytmów, ryzykiem halucynacji, problemami

etycznymi (*deepfake*, uprzedzenia, odpowiedzialność za błędy) oraz koniecznością inwestycji w infrastrukturę i szkolenia. W przypadku czynników sukcesu, w przeglądzie literatury podkreśla się znaczenie stosowania zarówno metryk materialnych (np. redukcja kosztów, wzrost przychodów), jak i niematerialnych (np. zmiana kultury organizacyjnej, przewaga konkurencyjna, efekt halo). Omawiane są także konkretne narzędzia oceny modeli generatywnej AI, takie jak FID i IS, oraz potrzeba eksploracji alternatywnych paradygmatów oceny. Czynniki sukcesu obejmują także dobrą znajomość wymagań technicznych i użytkowych, kulturę innowacji, silne przywództwo, wsparcie ekspertów oraz łatwość wdrażania i testowania rozwiązań.

Rozdział 2 odpowiada przede wszystkim na pytanie badawcze 1: zidentyfikowano i porównano istniejące modele dojrzałości procesu rozwoju nowego produktu oraz modele dojrzałości AI, wskazując na możliwość wykorzystania i adaptacji sprawdzonych narzędzi NPD zamiast tworzenia całkowicie nowych oraz na lukę w modelach dojrzałości dotyczących generatywnej AI. W odniesieniu do pytania badawczego 2 przegląd literatury syntetyzuje aktualne i potencjalne zastosowania GenAI w całym cyklu NPD, a także wyzwania oraz czynniki sukcesu. Ten korpus wiedzy zasila listę praktyk i wymiarów wykorzystanych później przy konstrukcji modelu dojrzałości. Zidentyfikowane zastosowania, wyzwania i czynniki sukcesu tworzą punkt wyjścia do empirycznej weryfikacji – dlatego kolejny rozdział przedstawia wyniki częściowo ustrukturyzowanych wywiadów, których celem jest pogłębienie tych ustaleń i przełożenie ich na praktykę wdrażania rozwiązań GenAI w procesie NPD.

Rozdział 3. Wywiady – zastosowania, wyzwania i czynniki sukcesu wprowadzenia rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju nowego produktu

Celem niniejszego rozdziału jest przeprowadzenie oraz przedstawienie wyników częściowo ustrukturyzowanych wywiadów w celu zidentyfikowania rozwiązań generatywnej sztucznej inteligencji (*Generative Artificial Intelligence – GenAI*), które mogą być wykorzystane przez organizacje w procesie rozwoju nowego produktu (*New Product Development – NPD*), wyzwań, przed którymi stają organizacje chcące wdrożyć takie rozwiązania w wymienionym procesie, oraz czynników wpływających na sukces związany ze skutecznym wdrożeniem tych rozwiązań. W niniejszym rozdziale skoncentrowano się na rozwiązaniach generatywnej sztucznej inteligencji, jednak pojawiają się również odniesienia do sztucznej inteligencji ogólnie (ze względu na fakt, że rozwiązania GenAI stanowią podzbiór rozwiązań AI i niekiedy są integralnym elementem szerszych rozwiązań należących do tego zbioru). Na podstawie pracy Beckera, Knackstedta i Pöppelbuşa (2009), przeprowadzenie wywiadów eksploracyjnych ma na celu wsparcie w opracowaniu elementów modelu, co, w połączeniu z wcześniejszymi badaniami literaturowymi w tym temacie, zapewnia triangulację metod. Dzięki temu wyniki wywiadów mogą być konfrontowane z ustaleniami z literatury, co pozwala na głębszą analizę i weryfikację wniosków.

3.1. Wywiady – podejście badawcze

Przeprowadzono częściowo ustrukturyzowane wywiady z ekspertami w kluczowych obszarach AI oraz rozwoju nowego produktu, opierając się na pracy Adamsa (2015). Zastosowano dobór celowy ekspertów w oparciu o kryteria (*purposive expert criterion-based sampling*) (Ritchie i in., 2013), ukierunkowany na respondentów z doświadczeniem w procesie rozwoju nowego produktu i wdrożeniach sztucznej inteligencji. Ze względu na brak oficjalnych rejestrów tej populacji w Polsce, wykorzystano wyszukiwanie w Internecie za pomocą otwartych źródeł: LinkedIna oraz Google, aby zidentyfikować organizacje w Polsce w sektorach powiązanych z wytwarzaniem dóbr (lub produkcją oraz IT – wiele firm zajmujących się produkcją oferowało także, poza dobrami fizycznymi, oprogramowanie lub usługi powiązane z dobrami fizycznymi), które kładły nacisk na szerokie wykorzystanie rozwiązań AI w skali organizacyjnej.

W procesie rekrutacji ochotników wykorzystano pocztę elektroniczną lub wiadomość w serwisie LinkedIn, przekazując informację o badaniu i kryteriach włączenia. Kryteria włączenia obejmowały: ogólne doświadczenie zawodowe wynoszące co najmniej 5 lat, w tym co najmniej 1 rok w zarządzaniu produktem i co najmniej 1 rok pracy związanej z wdrażaniem rozwiązań AI (jako kierownik produktu, programista itp.). Opcjonalnie poszukiwano osób, które oprócz spełnienia powyższych kryteriów, były również zaangażowane w badania, co pomaga lepiej zrozumieć charakter badania oraz ułatwia zbieranie i weryfikację wyników. Wiarygodność była sprawdzana na początku wywiadu – jeśli respondent uznał, że dane online są nieprawdziwe, tj. że organizacja nie była zaangażowana w wykorzystanie rozwiązań AI w procesie rozwoju nowego produktu lub kandydat nie spełniał powyższych kryteriów, wywiad nie był kontynuowany. Łącznie znaleziono 42 kandydatów. 17 osób odmówiło, a 13 osób nie spełniło kryteriów, co dało łącznie 12 wywiadów. Wybrani uczestnicy pochodzili z Polski i reprezentowali dwanaście różnych organizacji. Rekrutację zakończono po osiągnięciu tzw. nasycenia tematycznego (Guest i in., 2006), rozumianego jako brak nowych kodów / tematów w kolejnych wywiadach. Sousa (2014) twierdzi, że różnorodność ze względu na doświadczenie jest bardziej wartościowa dla uzyskania wnikliwego wkładu w badanie niż większa liczba uczestników, a w przeprowadzonym badaniu rozróżnienie między rolą i doświadczeniem zapewniło wystarczającą różnorodność w grupie, aby umożliwić pewien stopień uogólnienia. Podsumowanie zawierające profile uczestników można znaleźć w Tabeli 10.

Podejście częściowo ustrukturyzowane zapewniło kompleksowe objęcie wszystkich obszarów badawczych. Otwarty styl zadawania pytań uzupełniał pytania częściowo ustrukturyzowane, a ankieter odpowiadał na wszelkie pytania wymagające wyjaśnienia. Wywiad pilotażowy udoskonalił pytania, aby zapewnić jasność i skupić się na wszystkich aspektach związanych z zastosowaniami, wyzwaniami i czynnikami sukcesu we wdrażaniu rozwiązań AI w procesie rozwoju nowego produktu.

Informacje zwrotne z wywiadu pilotażowego skłoniły do dodania dwóch dodatkowych pytań. Wywiad został zaprojektowany w formacie odpowiednim zarówno dla wywiadów osobistych, jak i zdalnych. Pytania zostały podzielone na cztery sekcje:

- Sekcja 1, „O tobie”, w której zbierano niezbędne informacje demograficzne, opis roli i doświadczenie w zarządzaniu produktem i rozwiązaniami AI.

Tabela 10. Profil uczestników wywiadów.

Numer respondenta	Aktualna pozycja respondenta	Lata doświadczenia
A1	Inżynier ds. AI	5 lat
A2	Kierownik działu zarządzania produktem	11 lat
A3	Kierownik działu R&D / Naukowiec	10 lat
A4	Product Owner / Kierownik linii produktów AI	5 lat
A5	Założyciel Venture Capital / Naukowiec	15 lat
A6	Kierownik działu Data Science / Naukowiec	6 lat
A7	Kierownik działu AI / Naukowiec	7 lat
A8	Inwestor / Naukowiec	6 lat
A9	CTO / Naukowiec	9 lat
A10	Kierownik produktu	9 lat
A11	Konsultant ds. AI / Naukowiec	6 lat
A12	Kierownik produktu (Senior Product Manager)	8 lat

Źródło: opracowanie własne.

- Sekcja 2, „Wdrożenie rozwiązań GenAI / AI”, w której skupiano się na obecnych i potencjalnych rozwiązaniach GenAI / AI w procesie rozwoju nowego produktu.
- Sekcja 3, „Wyzwania i czynniki sukcesu”, w której badano wyzwania, z którymi respondenci się zetknęli, czynniki sukcesu i metody pomiaru sukcesu.
- Sekcja 4, w której proszono o ewentualne dodatkowe komentarze.

Scenariusz wywiadów można znaleźć w Załączniku 1. Wywiady trwały zwykle od 30 do 90 minut. Upewniano się, że wszyscy respondenci zrozumieli i zinterpretowali pytania w ten sam sposób. Dane zanonimizowano i zabezpieczono. Wszystkie dane zostały zakodowane na podstawie analizy tematycznej (Braun i Clarke, 2012). Analiza tematyczna została przeprowadzona dedukcyjnie (szukano w danych z góry przewidzianych kategorii – zastosowań, wyzwań i czynników sukcesu – tematy niepasujące do tych kategorii zostały wyodrębnione osobno) na semantycznym poziomie znaczeń (to, co wprost pada) w sześciu krokach. Po wielokrotnej lekturze (krok 1) wygenerowano kody początkowe (krok 2). Następnie agregowano kody w kandydatów na tematy (krok 3) i weryfikowano ich spójność z wycinkami oraz całym zbiorem danych (krok 4). Po doprecyzowaniu i nazwaniu tematów (krok 5) przygotowano podsumowania (krok 6), ilustrując każdy temat cytatai. Dane zostały przeczytane raz, po czym zostały przeczytane ponownie, aby potwierdzić, że zidentyfikowane tematy zostały dokładnie uchwycone.

3.2. Wywiady – rezultaty badań

Dane dotyczyły trzech kluczowych obszarów badawczych, a mianowicie zastosowań, wyzwań i czynników sukcesu wdrażania rozwiązań generatywnej sztucznej inteligencji w procesach rozwoju nowego produktu, przy czym z danych wyłoniły się trzy dodatkowe tematy. Sposób, w jaki dane zostały wybrane jako istotne dla kluczowych obszarów badawczych, wynikał z analizy treści tematów. Tematy dotyczące wiedzy i obowiązków menedżera produktu, traktowania doskonalenia procesu jako produktu oraz różnic między AI a GenAI były związane ze wszystkimi trzema kluczowymi obszarami badawczymi i zostały omówione osobno jako tematy przewodnie. Te tematy przewodnie zostały zidentyfikowane poprzez analizę treści i ich związku z ogólnym wdrażaniem rozwiązań sztucznej inteligencji w procesie rozwoju nowego produktu. Najpierw omówiono tematy przewodnie, a następnie każdy z trzech głównych obszarów badawczych i powiązane z nimi tematy. Tabela 11 podsumowuje te wyniki.

Tematy przewodnie

Jak wspomniano powyżej, trzy poniższe tematy określono jako tematy przewodnie, związane ze wszystkimi trzema kluczowymi obszarami badawczymi:

5. Wiedza i obowiązki menedżera produktu;
6. Doskonalenie procesów jako produkt;
7. Różnica między sztuczną inteligencją a generatywną sztuczną inteligencją.

Te tematy są poniżej analizowane w odniesieniu do danych z wywiadów.

Wiedza i obowiązki menedżera produktu: Większość respondentów (A1, A2, A4, A5, A7, A9, A10) zgodziła się, że procesy rozwoju nowego produktu różnią się między organizacjami, co implikuje zróżnicowanie obowiązków menedżerów produktu. Wprowadzenie rozwiązań AI w procesie zależy od obowiązków menedżera produktu: „Zanim zada się pytanie o zastosowania AI w procesie rozwoju nowego produktu, ważne jest, aby zapytać o obowiązki menedżera produktu, ponieważ w każdej organizacji te obowiązki będą się różnić. W jednej organizacji może to oznaczać *product ownera* zarządzającego zespołem programistycznym, w innej menedżera ds. marketingu produktu głównie odpowiedzialnego za kampanię marketingową produktu, a w jeszcze

Tabela 11. Zastosowania, wyzwania i czynniki sukcesu zidentyfikowane na podstawie wywiadów. W nawiasach przedstawiono odniesienia do wywiadów, z których pochodzą dane elementy.

Elementy	Czynniki / zidentyfikowane przykłady
Zastosowania	Codzienne narzędzia wspierające pracę menedżerów produktu, oparte na rozwiązaniach sztucznej inteligencji, zwiększające wydajność i szybkość pracy (A4, A8, A10) Rozwiązania, które uwalniają menedżera produktu od zadań niezwiązanych z podstawowymi obowiązkami dotyczącymi zarządzaniem produktem (A3, A12) Przewodnik w procesie rozwoju nowego produktu, oparty o rozwiązania sztucznej inteligencji, który kieruje menedżerami produktu w podejmowaniu działań na poszczególnych etapach procesu (A4, A6, A11) Narzędzia sztucznej inteligencji wspomagające podejmowanie decyzji biznesowych dotyczących produktu (A6, A9, A10)
Wyzwania	Duży wolumen danych wysokiej jakości i przetwarzanie tych danych w celu podejmowania lepszych decyzji biznesowych (A1 – A12) Podejście pracowników w organizacji do wykorzystania rozwiązań sztucznej inteligencji – głównie nierealistyczne oczekiwania dotyczące tego, co jest osiągalne (A1, A3, A5, A6, A8, A9, A10) Bezpieczeństwo i prywatność danych dotyczących produktu, zwłaszcza gdy dotyczy to wykorzystania tych danych przez zewnętrzne organizacje w celu opracowania narzędzi wspierających pracę menedżera produktu (A1, A4, A5, A7, A8, A11) Zaufanie i możliwość wyjaśnienia przedstawianych menedżerowi produktu danych (A1, A2, A4, A5, A7, A8, A11) Potrzebna moc obliczeniowa do wdrożenia i utrzymania modeli dla rozwiązań sztucznej inteligencji (A9, A10, A11) Brak klarownej metodologii dotyczącej wprowadzania rozwiązań sztucznej inteligencji w proces rozwoju nowego produktu (A1, A11, A12)
Czynniki sukcesu	Odpowiednie mierniki do oceny, w jaki sposób rozwiązanie oparte na sztucznej inteligencji wspierało proces (np. oparte na finansach lub czasie) (A1, A4, A7, A8, A9, A11) Możliwość dokładnej oceny wpływu biznesowego i wykonalności wprowadzonego rozwiązania opartego na sztucznej inteligencji z wyprzedzeniem (A1, A3, A5) Jakość zespołu i współpraca międzydziałowa w całej organizacji (A2, A3, A5, A7, A12) Jeden ogólny słownik danych we wszystkich obszarach organizacji (A2, A12)

Źródło: opracowanie własne.

innej menedżera produktu odpowiedzialnego za mapę drogową i wyniki finansowe produktu [...]. W każdym z tych przypadków wprowadzenie takich zmian może nie być częścią obowiązków menedżera produktu” (A4). Inny respondent dodaje: „Czasem to dyrektor lub najwyższe kierownictwo dyktuje, jak powinien wyglądać proces. Często zależy to również od wielkości organizacji – w dużych korporacjach są dedykowane osoby odpowiedzialne za doskonalenie procesów, podczas gdy w start-upach menedżer produktu ma więcej swobody, ale mniej czasu na doskonalenie procesu, bo skupia się na udowadnianiu wartości produktu” (A5). Respondenci zgadzają się również, że menedżerowie produktu posiadają obecnie ograniczoną wiedzę na temat rozwiązań AI, co stanowi wyzwanie dla propozycji wykorzystania tych rozwiązań w usprawnianiu procesu rozwoju nowego produktu: „Menedżer produktu powinien poświęcić czas na zrozumienie, co jest możliwe w kwestii rozwiązań AI i tego, w jaki sposób te rozwiązania oraz ilość danych wpływają na to, co można osiągnąć” (A2). W niektórych przypadkach problem, który ma rozwiązać model AI, jest zbyt skomplikowany, lub taki przypadek wcześniej nie istniał, co powoduje, że system AI pyta człowieka o odpowiedź, np. AI analizujący sentyment produktu jest niepewny, czy opinia jest pozytywna czy negatywna. Ta metoda jest powszechnie nazywana *Human In The Loop (HITL)*. Respondenci dodają: „Nawet jeśli ten człowiek w pętli to programista, menedżer produktu musi mieć wiedzę na temat procesu i tych rozwiązań, aby w nim uczestniczyć” (A9).

Doskonalenie procesów jako produkt: Wielu respondentów podkreśla, że zanim zacznie się dyskusję na temat zastosowań AI lub wyzwań, należy rozważyć kwestię wdrożenia. „Wprowadzenie każdego narzędzia mogącego pomóc menedżerom produktu w ich codziennej pracy powinno być po prostu traktowane jako stworzenie kolejnego produktu” (A4). Respondenci zauważają, że traktowanie procesu jako produktu porusza również dwie dodatkowe kwestie związane z czasem i finansowaniem takich projektów. Gdyby ciągle proponowano nowe narzędzia do usprawnienia procesu, nie byłoby czasu na zarządzanie i promowanie produktów, które stanowią rdzeń działalności: „Najlepszym sposobem na rozpoczęcie jest prosty produkt o kluczowej funkcjonalności (*Minimum Viable Product – MVP*) dla takiego narzędzia, usprawniającego proces – zbuduj MVP przy niewielkim nakładzie czasu i funduszy, aby zademonstrować jego wartość i pokazać kluczowym interesariuszom. Jednak MVP nie jest gotowe do produkcji i tu tkwi ryzyko – czas od MVP do rzeczywistego wdrożenia” (A12).

Różnica między sztuczną inteligencją a generatywną sztuczną inteligencją: Większość respondentów (A1, A2, A3, A4, A6, A7, A9) podkreśliła, że kiedy jest mowa o wyzwaniach i czynnikach sukcesu związanych z wdrożeniem rozwiązań sztucznej inteligencji lub rozwiązań generatywnej sztucznej inteligencji, nie widzą dużej różnicy: „Niezależnie czy mówimy szerzej o rozwiązaniach sztucznej inteligencji czy skupiamy się tylko na generatywnej sztucznej inteligencji, te wyzwania czy czynniki sukcesu będą w zasadzie takie same, bo i tu, i tu mierzymy się z tymi samymi problemami dotyczącymi danych czy ludzi” (A4). Kolejny z respondentów dodaje: „I tu, i tu pojawiają się te same lub podobne wyzwania. Według mnie warto pytać szerzej, ogólnie o sztuczną inteligencję, bo daje to pełniejszy obraz problemu” (A7). Respondenci zwracają też uwagę na fakt, że pytając o rozwiązania generatywnej sztucznej inteligencji, nie można wykluczać innych rozwiązań, które mogą wspomóc menedżerów produktu: „Trzeba pamiętać, że to często może być mieszanka różnych rozwiązań, gdzie część z nich wcale nie opiera się na technologiach generatywnych, a wciąż są w stanie pomóc *product managerowi* w jego codziennych obowiązkach” (A5). Inny dodaje: „Ograniczenie się do rozwiązań generatywnej sztucznej inteligencji daje dużo mniejsze pole manewru, a może być tak, że w danym narzędziu tylko jakaś jego część opiera się na generatywnej sztucznej inteligencji, a reszta już nie” (A9).

Zastosowania AI w procesie rozwoju nowego produktu

Rozmowy z respondentami na temat zastosowań i narzędzi GenAI i AI w procesie rozwoju nowego produktu koncentrowały się wokół dwóch tematów – obecnych zastosowań i narzędzi oraz tych, które mogą pojawić się w celu wsparcia procesu. Respondenci (A4, A8, A10) omawiali obecne zastosowania i narzędzia GenAI i AI, które obserwują w trakcie rozwoju nowego produktu: „Te rozwiązania podczas procesu rozwoju nowego produktu można zauważyć w mikrouslugach, które sugerują, co napisać, łączą zadania do wykonania i polecają osoby” (A4). Kolejny respondent dodaje: „Te rozwiązania sztucznej inteligencji czy generatywnej sztucznej inteligencji to będą wszystkie narzędzia związane z *Computer Vision*, przetwarzaniem języka naturalnego, automatycznym rozpoznawaniem mowy, przekształcaniem tekstu na mowę, takie jak *Google Docs*, gdzie rozwiązania AI uzupełniają zdanie, mogą pomóc menedżerowi produktu w procesie” (A8). Inny z respondentów podkreśla: „Myślę, że takich rozwiązań opartych o rozwiązania

generatywnej sztucznej inteligencji będzie coraz więcej, a my przestaniemy zwracać nawet na to uwagę, ale będzie nam się pracować szybciej i efektywniej” (A10).

Niektórzy respondenci (A3, A12) wyrazili potrzebę posiadania narzędzia, które uwolniłoby ich od zadań niezwiązanych z produktem: „Bardzo korzystne byłoby, gdyby wprowadzone narzędzie mogło uwolnić menedżera produktu od wszystkich obowiązków niezwiązanych z tworzeniem *roadmapy*, ponoszeniem odpowiedzialności za wyniki finansowe i skupianiem się na nowych grupach docelowych” (A3).

Inni respondenci (A4, A6, A11) wskazują, że byłoby korzystne mieć wsparcie w trakcie faz procesu rozwoju nowego produktu: „Byłoby świetne mieć narzędzie, które pokazuje, na czym się skupić w danym momencie przy tworzeniu produktu, narzędzie, które prowadzi przez proces i pomaga w zarządzaniu” (A4). Jeden z respondentów podkreśla, że zależy to od produktu i opisuje, jak to wygląda w branży odkrywania leków: „Takie rozwiązania są przydatne we wczesnym etapie, czyli przy koncepcji produktu i etapie przeglądania pomysłów, gdzie pewne pomysły trzeba odrzucić, oraz przy projektowaniu produktu, gdzie może sugerować nowe związki chemiczne” (A9).

Kolejnym tematem poruszonym przez respondentów (A6, A9, A10) była pomoc w podejmowaniu decyzji dotyczących produktu: „Rozwiązania mogłyby szczególnie pomóc w kwestiach podejmowania decyzji dotyczących produktu, takich jak wybory modelu biznesowego, sugerowanie, które elementy prototypu testować, czy podpowiadanie, jak przeprowadzić testy A/B” (A6). Inny z respondentów dodaje: „Aktualnie wiele decyzji podejmujemy w sposób mechaniczny, to znaczy, że na przykład musimy przygotować dane, przejrzeć je i bazując na nich podjąć jakąś decyzję, jeśli chodzi na przykład o wycofanie produktu z portfolio z danego kraju, ale gdybyśmy mieli rozwiązanie generatywnej AI, która nie tylko porządkuje sama dane, ale też bazując na nich, sugeruje co zrobić – najlepiej 24/7 – to by było bardzo przydatne” (A10).

Wyzwania związane z wprowadzeniem AI w procesie rozwoju nowego produktu

Podczas wywiadów dotyczących wyzwań związanych z wdrażaniem rozwiązań AI w procesie rozwoju nowego produktu wszyscy respondenci (A1 – A12) zgodzili się, że ilość i jakość dostępnych danych są kluczowe. „Jeśli chcielibyśmy wdrożyć jakiekolwiek rozwiązanie AI, które miałoby pomóc we wszystkich fazach wdrażania produktu i późniejszego zarządzania nim,

organizacja musi dysponować ogromnymi ilościami danych. Ponadto trzeba rozważyć, przy jakiej liczbie produktów, przy jakiej liczbie sprzedaży, ma to sens, aby wprowadzić takie rozwiązanie i jaką decyzję pomoże podjąć menedżerowi produktu” (A2). Kolejny dodaje: „Zdobycie, oczyszczenie i przygotowanie danych tak, aby były gotowe do użycia w modelu AI, to najtrudniejsze i najbardziej czasochłonne zadanie. Nie ma ogólnego programu, który domyślnie zbierałby dane różnych typów, z różnych źródeł i modelował je w taki sposób, żeby były gotowe do implementacji w modelu AI” (A1). Jeden respondent zauważa, że dojrzałość lub gotowość organizacji do korzystania z rozwiązań AI, związana z zebranymi danymi, jest istotnym czynnikiem: „Pracując jako konsultant ds. wdrożeń AI, zdarzały się przypadki, gdzie menedżerowie produktu chcieli usprawnić proces rozwoju nowego produktu, ale klienci porzucali pomysł, ponieważ nie osiągnęli jeszcze poziomu, jeśli chodzi o ilość i jakość danych, aby zacząć korzystać z rozwiązań AI” (A6). Respondenci zauważają także, że przygotowanie samego modelu nie jest trudne i często można użyć istniejących modeli – jeśli organizacja wcześniej wprowadziła na przykład modele do prognozowania sprzedaży, to można użyć tej prognozy w innym procesie po drobnych modyfikacjach.

Brakuje metodologii lub ram, które wskazywałyby, jak korzystać z AI w procesie rozwoju nowego produktu: „Organizacje stosują różne metodyki, modele i techniki przy tworzeniu nowych produktów, takie jak *CRISP-DM*, *AgilePM*, *TDSP* i inne, ale nie ma metodologii ani modelu, który instruowałby, jak najlepiej podejść do produktów opartych o AI czy to jeśli chodzi o tworzenie narzędzia wspierającego proces, czy kiedy AI jest częścią produktu” (A12). Jeden z respondentów proponuje *MLOps* jako potencjalne rozwiązanie: „*MLOps* jako zbiór praktyk zwykle nie jest przeznaczony do rozwoju nowego produktu AI, ale mógłby stanowić podstawę dla metodyki lub ram” (A1). Jednak zdaniem innego respondenta, tworząc taką ramę na podstawie innej, trzeba zapytać: „Różne firmy mają różne podejścia do rozwoju produktu, dlatego, jeśli mielibyśmy włączyć rozwiązania AI, które pomagają menedżerowi produktu, pojawia się pytanie: jaka byłaby z tego korzyść? Musielibyśmy mieć jakieś miary, które oceniają, w jaki sposób dane rozwiązanie AI pomaga, czyli czy przyspiesza proces o X%, czy zmniejsza koszty o Y%, itp.” (A11).

Kolejnym istotnym czynnikiem, który był wspomniany wcześniej i stanowi znaczne wyzwanie według części respondentów (A1, A3, A5, A6, A8, A9, A10), jest postawa ludzi w organizacji wobec korzystania z rozwiązań AI — menedżerów produktu, inżynierów i kadry kierowniczej. „Kiedy jeszcze pracowałem jako inżynier AI i miałem spotkania z menedżerem produktu

dotyczące propozycji wdrożenia tych rozwiązań, nawet takich, które mogły pomóc menedżerowi produktu na co dzień, ważne były twarde, zimne liczby” (A3). Inny dodaje: „Często rozmawiałem z kolegami pracującymi jako *data scientist* i zaskakująco często wolą pracować nad projektami, gdzie nie muszą wdrażać modeli AI. Wynikało to z faktu, że kadra kierownicza często kazała im poprawić dokładność modeli w nieskończoność, co nie oszczędzało tyle pieniędzy, ile pierwotnie myśleli kierownicy” (A1). Inny z respondentów wskazuje: „Zdarzało mi się pracować z osobami, które mówiły, że AI to bańka i że większość ludzi niepotrzebnie ekscytuje się tymi rozwiązaniami, bo one nie są w stanie pomóc w tak dużym stopniu, w jakim ludziom się wydaje. Dla mnie jest to kwestia braku świadomości i odpowiednich szkoleń i pokazania, jak dana technologia może pomóc w procesie czy w codziennej pracy” (A10).

Kolejnym, często wspominanym (A1, A4, A5, A7, A8, A11), wyzwaniem była kwestia bezpieczeństwa i prywatności, zwłaszcza jeśli produkt był wdrażany w sektorach wrażliwych na te czynniki: „Pracując nad produktem wdrożonym na przykład w bankach czy instytucjach medycznych, nawet jeśli rozwiązanie AI nie obsługuje samego produktu, lecz proces, kwestie bezpieczeństwa i prywatności są na pierwszym planie” (A7). Kolejny dodaje: „Powiedzmy, że chcesz wprowadzić rozwiązanie AI, które wspiera proces rozwoju nowego produktu – jeśli go nie opracujesz sam, istnieje duże ryzyko związane z użyciem zewnętrznych firm i narzędzi przez udostępnianie im danych. W takich przypadkach chcesz dokładnie wiedzieć, kim jest firma, która wprowadza takie rozwiązanie dla ciebie” (A5).

Kilku respondentów (A1, A2, A4, A5, A7, A8, A11) również podkreśla wyzwania związane z zaufaniem i zrozumieniem rozwiązań AI: „Jeśli mielibyśmy program, który sam by przetwarzał dane, wprowadzał je do modelu, a na tej podstawie podejmowałby jakieś działania lub decyzje, pojawia się kwestia zaufania do całego tego procesu – czy jesteśmy w stanie ufać decyzjom AI bez żadnego nadzoru?” (A1). Inny respondent proponuje rozwiązanie: „Jeśli menedżer produktu korzystałby z modeli AI do wspierania procesu, lepiej byłoby wyjaśnić przewidywanie, zamiast tylko je pokazywać – zamiast zastępować człowieka, możemy mu pomóc. Mamy tu rozwiązanie *Human In The Loop*, ale z dodatkiem nadludzkich zdolności” (A4). Podobnie jak w przypadku bezpieczeństwa i prywatności, czynniki zaufania i zrozumienia są istotne w pewnych konkretnych dziedzinach: „W zależności od tego, w czym rozwiązanie AI miałoby pomóc w procesie rozwoju nowego produktu, ważne jest pamiętać, że tam, gdzie mamy do czynienia z produktami

finansowymi, medycznymi lub związanymi z centrami danych, znacznie większy nacisk kładzie się na wyjaśnienie tego, co się dzieje, niż w innych sektorach” (A11).

Jeden czynnik wymieniony przez respondentów, który często nie jest uważany za wyzwanie w projekcie, to moc obliczeniowa: „Podczas wdrażania rozwiązania AI niezależnie od procesu, ludzie często zapominają, jak istotna jest moc obliczeniowa potrzebna do wygenerowania modeli. Czasami może to nawet zatrzymać cały projekt” (A11). Jeden z respondentów wskazuje: „Innym wyzwaniem jest moc obliczeniowa – mieliśmy z tym problemy i musieliśmy posiłkować się zewnętrznym klastrem obliczeniowym” (A10). Kolejny dodaje: „Podczas wdrażania rozwiązania AI ludzie zazwyczaj szacują koszty wdrożenia modeli, ale bardzo często zapominają o oszacowaniu kosztów korzystania z modelu. Później okazuje się, że model jest używany setki razy w krótkim czasie, co pochłania ogromne ilości mocy obliczeniowej” (A9).

Czynniki sukcesu wdrażania rozwiązań AI w procesie rozwoju nowego produktu

Respondenci uznali za trudniejsze omówienie czynników sukcesu przy wdrażaniu rozwiązań AI w procesie rozwoju nowego produktu w porównaniu z wcześniejszymi dyskusjami na temat wyzwań. Niektórzy respondenci (A1, A4, A7, A8, A9, A11) podkreślają konieczność posiadania odpowiednich metryk, np. finansowych. Jeden z respondentów stwierdza: „Definiujemy sukces produktu finansowo – mamy plan finansowy i jeśli produkt spełnia ten plan, to jest sukces. Jeśli wprowadzimy narzędzie, które poprawia proces tworzenia tego produktu lub ułatwia pracę menedżera produktu, to powinno to przekładać się na bardziej udany produkt. Kwestia polega tylko na tym, jak to zmierzyć” (A4). Inny respondent podnosi również kwestię odpowiednich metryk: „Są dwie drogi – jedna, gdzie mamy dwa podobne produkty o podobnych funkcjonalnościach, przeprowadzamy cały proces rozwoju pierwszego produktu i badamy czas i zasoby, jakie były do tego potrzebne, bez użycia rozwiązań AI, a na drugim przeprowadzamy ten sam proces, ale z narzędziami AI i porównujemy — ale to bardzo czasochłonne. Druga droga to taka, gdzie mamy narzędzie AI i patrzymy, jak menedżer produktu radzi sobie z tym narzędziem i bez niego. W tym drugim przypadku trzeba byłoby wprowadzić jakieś skwantyfikowane miary” (A7). Jeden z respondentów uważa, że taka miara mogłaby być wynikiem satysfakcji, ale trzeba zachować ostrożność: „Dobrą miarą określenia sukcesu narzędzia AI w procesie może być wynik satysfakcji, czyli badamy zadowolenie osób, które zaczynają korzystać z narzędzia. Jest to jednak także

niebezpieczna miara, ponieważ dużo zależy od ankietowanych osób i wielkości próby, więc wyniki mogą być zniekształcone przez różne czynniki zakłócające” (A8).

Inni respondenci (A1, A3, A5) przedstawili miarę w kontekście wykonalności i wpływu na biznes wdrożonego rozwiązania: „Pracując jako konsultant dla wielu firm nad rozwiązaniami z zakresu danych i AI, sukces odniosły te firmy, które w procesie dla wdrożonego rozwiązania potrafiły z góry dobrze odpowiedzieć na pytanie o to, jak ważne i wykonalne jest to rozwiązanie. Aby ocenić wykonalność, trzeba odpowiedzieć na pytania, czy dostępne są dane, czy te dane są reprezentatywne, czy technologicznie trudno, czy łatwo je opracować, czy dostępna jest wiedza. Aby ocenić wpływ na biznes, często potrzebna jest miara i w zależności od wprowadzanego rozwiązania, możesz przeprowadzić tutaj analizę rynku lub konkurencji, aby określić, jaka ta miara może być” (A5). Kolejny istotny punkt podniesiony przez respondentów, odnoszący się do wykonalności, to zastanowienie się, czy AI jest niezbędne w procesie, nawet gdy dane są dostępne: „Kiedyś mieliśmy projekt, w którym chcieliśmy poprawić menu jednego z naszych urządzeń. W tym celu zebraliśmy dane z różnych urządzeń, aby zobaczyć, których pozycji menu klienci używają, a które nie, a następnie dostosowaliśmy menu tak, aby wszystkie najczęściej używane pozycje były najbardziej widoczne. To jest rozwijanie produktu lub optymalizacja oparta na danych i zastanawialiśmy się nad użyciem AI, ale okazało się, że zrobienie tego bez niej było szybsze” (A1). Inny respondent dodał: „Mieliśmy jeden produkt, w przypadku którego wiedzieliśmy od samego początku, że chcemy używać rozwiązań AI, a konkretnie rozwiązań z zakresu Widzenia Komputerowego i nie było to nawet przedmiotem rozważań, ponieważ alternatywą było zatrudnienie licznej grupy osób, które musiałyby napisać algorytm dla danego procesu produkcyjnego i oznaczyć dane, a praca nad tym projektem zakończyłaby się po kilku miesiącach, a wszyscy ci ludzie musieliby zostać zwolnieni. Oczywiście przeprowadziliśmy analizę kosztów w obu przypadkach, ale chcę podkreślić, że czasami po prostu jest oczywiste, że użycie rozwiązań AI jest znacznie lepsze” (A3).

Kilku respondentów (A2, A3, A5, A7, A12) identyfikuje jako jeden z kluczowych czynników sukcesu jakość zespołu: „Podstawowym ogniwem między wszystkimi udanymi projektami, w których uczestniczyłem jako menedżer produktu, była jakość zespołu. Mam tu na myśli osoby z różnych działów – sprzedaży, zaopatrzenia itp.” (A2). Inny respondent podkreśla znaczenie współpracy między działami: „Kiedyś mieliśmy na celu poprawienie analizy danych związanej z naszymi produktami w dziale menedżerów produktu, aby przyspieszyć pewne funkcje. Okazało

się, że do osiągnięcia tego celu potrzebowaliśmy danych zarówno z działu sprzedaży, jak i zaopatrzenia, aby uzyskać informacje o klientach, od których kupowaliśmy produkty – często ci klienci byli tymi samymi, którzy kupowali od nas produkty. Może to wydawać się zadziwiające, ale te działy nigdy wcześniej nie współpracowały i to dopiero dzięki współdzielonym danym byliśmy w stanie zobaczyć pełny związek z niektórymi firmami. Taka współpraca międzydziałowa była kluczowa, a my, jako menedżerowie produktu, mamy tę szeroką perspektywę, aby coś takiego zainicjować” (A12). Obydwaj powyżsi respondenci (A2, A12) wskazali również, że posiadanie jednego słownika danych w organizacji było ważnym czynnikiem.

3.3. Wywiady – dyskusja wyników

Wyniki tego badania umożliwiły głębsze zrozumienie zastosowań, wyzwań i czynników sukcesu związanych z rozwojem nowego produktu opartym na rozwiązaniach sztucznej inteligencji. Podczas badania pojawiły się również trzy ogólne tematy, które zostały podkreślone przez licznych respondentów podczas badania, które są związane ze wszystkimi badanymi obszarami.

Odnosnie do pierwszego z ogólnych tematów, podniesionego przez respondentów A1, A2, A4, A5, A7, A9, A10, obowiązki kierownika produktu często zależą od rodzaju produktu lub sektora oraz wielkości organizacji. W przypadku mniejszych organizacji istnieje znacznie większe prawdopodobieństwo, że kierownik produktu, oprócz odpowiedzialności za zyski i straty produktu, będzie również pełnił funkcje marketingowe lub będzie odpowiedzialny za zespół programistów, jak określono w wywiadzie A4. W sektorze IT często występuje tylko rola *product ownera*, a kierunek produktu jest determinowany przez kierownictwo. To również kierownictwo często decyduje o ulepszeniach związanych z procesami. Jednak pojawiają się nowe role, takie jak *Product Ops*, których zadaniem jest doskonalenie procesów, dostosowanie i komunikacja związane z produktem. Często osoby w tej roli dostarczają menedżerom produktu odpowiednie dane, umożliwiając im podejmowanie przemyślanych decyzji biznesowych i przejmując od nich bardziej operacyjne i czasochłonne zadania. Taka rola może również zredukować potrzebę, aby menedżerowie produktu mieli szczegółową wiedzę na temat danych i rozwiązań AI, co respondenci A2, A9 i A10 uważają za istotne. Zbadanie wpływu tej nowej roli na funkcjonowanie procesu rozwoju nowego produktu, w kontekście rosnącej komercyjnej powszechności rozwiązań AI czy GenAI, może być fascynującym obszarem badawczym dla przyszłych badaczy.

Co do drugiego ogólnego tematu, związanego z wprowadzaniem doskonalenia procesu jako produktu, rola *Product Ops* może również zajmować się tym zagadnieniem. Jak podnosi respondent A4, każde wdrożenie, w tym doskonalenie procesu, powinno być traktowane jako produkt. Oznacza to również, że głównym motorem tego działania powinien być menedżer produktu. Jednak pojawia się tu trudny problem: jeśli menedżer produktu jest odpowiedzialny za wprowadzanie usprawnień procesów, to odbiera mu to czas przeznaczony na zarządzanie samymi produktami. Dlatego rola taka jak *Product Ops* w ramach swoich obowiązków, może zajmować się doskonaleniem procesu nie traktując tego jako nowego produktu. To jednak nie rozwiązuje problemu finansowania takich usprawnień, co respondent A12 uznaje za istotne. Taka nowa rola mogłaby skoncentrować się na budowie *Minimum Viable Product (MVP)* przy niewielkim budżecie, aby zademonstrować kierownictwu i uzyskać środki finansowe. Z nową rolą lub bez niej, wcześniejsze zidentyfikowanie kluczowych obowiązków menedżerów produktu i określenie sposobu traktowania implementacji narzędzi AI lub GenAI wspierających proces rozwoju nowego produktu może ułatwić ich wdrożenie.

Jeśli chodzi o temat związany z różnicami między rozwiązaniami sztucznej inteligencji oraz generatywnej sztucznej inteligencji, większość respondentów zgodziła się, że wyzwania i czynniki sukcesu są takie same lub bardzo podobne w obu przypadkach. W wywiadzie pilotażowym również pojawiło się to stwierdzenie, stąd w trakcie wywiadów pytano respondentów głównie o rozwiązania generatywnej sztucznej inteligencji, ale wskazując, że mogą być one częścią rozwiązań sztucznej inteligencji ogólnie. W przypadku zastosowań respondenci wskazywali, że ostateczne rozwiązanie jest często połączeniem różnych rozwiązań, czyli nie musi się w całości opierać na generatywnej sztucznej inteligencji, ale jakaś część tego rozwiązania może zawierać komponent GenAI. Stąd respondenci sugerowali, aby nie zamykać się jedynie w obrębie samych rozwiązań GenAI, ale uwzględniać też takie, gdzie GenAI może być jednym składnikiem większego zastosowania.

- Zastosowania AI w procesie rozwoju nowego produktu

Respondenci starali się skupiać na rozwiązaniach generatywnej sztucznej inteligencji, ale, jak wcześniej wspomniano, wskazywali też ogólne rozwiązania sztucznej inteligencji, gdzie rozwiązania GenAI mogły być jedynie częścią. Na podstawie odpowiedzi respondentów,

rozwiązania oparte na sztucznej inteligencji w procesie rozwoju nowego produktu można ogólnie podzielić na cztery segmenty.

Pierwszy segment obejmuje codzienne narzędzia wspierające procesy pracy (na podstawie wywiadów A4, A8, A10). Istnieje wiele rozwiązań AI, które mogą zwiększyć efektywność i skuteczność menedżerów produktu, takie jak narzędzia automatycznie uzupełniające zdania, sugerujące zadania priorytetowe czy identyfikujące obszary do poprawy. Chociaż te narzędzia mogą być dostępne dla wszystkich członków organizacji, kluczowe jest określenie, które z nich są szczególnie korzystne dla menedżerów produktu i w jaki sposób można je zintegrować z ich procesami pracy. Warto zauważyć, że respondenci mieli trudności z dokładnym wskazaniem konkretnych narzędzi i zwykle wskazywali na ogólnie dostępne narzędzia (np. *Google Docs* – respondent A8), które na przykład zaczęły korzystać z rozwiązań AI do automatycznego uzupełniania zdań.

Drugi segment obejmuje narzędzia, które ułatwiają uciążliwe zadania menedżerów produktu, takie jak automatyczne wprowadzanie danych czy generowanie raportów (na podstawie wywiadów A3, A12). Identyfikacja zadań, które są szczególnie czasochłonne dla menedżerów produktu, oraz zastosowanie automatyzacji znacząco poprawia ich produktywność, co może przełożyć się na sukces produktu. W tym przypadku respondenci mieli trudności ze wskazaniem nawet jednego istniejącego narzędzia.

W odniesieniu do trzeciego segmentu, respondenci (A4, A6, A11) wyrazili potrzebę posiadania przewodnika opartego na AI, który może być wykorzystywany w całym cyklu życia produktu, z narzędziami wspomagającymi proces rozwoju nowego produktu. Może to obejmować techniki NLP do analizy opinii klientów czy rozwiązania widzenia maszynowego do badania obrazów produktów. Chatboty oparte na AI lub systemy eksperckie mogą prowadzić menedżerów produktu przez cały proces, ułatwiając podejmowanie lepszych decyzji opartych na dostępnych danych.

Ostatni segment obejmuje narzędzia wspomagające podejmowanie decyzji dotyczących istniejących produktów (jak podkreślają respondenci A6, A9 i A10). Chatboty lub systemy eksperckie mogą pomagać menedżerom produktu w ocenie opinii klientów i podejmowaniu świadomych decyzji dotyczących cech produktu czy strategii rynkowej. Może to obejmować analizę danych z testów A/B, aby zdecydować czy wprowadzić produkt na konkretny rynek, czy zaniechać określonej funkcji.

Podsumowując, chociaż identyfikacja rozwiązań AI szczególnie przydatnych dla menedżerów produktu i ich integracja z procesami pracy są kluczowe dla udanego rozwoju nowego produktu, respondenci mieli trudności z identyfikacją konkretnych rozwiązań. Najczęściej wskazywali na rozwiązania ogólnego zastosowania, które są używane przez więcej, niż tylko menedżerów produktu do wsparcia podstawowej codziennej pracy. Nie było wskazań dotyczących wielu rozwiązań zidentyfikowanych w literaturze, takich jak wykorzystanie rozwiązań przy projektowaniu produktu lub do detekcji anomalii przy testowaniu produktu czy do analizy sentymentu w celu oceny wydźwięku recenzji produktów. Niemniej jednak warto zauważyć, że respondenci wskazywali na wiele obszarów, gdzie sądzili, że rozwiązania mogłyby im pomóc, takich jak przewodnik oparty na AI dla procesu rozwoju nowego produktu czy narzędzie wspomagające podejmowanie decyzji biznesowych dla już zakończonych produktów. Respondenci przyznają, że wdrożenie takich rozwiązań w organizacji oznaczałoby szybsze wykonywanie zadań i większą efektywność.

- Wyzwania i czynniki sukcesu wdrożeń rozwiązań AI w procesie rozwoju nowego produktu

Odpowiedzi respondentów ujawniają, że przyjęcie procesów rozwoju nowego produktu opartych na sztucznej inteligencji stwarza szereg wyzwań dla organizacji. Jednym z takich wyzwań, jak zauważyli wszyscy respondenci (A1 – A12), jest radzenie sobie z przetwarzaniem i obsługą dużych ilości danych wysokiej jakości. Budowanie dokładnych modeli AI, które pomagają menedżerom produktu w podejmowaniu świadomych decyzji, wymaga odpowiednich danych. Organizacje muszą inwestować w technologie zdolne do efektywnego przetwarzania i analizowania ogromnych ilości danych, aby wydobywać znaczące wnioski. Wymaga to znacznej mocy obliczeniowej (jak stwierdzili respondenci A9, A11) i zaawansowanych algorytmów, co może być kosztowne i czasochłonne we wdrożeniu i utrzymaniu. Obawy dotyczące bezpieczeństwa i prywatności są kluczowe w procesie rozwoju nowego produktu opartym na AI (jak zauważyli respondenci A1, A4, A5, A7, A8, A11). Dane produktowe są często poufne, a zewnętrzne organizacje używające tych danych do budowy narzędzi wspomagających dla menedżerów produktu mogą stanowić potencjalne ryzyko dla bezpieczeństwa i prywatności (jak zauważył respondent A5). Organizacje muszą wdrożyć odpowiednie środki bezpieczeństwa, aby chronić dane produktowe i zapewnić ich używanie tylko w celach autoryzowanych. Zaufanie do danych i możliwość wyjaśnienia danych

pokazywanych menedżerom produktu stanowi kolejne wyzwanie, jak zauważono w wywiadach A1, A2, A4, A5, A7, A8 i A11. Menedżerowie produktu muszą zrozumieć procesy podejmowania decyzji przez modele AI, aby podejmować świadome decyzje, w przeciwnym razie pojawia się kwestia pełnego zaufania AI, bez żadnego nadzoru, jak to podniesiono w wywiadzie A4. Organizacje powinny zapewnić, że modele AI są transparentne i możliwe do wyjaśnienia, budując zaufanie do rozwiązań AI, zwłaszcza w sektorach finansowym i medycznym oraz centrach danych, jak zauważył respondent A11. Wszystkie powyższe wyzwania związane z danymi są zgodne z tymi wskazanymi w literaturze, co oznacza, że rozwiązanie tych wyzwań w organizacji ogólnie pomogłoby rozwiązać te wyzwania także dla procesu rozwoju nowego produktu.

Kolejnym wyzwaniem jest podejście ludzi do korzystania z rozwiązań AI w obrębie organizacji, jak zauważyli respondenci A1, A3, A5, A6, A8, A9, A10. Chociaż ogólne nastawienie do rozwiązań AI jest pozytywne i ludzie chcą je wprowadzać, często istnieją nierealistyczne oczekiwania co do ich wpływu na sprzedaż produktu oraz nieporozumienia dotyczące rozwiązań i związanych z nimi kosztów, jak wspomniał respondent A1. Jednym z wniosków dla organizacji jest to, że powinny edukować interesariuszy na temat możliwości i ograniczeń AI, budując realistyczne oczekiwania poprzez programy szkoleniowe, które wyjaśniają korzyści i ograniczenia rozwiązań AI. Wyzwania związane z podejściem ludzi do danych i AI nakładają się również na te związane z literaturą, zwłaszcza jeśli chodzi o brak wystarczającej wiedzy, jeśli chodzi o to, co jest możliwe np. z nieskończonymi ulepszeniami w dokładności modelu (wywiad A1) lub gdy kieruje się przede wszystkim zyskiem (wywiad A3).

Brak klarownej metodologii lub modelu to istotny problem, który pojawił się w wypowiedziach respondentów (A1, A11, A12). *MLOps*, zaproponowane przez respondenta A1 jako podstawa dla takiego nowego modelu, to zbiór praktyk służących wdrażaniu i utrzymaniu modeli uczenia maszynowego i obejmuje pętlę sprzężenia zwrotnego. Taka pętla mogłaby zostać dodana do procesu rozwoju nowego produktu, a menedżer produktu (lub wspomniana wcześniej rola *Product Ops*) byłby odpowiedzialny za śledzenie i utrzymanie takiego procesu. Kolejnym problemem z wprowadzeniem takiego podejścia ramowego, jak zauważył respondent A11, jest to, że jeśli rozwiązania AI są wprowadzane do procesu, powinno być także jasne, jakie korzyści przynosi to procesowi. Oznacza to, że wprowadzając AI w procesie, organizacja powinna wiedzieć, dokąd chce dojść, co może wymagać dyskusji na temat gotowości lub dojrzałości organizacji w

kontekście AI. Wskazania respondentów są zgodne z literaturą pod względem braku klarownej metodologii wprowadzania rozwiązań AI do procesu rozwoju nowego produktu.

Mimo że wszyscy respondenci pracowali przy zarządzaniu produktami, byli dobrze zaznajomieni z rozwiązaniami AI i w dużej mierze zorientowani na badania, wskazanie konkretnych metryk istotnych dla procesów rozwoju nowego produktu opartych na AI okazało się dla nich trudne, ale podkreślili potrzebę takich metryk (jak zauważono w wywiadach A1, A4, A7, A8, A9, A11). Respondenci wskazali, że metryki oceny sukcesu mogą być na przykład finansowe (wywiad A4) lub oparte na czasie (wywiad A7), a organizacje określają te metryki poprzez analizy rynku lub konkurencji. Alternatywnie można byłoby stosować wskaźniki satysfakcji (wywiad A8), ale mogą być to czynniki zakłócające, ponieważ respondent zauważył, że niekoniecznie odzwierciedlają one rzeczywisty sukces rozwiązania. Porównując te wyniki z literaturą, w McKinsey (2021) stosowane były metryki związane z redukcją kosztów lub wzrostem przychodów, więc metryki finansowe oraz wskaźnik satysfakcji, które również zostały wymienione przez respondentów. Inne miary, takie jak ograniczenie ryzyka lub miary niematerialne, takie jak zmiana kultury czy przewaga konkurencyjna, zostały również zidentyfikowane w literaturze, ale respondenci nie uznali ich za kluczowe. Jednym z wniosków dla organizacji jest to, że podczas próby wdrażania rozwiązań AI w procesie rozwoju nowego produktu, powinna zostać zaimplementowana jakaś miara sukcesu (finansowa, oparta na czasie, oparta na satysfakcji lub inna) w celu oceny wdrożenia.

Inni respondenci (A1, A3, A5) wskazali na określenie wpływu na biznes oraz wcześniej rozważaną wykonalność jako kluczowe czynniki sukcesu. Wpływ na biznes odnosi się przede wszystkim do narzuconego celu oraz wspomnianych metryk, uwzględniając wcześniej wspomniane i inne potencjalne wyzwania, co zostało podkreślone przez respondenta A5. W odniesieniu do wykonalności respondenci wskazywali przypadki, gdzie zastosowanie sztucznej inteligencji było oczywiste od początku projektu (wywiad A3), ale także przypadki, gdzie było to rozważane, ale uznano to za zbędne, ponieważ rozwiązanie bez sztucznej inteligencji było szybsze (wywiad A1). Jakość i efektywna współpraca między zespołami są również istotnymi czynnikami sukcesu, jak zauważyło wielu respondentów (A2, A3, A5, A7, A12). Jak pokazał przykład jednego z respondentów (A12), różne działy lub zespoły w organizacji mogą pracować na tych samych danych, ale używać różnych terminów, definicji lub formatów. To może prowadzić do niezgodności i błędów, utrudniając efektywne korzystanie i udostępnianie danych. Ustanowienie jednego słownika danych, jak zauważyli respondenci A2 i A12, który dostarcza wspólnego

zrozumienia definicji, formatów i relacji danych, jest istotne i może zapewnić spójność i dokładność. W odniesieniu do słowników danych, architektury siatki danych (*data mesh*) stanowią stosunkowo nowe podejście do zarządzania danymi, które zyskuje popularność. W architekturze siatki danych, dane są traktowane jako produkt, a poszczególne zespoły są odpowiedzialne za tworzenie produktów danych. Każdy produkt danych jest traktowany jako odrębna jednostka z własnym językiem i schematem specyficznym dla domeny. To podejście umożliwia zdecentralizowane, skalowalne zarządzanie danymi, zachowując jednocześnie wspólne zrozumienie danych w całej organizacji. Posiadanie takiego zrozumienia jest kluczowym składnikiem skutecznego modelu zarządzania wiedzą (*Knowledge Management – KM*). Wdrażanie strategii KM, które obejmują wspomnianą architekturę siatki danych, może skutkować bardziej efektywnym podejmowaniem decyzji dotyczących produktu i poprawą wyników biznesowych. Chociaż wykonalność, wpływ na biznes, jakość zespołu i współpraca są ważnymi czynnikami sukcesu, w literaturze można znaleźć wiele innych, zarówno tych typowo wpływających na sukces produktu (takich jak wartość innowacyjna czy skoncentrowanie na kliencie), jak i tych związanych z wdrażaniem rozwiązania opartego na sztucznej inteligencji (takich jak *design thinking* w opracowywaniu rozwiązań czy angażowanie organizacji zewnętrznych do testowania i walidacji modeli sztucznej inteligencji).

3.4. Podsumowanie zidentyfikowanych zastosowań, wyzwań i czynników sukcesu

W niniejszym rozdziale przeprowadzono wywiady, w celu identyfikacji zastosowań, wyzwań i czynników sukcesu wdrożeń rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju nowego produktu. Identyfikacja ma na celu wsparcie w budowie elementów modelu dojrzałości. Wywiady uzupełniały wcześniej przeprowadzone badania literaturowe, zapewniając triangulację metod, dostarczając więcej informacji i poszerzając zbiór potencjalnych elementów modelu.

W przypadku zastosowań generatywnej sztucznej inteligencji widać było różnice między badaniami literaturowymi a wywiadami. Dzięki systematycznemu przeglądowi literatury możliwa była identyfikacja wielu specyficznych rozwiązań generatywnej AI w różnych fazach procesu rozwoju produktu. Z kolei w wywiadach, respondenci skupiali się na ogólnych grupach rozwiązań (na przykład takich, które mogą pomóc im podejmować lepsze decyzje biznesowe lub być przewodnikiem po procesie rozwoju nowego produktu). Zarówno w przeglądzie literatury, jak i w

wywiadach można było zauważyć, że rozwiązania generatywnej sztucznej inteligencji mogą być częścią większego rozwiązania sztucznej inteligencji. Wskazywali na to niektórzy respondenci, pokazując np. model BERT, będący częścią szerszego rozwiązania.

Jeżeli chodzi o wyzwania, zarówno systematyczny przegląd literatury, jak i wywiady podkreślają, że aspekty techniczne stanowią istotną barierę przy wdrażaniu AI i zwracają uwagę na złożoność algorytmów, kwestie związane z mocą obliczeniową oraz trudności związane z przygotowaniem i jakością danych. W obu pojawia się także problem zaufania do rozwiązań AI – zarówno w kontekście wiarygodności generowanych informacji (np. halucynacje, błędy decyzyjne), jak i w zakresie zaufania do procesów przetwarzania danych oraz decyzji podejmowanych przez modele. Pojawiają się także podobieństwa w przypadku społecznych barier wdrożeniowych, czyli oporu pracowników jako kluczowego czynnika utrudniającego adopcję rozwiązań.

Respondenci zwracają także uwagę na konieczność określenia odpowiednich miar sukcesu. Podkreślają potrzebę ustalenia wskaźników finansowych oraz operacyjnych, które umożliwią porównanie efektywności wdrożeń generatywnej AI (np. analiza czasu, zasobów, satysfakcji użytkowników). Wskazywana jest także rola kultury organizacyjnej i współpracy. W literaturze podkreśla się wpływ jakości liderów oraz relacji z podmiotami zewnętrznymi na sukces wdrożeń generatywnej AI, a z kolei respondenci zwracają uwagę na znaczenie współpracy między działami oraz jakości zespołu.

Rozdział 3 przede wszystkim wzmacnia pytanie badawcze 2: empirycznie identyfikuje aktualne i potencjalne zastosowania GenAI w NPD, a także wyzwania i czynniki sukcesu. Wyniki te dostarczają treści do operacjonalizacji pomiaru (warstwy, praktyki, metryki), co bezpośrednio wspiera pytanie badawcze 3. Kolejnym krokiem jest opracowanie modelu dojrzałości w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju nowego produktu, wykorzystując informacje z wcześniej wykonanej analizy modeli i badań literaturowych oraz z wykonanych w tym rozdziale wywiadów.


Rozdział 4. Opracowanie modelu dojrzałości w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju nowego produktu

Celem poniższego rozdziału jest opracowanie modelu dojrzałości w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji (*Generative Artificial Intelligence – GenAI*) w procesie rozwoju nowego produktu (*New Product Development – NPD*), bazując na podejściu nauk o projektowaniu (*Design Science Research – DSR*) według Beckera, Knackstedta i Pöppelbußa (2009). W rozdziale przedstawiono definicję problemu, określono strategię budowy modelu, uwzględniając krytykę aktualnych modeli oraz opracowano iteracyjnie model, wykorzystując informacje z poprzednich rozdziałów. Pokazano także budowę narzędzia odpowiadającego za część preskryptywną modelu oraz sprawdzono wiarygodność modelu z ekspertami.

4.1. Podejście badawcze

Podejście badawcze Autora do budowy modelu opiera się na paradygmacie znanym jako nauki o projektowaniu (*Design Science Research – DSR*), zaprezentowanym przez prof. Alana Hevnera (Hevner i in., 2004) i rozwiniętym dla modeli dojrzałości przez prof. Jörga Beckera⁴ (Becker i in., 2009). Uznaje się go za sprawdzony sposób organizacji prac naukowych dotyczących analizy wpływu innowacji technologicznych na rzeczywistość. Opracowanie modelu obejmuje następujące etapy projektowe: definicja problemu, porównanie istniejących modeli dojrzałości, określenie strategii budowy modelu, iteracyjny rozwój modelu, koncepcja transferu i ewaluacji, implementacja mediów oraz ewaluacja modelu. Rysunek 7 przedstawia ogólne podejście badawcze.

⁴ Zarówno prof. Alan Hevner, jak i prof. Jörg Becker są jednymi z najczęściej cytowanych osób, jeśli chodzi o projektowanie modeli (w przypadku prof. Beckera szczególnie projektowanie modeli dojrzałości) – prace prof. Hevnera na temat DSR były cytowane ponad 25000 razy (profesor był cytowany łącznie ponad 44000 razy), praca prof. Beckera dotycząca projektowania modeli dojrzałości była cytowana ponad 1700 razy (łącznie ponad 28000 cytowań wszystkich prac).



Rysunek 7. Podejście badawcze.

Źródło: opracowanie własne, bazując na pracy Beckera, Knackstedta i Pöppelbußa (2009).

4.2. Definicja problemu

Opierając się na pracy Beckera, Knackstedta i Pöppelbußa (2009) oraz aktualnie dostępnych modelach dojrzałości, definicja problemu pokrywa się z przesłankami oraz sformułowaniem problemu badawczego wymienionymi we Wprowadzeniu do niniejszej pracy. Tematyka rozważań opiera się na rosnącym wpływie sztucznej inteligencji (AI), szczególnie generatywnej AI, zarówno na poziomie mikro (organizacje i procesy), jak i makro (gospodarka). Jak napisano we Wprowadzeniu, w raporcie Polskiej Agencji Rozwoju Przedsiębiorczości generatywna AI jest przedstawiana jako kluczowy trend, a przewidywania dotyczące jej rynku wskazują na znaczny wzrost. Model dojrzałości pomaga firmom określić ich aktualną pozycję. Dzięki niemu menedżerowie mogą uzyskać wgląd w postępy w dziedzinie AI, co umożliwia krytyczną ocenę wydajności organizacji oraz podjęcie działań mających na celu optymalizację. Aby to osiągnąć, konieczne jest ustalenie poziomu dojrzałości (Schuster i in., 2021). Model opracowany w niniejszej rozprawie ma na celu wspieranie firm w ulepszaniu procesu rozwoju nowego produktu poprzez wykorzystanie rozwiązań generatywnej AI i ma pełnić rolę narzędzia, które zwraca uwagę na potencjalne zaniedbanie wykorzystania rozwiązań generatywnej AI w procesie rozwoju nowego produktu. Znaczenie proponowanego modelu zostało potwierdzone w wywiadach z dwunastoma specjalistami zajmującymi się procesami rozwoju nowego produktu. Identyfikacja obecnych słabości i przyszłych obszarów do działania za pomocą modelu dojrzałości spotkała się z pozytywnym przyjęciem – eksperci ocenili proponowany kierunek jako użyteczny dla praktyki.

4.3. Określenie strategii budowy modelu

Becker, Knackstedt i Pöppelbuß (2009) wśród najważniejszych strategii bazowych budowy modelu wyróżniają budowę całkowicie nowego modelu, udoskonalenie istniejącego modelu, połączenie kilku modeli w jeden nowy oraz transfer struktur lub zawartości z istniejących modeli do nowych obszarów zastosowań. Nie jest konieczne wybranie tylko jednej strategii – np. Fukas i in. (2021) budują swój model, opierając się na zintegrowanym podejściu łączącym trzy z wcześniej wymienionych strategii. Analiza istniejących modeli dojrzałości AI ujawniła kilka naukowych prób (z których część spełnia kryteria przedstawione przez Beckera, Knackstedta i Pöppelbuß (2009)). W związku z tym, zdaniem Autora niniejszej rozprawy, nie ma potrzeby tworzenia zupełnie nowego modelu od podstaw, ponieważ każde podejście oferuje interesujące i unikalne pomysły. W pracy wykorzystano zintegrowane podejście polegające na transferze struktur lub treści z istniejących modeli do nowych obszarów zastosowań oraz udoskonaleniu istniejącego modelu. Przed przystąpieniem do budowy modelu konceptualnego Autor pragnie jednak odnieść się do krytyki obecnych modeli dojrzałości, która została omówiona w rozdziale pierwszym, dążąc do stworzenia modelu możliwie najbardziej odpornego na krytykę. W poniższych punktach wymieniono najistotniejsze kwestie oraz odpowiedzi Autora.

1. Model zbyt skomplikowany / czasochłonny / wymagający zbyt dużej liczby zasobów i zaangażowania (Kuilboer i Ashrafi, 2000; Reifer, 2000)

Taka krytyka w literaturze dotyczy głównie modelu CMMI, z czym Autor się zgadza. Podobnie model OMG-BPMN może wydawać się dość skomplikowany przy pierwszym podejściu. Większość modeli nie wydaje się tak rozbudowana jak CMMI czy OMG-BPMN, ale może to wynikać z faktu, że często brakuje odpowiedniej dokumentacji, a badacz, czytając artykuł opisujący model, nie jest świadomy, jak bardzo rozbudowany może być sposób oceny (np. poprzez kwestionariusz z pytaniami). Należy jednak zaznaczyć, że modele dojrzałości zazwyczaj badają wiele wymiarów organizacji w danej dziedzinie, a każdy z tych wymiarów obejmuje określoną liczbę elementów, których sprawdzenie wymaga czasu.

2. Zbyt duża liczba modeli (Röglinger i in., 2012) / Podobieństwo dużej liczby istniejących modeli (Albliwi i in., 2014) / Niezadowalająca dokumentacja (Albliwi i in., 2014; Becker i in., 2009)

Zdecydowano się odnieść do krytyki dotyczącej zbyt dużej liczby modeli, ich podobieństwa oraz niezadowalającej dokumentacji w jednym punkcie, ponieważ, zdaniem Autora, można ograniczyć liczbę modeli poprzez ponowne wykorzystanie tych, które już istnieją w literaturze, jednak problemem jest brak wystarczającej dokumentacji do ich ponownego użycia. Zgodzono się, że większość istniejących badań nad modelami dojrzałości zawiera opisy poziomów oraz czasami wizualizacje, takie jak wykresy radarowe, które pokazują, jak firmy radzą sobie w różnych wymiarach. Jednakże istotnym problemem tych modeli jest często niedostępność kwestionariuszy z pytaniami, które mogłyby być używane do oceny tych poziomów. W artykule Sassanelliego, Rossi i Terziego (2020) autorzy używają wcześniej wspomnianego modelu CLIMB, w połączeniu z modelem gotowości cyfrowej DREAMY. Autor próbował skontaktować się mailowo z twórcami obu tych modeli (oraz innych), aby uzyskać dostęp do dodatkowej dokumentacji, jednak nie otrzymał żadnej odpowiedzi. Utrudnia to ponowne wykorzystanie istniejących modeli dokładnie w takiej formie, w jakiej czynili to autorzy modelu i skutkuje koniecznością (choć w pewnym stopniu) budowy nowych. Mimo to można wykorzystać już istniejące modele, takie jak model CLIMB, aby ograniczyć liczbę pojawiających się w literaturze modeli, budując własny kwestionariusz pytań. Należy jednak zaznaczyć, że ocena organizacji przy użyciu własnego kwestionariusza może nieznacznie różnić się od tej uzyskanej w pierwotnym modelu, na przykład ze względu na inną formę zadanego pytania dotyczącego danej praktyki w danym wymiarze.

Wiele modeli dostępnych w literaturze opiera się na modelu CMM/CMMI, więc nie jest zaskoczeniem, że są one do siebie podobne. Autor jednak nie uważa tego za problem. Röglinger, Pöppelbuß i Becker (2012) podkreślają, że istnieje zbyt wiele różnych modeli, więc gdyby te już istniejące były bardziej zbliżone do siebie, to po pierwsze, organizacje, wybierając dowolny z dostępnych modeli, miałyby wysokie prawdopodobieństwo uzyskania zbliżonych wyników w ocenie dojrzałości. Po drugie, łatwiej byłoby porównywać różne firmy, nawet jeśli korzystałyby z innych modeli.

3. Brak bazowania na teorii, naukowych wytycznych / bezrefleksyjne przyjmowanie szablonu CMM (Albliwi i in., 2014)

Jeśli chodzi o bezrefleksyjne przyjmowanie szablonu CMM, z jednej strony jest to sprawdzony model, który był przygotowany dla Departamentu Obrony Stanów Zjednoczonych, ale z drugiej nie będzie on pasował w każdej sytuacji, co pokazała krytyka (np. że może być zbyt skomplikowany dla mniejszych firm, albo że jest zbyt czasochłonny), więc Autor uważa, że istotniejsze jest bazowanie na naukowych wytycznych przy budowaniu modelu. Jednocześnie zgodzono się, że wielu modelom brak jest teoretycznego fundamentu, ale jest także wiele tych, które bazują na teorii. W szczególności w literaturze pojawiają się odwołania (np. Das i in. (2023); Sonntag i in. (2024); Thordsen i in. (2020); Hellweg i in. (2023)) do omawianego wcześniej podejścia nauk o projektowaniu (*Design Science Research – DSR*), zaadaptowanego przez Beckera, Knackstedta i Pöppelbußa (2009) dla modeli dojrzałości.

4. Często brakuje walidacji opracowanych modeli dojrzałości w badaniach empirycznych (Wendler, 2012)

Autor częściowo zgadza się z tym stwierdzeniem – w wielu przeglądanych artykułach dotyczących modeli dojrzałości istnieje przegląd literatury modeli z konkretnej dziedziny, następnie na podstawie tego przeglądu i dodatkowych informacji albo pewnej krytyki jest budowany kolejny model, ale nie jest sprawdzany w badaniach empirycznych. Trzeba jednak zaznaczyć, że nie dotyczy to wszystkich artykułów – w wielu są przeprowadzone badania empiryczne na zbudowanych modelach, ale najczęściej sprowadza się to do krótkiego przedstawienia badanych organizacji i pokazania, na jakim są poziomie dojrzałości, ewentualnie zaprezentowania osiągniętego wyniku w danych wymiarach na wykresie radarowym. Rzadko przedstawiany jest kwestionariusz z pytaniami, a bardzo rzadko odpowiedzi danej organizacji na wszystkie pytania.

5. Ograniczone wskazówki dotyczące konkretnych kroków, które powinny zostać podjęte w celu poprawy poziomów dojrzałości / brak kryteriów, które pomogą użytkownikom zrozumieć metodyczny postęp do kolejnego etapu (Cronemyr i Danielsson, 2013;

Röglinger i in., 2012) / pomijanie wdrożenia praktyk z aktualnego poziomu i skupienie na wdrażaniu praktyk z poziomów wyższych (Dooley i in., 2001; Rae i in., 2014)

Autor zgadza się z powyższym punktem – jak zauważają Röglinger, Pöppelbuß i Becker (2012), większość zbadanych przez nich modeli dojrzałości w literaturze ma charakter deskryptywny (*descriptive*), co oznacza, że są one używane głównie do oceny aktualnego stanu organizacji w kontekście zarządzania procesami biznesowymi. Autorzy tego artykułu wskazują także, że istnieją trzy wcześniej omawiane reguły budowania modeli preskryptywnych (*prescriptive*). W badanych przez autorów modelach, zauważają oni, że istnieje ogólnie ograniczona liczba modeli preskryptywnych, przy czym modele te zazwyczaj spełniają jedynie pierwszy punkt z ich listy, nie spełniając pozostałych reguł lub odnosząc się do nich bardzo lakonicznie. Zaletą takiego preskryptywnego podejścia jest możliwość nie tylko diagnozy, ale również aktywnego prowadzenia organizacji przez proces poprawy, co zwiększa szanse na osiągnięcie lepszych wyników i adaptację do zmieniających się warunków rynkowych. Ten proces poprawy powinien uwzględniać kroki pośrednie (tj., jeśli dana praktyka jest na poziomie pierwszym, rekomendacje powinny dotyczyć najpierw przejścia na poziom drugi, a nie na poziomy wyższe), aby uniknąć pomijania praktyk z danych poziomów.

6. Mało empirycznych dowodów na użyteczność modeli (Tarhan i in., 2016) / brak ekonomicznego fundamentu (Albliwi i in., 2014)

Autor zgadza się z tym stwierdzeniem. Nawet jeśli model jest już zbudowany i sprawdzony w badaniach empirycznych, to tak jak opisywano w poprzednim punkcie – jest to najczęściej model opisowy, w którym określana jest dojrzałość firmy lub rzadziej model preskryptywny, gdzie opisane są środki poprawy poziomu dojrzałości. Brak jest jednak informacji czy dana organizacja uważa model za użyteczny lub wskazówek odnośnie do zakładanego budżetu i potencjalnych korzyści.

7. Pomijanie w modelu istotnych czynników (np. skupienie się na procesie i pomijanie ludzi, kultury itd.) (Höggerl i in., 2006; Röglinger i in., 2012) / Większość modeli opierająca się

na poziomach z góry prowadzących do określonego stanu, zamiast na czynnikach wpływających na ewolucję i dążenie do doskonalenia (Röglinger i in., 2012)

Uwaga dotycząca pomijania istotnych czynników dotyczy głównie modelu CMMI. Autor nie zgadza się ze stwierdzeniem, że większość modeli nie opiera się na czynnikach wpływających na dążenie do doskonalenia, szczególnie jeśli chodzi o modele badane w tej pracy. W badanych modelach dojrzałości – niezależnie czy to modele dojrzałości procesowej czy modele dojrzałości AI – po to wskazywane są wymiary oraz różne czynniki i najlepsze praktyki przy budowie modelu, żeby wpływać na dążenie do doskonalenia organizacji, a poziomy dojrzałości są pewną miarą ewaluacji tego dążenia. Należy jednak wskazać, że doświadczenia Röglingera, Pöppelbußa i Beckera (2012) mogą być inne ze względu na inny zbiór badanych modeli. Autor uważa, że nie zależy to także od typu przyjętego podejścia (*bottom-up* lub *top-down*), gdyż, jak wcześniej wspomniano, oba podejścia zawierają zbliżone etapy, które różnią się jedynie kolejnością ich wykonania (Mettler, 2011).

8. Modele zbyt uniwersalne lub zbyt specyficzne (R. Batenburg i in., 2005; Dayan i Evans, 2006)

Autor uważa, że istnieje możliwość zbudowania uniwersalnego modelu z danej dziedziny, który wciąż będzie dostosowany do większości organizacji i sektorów. Ponadto, gdyby model był budowany zgodnie z wcześniej wspomnianymi regułami budowania modeli preskryptywnych, mogłoby to pomóc, jeśli chodzi o dopasowanie modelu do różnych logik biznesowych różnych sektorów.

Bazując na przedstawionej krytyce z tego rozdziału, Autor chciałby opracować model, który jest:

- Możliwie nieskomplikowany i niewymagający dużej liczby zasobów;
- Uwzględniający dokumentację, która pozwala na ponowne wykorzystanie;
- Oparty na teorii i naukowych wytycznych;
- Przebadany w badaniach empirycznych;
- Preskryptywny;
- Uwzględniający aspekt finansowy i użyteczność;
- Uwzględniający istotne czynniki;

- Uniwersalny, ale kompleksowy.

Kolejnym krokiem jest iteracyjna budowa modelu.

4.4. Iteracyjny rozwój modelu

Bazując na pracy Beckera, Knackstedta i Pöppelbußa (2009), iteracyjny rozwój modelu jest centralnym punktem budowy każdego modelu dojrzałości, w którym budowana jest architektura modelu – zarówno poziomy, jak i wymiary. Popularnymi metodami, jeśli chodzi o pomoc w ustaleniu kryteriów oceny dla każdego poziomu, są przeglądy literatury czy wywiady z ekspertami lub ankiety w celu poznania czynników sukcesu i typowych przypadków użycia. Becker, Knackstedt i Pöppelbuß (2009), budując swój model, wykonali pięć iteracji – w pierwszej zbudowali szkic architektury z czterema poziomami i trzema wymiarami; w drugiej iteracji zbadali literaturę w celu potwierdzenia wymiarów i ich zawartości oraz wykonali dziewięć wywiadów z menedżerami, aby sprawdzić wiarygodność modelu; w trzeciej iteracji, bazując na wcześniejszych komentarzach wprowadzili poprawki do modelu; w czwartej iteracji ponownie przedyskutowali model z konsultantami, którzy zasugerowali jedynie uszczegółowienie jednego z wymiarów; dalsze dostosowanie architektury nie było więc konieczne w piątej iteracji, poza powyższym uszczegółowieniem. Autor chciałby podążać analogiczną ścieżką. Dodatkowym założeniem, jak wspomniano we Wprowadzeniu, jest to, że organizacja powinna być już na pewnym poziomie dojrzałości procesu rozwoju produktu, zanim zbadana zostanie dojrzałość w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w tym procesie. Pierwszym krokiem było zatem określenie stopnia dojrzałości procesu rozwoju produktu za pomocą odpowiedniego modelu.

Model dojrzałości procesu rozwoju nowego produktu

Autor uważa, że rozważając krytykę dotyczącą liczby modeli, nie ma potrzeby budowania kolejnego modelu z zakresu dojrzałości procesu rozwoju produktu. Ze wszystkich zidentyfikowanych modeli dojrzałości procesowej sześć dotyczyło bezpośrednio nurtu procesu rozwoju nowego produktu. Jeden z nich, omawiany wcześniej model CLIMB, oparty jest na

modelu najlepszych praktyk w rozwoju produktu, który bazuje na teorii, zawiera najlepsze praktyki z zakresu rozwoju produktu, został sprawdzony przez praktyków i przebadany w badaniach empirycznych łącznie z innym modelem. Model jest także nieskomplikowany i uniwersalny – średni czas wywiadów według autorów modelu to 2,5 godziny w każdej z badanych 107 firm (pozostałe z modeli z tego nurtu badały jedynie jedną organizację lub nie przeprowadzono badań empirycznych), gdzie badane były zarówno małe i średnie przedsiębiorstwa, jak i duże organizacje, w porównaniu np. z modelem CMMI, gdzie przejście przez wszystkie aspekty według wcześniej omawianych badań może zajmować nawet ponad rok i stopień skomplikowania jest zbyt duży dla małych i średnich przedsiębiorstw. Dlatego zdecydowano się na wybór tego modelu jako kroku wstępnego w procedurze.

Model można jedynie rozszerzyć o kilka elementów. Autor tej rozprawy nazywa zaproponowane rozszerzenie modelu wersją drugą modelu CLIMB, w skrócie CLIMB2. Pierwszą rzeczą jest dokładniejszy opis wymiarów i poziomów (autorzy modelu CLIMB używali słowa „obszar” do opisu głównych elementów modelu – w dalszej części rozprawy Autor używa głównie słowa „wymiar” do opisu tych części modelu w celu ujednolicenia terminologii). Tabela 12 przedstawia opisy modelu dojrzałości procesu rozwoju nowego produktu, bazując na omówionych wcześniej najlepszych praktykach. W modelu CLIMB nazwy poziomów to odpowiednio chaotyczny (*Chaos*), niski (*Low*), średniozaawansowany (*Intermediate*), dojrzały (*Mature*), najlepsza praktyka (*Best practice*). Każdy z ośmiu wymiarów wyrażony jest w procentach, a pięć możliwych etapów osiągnięcia stanu najlepszej praktyki jest zdefiniowanych w odniesieniu do danego wymiaru. Każdy z poziomów to przedział o szerokości 20% w skali od 0 do 100%, a mianowicie: chaotyczny (od 0% do 20%), niski (od 21% do 40%), średniozaawansowany (od 41% do 60%), dojrzały (od 61% do 80%) i najlepsza praktyka (od 81% do 100%). Autor uważa, że w celach porównawczych między badanymi organizacjami, warto wskazywać obie metody ewaluacji tj. hierarchiczną (poziomy jako liczby całkowite od 1 do 5) oraz w formie średniej ważonej (wagi od 1 do 5 w zależności od tego, na którym poziomie jest dana praktyka) i na taką metodę zdecydowano się w modelu CLIMB2. Możliwa jest sytuacja, w której organizacja na przykład nie spełnia tylko jednej praktyki z poziomu pierwszego w jednym wymiarze, a w innych wymiarach spełnia wszystkie praktyki z poziomów pierwszego i drugiego. W takiej sytuacji w ocenie hierarchicznej organizacja byłaby na najniższym poziomie dojrzałości, ale procentowo osiągałaby wynik zbliżony do 3, co

Tabela 12. Wymiary modelu dojrzałości procesu rozwoju nowego produktu i ich opisy.

Wymiar	Opisy
Role i współpraca	Dotyczy efektywnego podziału ról w zespole, który jest międzyfunkcyjny i globalnie rozproszony, a także pełnego zaangażowania wszystkich interesariuszy. Jasno określone role i obowiązki zwiększają elastyczność pracy. Ważnym elementem jest odpowiedzialność kierownika produktu z technicznym zapleczem oraz zaangażowanie klienta i doświadczonych projektantów od najwcześniejszych etapów projektów.
Szkolenie	Skupia się na formalnych programach wspierających interdyscyplinarne rozwijanie umiejętności zespołów. Praktyki obejmują indywidualne korepetycje oraz monitorowanie wyników za pomocą KPI, co pozwala na ocenę skuteczności szkolenia i ciągłe doskonalenie umiejętności członków zespołu.
Działania i przepływ	Dotyczy przestrzegania formalnych modeli rozwoju produktu, które są dokumentowane przez wszystkich zaangażowanych aktorów. Ważnym elementem jest współpraca, złożone KPI do pomiaru efektywności, frontloading procesu, ciągłe doskonalenie oraz systematyczne odrzucanie słabszych rozwiązań na rzecz nowych, lepszych informacji. Pełne skupienie na wartości dla klienta.
Podejmowanie decyzji	Praktyki związane z podejmowaniem decyzji opierają się na perspektywie cyklu życia produktu, od projektowania po użycie. Uwzględniane są czynniki strategiczne, takie jak koszty, ROI, innowacyjność, wizerunek marki, wydajność funkcjonalna i jakościowa, zgodność z przepisami oraz inne parametry, które mają wpływ na sukces produktu w oczach klienta.
Procesy KM	Skupiają się na formalnym planie zarządzania wiedzą (KM), obejmującym pięć etapów rozwoju produktu (od projektu koncepcyjnego po końcową weryfikację). Wiedza pochodzi z formalnych źródeł (zasady projektowania, podręczniki, standardy) i jest stale aktualizowana. Proces ten obejmuje też odzyskiwanie wiedzy z wcześniejszych projektów.
Techniki KM	Obejmują formalne narzędzia i techniki do przechwytywania, udostępniania i ponownego wykorzystywania wiedzy. Praktyki te obejmują werbalną komunikację, dokumenty z lekcji, specyfikacje projektów, kwestionariusze, zarządzanie wizualne, systemy PDM/PLM, oprogramowanie KBE i inne narzędzia wspierające efektywne zarządzanie wiedzą w procesach.
Metody	Praktyki obejmują formalne metody inżynierskie, takie jak zasady modularyzacji, projektowanie dla X (DFX), analiza wartości (VA), funkcje jakości (QFD), analiza ryzyka (FMEA), systematyczna innowacja (TRIZ), zarządzanie kosztami docelowymi (TCM) oraz inne metody, które wspierają efektywne zarządzanie procesami inżynierskimi i projektowymi.
Oprogramowanie	Rozwój produktu jest wspierany przez różne platformy i oprogramowanie, w tym CAD, CAM, PDM/PLM, systemy ERP, CRM, SCM, narzędzia analityczne (LCA), symulacje, rzeczywistość rozszerzoną (AR/VR) czy zautomatyzowane systemy zarządzania produkcją i konserwacją. Te narzędzia optymalizują rozwój produktów na wszystkich etapach.

Źródło: opracowanie własne.

mogłoby być lepszym odwzorowaniem rzeczywistej sytuacji. Poniżej zaprezentowano opis poziomów dla modelu CLIMB2:

Poziom 1 – Chaotyczny (*Chaos*): Na tym poziomie brak jest spójnych struktur i procesów. Zespoły międzyfunkcyjne nie istnieją lub ich współpraca jest minimalna, role nie są jasno określone, a elastyczność w działaniach jest znikoma. Brakuje formalnych programów szkoleniowych i jasno zdefiniowanych ról, co prowadzi do braku odpowiedzialności. Procesy rozwoju produktu nie są zdefiniowane, a zarządzanie wiedzą jest niesystematyczne, co skutkuje brakiem integracji poprzednich doświadczeń. Wykorzystanie narzędzi i technologii jest znikome, a metody inżynierskie i komputerowe wsparcie są rzadko stosowane.

Poziom 2 – Niski (*Low*): Na tym poziomie istnieją już struktury, ale są one słabo rozwinięte i sporadycznie stosowane. Zespoły międzyfunkcyjne są angażowane tylko w niektóre etapy, a interesariusze lokalni mogą brać udział, ale współpraca globalna jest ograniczona. Role są częściowo zdefiniowane, ale nie zawsze zrozumiałe. Szkolenia są oferowane w ograniczonym zakresie, a procesy są stosowane tylko na niektórych etapach. Wiedza z poprzednich projektów jest sporadycznie wykorzystywana, a technologie wspomagające rozwój są używane jedynie w wybranych przypadkach. Narzędzia są wdrażane, ale ich zastosowanie jest ograniczone.

Poziom 3 – Średniozaawansowany (*Intermediate*): Na tym poziomie zespoły międzyfunkcyjne są angażowane w większość projektów, a interesariusze z różnych lokalizacji są częściowo uwzględniani. Role i obowiązki są jasno określone, choć nadal występują niejasności. Szkolenia interdyscyplinarne są dostępne, ale nie dla wszystkich pracowników. Procesy są stosowane na większości etapów, ale brakuje pełnej systematyczności. Zarządzanie wiedzą i korzystanie z poprzednich doświadczeń są powszechne, choć nie zawsze w pełni zintegrowane. Technologie są szeroko stosowane, ale nie zawsze optymalnie, a narzędzia inżynierskie wspomagają większość projektów.

Poziom 4 – Dojrzały (*Mature*): Na poziomie dojrzałym zespoły międzyfunkcyjne są angażowane we wszystkie projekty, a współpraca globalna jest efektywna. Role i obowiązki są jasno określone i przestrzegane przez większość członków zespołu. Szkolenia interdyscyplinarne są dostępne dla wszystkich pracowników, a procesy są systematycznie stosowane i dobrze dokumentowane. Zarządzanie wiedzą jest efektywne, a wcześniejsze doświadczenia są regularnie wykorzystywane.

Technologie wspierają większość etapów rozwoju produktu, a narzędzia inżynierskie i oprogramowanie komputerowe są w pełni wdrażane w projektach.

Poziom 5 – Najlepsza praktyka (*Best practice*): Na najwyższym poziomie wszystkie elementy są w pełni zintegrowane i optymalnie wykorzystywane. Zespoły międzyfunkcyjne są zaangażowane na każdym etapie, a interesariusze globalni uczestniczą w projektach w pełni. Role i obowiązki są jasno określone, przestrzegane i rozumiane przez wszystkich. Szkolenia są systematyczne, dobrze zaplanowane i obejmują wszystkich pracowników. Procesy są rygorystycznie przestrzegane, a zarządzanie wiedzą jest w pełni zintegrowane z każdym projektem, zapewniając maksymalne wykorzystanie wcześniejszych doświadczeń. Technologie, narzędzia inżynierskie i oprogramowanie wspierają rozwój na wszystkich etapach, zapewniając efektywność i innowacyjność.

Kolejnym aspektem modelu jest kwestionariusz. Autorzy modelu CLIMB w swoim artykule pokazali jedynie przykład jednego pytania dla jednej z praktyk, dlatego istotne jest określenie pytań oraz odpowiedzi dla każdej praktyki, dla każdego z poziomów. Kwestionariusz składa się zatem ze 107 pytań (po jednym na każdą praktykę) i pięciu odpowiedzi dla każdego z pytań (od A do E) oznaczających określone poziomy dojrzałości (A – poziom najniższy, E – poziom najwyższy). Przygotowany kwestionariusz znajduje się w Załączniku 2. Model CLIMB2 jest zatem jedynie rozszerzeniem modelu CLIMB o dokładniejszą dokumentację i dostępny kwestionariusz.

Model dojrzałości w wykorzystaniu generatywnej AI

Podjęcie rozpoczęto od modelu dojrzałości w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji. W literaturze naukowej dostępny jest tylko jeden model dotyczący dojrzałości generatywnej AI, dlatego wyzwaniem jest określenie odpowiednich wymiarów. Autor przeprowadził jednak systematyczny przegląd literatury i wywiady dotyczące zastosowań, wyzwań i czynników sukcesu w rozwoju nowego produktu (w poprzednich rozdziałach), co było sugestią Beckera, Knackstedta i Pöppelbußa (2009) odnośnie poszukiwania pomocy w definiowaniu wymiarów. Fukas i in. (2021) przygotowali swój model dojrzałości AI dedykowany dla firm audytorskich, bazując na omawianym wcześniej modelu referencyjnym zarządzania sztuczną inteligencją (Fukas i Thomas, 2023). Model ten, jak wcześniej wspomniano, obejmuje

osiem wymiarów uwzględniając wymiary: Technologie i Infrastruktura, Dane, Ludzie i kompetencje, Organizacja i procesy, Strategia i zarządzanie, Budżet, Produkty i usługi oraz Etyka i regulacje. Wszystkie te wymiary są istotne również z perspektywy generatywnej AI, ale wymagają adaptacji do jej konkretnych wymagań, bazując na przeprowadzonym wcześniej systematycznym przeglądzie literatury i wywiadach. Tabela 13 przedstawia opis wymiarów ze wspomnianą adaptacją.

Kolejnym krokiem było zdefiniowanie poziomów. Zdecydowano się na najczęściej wybierane w literaturze podejście pięciopoziomowe. Nazwano ten model OLIMP, bazując na pierwszych literach nazw angielskich każdego z poziomów:

Poziom 1 – Poziom Zorganizowania (*Organizing Level*): Na tym poziomie organizacja koncentruje się na strukturyzacji procesu rozwoju nowego produktu i zasobów w sposób ułatwiający integrację rozwiązań generatywnej sztucznej inteligencji. Organizacja monitoruje i identyfikuje możliwości poprawy efektywności procesu rozwoju nowego produktu przy wsparciu generatywnej AI. Podejmowane są pierwsze kroki w kierunku wdrażania zmian i otwierania nowych możliwości, co stanowi fundament dla przyszłego rozwoju technologii GenAI w procesie rozwoju nowego produktu.

Poziom 2 – Poziom Uczenia się (*Learning Level*): Na tym etapie organizacja skutecznie wykorzystuje zasoby i procesy wspierane przez generatywną AI, aby poprawić wyniki procesu rozwoju nowego produktu. Tworzone są połączenia między różnymi działami, takimi jak R&D, marketing i produkcja, w celu lepszej współpracy i wymiany informacji. Organizacja adaptuje się na podstawie danych zebranych przez systemy AI, co pozwala na bieżące dostosowywanie strategii i procedur w rozwoju nowego produktu.

Poziom 3 – Poziom Wdrażania (*Implementing Level*): Na tym poziomie organizacja zaczyna intensywnie integrować generatywną AI z istniejącymi procesami rozwoju nowego produktu, tworząc spójne i zintegrowane operacje. Rozwiązania AI są wykorzystywane do automatyzacji i optymalizacji kluczowych etapów rozwoju produktu, takich jak generowanie koncepcji, projektowanie, testowanie i analiza rynku. Udoskonalenia te prowadzą do bardziej efektywnego i spójnego procesu tworzenia nowych produktów.

Tabela 13. Wymiary modelu dojrzałości w wykorzystaniu rozwiązań generatywnej AI i ich opisy.

Wymiar	Opis
Technologie i infrastruktura	Wymiar Technologie i infrastruktura odnosi się do infrastruktury IT, narzędzi i technologii koniecznych do wdrożenia generatywnej AI w procesie rozwoju nowego produktu. Obejmuje elementy technologiczne wspierające rozwój AI, takie jak systemy komputerowe, oprogramowanie do analizy danych oraz platformy integracyjne umożliwiające automatyzację i optymalizację etapów rozwoju produktu.
Dane	Wymiar Dane koncentruje się na znaczeniu jakości i zarządzania danymi w procesie rozwoju nowego produktu z wykorzystaniem generatywnej AI. Dotyczy to gromadzenia, przetwarzania i analizowania dużych zbiorów danych, które są niezbędne do treningu modeli AI oraz generowania dokładnych prognoz i rekomendacji na różnych etapach rozwoju produktu.
Ludzie i kompetencje	Wymiar Ludzie i Kompetencje odnosi się do umiejętności i wiedzy zespołów odpowiedzialnych za proces rozwoju nowego produktu. Dotyczy identyfikacji i rozwijania kompetencji pracowników potrzebnych do efektywnego korzystania z generatywnej AI, w tym umiejętności programowania, analizy danych oraz zarządzania projektami AI, a także kształcenia zespołów w zakresie nowych technologii AI.
Organizacja i procesy	Wymiar Organizacja i Procesy dotyczy struktury organizacyjnej i procesów biznesowych wspierających wdrożenie generatywnej AI w procesie rozwoju nowego produktu. Obejmuje integrację generatywnej AI z istniejącymi procesami rozwoju produktów, zarządzania projektami i podejmowania decyzji, które wpływają na efektywność i skuteczność wdrażania nowych produktów na rynek.
Strategia i zarządzanie	Wymiar Strategia i Zarządzanie dotyczy planowania i formułowania strategii w zakresie wykorzystania generatywnej AI w procesie rozwoju nowego produktu. Obejmuje ustalanie celów strategicznych i operacyjnych związanych z AI, takich jak poprawa innowacyjności, skrócenie czasu wprowadzenia produktów na rynek (TTM) oraz optymalizacja kosztów rozwoju produktu.
Budżet	Wymiar Budżet odnosi się do inwestycji finansowych przeznaczonych na rozwój i wdrożenie generatywnej AI w procesie rozwoju nowego produktu. Uwzględnia alokację środków na rozwój technologii AI, szkolenia pracowników, zakup niezbędnej infrastruktury oraz realizację projektów pilotażowych mających na celu weryfikację skuteczności generatywnej AI w rozwoju produktów.
Produkty i usługi	Wymiar Produkty i Usługi ocenia wpływ wdrożenia generatywnej AI na ofertę produktową i usługową firmy. Dotyczy zdolności AI do tworzenia innowacyjnych produktów i usług, które spełniają oczekiwania klientów, optymalizacji procesów rozwoju nowych produktów oraz zwiększenia wartości dodanej oferowanych produktów.
Etyka i regulacje	Wymiar Etyka i Regulacje odnosi się do kwestii etycznych i regulacyjnych związanych z zastosowaniem generatywnej AI w NPD. Obejmuje przestrzeganie przepisów dotyczących prywatności danych, przejrzystości algorytmów AI, etycznych zasad projektowania AI oraz odpowiedzialności za decyzje podejmowane przez systemy AI w kontekście rozwoju produktów.

Źródło: opracowanie własne.

Poziom 4 – Poziom Zarządzania (*Managing Level*): Na tym poziomie organizacja zarządza i kontroluje procesy rozwoju nowego produktu z wykorzystaniem generatywnej AI, stale monitorując postępy i dokonując niezbędnych korekt. Wszystkie zasoby, w tym technologie AI, są w pełni wykorzystywane, by maksymalizować ich potencjał w kontekście procesów rozwoju nowego produktu. Organizacja śledzi wyniki i efekty wdrożenia AI, co pozwala na utrzymanie wysokiego poziomu jakości i efektywności w tworzeniu nowych produktów.

Poziom 5 – Poziom Prekursora (*Pioneering Level*): Na tym zaawansowanym poziomie organizacja w pełni wykorzystuje potencjał generatywnej AI w procesie rozwoju nowego produktu, osiągając przewidywalne i wysokiej jakości wyniki. Organizacja staje się liderem w wykorzystaniu najnowocześniejszych technologii AI do tworzenia innowacyjnych produktów. Procesy rozwoju nowego produktu są ciągle doskonalone, a najlepsze praktyki są wdrażane i rozprzestrzeniane w całej organizacji, umożliwiając jej przewodzenie na rynku i wyznaczanie nowych standardów w branży.

Jeśli chodzi o przedstawienie poziomu organizacji, podobnie jak w modelu CLIMB2, zdecydowano się przedstawić poziom (ogólny oraz w wymiarach) zarówno jako liczbę całkowitą, jak i jako średnią ważoną. Konieczne jest także określenie najlepszych praktyk dla każdego z wymiarów, tak aby możliwe było stworzenie kwestionariusza. Praktyki zostały zidentyfikowane na podstawie przeprowadzonych badań literaturowych i wywiadów dotyczących elementów modelu oraz zidentyfikowanych i przeanalizowanych innych modeli dojrzałości, a następnie przypisane do odpowiednich wymiarów. W przypadku praktyk znalezionych w innych modelach dojrzałości, praktyki niekiedy mapowano na dziedzinę związaną z rozwiązaniami generatywnej AI. Niektóre praktyki mogły zostać przypisane do więcej niż jednej grupy, lecz przypisano je do wymiaru o największym wpływie (według Autora rozprawy). Tabela 14 przedstawia zidentyfikowane praktyki.

Kolejnym krokiem jest przygotowanie kwestionariusza. Na podstawie listy najlepszych praktyk zidentyfikowanych w Tabeli 14, przygotowano kwestionariusz z pytaniami i odpowiedziami dla każdego poziomu, który znajduje się w Załączniku 3. Autor chciałby podkreślić, że konieczność stworzenia modelu OLIMP wynika z braku dostępnego w literaturze (w momencie pisania tej rozprawy) ogólnego lub skupiającego się na procesie rozwoju nowego produktu modelu

Tabela 14. Zidentyfikowane najlepsze praktyki razem ze źródłami – wersja wstępna.

Wymiar	Zidentyfikowane najlepsze praktyki	Źródło
Technologie i infrastruktura	Budowa skalowalnej infrastruktury IT wspierającej generatywną AI	Analiza modeli (W. Chen i in., 2021)
	Integracja technologii generatywnej AI z innymi systemami wykorzystywanymi w procesie rozwoju nowego produktu (ERP, CRM, etc.)	Analiza modeli (Sonntag i in., 2024)
	Automatyzacja wdrażania modeli generatywnej AI	Analiza modeli (Sonntag i in., 2024)
	Wykorzystanie chmury do przechowywania i przetwarzania danych dla generatywnej AI	Analiza modeli (W. Chen i in., 2021; Sonntag i in., 2024)
	Infrastruktura wspierająca obsługę dużych zbiorów danych	Analiza modeli (W. Chen i in., 2021; Sonntag i in., 2024)
	Wdrożenie technologii wspierających przetwarzanie w czasie rzeczywistym	Analiza modeli (W. Chen i in., 2021)
	Moc obliczeniowa potrzebna do wdrożenia i utrzymania modeli dla rozwiązań generatywnej AI	Wywiady, analiza modeli (W. Chen i in., 2021)
	Użycie różnorodnych narzędzi (wewnętrznych lub zewnętrznych) opartych o generatywną AI w codziennej pracy (np. ChatGPT, MS Copilot)	Przegląd literatury, analiza modeli (Chukhlomin, 2024)
	Skalowalność wykorzystywanych rozwiązań generatywnej AI	Analiza modeli (Sonntag i in., 2024)
Dane	Budowanie wysokiej jakości zbiorów danych	Wywiady, analiza modeli (W. Chen i in., 2021; Sonntag i in., 2024)
	Automatyzacja analizy i przetwarzania danych	Wywiady, analiza modeli (W. Chen i in., 2021; Chukhlomin, 2024; Sonntag i in., 2024)
	Centralizacja zbiorów danych (jeden słownik danych w organizacji)	Wywiady, analiza modeli (W. Chen i in., 2021)
	Zastosowanie zaawansowanych narzędzi do oceny jakości danych	Analiza modeli (W. Chen i in., 2021; Sonntag i in., 2024)
	Budowanie strategii zarządzania danymi	Analiza modeli (W. Chen i in., 2021; Sonntag i in., 2024)
	Automatyzacja procesu zbierania i czyszczenia danych	Analiza modeli (W. Chen i in., 2021)
	Identyfikacja danych z wewnętrznych i zewnętrznych źródeł i integracja z aktualnymi zbiorami danych	Analiza modeli (W. Chen i in., 2021; Sonntag i in., 2024)
	Istnienie jednego standardowego modelu danych i zbioru standardowych metadanych	Analiza modeli (Sonntag i in., 2024)
	Wykorzystanie generatywnej AI do wspomaganie wizualizacji danych	Analiza modeli (W. Chen i in., 2021; Chukhlomin, 2024)
Ludzie i kompetencje	Rozwijanie świadomości i zrozumienia rozwiązań generatywnej AI	Przegląd literatury, wywiady, analiza modeli (Sonntag i in., 2024)

Wymiar	Zidentyfikowane najlepsze praktyki	Źródło
	Szkolenie zespołów z zakresu programowania (także promptingu) i analizy danych	Analiza modeli (W. Chen i in., 2021; Chukhlomin, 2024; Sonntag i in., 2024)
	Tworzenie interdyscyplinarnych zespołów ds. generatywnej AI	Wywiady, analiza modeli (Sonntag i in., 2024)
	Wprowadzenie zewnętrznych konsultantów ds. generatywnej AI do zespołów	Przegląd literatury
	Kształcenie liderów w zakresie zarządzania projektami (budowy nowych produktów) wykorzystującymi generatywną AI	Przegląd literatury, analiza modeli (Chukhlomin, 2024)
	Usprawnienie transferu wiedzy między ludźmi poprzez wykorzystanie procesów zarządzania wiedzą w zakresie generatywnej AI	Analiza modeli (Sonntag i in., 2024)
Organizacja i procesy	Integracja generatywnej AI z istniejącymi procesami rozwoju nowego produktu (rozwiązania generatywnej AI, które uwalniają kierownika produktu od zadań niezwiązanych z podstawowymi obowiązkami)	Wywiady
	Automatyzacja procesów rozwoju produktu z wykorzystaniem generatywnej AI	Analiza modeli (Chukhlomin, 2024; Sonntag i in., 2024)
	Zastosowanie generatywnej AI do wsparcia podejmowania decyzji	Wywiady, analiza modeli (W. Chen i in., 2021)
	Implementacja narzędzi generatywnej AI wspierających pracę zespołów (codzienne narzędzia wspierające kierowników produktu)	Wywiady
	Wprowadzenie cykli ciągłego doskonalenia we wdrażaniu rozwiązań generatywnej AI (nauka z przeszłości i teraźniejszych wdrożeń na przyszłość)	Analiza modeli (Sonntag i in., 2024)
	Zdefiniowany proces zarządzania cyklem życia dla oprogramowania używanego do dostarczania rozwiązań generatywnej AI	Analiza modeli (Sonntag i in., 2024)
	Przewodnik po procesie rozwoju produktu, oparty o rozwiązania generatywnej AI	Wywiady
Strategia i zarządzanie	Opracowanie długoterminowej strategii inwestycji w generatywną AI	Analiza modeli (Chukhlomin, 2024; Sonntag i in., 2024)
	Wdrożenie strategii generatywnej AI w rozwój produktów (metodologia wdrażania)	Przegląd literatury, wywiady
	Określenie celów strategicznych dla generatywnej AI	Analiza modeli (Sonntag i in., 2024)
	Ocena wpływu biznesowego i wykonalności rozwiązania opartego o generatywną AI z wyprzedzeniem	Wywiady
	Opracowanie systemu monitorowania wyników wdrożenia generatywnej AI (mierniki do oceny w jaki sposób rozwiązanie miało wpływ na proces)	Przegląd literatury, Wywiady
	Analiza konkurencji pod względem ich zdolności do wdrożeń generatywnej AI	Analiza modeli (Sonntag i in., 2024)

Wymiar	Zidentyfikowane najlepsze praktyki	Źródło
Budżet	Długoterminowe planowanie budżetu na rozwój rozwiązań i infrastruktury wspierającej rozwiązania generatywnej AI	Przegląd literatury, analiza modeli (Sonntag i in., 2024)
	Przeznaczanie środków na rozwój kompetencji pracowników w zakresie generatywnej AI	Przegląd literatury, analiza modeli (Sonntag i in., 2024)
	Finansowanie projektów pilotażowych i innowacyjnych dotyczących rozwiązań generatywnej AI	Analiza modeli (Sonntag i in., 2024)
Produkty i usługi	Wspomaganie / automatyzacja procesów projektowania i wytwarzania produktów (także przez zwiększenie kreatywności / wspomaganie oceny przy projektowaniu) przy pomocy generatywnej AI	Przegląd literatury
	Użycie generatywnej AI do generowania pomysłów związanych z produktem (także poprzez analizę sentymentu / analizę opinii)	Przegląd literatury, analiza modeli (Chukhlomin, 2024)
	Wspomaganie redukcji informacji (np. streszczenia tekstu) przy pomocy generatywnej AI	Przegląd literatury, analiza modeli (Chukhlomin, 2024)
	Wykorzystanie generatywnej AI do wspomaganie i ulepszania procesu oceny koncepcji (analizy wymagań, oceny ryzyka czy planowania zadań)	Przegląd literatury
	Skrócenie czasu testowania produktu przy pomocy rozwiązań generatywnej AI	Przegląd literatury
	Wspomaganie marketingu produktowego (tworzenie reklam, słów kluczowych, filmów promocyjnych) wykorzystując rozwiązania generatywnej AI	Przegląd literatury
	Wykorzystanie generatywnej AI do doskonalenia systemów rekomendacji produktów	Przegląd literatury
	Udoskonalenie działania baz danych produktów przy pomocy generatywnej AI	Przegląd literatury, analiza modeli (Chukhlomin, 2024)
	Użycie rozwiązań generatywnej AI jako komponentu w profesjonalnych aplikacjach	Przegląd literatury, Analiza modeli (Chukhlomin, 2024)
	Poszukiwanie nowych przypadków użycia rozwiązań generatywnej AI	Analiza modeli (Sonntag i in., 2024)
Etyka i regulacje	Przestrzeganie zasad etyki w projektowaniu generatywnej AI	Przegląd literatury
	Bezpieczeństwo i prywatność danych dotyczących procesu rozwoju produktu	Przegląd literatury, wywiady, analiza modeli (Das i in., 2023; Sonntag i in., 2024)
	Zaufanie do danych i możliwość ich wyjaśnienia	Przegląd literatury, wywiady, analiza modeli (Das i in., 2023; Sonntag i in., 2024)
	Wdrożenie standardów ochrony i mechanizmów dotyczących kopii zapasowych danych	Analiza modeli (W. Chen i in., 2021)
	Przeciwdziałanie uprzedzeniom i niesprawiedliwości w algorytmach generatywnej AI	Przegląd literatury, analiza modeli (Das i in., 2023)
	Tworzenie systemów audytu decyzji podejmowanych przez generatywną AI (odpowiedzialność za decyzje podejmowane przez generatywną AI)	Przegląd literatury

Wymiar	Zidentyfikowane najlepsze praktyki	Źródło
	Poszerzanie świadomości dotyczących ochrony danych wśród pracowników	Przegląd literatury, analiza modeli (W. Chen i in., 2021)
	Użycie technologii dotyczących cyberbezpieczeństwa	Analiza modeli (W. Chen i in., 2021)
	Utrzymywanie dokumentacji (przypadki użycia generatywnej AI, logi systemowe, testy, kontrola wersji, etc.) do monitorowania użycia rozwiązań generatywnej AI (niespójności, nietypowe zdarzenia)	Analiza modeli (Das i in., 2023)

Źródło: opracowanie własne.

dotyczącego dojrzałości organizacji w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji. Następnym krokiem jest rozszerzenie modelu o część preskryptywną.

Preskryptywność modelu dojrzałości w wykorzystaniu generatywnej AI

Jak wcześniej wspomniano, Röglinger, Pöppelbuß i Becker (2012) wskazali trzy punkty, które są cechami modeli preskryptywnych. Poza pokazaniem najlepszych praktyk dla każdego poziomu, istotne jest także wskazanie alternatywnych rekomendacji dojścia do kolejnego poziomu, uwzględniając relację kosztów i korzyści oraz pokazanie procedury wdrażania. Omówione wcześniej metodologiczne rozszerzenie, zaproponowane przez Linharta, Klausa i Röglingera (2017), czyli budowa macierzy i użycie wzorów, może okazać się zniechęcające lub niezrozumiałe dla grupy docelowej.


Interesującym poznawczo zagadnieniem jest wykorzystanie rozwiązań generatywnej AI. Bazując na wcześniejszych przesłankach dotyczących użycia technologii generatywnych w zespołach innowacyjnych i ograniczeniach związanych z ChatGPT, postanowiono zbudować własne narzędzie oparte na dużych modelach językowych, które proponowałoby użytkownikom ścieżki dojścia do danego poziomu, uwzględniając przy tym relację koszt – korzyść. Zbudowano narzędzie, które na podstawie odpowiedzi z kwestionariuszy, korzysta z trzech agentów AI, opartych o modele językowe firm OpenAI, Anthropic oraz Google. Każdy z agentów analizuje stan organizacji na podstawie odpowiedzi z kwestionariusza, a następnie model końcowy (Gemini 2.5 Pro) formułuje rekomendacje, które mają na celu zwiększenie poziomu jej dojrzałości.

Narzędzie (w tym szczegóły techniczne dotyczące budowy narzędzia) wraz z przygotowanymi instrukcjami dla modelu można znaleźć pod linkiem podanym w Załączniku 4.

Model łączony – procedura

Uwzględniając poprzednie punkty krytyki modeli, zaproponowano model CLIMB2-OLIMP (ang. *Climb to Olimp* – gra słów, oznaczająca po polsku „wspięcie się na Olimp”), czyli model uwzględniający połączenie rozszerzonego modelu CLIMB (CLIMB2) i własnego modelu OLIMP. Połączenie obu modeli zapewni bardziej kompleksowe podejście do badania dojrzałości organizacji w wykorzystaniu rozwiązań GenAI w procesie rozwoju nowego produktu. Procedura oceny dojrzałości organizacji uwzględnia kilka kroków. Pierwszym krokiem jest pomiar dojrzałości procesu rozwoju nowego produktu. Uzyskanie poziomu drugiego podczas tej oceny jest warunkiem wstępnym do rozpoczęcia pomiaru dojrzałości organizacji w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju produktu. Wybrano arbitralnie poziom drugi, zakładając, że organizacja powinna mieć zdefiniowany na poziomie podstawowym strukturę procesu rozwoju produktu, aby myśleć o wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w tym procesie i o pomiarze dojrzałości tego wykorzystania. Organizacje niekwalifikujące się na poziom pierwszy, czyli niespełniające warunku wstępnego, nie przechodzą do kroku drugiego. Organizacje, które są na co najmniej pierwszym poziomie, są kolejno badane modelem OLIMP. Ostatnim krokiem jest określenie przez organizację docelowego poziomu dojrzałości w każdym z wymiarów modelu i wykorzystanie części preskryptywnej modelu do zaproponowania rekomendacji dojścia do poziomu docelowego, uwzględniając analizę kosztów i potencjalnych korzyści. Wstępna wersja modelu CLIMB2-OLIMP została przedstawiona na Rysunku 8.

W odniesieniu do wcześniejszej krytyki tak przygotowany model jest oparty na teorii, uwzględnia znalezione w wywiadach i literaturze istotne czynniki, zawiera część preskryptywną i zawarty w rekomendacjach aspekt finansowy. Zdaniem Autora, model jest też kompleksowy ze względu na podejście łączone i zbadanie procesu rozwoju nowego produktu z dwóch różnych perspektyw, a jednocześnie uniwersalny – model może być użyty do zbadania wykorzystania rozwiązań generatywnej AI w procesach rozwoju nowego produktu w różnych organizacjach z różnych branż.



Rysunek 8. Model CLIMB2-OLIMP – wersja wstępna.

Źródło: opracowanie własne.

Dodatkowo model posiada dokumentację, pozwalającą na ponowne wykorzystanie – składa się z dwóch kwestionariuszy, a jego poziom skomplikowania jest niższy, chociażby od wcześniej omawianego modelu W. Chena i in. (2021) oraz modelu CMMI, któremu zarzucana jest w literaturze potrzeba użycia dużej liczby zasobów do zbadania dojrzałości. Pozostałe, omawiane wcześniej aspekty – zbadanie modelu w badaniach empirycznych oraz określenie jego użyteczności – omówiono w dalszej części rozprawy. Tak zbudowany model jest pierwszą, początkową wersją. Kolejnym krokiem jest sprawdzenie wiarygodności modelu wraz z ekspertami.

Dyskusje i sprawdzenie wiarygodności modelu

Przygotowany model CLIMB2-OLIMP został następnie sprawdzony z dziewięcioma ekspertami zajmującymi się zarządzaniem produktem oraz rozwiązaniami generatywnej sztucznej inteligencji (zakończono iterację, gdy pojawiło się nasycenie tematyczne – brak nowych uwag ani propozycji praktyk). Jeżeli chodzi o procedurę modelu, eksperci mieli jedynie pozytywne komentarze, podkreślając istotność pomiaru dojrzałości procesu rozwoju nowego produktu oraz wyrażając zainteresowanie sugestiami podawanymi w części preskryptywnej za pomocą zbudowanego narzędzia opartego na generatywnej sztucznej inteligencji.

Jedna z uwag dotyczących pomiaru modelem CLIMB2 dotyczyła poziomu dojrzałości, na którym organizacja powinna się znaleźć, aby kontynuować pomiar modelem OLIMP. Ekspertci sugerowali, że organizacja powinna mieć już pewne struktury procesu rozwoju nowego produktu, przed pomiarem dojrzałości wykorzystania rozwiązań generatywnej sztucznej inteligencji w tym procesie, sugerując, że organizacja powinna być co najmniej na poziomie drugim modelu CLIMB2. Podkreślili jednak, że biorąc pod uwagę liczbę praktyk, może zdarzyć się sytuacja, że w którejś z nich organizacja będzie na poziomie pierwszym i już jedna taka praktyka spowoduje brak możliwości kontynuacji pomiaru modelem OLIMP. Nie było jednak jednolitego rozwiązania – sugestie ekspertów były takie, żeby każdy przypadek rozpatrywać oddzielnie – tzn., że jeśli badający organizację uzna, że warto zrobić pomiar modelem OLIMP (nawet mimo większej liczby praktyk na poziomie pierwszym), powinno się tak zrobić. Inna z uwag dotyczyła tego, że nie zawsze niektóre praktyki będą dotyczyć organizacji, na przykład organizacja może nie wykorzystywać z różnych powodów określonych metod lub oprogramowania. Sugestia była taka, żeby uwzględnić w modelu możliwość niezaznaczenia żadnej odpowiedzi, co znaczyłoby, że dana praktyka nie dotyczy organizacji.

W przypadku modelu OLIMP eksperci stwierdzili, że został on zbudowany poprawnie i nie ma potrzeby dodawania nowych wymiarów do modelu lub usuwania praktyk z aktualnych wymiarów. Stwierdzili jednak, że istotne byłoby dodanie kilku praktyk. Jedna z sugestii dotyczyła dodania praktyki „Zastosowanie narzędzi do zarządzania cyklem życia modeli generatywnej AI” w wymiarze Technologie i infrastruktura, podkreślając istotność monitorowania wprowadzanych modeli w ich cyklu życia i wprowadzenia potrzebnych zmian. Inna sugestia dotyczyła dodania dwóch praktyk do wymiaru Budżet – „Alokacji środków na zewnętrzne konsultacje dotyczące

generatywnej AI” oraz „Priorytetyzacji projektów generujących wysoką wartość dodaną dzięki generatywnej AI”. Pierwsza z nich jest związana z faktem, że w wymiarze Ludzie i kompetencje pojawia się praktyka „Wprowadzenie zewnętrznych konsultantów ds. generatywnej AI do zespołów” i zdaniem ekspertów, alokacja środków na takie zewnętrzne konsultacje była na tyle istotnym punktem, że powinna się znaleźć jako praktyka oddzielna od planowania długoterminowego budżetu na rozwój rozwiązań AI. Druga z nich dotyczy faktu, że generatywna AI jest narzędziem, które może pomóc w wielu różnych projektach i wciąż trzeba pamiętać o zwrocie z inwestycji w te projekty i rozwój przeznaczonych dla nich rozwiązań generatywnej AI, stąd priorytetyzacja jest istotnym punktem, który powinien znaleźć się w modelu. Ostatnią sugestią było dodanie praktyki „Wykorzystanie generatywnej AI do personalizacji produktów” do wymiaru Produkty i usługi. Zdaniem ekspertów, rozwiązania generatywnej AI oferują na tyle dużo możliwości personalizacji produktów, że powinno się to znaleźć jako oddzielna praktyka w modelu.

Uwzględniono powyższe cztery praktyki w modelu OLIMP zgodnie z sugestiami ekspertów. W przypadku modelu CLIMB2, postanowiono dopuszczać do dalszej analizy przypadki, w których część praktyk będzie na poziomie niższym niż 2 – pozostawiono to do indywidualnej oceny badacza. Zdecydowano również uwzględnić w modelu przypadek sytuację, w której jakaś praktyka może nie dotyczyć organizacji – w takim przypadku organizacja może napisać ‘N/D’ (nie dotyczy) w kwestionariuszu przy danej praktyce (ta praktyka nie będzie w takim przypadku liczona ani do poziomu organizacji, ani do średniej). Kolejno przeprowadzono dyskusje z pięcioma ekspertami po wprowadzonych poprawkach (podobnie jak w badaniach Beckera, Knackstedta i Pöppelbußa (2009); mniejsza, kompetentna liczba ekspertów wystarczająca do iteracyjnych poprawek umożliwiającą szybką pętlę informacji zwrotnej, złożona z trzech osób z pierwszej iteracji i dwóch nowych osób). Jedyna uwaga dotyczyła modelu OLIMP i była związana z sugestią dodania praktyki „Regularna ocena zgodności algorytmów i narzędzi generatywnej AI z regulacjami prawnymi” do wymiaru Etyka i regulacje. Eksperti podkreślili, że w świetle zmieniających się przepisów i pojawiających się nowych rozwiązań generatywnej AI, istotne jest, aby regularnie sprawdzać zgodność z regulacjami prawnymi. Zdecydowano się na uwzględnienie powyższej praktyki w modelu. Dalsze rozmowy z ekspertami nie przyniosły żadnych nowych uwag. Kwestionariusz modelu OLIMP, dostępny w Załączniku 3, został uzupełniony o praktyki

zasugerowane przez ekspertów. Tabela 15 zawiera wszystkie zidentyfikowane praktyki modelu OLIMP.

Ekspertom zaprezentowany został także przykładowy raport, przygotowany przy pomocy dużych modeli językowych, dotyczący rekomendacji w dojściu do wyższych poziomów dojrzałości. Ogólna ocena przygotowanego raportu była bardzo dobra, z komentarzami ekspertów, że jest to raport poziomu największych firm audytorskich takich jak EY. Komentarz jednego z ekspertów dotyczył tego, jak podchodzi się aktualnie do tematu rekomendacji w organizacjach: „W organizacjach są często przeprowadzane ankiety tego, co można poprawić w organizacji, a później, gdy w jakimś obszarze wynik jest niski, pracownikom zadawane są pytania odnośnie do tego, w jaki sposób widzieliby poprawę w tym obszarze – teraz to AI może odpowiadać”. Inny z komentarzy dotyczył tego, że raport będzie dobry dla dużych firm, gdzie są szanse na dedykowane zespoły, dokładną analizę poszczególnych wymiarów i zaplanowanie działań na trzy lata lub dłużej, a może się okazać zbyt szczegółowy dla średnich lub mniejszych organizacji. Sugestia była jednak taka, żeby zrobić badania także w mniejszych lub średnich firmach, żeby dokonać weryfikacji tego komentarza. Jeden z ekspertów dodał, że przydatne byłyby metryki, które można by śledzić w trakcie transformacji i podsumowanie raportu ze wskazaniem na czym się skupić na początku. Inny komentarz dotyczył tego, żeby proponować organizacjom ograniczony wybór wymiarów do poprawy, skupiając się na dwóch lub trzech najważniejszych, argumentując to tym, że z jednej strony raport dla wzrostu we wszystkich wymiarach jest bardzo długi, a z drugiej strony skupienie się na kilku początkowych wymiarach nie spowoduje paraliżu decyzyjnego, a organizacje i tak będą musiały wybrać jakieś wymiary, od których chcą zacząć, jeśli chciałyby wzrastać we wszystkich. Ostatni komentarz dotyczył tego, że sytuacja, w jakiej znajduje się dana organizacja np. jeśli chodzi o wsparcie inicjatyw takich transformacji przez kierownictwo, będzie różna w każdym przypadku i priorytety będą zależały od dostępnych zasobów i czasu, stąd, mimo że raport może być użyteczny, organizacja może chcieć skoncentrować się tymczasowo na innych obszarach działania. Podkreślono jednak, że otrzymanie takiego raportu może posłużyć jako zbiór możliwych czynności i drogowskaz dla przyszłych inicjatyw, a organizacja sama zdecyduje, które punkty uwzględnić w transformacji.


Tabela 15. Zidentyfikowane najlepsze praktyki przy wykorzystaniu rozwiązań generatywnej AI – wersja końcowa.

Wymiar	Zidentyfikowane najlepsze praktyki
Technologie i infrastruktura	Budowa skalowalnej infrastruktury IT wspierającej generatywną AI, Integracja technologii generatywnej AI z innymi systemami wykorzystywanymi w procesie rozwoju nowego produktu (ERP, CRM, etc.), Automatyzacja wdrażania modeli generatywnej AI, Wykorzystanie chmury do przechowywania i przetwarzania danych dla generatywnej AI, Zastosowanie narzędzi do zarządzania cyklem życia modeli generatywnej AI, Infrastruktura wspierająca obsługę dużych zbiorów danych, Wdrożenie technologii wspierających przetwarzanie w czasie rzeczywistym, Moc obliczeniowa potrzebna do wdrożenia i utrzymania modeli dla rozwiązań generatywnej AI, Użycie narzędzi (wewnętrznych lub zewnętrznych) opartych o generatywną AI w codziennej pracy (np. ChatGPT, MS Copilot), Skalowalność wykorzystywanych rozwiązań generatywnej AI
Dane	Budowanie wysokiej jakości zbiorów danych, Automatyzacja analizy i przetwarzania danych, Centralizacja zbiorów danych (jeden słownik danych w organizacji), Zastosowanie zaawansowanych narzędzi do oceny jakości danych, Budowanie strategii zarządzania danymi, Automatyzacja procesu zbierania i czyszczenia danych, Identyfikacja danych z wewnętrznych i zewnętrznych źródeł i integracja z aktualnymi zbiorami danych, Istnienie jednego standardowego modelu danych i zbioru standardowych metadanych, Wykorzystanie generatywnej AI do wspomaganie wizualizacji danych
Ludzie i kompetencje	Rozwijanie świadomości i zrozumienia rozwiązań generatywnej AI, Szkolenie zespołów z zakresu programowania (także prompting) i analizy danych, Tworzenie interdyscyplinarnych zespołów ds. generatywnej AI, Wprowadzenie zewnętrznych konsultantów ds. generatywnej AI do zespołów, Kształcenie w zakresie zarządzania projektami (budowy nowych produktów) wykorzystującymi generatywną AI, Usprawnienie transferu wiedzy między ludźmi poprzez wykorzystanie procesów zarządzania wiedzą w zakresie generatywnej AI
Organizacja i procesy	Integracja generatywnej AI z istniejącymi procesami rozwoju nowego produktu (rozwiązania generatywnej AI, które uwalniają kierownika produktu od zadań niezwiązanych z podstawowymi obowiązkami), Automatyzacja procesów rozwoju produktu z wykorzystaniem generatywnej AI, Zastosowanie generatywnej AI do wsparcia podejmowania decyzji, Implementacja narzędzi generatywnej AI wspierających pracę zespołów (codzienne narzędzia wspierające kierowników produktu), Wprowadzenie cykli ciągłego doskonalenia we wdrażaniu rozwiązań generatywnej AI (nauka z przeszłych i teraźniejszych wdrożeń na przyszłość), Zdefiniowany proces zarządzania cyklem życia dla oprogramowania używanego do dostarczania rozwiązań generatywnej AI, Przewodnik po procesie rozwoju produktu, oparty o rozwiązania generatywnej AI
Strategia i zarządzanie	Opracowanie długoterminowej strategii inwestycji w generatywną AI, Wdrożenie strategii AI w rozwój produktów (metodologia wdrażania), Określenie celów strategicznych dla generatywnej AI, Ocena wpływu biznesowego i wykonalności rozwiązania opartego o generatywną AI z wyprzedzeniem, Opracowanie systemu monitorowania wyników wdrożenia generatywnej AI (mierniki do oceny w jaki sposób rozwiązanie miało wpływ na proces), Analiza konkurencji pod względem ich zdolności do wdrożeń generatywnej AI
Budżet	Długoterminowe planowanie budżetu na rozwój rozwiązań i infrastruktury wspierającej rozwiązania generatywnej AI, Przeznaczanie środków na rozwój kompetencji

Wymiar	Zidentyfikowane najlepsze praktyki
	pracowników w zakresie generatywnej AI, Finansowanie projektów pilotażowych i innowacyjnych dotyczących rozwiązań generatywnej AI, Alokacja środków na zewnętrzne konsultacje dotyczące generatywnej AI, Priorytetyzacja projektów generujących wysoką wartość dodaną dzięki generatywnej AI
Produkty i usługi	Wspomaganie / automatyzacja procesów projektowania i wytwarzania produktów przy pomocy generatywnej AI, Wykorzystanie generatywnej AI do personalizacji produktów, Użycie generatywnej AI do generowania pomysłów związanych z produktem (także poprzez analizę sentymentu / analizę opinii), Wspomaganie redukcji informacji (np. streszczenia tekstu) przy pomocy generatywnej AI, Wykorzystanie generatywnej AI do wspomagania i ulepszania procesu oceny koncepcji (analizy wymagań, oceny ryzyka czy planowania zadań), Skrócenie czasu testowania produktu przy pomocy generatywnej AI, Wspomaganie marketingu produktowego (tworzenie reklam, słów kluczowych, filmów promocyjnych) wykorzystując rozwiązania generatywnej AI, Wykorzystanie generatywnej AI do udoskonalania systemów rekomendacji produktów, Udoskonalenie działania baz danych produktów przy pomocy generatywnej AI, Użycie rozwiązań generatywnej AI jako komponentu w profesjonalnych aplikacjach, Poszukiwanie nowych przypadków użycia rozwiązań generatywnej AI
Etyka i regulacje	Przestrzeganie zasad etyki w projektowaniu generatywnej AI, Bezpieczeństwo i prywatność danych dotyczących procesu rozwoju produktu, Zaufanie do danych i możliwość ich wyjaśnienia, Wdrożenie standardów ochrony i mechanizmów dotyczących kopii zapasowych danych, Przeciwdziałanie uprzedzeniom i niesprawiedliwości w algorytmach generatywnej AI, Regularna ocena zgodności algorytmów i narzędzi generatywnej AI z regulacjami prawnymi, Tworzenie systemów audytu decyzji podejmowanych przez generatywną AI (odpowiedzialność za decyzje podejmowane przez generatywną AI), Poszerzanie świadomości dotyczących ochrony danych wśród pracowników, Użycie technologii dotyczących cyberbezpieczeństwa, Utrzymywanie dokumentacji (przypadki użycia generatywnej AI, logi systemowe, testy, kontrola wersji, etc.) do monitorowania użycia rozwiązań generatywnej AI (niespójności, nietypowe zdarzenia)

Źródło: opracowanie własne.

Zdecydowano się na uwzględnienie podsumowania i metryk w raportach. Pozostawiono aktualną objętość raportu, bazując na sugestii, że raport może zostać zmodyfikowany po wykonaniu badań na mniejszych lub średnich organizacjach. Uwzględniono także komentarz dotyczący proponowania organizacjom wyboru trzech kluczowych wymiarów, w których chcą osiągnąć wyższy poziom dojrzałości. Końcowa wersja modelu została przedstawiona na Rysunku 9. W kolejnym rozdziale przebadano cztery organizacje, a ostateczne raporty można znaleźć pod linkiem zamieszczonym w Załączniku 4. Kolejnym krokiem po przygotowaniu modelu była faza koncepcji transferu i ewaluacji oraz implementacja mediów.



Rysunek 9. Model CLIMB2-OLIMP – wersja końcowa.

Źródło: opracowanie własne.

4.5. Koncepcja transferu i ewaluacji oraz implementacja mediów

Bazując na pracy Beckera, Knackstedta i Pöppelbußa (2009), w fazie koncepcji transferu i ewaluacji konieczne jest ustalenie różnych metod przekazania wyników zarówno do środowiska akademickiego, jak i do użytkowników. Oprócz udostępniania modelu w formie dokumentów (np. kwestionariusza), sugerowane jest także wykorzystanie Internetu. Poza przygotowanymi kwestionariuszami i publikacją modelu w artykule naukowym, zdecydowano się także na udostępnienie narzędzia w formie repozytorium na GitHub, aby nie tylko umożliwić

przeprowadzenie badania, ale również wgląd dla społeczności akademickiej w szczegóły implementacji narzędzia. Celem kolejnej fazy, czyli implementacji mediów, jest udostępnienie modelu dojrzałości w zaplanowanej formie dla wszystkich określonych wcześniej użytkowników (jeśli zakłada również samoocenę organizacji, co często nie ma miejsca w przypadku modeli tworzonych przez firmy szkoleniowe lub doradcze na potrzeby własnych działań). Jak wspomniano w poprzednim punkcie, udostępniono model w Internecie, w repozytorium GitHub, które można znaleźć pod linkiem w Załączniku 4.

4.6. Podsumowanie opracowania modelu dojrzałości

Bazując na podejściu nauk o projektowaniu, wykorzystując przeprowadzone badania literaturowe i wywiady, możliwe było opracowanie modelu dojrzałości w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju nowego produktu. Sprawdzono wiarygodność modelu z udziałem ekspertów – ich sugestie doprowadziły do dodania kilku elementów modelu, ale bez zmian w jego wymiarach. Jednocześnie opracowany model nie jest inkluzywny tzn., że w przyszłych opracowaniach można go rozszerzyć o dodatkowe elementy, wraz z rozwojem rozwiązań generatywnej sztucznej inteligencji. Opracowano także narzędzie odpowiadające za część preskryptywną modelu, oparte na rozwiązaniach generatywnej sztucznej inteligencji. Narzędzie wskazuje rekomendacje dotyczące przejścia do wyższych poziomów dojrzałości. Przedstawiono procedurę korzystania z modelu, nazwanego CLIMB2-OLIMP, skupiającą się na kroku początkowym, czyli zbadaniu wstępnie dojrzałości procesu rozwoju nowego produktu, kroku drugim, czyli zbadaniu dojrzałości w wykorzystaniu rozwiązań generatywnej AI w tym procesie oraz kroku trzecim, czyli użyciu narzędzia odpowiadającego za część preskryptywną.

Rozdział 4 bezpośrednio odpowiada na pytanie badawcze 3. Po pierwsze, rozszerzono istniejący model dojrzałości NPD do CLIMB2, a następnie zaprojektowano pięciopoziomowy model OLIMP dla dojrzałości w wykorzystaniu GenAI. Po drugie, oba modele scalono w procedurę CLIMB2-OLIMP, w której ocena GenAI jest warunkowana sprawdzeniem poziomu dojrzałości NPD. Zaprojektowany model reaguje na zidentyfikowaną krytykę literatury (prostota, dokumentacja, oparcie na teorii i naukowych wytycznych, uwzględnienie istotnych czynników, uniwersalność

przy zachowaniu kompleksowości). W odniesieniu do pytania badawczego 4 wprowadzono część preskryptywną (której brak również był wskazywany jako punkt krytyki aktualnych modeli): narzędzie oparte na wielu dużych modelach językowych generuje ścieżki dojścia do wyższych poziomów dojrzałości wraz z uwzględnieniem aspektu finansowego.

Podczas opracowywania modelu uwzględniono większość zidentyfikowanej krytyki modeli. Pozostałe punkty, czyli ewaluacja modelu w badaniach empirycznych oraz określenie jego użyteczności, zostaną omówione w kolejnym rozdziale.

Rozdział 5. Ewaluacja modelu dojrzałości w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju nowego produktu

Celem poniższego rozdziału jest zbadanie dojrzałości organizacji i sprawdzenie, czy opracowany model dojrzałości dostarcza oczekiwane korzyści. Przeprowadzono cztery studia przypadków (*case studies*) organizacji z sektora produkcyjnego. Jak wcześniej wspomniano, model udostępniono w Internecie do samooceny, ale główną metodą ewaluacji są przeprowadzone studia przypadków, które pełnią funkcję ewaluacji modelu (ostatni krok w opisywanej wcześniej procedurze) i były sugerowane przez Beckera, Knackstedta i Pöppelbußa (2009). Studium przypadku jest opisywane jako dogłębna analiza pojedynczej jednostki (np. osoby, grupy, zdarzenia czy innego obszaru), która uwzględnia czynniki rozwojowe w kontekście otoczenia (Flyvbjerg, 2011) lub jako empiryczne badanie, które podejmuje próbę zrozumienia współczesnego zjawiska osadzonego w rzeczywistym kontekście (R. K. Yin, 2003). Ważnym elementem studiów przypadków jest stosowanie niewielkich prób, co pozwala na uzyskanie głębszego i bardziej kompleksowego zrozumienia badanego zjawiska niż przy analizie dużych prób ankietowych (Kasanen i in., 1993). Studia przypadku stanowią odpowiednią strategię badawczą, zwłaszcza w nowych dziedzinach, gdzie niezbędne są dane jakościowe dla pełniejszego poznania badanych zjawisk. Modelowanie dojrzałości w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji jest stosunkowo nowym obszarem badań, stąd studia przypadków uznano za użyteczne w celu pogłębienia wiedzy w tej domenie.

5.1. Dobór i opis organizacji

Celem jest zbadanie dojrzałości w wykorzystaniu generatywnej sztucznej inteligencji (*Generative Artificial Intelligence – GenAI*) w procesie rozwoju nowego produktu (*New Product Development – NPD*) poprzez model CLIMB2-OLIMP i zbadanie użyteczności modelu. W badaniach skupiono się na sektorze produkcyjnym (wysokie koszty cyklu NPD, większa presja na efektywność GenAI; pierwotnie także model CLIMB był przeznaczony dla sektora produkcyjnego). W tym celu wybrano cztery organizacje charakteryzujące się zbliżoną logiką biznesową, mające długie cykle życia swoich produktów (trwające zazwyczaj dłużej niż 10 lat), uwzględniające późniejszą modernizację lub serwis. W badaniu ujęto przedsiębiorstwa przedstawione poniżej:

Organizacja A (OrgA) to wiodące amerykańskie przedsiębiorstwo z sektora produkcyjnego, obecne na wszystkich rynkach światowych, z lokalizacjami w ponad 30 krajach. Jest to globalnie rozpoznawany lider w produkcji przemysłowych urządzeń elektronicznych, zatrudniający ponad 1000 pracowników na całym świecie. Trzech ekspertów z organizacji A – dwóch kierowników produktów z długim stażem w organizacji oraz jeden inżynier zajmujący się wdrożeniami technologii – odpowiedziało oddzielnie na pytania dotyczące oceny dojrzałości. Wyniki oceny zostały następnie zweryfikowane i skonsolidowane przez dyrektora ds. technologii (włączonego w procesy rozwoju nowego produktu), który dodatkowo uczestniczył w wywiadzie.

Organizacja B (OrgB) to średniej wielkości polskie przedsiębiorstwo inżynierskie działające od wielu lat w sektorze rozwiązań technologicznych dla przemysłu. Firma specjalizuje się w projektowaniu i wdrażaniu systemów wspierających automatyzację procesów produkcyjnych. Jej oferta obejmuje zarówno produkty sprzętowe, jak i komponenty oprogramowania przemysłowego. Zatrudnia ponad 200 pracowników w różnych lokalizacjach w Polsce. W badaniu wziął udział prezes zarządu, który wypełnił kwestionariusz oraz uczestniczył w indywidualnym wywiadzie.

Organizacja C (OrgC) to polska technologiczna firma produkcyjna, która jest wiodącym wytwórcą sprzętu elektronicznego na rynku polskim, działająca w tym sektorze od ponad 30 lat. Organizacja zatrudnia obecnie ponad 150 osób. Jeden ekspert z organizacji C, pracujący jako strategiczny konsultant technologiczny, wypełnił kwestionariusz i uczestniczył w częściowo ustrukturyzowanym wywiadzie.

Organizacja D (OrgD) to polski oddział niemieckiej firmy technologicznej zajmującej się produkcją elektroniki przemysłowej, z zakładami produkcyjnymi w Polsce, zatrudniający ponad 1000 pracowników w kraju, a łącznie ponad 15 000 pracowników na całym świecie. Kierownik produktu wypełnił kwestionariusz i został poproszony o ocenę modelu.


5.2. Wyniki oceny dojrzałości

Najpierw przeprowadzono ocenę dojrzałości organizacji A. Pierwszym krokiem była ocena dojrzałości procesu rozwoju nowego produktu modelem CLIMB2. Po przeprowadzeniu oceny i potwierdzeniu, że organizacja w każdym z wymiarów znajduje się przynajmniej na poziomie 2, wykonano ocenę dojrzałości w wykorzystaniu generatywnej sztucznej inteligencji w procesie

rozwoju nowego produktu modelem OLIMP. Odpowiedzi respondentów zostały zapisane na kwestionariuszach w Załącznikach 2 i 3 – organizacja A została oznaczona jako „OrgA”. Wyniki zostały przedstawione na wykresach radarowych na Rysunku 10.

Pomiar dojrzałości organizacji A modelem CLIMB2 wskazał, że większość wymiarów znajduje się na poziomie drugim (stąd również cała organizacja). Jedyne wymiar – „Metody” – znalazł się na poziomie trzecim. Wyniki praktyk w poszczególnych wymiarach wyglądają następująco:

- **Role i współpraca** – po trzy praktyki znajdują się na poziomie trzecim i czwartym, jedynie jedna praktyka znajduje się na poziomie drugim, dotycząca ról i obowiązków każdej z osób. Jeden z respondentów podkreślił: „Procesy są jasno zdefiniowane, ale wielu członków zespołów międzyfunkcyjnych nie jest w ogóle przeszkolonych w zakresie tego procesu lub nawet nie wie, gdzie szukać informacji”.
- **Szkolenie** – wszystkie trzy praktyki znajdują się na poziomie drugim.
- **Działania i przepływ** – poza dwiema praktykami na poziomie drugim, cztery praktyki są na poziomie trzecim i dwie praktyki na poziomie piątym. Praktyki na poziomie piątym wskazują wysoką formalizację procesu rozwoju nowego produktu oraz istotność współpracy. W przypadku jednej z praktyk na poziomie drugim dotyczącej frontloadingu, respondenci wskazują: „Frontloading nie jest standardem, jest to raczej coś, co odbiega od procesu w celu osiągnięcia pożądanego rezultatu na czas. Decyzja o rozpoczęciu pracy nad zadaniami z dużym wyprzedzeniem leży w gestii zespołu projektowego (często promowanego przez kierownika produktu lub kierownika programu) i opiera się na doświadczeniu”. Respondenci skomentowali także drugą z praktyk na poziomie drugim dotyczącą analizy konkurencji: „Zależy to od rodzaju projektu. Mieliśmy projekty, w których analiza konkurencyjnych produktów była bardzo ważna i mieliśmy także projekty, w których konkurencyjne produkty nie były w ogóle analizowane”.
- **Podjęmowanie decyzji** – siedem praktyk z tego wymiaru jest na poziomie drugim, trzynaście na poziomie trzecim i dwie na poziomie czwartym. Duży wpływ w organizacji ma proces testowania i eksperymentowania w procesie rozwoju nowego produktu oraz zgodność z normami i regulacjami.
- **Procesy zarządzania wiedzą** – osiemnaście praktyk znajduje się na poziomie drugim, cztery praktyki znajdują się na poziomie trzecim.



Rysunek 10. Ocena dojrzałości organizacji A modelem CLIMB2-OLIMP.

Źródło: opracowanie własne.

- **Techniki zarządzania wiedzą** – pięć praktyk znajduje się na poziomie drugim, dwie na poziomie trzecim oraz cztery na poziomie czwartym. Respondenci wskazywali narzędzia Microsoft SharePoint oraz Microsoft Teams jako platformy o rosnącym znaczeniu w zarządzaniu wiedzą w organizacji.
- **Metody** – cztery praktyki znajdują się na poziomie trzecim, cztery na poziomie czwartym oraz trzy na poziomie piątym. Organizacja korzysta ze wszystkich metod uwzględnionych w tym wymiarze z wysoką regularnością.
- **Oprogramowanie** – osiem praktyk jest na poziomie drugim, siedem na poziomie trzecim, pięć na poziomie czwartym, a trzy praktyki nie dotyczą organizacji. Obliczeniowa dynamika płynów, symulacja zdarzeń dyskretnych czy skomputeryzowany system zarządzania konserwacją nie dotyczą branży, w której działa organizacja.

Powyższe praktyki zostały przedstawione w Tabeli 16. Zdecydowano się, jak wcześniej wspomniano, na uwzględnienie w tabeli średniej ważonej, zarówno dla poszczególnych wymiarów, jak i łącznej, w celu porównania między badanymi organizacjami. Wartości „N/D” (nie dotyczy) zostały pominięte w obliczeniach, ponieważ nie reprezentują żadnego poziomu oceny. Pomiar dojrzałości organizacji A modelem OLIMP pokazał, że pięć z ośmiu wymiarów znajduje się na poziomie pierwszym (cała organizacja także), a trzy wymiary – „Dane”, „Strategia i

Tabela 16. Liczba praktyk w danym wymiarze w modelu CLIMB2 dla organizacji A.

Wymiar	Poziom 1	Poziom 2	Poziom 3	Poziom 4	Poziom 5	N/D	Śr. waż.
Role i współpraca	-	1	3	3	-	-	3,29
Szkolenie	-	3	-	-	-	-	2,00
Działania i przepływ	-	2	4	-	2	-	3,25
Podejmowanie decyzji	-	7	13	2	-	-	2,77
Procesy KM	-	18	4	-	-	-	2,18
Techniki KM	-	5	2	4	-	-	2,91
Metody	-	-	4	4	3	-	3,91
Oprogramowanie	-	8	7	5	-	3	2,85
Łącznie	0	44	37	18	5	3	2,85

Źródło: opracowanie własne.

zarządzanie” oraz „Etyka i regulacje” – na poziomie drugim. Poniżej przedstawiono rozmieszczenie praktyk związane z każdym z wymiarów:

- **Technologie i infrastruktura** – dwie praktyki znajdują się na poziomie drugim, siedem na poziomie trzecim, a jedna na poziomie pierwszym, związana z automatyzacją wdrażania modeli generatywnej AI, co wskazuje na ręczne wdrażanie.
- **Dane** – sześć praktyk znajduje się na poziomie drugim, trzy praktyki znajdują się na poziomie trzecim.
- **Ludzie i kompetencje** – cztery praktyki na poziomie pierwszym, dwie praktyki na poziomie drugim.
- **Organizacja i procesy** – pięć praktyk na poziomie pierwszym, dwie praktyki na poziomie drugim.
- **Strategia i zarządzanie** – pięć praktyk na poziomie drugim, jedna praktyka na poziomie trzecim – organizacja ma załączki strategii związanej z inwestycjami w generatywną AI.
- **Budżet** – dwie praktyki na poziomie pierwszym, trzy praktyki na poziomie drugim.
- **Produkty i usługi** – siedem praktyk na poziomie pierwszym, cztery praktyki na poziomie drugim.

- **Etyka i regulacje** – cztery praktyki na poziomie drugim, jedna na poziomie trzecim oraz pięć na poziomie czwartym.

Powyższe praktyki wraz ze średnimi ważonymi zostały przedstawione w Tabeli 17.

Ostatnim krokiem było użycie narzędzia odpowiadającego za część preskryptywną modelu i ocena użyteczności modelu. Organizacja A wybrała trzy wymiary – „Ludzie i kompetencje”, „Organizacja i procesy” oraz „Budżet” – jako kluczowe, czyli takie, w których chciałaby osiągnąć poziom piąty, pozostawiając pozostałe wymiary na aktualnym poziomie. Bazując na tych wskazaniach wygenerowano raport, który znajduje się pod linkiem w Załączniku 4. Następnie poproszono o ocenę użyteczności całego modelu. Model został oceniony na 8 w skali od 0 do 10 (samą część preskryptywną organizacja też oceniła na 8 punktów) wraz z komentarzem: „Uzasadnienie jest takie, że kwestionariusze wydają się dość proste do wypełnienia w stosunku do rekomendacji, które otrzymujemy na ich bazie. Zalecenia wydają się całkiem odpowiednie. Próba zapewnienia większej ilości szczegółów byłaby wyzwaniem, ponieważ każda sytuacja będzie wyjątkowa, a priorytety będą również oparte na dostępnych zasobach, czasie itp. Raport jest bardzo przydatny, aby zapewnić mapę drogową możliwych działań”.

Kolejno przeprowadzono ocenę dojrzałości organizacji B. Rozpoczęto od oceny dojrzałości procesu rozwoju nowego produktu modelem CLIMB2. W trakcie oceny, jedynie jeden element w jednym wymiarze znajdował się na poziomie pierwszym – wszystkie inne elementy we wszystkich wymiarach znajdowały się na poziomie co najmniej drugim. Stąd zdecydowano się kolejno na przeprowadzenie oceny modelem OLIMP. Udzielone przez uczestników badania informacje zostały umieszczone w kwestionariuszach badawczych, które można znaleźć w Załącznikach 2 oraz 3 – gdzie podmiot B został oznaczony symbolem „OrgB”. Uzyskane dane badawcze zaprezentowano w formie wykresów radarowych widocznych na Rysunku 11.


Pomiar dojrzałości organizacji B modelem CLIMB2 wskazał, że jeden z wymiarów – „Szkolenie” – znalazł się na poziomie czwartym, a wymiar „Procesy zarządzania wiedzą” – na poziomie pierwszym (jak i cała organizacja), a wszystkie pozostałe na poziomie drugim. Wyniki praktyk w poszczególnych wymiarach wyglądają następująco:

- **Role i współpraca** – po dwie praktyki znajdują się na poziomie drugim i trzecim, trzy praktyki znajdują się na poziomie czwartym.

Tabela 17. Liczba praktyk w danym wymiarze w modelu OLIMP dla organizacji A.

Wymiar	Poziom 1	Poziom 2	Poziom 3	Poziom 4	Poziom 5	Śr. waż.
Technologie i infrastruktura	1	2	7	-	-	2,60
Dane	-	6	3	-	-	2,33
Ludzie i kompetencje	4	2	-	-	-	1,33
Organizacja i procesy	5	2	-	-	-	1,29
Strategia i zarządzanie	-	5	1	-	-	2,17
Budżet	2	3	-	-	-	1,60
Produkty i usługi	7	4	-	-	-	1,36
Etyka i regulacje	-	4	1	5	-	3,10
Łącznie	19	28	12	5	0	2,05

Źródło: opracowanie własne.



Rysunek 11. Ocena dojrzałości organizacji B modelem CLIMB2-OLIMP.

Źródło: opracowanie własne.

- **Szkolenie** – jedna praktyka znajduje się na poziomie czwartym, a dwie na poziomie piątym – organizacja skupia się na rozwijaniu kompetencji pracowników.

- **Działania i przepływ** – poza czterema praktykami na poziomie drugim, trzy praktyki są na poziomie czwartym i jedna praktyka na poziomie piątym, dotycząca uwzględniania współpracy na każdym etapie procesu rozwoju produktu
- **Podejmowanie decyzji** – trzy praktyki z tego wymiaru są na poziomie drugim, sześć na poziomie trzecim, dziesięć na poziomie czwartym i trzy na poziomie piątym. Kluczowe dla organizacji przy podejmowaniu decyzji są innowacyjność, czas wprowadzenia na rynek i czas dostawy oraz uwzględnienie sposobu użytkowania produktu przez klienta.
- **Procesy zarządzania wiedzą** – jedna praktyka, dotycząca posiadania formalnego planu zarządzania wiedzą, jest na poziomie pierwszym, cztery praktyki na poziomie drugim, osiem praktyk na poziomie trzecim oraz dziewięć praktyk na poziomie czwartym. Praktyka będąca na poziomie pierwszym jest jednocześnie jedyną na tym poziomie, patrząc na wszystkie wymiary.
- **Techniki zarządzania wiedzą** – po jednej praktyce znajduje się na poziomie drugim i trzecim, pięć praktyk na poziomie czwartym oraz cztery na poziomie piątym. Organizacja wskazuje na wykorzystanie wielu różnych technik na wysokim poziomie, jeśli chodzi o zarządzanie i dzielenie się wiedzą.
- **Metody** – po cztery praktyki znajdują się na poziomie drugim i trzecim oraz trzy na poziomie czwartym. Organizacja skupia się w swoich projektach głównie na zasadach standaryzacji, analizie i inżynierii wartości oraz na analizie ryzyka i awarii.
- **Oprogramowanie** – siedem praktyk jest na poziomie drugim, osiem na poziomie trzecim, trzy na poziomie czwartym, a pięć na poziomie piątym. Organizacja przykłada największą uwagę do wykorzystywania w projektach nowych produktów cyfrowych modeli i komputerowego wspomagania projektowania 2D i 3D (CAD) oraz inżynierii (CAE).

Powyższe praktyki wraz ze średnimi ważonymi zostały przedstawione w Tabeli 18.

Pomiar dojrzałości organizacji B modelem OLIMP wskazał „Budżet” jako jedyny wymiar na poziomie drugim, wszystkie inne znajdują się na poziomie pierwszym (także organizacja jako całość). Poniżej rozmieszczenie praktyk związane z każdym z wymiarów:

- **Technologie i infrastruktura** – cztery praktyki znajdują się na poziomie pierwszym, cztery na poziomie drugim i dwie na poziomie trzecim.

Tabela 18. Liczba praktyk w danym wymiarze w modelu CLIMB2 dla organizacji B.

Wymiar	Poziom 1	Poziom 2	Poziom 3	Poziom 4	Poziom 5	N/D	Śr. waż.
Role i współpraca	-	2	2	3	-	-	3,14
Szkolenie	-	-	-	1	2	-	4,67
Działania i przepływ	-	4	-	3	1	-	3,13
Podejmowanie decyzji	-	3	6	10	3	-	3,59
Procesy KM	1	4	8	9	-	-	3,14
Techniki KM	-	1	1	5	4	-	4,09
Metody	-	4	4	3	-	-	2,91
Oprogramowanie	-	7	8	3	5	-	3,26
Łącznie	1	25	29	37	15	0	3,37

Źródło: opracowanie własne.

- **Dane** – po dwie praktyki znajdują się na poziomie pierwszym i drugim, jedna praktyka na poziomie trzecim i cztery praktyki na poziomie czwartym, związane z jakością, integracją i centralizacją danych oraz automatyzacją ich przetwarzania.
- **Ludzie i kompetencje** – jedna praktyka na poziomie pierwszym, cztery na poziomie drugim i jedna na poziomie trzecim.
- **Organizacja i procesy** – pięć praktyk na poziomie pierwszym, jedna na poziomie drugim i jedna na poziomie trzecim dotycząca wykorzystania AI do wspierania decyzji.
- **Strategia i zarządzanie** – cztery praktyki znajdują się na poziomie pierwszym, dwie praktyki na poziomie drugim.
- **Budżet** – trzy praktyki znajdują się na poziomie drugim, dwie praktyki na poziomie trzecim.
- **Produkty i usługi** – dwie praktyki znajdują się na poziomie pierwszym, pięć praktyk na poziomie drugim, jedna na poziomie trzecim, trzy na poziomie czwartym.
- **Etyka i regulacje** – cztery praktyki na poziomie pierwszym, jedna na poziomie drugim, cztery na poziomie czwartym oraz jedna na poziomie piątym, dotycząca wdrożenia standardów ochrony i mechanizmów kopii zapasowych danych.

Powyższe praktyki wraz ze średnimi ważonymi zostały przedstawione w Tabeli 19.


Tabela 19. Liczba praktyk w danym wymiarze w modelu OLIMP dla organizacji B.

Wymiar	Poziom 1	Poziom 2	Poziom 3	Poziom 4	Poziom 5	Śr. waż.
Technologie i infrastruktura	4	3	3	-	-	1,90
Dane	2	2	1	4	-	2,78
Ludzie i kompetencje	1	4	1	-	-	2,00
Organizacja i procesy	5	1	1	-	-	1,43
Strategia i zarządzanie	4	2	-	-	-	1,33
Budżet	-	3	2	-	-	2,40
Produkty i usługi	2	5	1	3	-	2,45
Etyka i regulacje	4	1	-	4	1	2,70
Łącznie	22	21	9	11	1	2,19

Źródło: opracowanie własne.

Kolejno użyto narzędzia odpowiadającego za część preskryptywną modelu i poproszono o ocenę użyteczności modelu. Podobnie jak w organizacji A, skupiono się na wyborze trzech kluczowych dla organizacji wymiarów „Organizacja i procesy”, „Ludzie i kompetencje” oraz „Produkty i usługi”, w których organizacja chciałaby osiągnąć maksymalny poziom dojrzałości. Na podstawie tego wyboru wygenerowano raport, który znajduje się pod linkiem w Załączniku 4. Kolejno poproszono o ocenę użyteczności modelu. Został on oceniony na 9 w skali od 0 do 10 (tak samo organizacja oceniła samą część preskryptywną modelu), podkreślając szczególnie wagę raportu: „Formularze są złożone i przejście ich zajmuje trochę czasu, ale raport jest bardzo kompleksowy i rzeczywiście pokazuje holistycznie, co warto robić w poszczególnych obszarach GenAI. Jest bardzo dużo inspiracji na temat projektów. W przypadku prezentowania raportu dla naukowej części społeczności, uważam, że taki format jest w porządku, natomiast prezentując taki raport dla zarządu, warto byłoby wygenerować oddzielnie trzypięciowy dokument z wykresami i tabelami, zawierający graficzne podsumowanie prezentowanych treści”.

W następnym kroku przeprowadzono ocenę dojrzałości organizacji C. Zebrane od respondentów dane zostały udokumentowane na kwestionariuszach, dostępnych jako Załączniki 2 i 3 – instytucję tę oznaczono identyfikatorem „OrgC”. Wizualizacja wyników badań została przedstawiona za pomocą wykresów radarowych zamieszczonych na Rysunku 12.



Rysunek 12. Ocena dojrzałości organizacji C modelem CLIMB2-OLIMP.

Źródło: opracowanie własne.

Pomiar dojrzałości organizacji C modelem CLIMB2 pokazał, że poza wymiarem „Procesy zarządzania wiedzą”, który znalazł się na poziomie pierwszym (stąd cała organizacja na poziomie pierwszym), wszystkie inne wymiary znajdują się na poziomie drugim. Wyniki praktyk w poszczególnych wymiarach wyglądają następująco:

- **Role i współpraca** – po trzy praktyki znajdują się na poziomie drugim i trzecim, jedna praktyka znajduje się na poziomie czwartym, dotycząca elastyczności w wykonywaniu zadań.
- **Szkolenie** – wszystkie trzy praktyki znajdują się na poziomie drugim.
- **Działania i przepływ** – poza pięcioma praktykami na poziomie drugim, jedna praktyka jest na poziomie trzecim i dwie praktyki na poziomie czwartym, dotyczące uwzględniania współpracy na każdym etapie procesu rozwoju produktu oraz skupiania się na wartości dla klienta.
- **Podejmowanie decyzji** – cztery praktyki z tego wymiaru są na poziomie drugim, dziesięć na poziomie trzecim i osiem na poziomie czwartym.
- **Procesy zarządzania wiedzą** – jedna praktyka, dotycząca posiadania formalnego planu zarządzania wiedzą, podobnie jak w organizacji B, jest na poziomie pierwszym, osiemnaście praktyk na poziomie drugim, jedna praktyka na poziomie trzecim oraz dwie praktyki na poziomie czwartym. Identycznie jak w organizacji B, praktyka będąca na

poziomie pierwszym jest jednocześnie jedyną na tym poziomie, patrząc na wszystkie wymiary.

- **Techniki zarządzania wiedzą** – dziewięć praktyk znajduje się na poziomie drugim, a dwie praktyki na poziomie czwartym, dotyczące werbalnej komunikacji i wspólnych folderów sieciowych wykorzystywanych w celu dzielenia się wiedzą.
- **Metody** – pięć praktyk znajduje się na poziomie drugim, cztery na poziomie trzecim i dwie na poziomie czwartym.
- **Oprogramowanie** – siedemnaście praktyk jest na poziomie drugim i jedna praktyka jest na poziomie czwartym. Pięć praktyk nie dotyczy branży, w której działa organizacja.

Powyższe praktyki wraz ze średnimi ważonymi zostały przedstawione w Tabeli 20.

Pomiar dojrzałości organizacji C modelem OLIMP wskazał, że wszystkie wymiary są na poziomie pierwszym (cała organizacja na poziomie pierwszym). Poniżej rozmieszczenie praktyk związane z każdym z wymiarów:

- **Technologie i infrastruktura** – po trzy praktyki znajdują się na poziomie pierwszym i drugim, a cztery na poziomie trzecim.
- **Dane** – jedna praktyka, dotycząca wykorzystania generatywnej AI do wizualizacji danych, znajduje się na poziomie pierwszym, pięć praktyk na poziomie drugim i trzy na poziomie trzecim.
- **Ludzie i kompetencje** – cztery praktyki znajdują się na poziomie pierwszym, a dwie na poziomie drugim.
- **Organizacja i procesy** – pięć praktyk znajduje się na poziomie pierwszym i dwie na poziomie drugim.
- **Strategia i zarządzanie** – dwie praktyki znajdują się na poziomie pierwszym, a cztery na poziomie drugim.
- **Budżet** – jedna praktyka, dotycząca braku alokacji środków na zewnętrzne konsultacje dotyczące AI, znajduje się na poziomie pierwszym, a cztery praktyki na poziomie drugim.
- **Produkty i usługi** – pięć praktyk znajduje się na poziomie pierwszym, a sześć praktyk na poziomie drugim.
- **Etyka i regulacje** – po dwie praktyki znajdują się na poziomie pierwszym i drugim oraz po trzy praktyki na poziomie trzecim i czwartym.

Tabela 20. Liczba praktyk w danym wymiarze w modelu CLIMB2 dla organizacji C.

Wymiar	Poziom 1	Poziom 2	Poziom 3	Poziom 4	Poziom 5	N/D	Śr. waż.
Role i współpraca	-	3	3	1	-	-	2,71
Szkolenie	-	3	-	-	-	-	2,00
Działania i przepływ	-	5	1	2	-	-	2,63
Podejmowanie decyzji	-	4	10	8	-	-	3,18
Procesy KM	1	18	1	2	-	-	2,18
Techniki KM	-	9	-	2	-	-	2,36
Metody	-	5	4	2	-	-	2,73
Oprogramowanie	-	17	-	1	-	5	2,11
Łącznie	1	64	19	18	0	5	2,53

Źródło: opracowanie własne.

Powyższe praktyki wraz ze średnimi ważonymi zostały przedstawione w Tabeli 21.

Następnie użyto przygotowanego narzędzia z rekomendacjami i zapytano o ocenę użyteczności modelu. Organizacja C wybrała trzy kluczowe z ich perspektywy wymiary, w których chciałaby osiągnąć maksymalny poziom – „Dane”, „Ludzie i kompetencje” oraz „Budżet”. Bazując na wybranych wymiarach, przygotowano raport, który znajduje się pod linkiem w Załączniku 4. Użyteczność określono tym razem na 5 punktów w skali od 0 do 10 (sama część preskryptywna została oceniona na 6), uzasadniając wybór komentarzem: „W niektórych wymiarach pytań jest bardzo dużo, co w przypadku podejścia ilościowego może powodować to, że część ludzi się podda w trakcie, ale w przypadku podejścia jakościowego według mnie jest to w miarę rozsądnie wyważone. Raport dotyka bardzo szczegółowo poszczególnych obszarów organizacji i przedstawia bardzo specjalistyczne rekomendacje. Z punktu widzenia średniej firmy taki raport jest chyba zbyt skomplikowany. Jeśli firma jest zakwalifikowana jako początkowy do średniego poziomu zaawansowania to pewnie kluczowym byłoby pokazanie, jakie najważniejsze kroki powinna podjąć firma, aby przejść na kolejny poziom. Raport przedstawia całą ścieżkę do „osiągnięcia doskonałości” - co jest pewnie dobrym kierunkiem, ale w przypadku średnich firm one raczej działają w trybie „step by step”. Z punktu widzenia założeń budżetowych - one też

Tabela 21. Liczba praktyk w danym wymiarze w modelu OLIMP dla organizacji C.


Wymiar	Poziom 1	Poziom 2	Poziom 3	Poziom 4	Poziom 5	Śr. waż.
Technologie i infrastruktura	3	3	4	-	-	2,10
Dane	1	5	3	-	-	2,22
Ludzie i kompetencje	4	2	-	-	-	1,33
Organizacja i procesy	5	2	-	-	-	1,29
Strategia i zarządzanie	2	4	-	-	-	1,67
Budżet	1	4	-	-	-	1,80
Produkty i usługi	5	6	-	-	-	1,55
Etyka i regulacje	2	2	3	3	-	2,70
Łącznie	23	28	10	3	0	1,89

Źródło: opracowanie własne.

powinny być jakoś skorelowane z rozmiarem firmy. W większości średnich firm, jeśli prezes dostałby raport, który mówi, że trzeba założyć minimum 10 milionów złotych na projekt (pomimo, że to są 3 lata) to może to być wyzwaniem, aby łatwo dostać zielone światło. Reasumując, generalnie raport jest bardzo dobry - ale według mojego subiektywnego zdania - sprawdzi się dobrze w dużych firmach, gdzie mamy szansę na dedykowane zespoły, dokładną analizę poszczególnych obszarów organizacji i zaplanowanie działań na 3 lata lub dłużej. W średnich firmach jak nasza, może być odebrany jako zbyt szczegółowy”.

Ostatnim etapem było przeprowadzenie oceny dojrzałości organizacji D. Podobnie jak w przypadku poprzednich organizacji, informacje pozyskane od uczestników badania zostały zarejestrowane w kwestionariuszach, które dołączono jako Załączniki 2 i 3 – z oznaczeniem tej jednostki jako „OrgD”. Rezultaty analizy zostały zobrazowane przy użyciu wykresów radarowych zamieszczonych na Rysunku 13.

Pomiar dojrzałości organizacji D modelem CLIMB2 pokazał, że poza wymiarami „Szkolenie” oraz „Role i współpraca”, które znalazły się na poziomie drugim, wszystkie inne wymiary znajdują się na poziomie pierwszym (stąd cała organizacja na poziomie pierwszym). Wyniki praktyk w poszczególnych wymiarach wyglądają następująco:



Rysunek 13. Ocena dojrzałości organizacji D modelem CLIMB2-OLIMP.

Źródło: opracowanie własne.

- **Role i współpraca** – pięć praktyk znajduje się na poziomie drugim i po jednej praktyce na poziomie trzecim i czwartym.
- **Szkolenie** – wszystkie trzy praktyki znajdują się na poziomie drugim.
- **Działania i przepływ** – po dwie praktyki znajdują się na poziomie pierwszym i drugim, cztery praktyki znajdują się na poziomie trzecim.
- **Podejmowanie decyzji** – pięć praktyk jest na poziomie pierwszym, jedna na poziomie drugim, siedem praktyk na poziomie trzecim, cztery na poziomie czwartym i pięć na poziomie piątym.
- **Procesy zarządzania wiedzą** – siedem praktyk znajduje się na poziomie pierwszym, pięć na poziomie drugim, siedem na poziomie trzecim, trzy na poziomie czwartym.
- **Techniki zarządzania wiedzą** – pięć praktyk znajduje się na poziomie pierwszym, jedna na poziomie drugim, po dwie na poziomie trzecim i czwartym oraz jedna na poziomie piątym, dotycząca priorytetu używania wspólnych folderów sieciowych w dzieleniu się wiedzą.
- **Metody** – trzy praktyki znajdują się na poziomie pierwszym, cztery na poziomie drugim, trzy na poziomie trzecim i jedna na poziomie piątym, dotycząca stosowania analizy ryzyka i awarii we wszystkich projektach, mającej kluczowy wpływ na decyzje projektowe.

- **Oprogramowanie** – trzy praktyki są na poziomie pierwszym, po cztery na poziomie drugim i trzecim, jedna na poziomie czwartym, osiem na poziomie piątym, a trzy praktyki nie dotyczą branży, w której działa organizacja.

Powyższe praktyki zostały przedstawione w tabeli 22.

Mimo że łącznie 25 praktyk znalazło się na poziomie pierwszym, zdecydowano się także na wykonanie pomiaru dojrzałości organizacji D modelem OLIMP, który pokazał, że wszystkie wymiary znajdują się na poziomie pierwszym (cała organizacja na poziomie pierwszym). Poniżej rozmieszczenie praktyk związane z każdym z wymiarów:

- **Technologie i infrastruktura** – sześć praktyk znajduje się na poziomie pierwszym, dwie na poziomie drugim, a po jednej na poziomie trzecim i czwartym.
- **Dane** – pięć praktyk znajduje się na poziomie pierwszym, trzy na poziomie drugim i jedna na poziomie trzecim.
- **Ludzie i kompetencje** – cztery praktyki znajdują się na poziomie pierwszym, a po jednej na poziomie drugim i trzecim.
- **Organizacja i procesy** – wszystkie siedem praktyk znajduje się na poziomie pierwszym.
- **Strategia i zarządzanie** – cztery praktyki znajdują się na poziomie pierwszym, a dwie na poziomie drugim.
- **Budżet** – dwie praktyki znajdują się na poziomie pierwszym, a trzy na poziomie drugim.
- **Produkty i usługi** – osiem praktyk znajduje się na poziomie pierwszym, dwie na poziomie drugim i jedna na poziomie trzecim.
- **Etyka i regulacje** – po trzy praktyki znajdują się na poziomie pierwszym i drugim oraz po dwie praktyki na poziomie trzecim i czwartym.

Powyższe praktyki zostały przedstawione w Tabeli 23.

Ostatnim krokiem było użycie narzędzia odpowiadającego za część preskryptywną modelu i ocena użyteczności modelu. Organizacja D postanowiła skupić się na trzech strategicznych wymiarach: „Ludzie i kompetencje”, „Organizacja i procesy” oraz „Produkty i usługi”, wybierając je jako kluczowe do osiągnięcia maksymalnego poziomu dojrzałości w kontekście GenAI. Po wygenerowaniu raportu na podstawie tych preferencji (dostępnego w Załączniku 4), organizacja

Tabela 22. Liczba praktyk w danym wymiarze w modelu CLIMB2 dla organizacji D.

Wymiar	Poziom 1	Poziom 2	Poziom 3	Poziom 4	Poziom 5	N/D	Śr. waż.
Role i współpraca	-	5	1	1	-	-	2,43
Szkolenie	-	3	-	-	-	-	2,00
Działania i przepływ	2	2	4	-	-	-	2,25
Podejmowanie decyzji	5	1	7	4	5	-	3,14
Procesy KM	7	5	7	3	-	-	2,27
Techniki KM	5	1	2	2	1	-	2,36
Metody	3	4	3	-	1	-	2,27
Oprogramowanie	3	4	4	1	8	3	3,35
Łącznie	25	25	28	11	15	3	2,67

Źródło: opracowanie własne.

Tabela 23. Liczba praktyk w danym wymiarze w modelu OLIMP dla organizacji D.

Wymiar	Poziom 1	Poziom 2	Poziom 3	Poziom 4	Poziom 5	Śr. waż.
Technologie i infrastruktura	6	2	1	1	-	1,70
Dane	5	3	1	-	-	1,56
Ludzie i kompetencje	4	1	1	-	-	1,50
Organizacja i procesy	7	-	-	-	-	1,00
Strategia i zarządzanie	4	2	-	-	-	1,33
Budżet	2	3	-	-	-	1,60
Produkty i usługi	8	1	2	-	-	1,45
Etyka i regulacje	3	3	2	2	-	2,30
Łącznie	39	15	7	3	0	1,59

Źródło: opracowanie własne.

została poproszona o ocenę użyteczności całego modelu. Organizacja D oceniła model na 7 punktów w skali od 0 do 10 (samą część preskryptywną na 8), uzasadniając swoją ocenę następującym komentarzem: „Model bardzo dobrze radzi sobie z identyfikacją technicznych aspektów wdrażania GenAI, szczególnie w kontekście infrastruktury. Rekomendacje są

merytoryczne i uwzględniają specyfikę naszej branży. Doceniamy również, że raport adresuje kwestie strategiczne i pomaga w definiowaniu długoterminowej wizji. Jednakże niektóre zalecenia wydają się być zbyt ogólne i mogłyby być bardziej spersonalizowane pod kątem naszego konkretnego profilu działalności. Dodatkowo, brakuje nam większego nacisku na aspekty związane z integracją z istniejącymi systemami legacy, co jest dla nas kluczowe. Raport jest solidny jako punkt wyjścia do dyskusji strategicznych, ale wymagałby dodatkowego dostosowania do naszych specyficznych potrzeb operacyjnych. Mimo tych ograniczeń, narzędzie stanowi wartościową pomoc w strukturyzowaniu podejścia do GenAI."

5.3. Dyskusja wyników oceny dojrzałości

Zestawiając wyniki uzyskane za pomocą dwóch modeli oceny dojrzałości — CLIMB2, skoncentrowanego na procesach rozwoju nowych produktów (NPD), oraz OLIMP, skupiającego się na dojrzałości wdrażania rozwiązań generatywnej sztucznej inteligencji (GenAI) — możliwe jest zbudowanie pogłębionej diagnozy pozycji każdej z czterech badanych organizacji (A, B, C, D) oraz lepsze zrozumienie potencjalnej dynamiki ich transformacji. W Tabelach 24 i 25 przedstawiono porównanie średnich ważonych w danych wymiarach i wynikową średnią arytmetyczną wszystkich badanych organizacji bazując na wynikach pomiaru modelami CLIMB2 i OLIMP.

W przypadku modelu CLIMB2 OrgB zdecydowanie dominuje w rankingu z wynikiem 3,37, ustanawiając się jako lider w zakresie rozwoju produktów. Na drugim miejscu plasuje się OrgA z oceną 2,85, która odpowiada również średniej dla wszystkich organizacji. OrgD zajmuje trzecie miejsce z wynikiem 2,67, podczas gdy OrgC zamyka zestawienie z najniższą, choć nadal przyzwoitą oceną 2,53. Analiza poszczególnych wymiarów wskazuje interesującą dynamikę różnych aspektów procesu rozwoju produktu. „Podejmowanie decyzji” osiąga najwyższą średnią 3,17, co wskazuje na to, że organizacje rozwinęły skuteczne mechanizmy podejmowania kluczowych decyzji w procesie innowacji produktowej, od koncepcji po komercjalizację. Tuż za nim plasują się „Metody” z wynikiem 2,95, co sugeruje dobre opanowanie różnych metod stosowanych w procesie rozwoju produktu oraz „Techniki KM” z oceną 2,93, wskazując na solidne umiejętności w zakresie technicznych aspektów zarządzania wiedzą. Wymiary „Role i współpraca”

Tabela 24. Średnie ważone i wynikowa średnia arytmetyczna w danym wymiarze w modelu CLIMB2 dla wszystkich organizacji (śr. ar. = średnia arytmetyczna).

Wymiar	OrgA	OrgB	OrgC	OrgD	Śr. ar.
Role i współpraca	3,29	3,14	2,71	2,43	2,89
Szkolenie	2,00	4,67	2,00	2,00	2,67
Działania i przepływ	3,25	3,13	2,63	2,25	2,82
Podjęmowanie decyzji	2,77	3,59	3,18	3,14	3,17
Procesy KM	2,18	3,14	2,18	2,27	2,44
Techniki KM	2,91	4,09	2,36	2,36	2,93
Metody	3,91	2,91	2,73	2,27	2,95
Oprogramowanie	2,85	3,26	2,11	3,35	2,89
Łącznie	2,85	3,37	2,53	2,67	2,86

Źródło: opracowanie własne.

Tabela 25. Średnie ważone i wynikowa średnia arytmetyczna w danym wymiarze w modelu OLIMP dla wszystkich organizacji (śr. ar. = średnia arytmetyczna).

Wymiar	OrgA	OrgB	OrgC	OrgD	Śr. ar.
Technologie i infrastruktura	2,60	1,90	2,10	1,70	2,08
Dane	2,33	2,78	2,22	1,56	2,22
Ludzie i kompetencje	1,33	2,00	1,33	1,50	1,54
Organizacja i procesy	1,29	1,43	1,29	1,00	1,25
Strategia i zarządzanie	2,17	1,33	1,67	1,33	1,63
Budżet	1,60	2,40	1,80	1,60	1,85
Produkty i usługi	1,36	2,45	1,55	1,45	1,70
Etyka i regulacje	3,10	2,70	2,70	2,30	2,70
Łącznie	2,05	2,19	1,89	1,59	1,93

Źródło: opracowanie własne.

oraz „Oprogramowanie” osiągają identyczną średnią 2,89, co może wskazywać na zrównoważone podejście do aspektów organizacyjnych i technologicznych w procesie rozwoju produktu.

„Działania i przepływ” z wynikiem 2,82 plasuje się w środkowej części rankingu, podczas gdy „Szkolenie” z oceną 2,67 oraz „Procesy KM” z najniższą średnią 2,44 wymagają największej uwagi. Szczególnie niski wynik w wymiarze dotyczącym procesów zarządzania wiedzą wskazuje na brak sformalizowanych, powtarzalnych procedur zarządzania wiedzą w procesie rozwoju produktu, co stanowi istotne zagrożenie dla skuteczności innowacji.

OrgA prezentuje profil organizacji o wyjątkowo silnych kompetencjach metodologicznych, osiągając najwyższy wynik w całej tabeli w kategorii „Metody” z oceną 3,91. Ta organizacja wyróżnia się również w wymiarach „Role i współpraca” oraz „Działania i przepływ”, co wskazuje na dobrze zorganizowaną strukturę zespołów projektowych z jasnymi rolami i efektywnymi procesami komunikacji. Silne wyniki w tych wymiarach sugerują organizację, która potrafi skutecznie koordynować multidyscyplinarne zespoły rozwoju produktu i zapewnić płynny przepływ informacji między różnymi etapami procesu innowacyjnego. Jednak OrgA wykazuje krytyczną słabość w wymiarze „Szkolenie” z najniższym wynikiem 2,00, co może wskazywać na niedostateczne inwestycje w rozwój kompetencji pracowników zaangażowanych w proces rozwoju produktu. Ta luka może prowadzić do stagnacji kompetencji technicznych i metodologicznych zespołów, szczególnie w dynamicznie zmieniającym się środowisku technologicznym. Podobnie niskie wyniki w „Procesach KM” sugerują, że mimo dobrych metod, formalne procesy zarządzania wiedzą nie są w pełni rozwinięte. OrgB stanowi wzorcowy przykład organizacji zorientowanej na ciągły rozwój kompetencji w zakresie innowacji produktowych. Wyjątkowo wysoki wynik 4,67 w wymiarze „Szkolenie” wskazuje na głęboko zakorzenioną kulturę uczenia się i systematycznego rozwoju umiejętności pracowników zaangażowanych w proces rozwoju produktu. Organizacja ta również przewodzi w kategoriach „Techniki KM” z wynikiem 4,09, co sugeruje zaawansowane wykorzystanie narzędzi zarządzania wiedzą oraz „Podejmowanie decyzji” z oceną 3,59, wskazując na skuteczne mechanizmy oceny i wyboru projektów oraz kluczowych decyzji rozwojowych. Jediną względną słabością OrgB są „Metody” z wynikiem 2,91, które, mimo że znajdują się na poziomie średniej, kontrastują z doskonałością w innych wymiarach. To może wskazywać na organizację, która rozwija kompetencje w zakresie rozwoju produktu w sposób pragmatyczny i adaptacyjny, być może kosztem bardziej sformalizowanego podejścia do użycia różnych metod. Taki profil może być szczególnie skuteczny w środowiskach wymagających szybkiej adaptacji do zmieniających się potrzeb rynku i technologicznych możliwości.

OrgC wykazuje profil organizacji o umiarkowanym, ale zrównoważonym poziomie dojrzałości w procesie rozwoju produktu. Najsilniejszą stroną tej organizacji jest „Podejmowanie decyzji” z wynikiem 3,18, co wskazuje na skuteczne mechanizmy oceny projektów i podejmowania kluczowych decyzji strategicznych w procesie rozwoju. Organizacja osiąga również przyzwoite wyniki w wymiarach „Role i współpraca” oraz „Metody”, co sugeruje solidne podstawy organizacyjne i metodologiczne. Słabszymi punktami OrgC są „Oprogramowanie” oraz „Techniki KM”, co może wskazywać na niedostateczne wykorzystanie nowoczesnych narzędzi CAD, symulacji czy innych technologii wspierających proces projektowania i rozwoju produktu. Ta luka może prowadzić do dłuższych cykli rozwoju produktu i niższej jakości rozwiązań projektowych w porównaniu do konkurencji. OrgD przedstawia najbardziej nietypowy i zróżnicowany profil, z wyraźnym ukierunkowaniem na rozwiązania technologiczne. Organizacja ta osiąga najwyższy wynik w kategorii „Oprogramowanie” z oceną 3,35, co wskazuje na zaawansowane wykorzystanie narzędzi CAD oraz innych technologii cyfrowych w procesie rozwoju produktu. Dodatkowo dobrze radzi sobie w „Podejmowaniu decyzji” z wynikiem 3,14, co wskazuje na wykorzystanie analityki danych i narzędzi wspierających decyzje w procesie selekcji i rozwoju projektów. Jednak OrgD wykazuje znaczące słabości w większości pozostałych wymiarów, szczególnie w „Metodach”, „Rolach i współpracy” oraz „Działaniach i przepływie”. Ten profil może wskazywać na organizację, która silnie inwestuje w infrastrukturę technologiczną, ale nie rozwija odpowiednio procesów współpracy i kultury organizacyjnej wspierającej efektywny rozwój produktu. Taka dysproporcja może prowadzić do sytuacji, w której zaawansowane narzędzia nie są w pełni wykorzystywane z powodu słabej koordynacji zespołów i nieefektywnych procesów komunikacji.

Podsumowując, OrgB prezentuje się jako najbardziej dojrzała organizacja z wysokimi i spójnymi wynikami we wszystkich wymiarach – szczególnie wyróżnia się w szkoleniu oraz technikach zarządzania wiedzą. OrgA uzyskuje wysokie oceny w zakresie metod i działań operacyjnych, jednak brakuje jej równowagi – szczególnie zauważalny jest niski wynik w szkoleniach. OrgD wypada przeciętnie, ale ma silny punkt w zakresie oprogramowania, co może być dobrym fundamentem do dalszego rozwoju. OrgC nie dominuje w żadnym z analizowanych wymiarów, co może sugerować potrzebę kompleksowego podejścia rozwojowego.

W przypadku modelu OLIMP OrgB osiąga najwyższą ocenę łączną wynoszącą 2,19, co czyni ją liderem w tym zestawieniu. Na drugim miejscu znajduje się OrgA z wynikiem 2,05, następnie

OrgC z oceną 1,89, a na ostatnim miejscu plasuje się OrgD z najniższym wynikiem 1,59. Mimo że OrgB prowadzi w rankingu, różnice między organizacjami nie są dramatyczne, co sugeruje, że wszystkie borykają się z podobnymi wyzwaniami strukturalnymi. Analiza poszczególnych wymiarów ujawnia fascynujący wzorzec podziału na kategorie "twarde" i "miękkie". Wymiar „Etyka i regulacje” wyraźnie dominuje z najwyższą średnią 2,70, co wskazuje na to, że wszystkie organizacje mają silnie rozwiniętą świadomość regulacyjną i etyczną. Jest to jedyny wymiar, w którym każda organizacja osiąga relatywnie wysokie wyniki. Kolejne miejsca zajmują „Dane” ze średnią 2,22 oraz „Technologie i infrastruktura” z wynikiem 2,08, co potwierdza, że organizacje radzą sobie dobrze z aspektami technicznymi swojego funkcjonowania. W przeciwieństwie do tego wymiary związane z zarządzaniem ludźmi i procesami wykazują alarmująco niskie wyniki. „Organizacja i procesy” osiąga najniższą średnią zaledwie 1,25, co wskazuje na systemowe problemy we wszystkich badanych jednostkach. „Ludzie i kompetencje” z wynikiem 1,54 oraz „Strategia i zarządzanie” z oceną 1,63 również plasują się w dolnej części rankingu. Wymiary pośrednie to „Budżet” z wynikiem 1,85 oraz „Produkty i usługi” z oceną 1,70.

OrgA prezentuje profil organizacji o silnych fundamentach technicznych i etycznych, ale z poważnymi lukami w zarządzaniu. Osiąga najwyższą ocenę w całej tabeli w kategorii „Etyka i regulacje” z wynikiem 3,10, co świadczy o wyjątkowo rozwiniętej kulturze dotyczącej regulacji. Dodatkowo radzi sobie dobrze w wymiarach „Technologie i infrastruktura” oraz „Dane”. Jednak organizacja ta wykazuje znaczące słabości w kluczowych wymiarach zarządzania, szczególnie w „Organizacji i procesach” oraz „Ludziach i kompetencjach”, gdzie osiąga jedne z najniższych wyników. OrgB, będąca liderem rankingu, wyróżnia się szczególnie w wymiarach operacyjnych i produktowych. Osiąga najwyższą ocenę w kategorii „Dane” z wynikiem 2,78, co wskazuje na zaawansowane wykorzystanie analityki biznesowej. Organizacja ta również dobrze radzi sobie w wymiarach „Produkty i usługi” oraz „Budżet”, co sugeruje silną orientację na wyniki biznesowe. Paradoksalnie, mimo ogólnie najlepszych wyników, OrgB ma znaczące problemy ze „Strategią i zarządzaniem”, co może stanowić zagrożenie dla długoterminowego rozwoju. OrgC wykazuje profil bardzo podobny do OrgA, z silnymi stronami w wymiarach technicznych i równie poważnymi problemami w zarządzaniu zasobami ludzkimi oraz procesami. Ta zbieżność może wskazywać na podobną kulturę organizacyjną lub model biznesowy. Organizacja osiąga dobre wyniki w „Etyce i regulacjach”, „Danych” oraz „Technologiach i infrastrukturze”, ale równocześnie boryka się z najniższymi ocenami w „Organizacji i procesach” oraz „Ludziach i

kompetencjach”. OrgD przedstawia najbardziej niepokojący obraz, z systemowymi problemami praktycznie we wszystkich obszarach funkcjonowania. Chociaż osiąga relatywnie przyzwoity wynik w „Etyce i regulacjach”, w pozostałych kategoriach wyniki są konsekwentnie niskie. Szczególnie alarmująca jest ocena 1,00 w wymiarze „Organizacja i procesy”, która stanowi najniższy wynik w całej tabeli. Ta organizacja wydaje się wymagać kompleksowej restrukturyzacji i transformacji organizacyjnej.

Podsumowując, analiza ujawnia paradoks organizacji, które mimo zaawansowania technicznego i wysokiej świadomości etycznej, nie potrafią skutecznie zarządzać podstawowymi procesami organizacyjnymi oraz rozwijać kompetencji swoich pracowników. Ten wzorzec może wynikać z nadmiernego skupienia na aspektach technicznych kosztem inwestycji w "miękkie" elementy zarządzania lub może odzwierciedlać kulturę organizacyjną preferującą rozwiązania techniczne nad systemowe podejście do zarządzania. Szczególnie niepokojące są wyniki w wymiarze „Organizacja i procesy”, gdzie wszystkie organizacje osiągają wyniki poniżej 1,5. Wskazuje to na brak integracji generatywnej AI w procesach rozwoju nowego produktu czy brak kultury ciągłego doskonalenia. Podobnie niskie wyniki w wymiarze „Ludzie i kompetencje” sugerują niewystarczające inwestycje w rozwój pracowników, słabe systemy kooperacji zewnętrznych, czy problemy z budowaniem interdyscyplinarnych zespołów.

Interesująca poznawczo wydaje się także analiza każdej z organizacji pod względem porównania wybranych konkretnych praktyk. W Tabelach 26 i 27 przedstawiono porównanie ilości praktyk na poszczególnych poziomach i średnich ważonych wszystkich badanych organizacji bazując na wynikach pomiaru modelami CLIMB2 i OLIMP.

W przypadku modelu CLIMB2 w organizacji A trzy praktyki z wymiaru „Metody” znalazły się na poziomie piątym – funkcje jakości, analiza ryzyka i awarii oraz analiza kosztów cyklu życia i całkowity koszt posiadania, które są kluczowe we wszystkich projektach. Poza tymi trzema praktykami, we wszystkich pozostałych wymiarach, jedynie 2 inne elementy z wymiaru „Działania i przepływ” także znalazły się na poziomie piątym – dotyczące formalnego procesu rozwoju nowego produktu i współpracy jako integralnej części na każdym etapie procesu. Praktyki te wydają się być powiązane – mając formalny i zawsze przestrzegany proces rozwoju nowego produktu, na każdym etapie można w nim definiować odpowiedzialność danego członka zespołu

Tabela 26. Porównanie organizacji A, B, C oraz D względem wyników pomiaru modelem CLIMB2.

Ilość elementów	OrgA	OrgB	OrgC	OrgD
Ilość elementów na poziomie 1	0	1	1	25
Ilość elementów na poziomie 2	44	25	64	25
Ilość elementów na poziomie 3	37	29	19	28
Ilość elementów na poziomie 4	18	37	18	11
Ilość elementów na poziomie 5	5	15	0	15
Ilość elementów, które nie dotyczyły organizacji	3	0	5	3
Średnia ważona	2,85	3,37	2,53	2,67

Źródło: opracowanie własne.

Tabela 27. Porównanie organizacji A, B, C oraz D względem wyników pomiaru modelem OLIMP.

Ilość elementów	OrgA	OrgB	OrgC	OrgD
Ilość elementów na poziomie 1	19	22	23	39
Ilość elementów na poziomie 2	28	21	28	15
Ilość elementów na poziomie 3	12	9	10	7
Ilość elementów na poziomie 4	5	11	3	3
Ilość elementów na poziomie 5	0	1	0	0
Średnia ważona	2,05	2,19	1,89	1,59

Źródło: opracowanie własne.

projektowego – np. inżynierowie wykonujący analizę ryzyka i awarii, dział finansowy dokonujący analizy kosztów cyklu życia itd. Stoi to natomiast w kontraście do organizacji D, gdzie nie ma żadnego formalnego modelu procesu rozwoju nowego produktu, którym organizacja się kieruje, współpraca jest na średnim poziomie (poziom trzeci), a wiele praktyk, związanych zwłaszcza z podejmowaniem decyzji i używanym oprogramowaniem, a także wspomniana wcześniej analiza ryzyka i awarii, znajdują się na poziomie piątym. W przypadku organizacji B na poziomie piątym znalazły się praktyki z aż 5 różnych wymiarów (łącznie 15 praktyk), głównie w wymiarze oprogramowania i technik zarządzania wiedzą, wskazując, że organizacja wykorzystuje wiele narzędzi na wysokim poziomie, zarówno do wspierania procesu rozwoju produktu, jak i procesów związanych z dzieleniem się, przechowywaniem i udostępnianiem wiedzy. W przypadku modelu OLIMP również najbardziej interesującym przypadkiem jest organizacja B – jest to jedyna organizacja, która posiada (jedną) praktykę na poziomie 5, pochodzącą z wymiaru „Etyka i regulacje” i dotyczącą wdrażania standardów ochrony i mechanizmów dotyczących kopii

zapasowych danych. W przypadku samego wymiaru „Dane” jest to też jedyna organizacja z praktykami na poziomie czwartym, dotyczącymi integracji danych z różnych źródeł, utrzymywania danych wysokiej jakości, ich centralizacji i przetwarzania oraz wysokiego poziomu automatyzacji analiz, bazując na tych danych. Im lepsze dane wejściowe, tym lepiej działają algorytmy generatywnej sztucznej inteligencji, które operują na tych danych. W przypadku organizacji B, przykłada się to też na wyniki w innych wymiarach np. w przypadku wymiaru „Organizacja i procesy” jest jedyną organizacją z praktyką na poziomie trzecim, dotyczącą wspierania przez GenAI podejmowania decyzji lub w przypadku wymiaru „Produkty i usługi”, gdzie ponownie organizacja B jest jedyną z praktykami na poziomie czwartym, dotyczącymi regularnego poszukiwania nowych przypadków użycia AI czy stosowania sztucznej inteligencji do redukcji informacji lub wsparcia marketingu.

Zestawienie wyników pomiarów zarówno modelem CLIMB2, jak i modelem OLIMP wskazuje, że organizacje osiągnęły ogólnie znacznie wyższy poziom dojrzałości w tradycyjnych procesach rozwoju produktu, niż w wykorzystaniu nowoczesnych technologii generatywnej sztucznej inteligencji. Średnie wyniki łączne pokazują tę różnicę: podczas gdy w procesach rozwoju produktu organizacje osiągają średnią 2,86, w wykorzystaniu generatywnej AI jest to 1,93. Różnica ta może być szczególnie istotna w kontekście współczesnych trendów technologicznych, gdzie generatywna AI jest postrzegana jako rewolucyjna technologia mogąca radykalnie przyspieszyć i usprawnić procesy rozwoju produktu. Organizacje wydają się znajdować w sytuacji, gdzie posiadają solidne fundamenty metodologiczne i procesowe, ale nie potrafią skutecznie zintegrować z nimi najnowszych możliwości technologicznych. Warty uwagi aspekt porównania jest konsystencja w rankingu organizacji między obiema tabelami. OrgB dominuje w obu przypadkach, osiągając średnią ważoną 2,19 w AI generatywnej i 3,37 w ogólnych procesach rozwoju produktu. OrgA zajmuje drugie miejsce w obu rankingach z wynikami odpowiednio 2,05 i 2,85. OrgC (wyniki odpowiednio 1,89 i 2,53) oraz OrgD (wyniki 1,59 i 2,67) zamykają zestawienie z najniższymi ocenami. Ta konsystencja może sugerować, że podobne czynniki organizacyjne wpływają na sukces w obu obszarach. Organizacje, które skutecznie zarządzają tradycyjnymi procesami innowacyjnymi, prawdopodobnie posiadają kulturę organizacyjną, struktury zarządzania i kompetencje, które ułatwiają również adopcję nowych technologii. Jednocześnie organizacje z fundamentalnymi problemami w zarządzaniu procesami borykają się z podobnymi wyzwaniami przy implementacji generatywnej AI. Porównanie poszczególnych wskazuje pewien

kontrast widoczny w wymiarach związanych z zasobami ludzkimi. Wymiar „Ludzie i kompetencje” w modelu OLIMP osiąga niską średnią 1,54, podczas gdy wymiary „Role i współpraca” oraz „Szkolenie” w modelu CLIMB2 uzyskują przyzwoite oceny 2,89 i 2,67. Z kolei wymiary techniczne wykazują mniejsze dysproporcje. Wymiary „Technologie i infrastruktura” oraz „Dane” w modelu OLIMP (średnie odpowiednio 2,08 i 2,22) nie różnią się aż w tak dużym stopniu od „Oprogramowania” czy „Metod” w modelu CLIMB2 (średnie odpowiednio 2,89 oraz 2,95), co może sugerować, że organizacje są lepiej przygotowane na wyzwania techniczne niż organizacyjne związane z implementacją AI.

Analiza odpowiedzi respondentów dostarczyła także interesujących wniosków w przypadku narzędzia preskryptywnego. Organizacje wybrały różne kombinacje wymiarów jako kluczowe dla swojego rozwoju, ale wszystkie cztery wybrały jako jeden z nich wymiar „Ludzie i kompetencje”. Trzy z nich wybrały także wymiar „Organizacja i procesy”. Wśród wybieranych wymiarów były także „Dane”, „Budżet” oraz „Produkty i usługi”. Ta różnorodność potwierdza założenie o konieczności indywidualizacji ścieżek rozwoju w zależności od specyfiki organizacji i jej aktualnych priorytetów strategicznych. Analiza komentarzy organizacji ujawnia wyraźny wzorzec związany z wielkością i złożonością organizacji. Organizacja C wprost wskazała, że raport „sprawdzi się dobrze w dużych firmach, gdzie mamy szansę na dedykowane zespoły, dokładną analizę poszczególnych obszarów i zaplanowanie działań na 3 lata lub dłużej”. W przeciwieństwie do tego średnie firmy preferują podejście „step by step” z naciskiem na najbardziej krytyczne pierwsze kroki. Ta obserwacja ma istotne implikacje dla praktycznego zastosowania modelu. Sugeruje ona konieczność opracowania zróżnicowanego podejścia do prezentacji wyników, uwzględniającego specyfikę różnych segmentów organizacyjnych. Wszystkie organizacje pozytywnie odniosły się do kompleksowego charakteru raportu. Organizacja B podkreśliła, że raport „pokazuje holistycznie, co warto robić w poszczególnych obszarach GenAI”, podczas gdy Organizacja A doceniła, że rekomendacje „wydają się całkiem odpowiednie” w stosunku do prostoty kwestionariuszy. Raport został także pozytywnie oceniony jako narzędzie wspierające planowanie strategiczne. Organizacja A określiła dokument jako „bardzo przydatny, aby zapewnić mapę drogową możliwych działań”, co wskazuje na jego wartość w strukturyzowaniu podejścia do wdrażania GenAI. Organizacja B szczególnie doceniła, że zawiera „bardzo dużo inspiracji na temat projektów”, co sugeruje, że model skutecznie pełni rolę katalizatora kreatywności organizacyjnej w kontekście GenAI. Organizacja C zwróciła uwagę na problematyczność założeń budżetowych,

wskazując, że rekomendacje zakładające inwestycje rzędu 10 milionów złotych mogą być nierealistyczne dla średnich przedsiębiorstw. Ta uwaga wskazuje na potrzebę wprowadzenia mechanizmów skalowania rekomendacji finansowych w zależności od wielkości i możliwości organizacji.

Przeprowadzone badanie pozwoliło także na kompleksową ocenę użyteczności opracowanego modelu dojrzałości GenAI. Uzyskane oceny wahały się od 5 do 9 punktów w skali 0-10, co wskazuje na znaczne zróżnicowanie percepcji wartości modelu w zależności od charakterystyki organizacji i jej potrzeb. Najwyższą ocenę (9 punktów – zarówno dla całego modelu, jak i wyłącznie dla jego części preskryptywnej) przyznała Organizacja B. Ta organizacja szczególnie doceniła kompleksowość i holistyczne podejście raportu, podkreślając jego wartość jako źródła inspiracji dla projektów GenAI. Organizacja A oceniła model na 8 punktów (podobnie jak organizacja B, taka sama ocena dla całego modelu i jego części preskryptywnej), wskazując na dobry balans między prostotą kwestionariuszy a jakością otrzymywanych rekomendacji. Organizacja D przyznała 7 punktów (8 punktów dla samej części preskryptywnej), doceniając merytoryczne podejście do kwestii technicznych i strategicznych, jednocześnie wskazując na potrzebę większej personalizacji rekomendacji. Najniższą ocenę (5 punktów dla modelu, 6 dla samego narzędzia odpowiadającego za część preskryptywną) wystawiła Organizacja C, która reprezentowała segment średnich przedsiębiorstw. Ta organizacja podkreśliła przydatność modelu dla dużych firm, jednocześnie wskazując na jego ograniczone użycie w kontekście mniejszych organizacji. Średnia ocen organizacji to 7,25 za ogół modelu i 7,75, gdyby mieli oceniać wyłącznie narzędzie odpowiadające za część preskryptywną, co uznano za pozytywny wynik, uwzględniając fakt, że organizacje, wystawiając ocenę, kierowały się istotnie głównie rekomendacjami przedstawionymi w raportach, a narzędzie przygotowujące raporty jest jego pierwszą wersją i może zostać w przyszłości ulepszane. Badanie obejmowało cztery organizacje, co może ograniczać generalizowalność wyników. Przyszłe badania powinny uwzględnić większą próbę organizacji o zróżnicowanych profilach działalności.

Poza dyskusją na temat wyników organizacji, interesujące wydają się być także aspekty dotyczące tego, jak przedstawione wyniki mogą wpływać na budowę przygotowanego modelu lub modeli dojrzałości w ogóle. Jednym z punktów jest praktyka z modelu CLIMB2 dotycząca posiadania formalnego planu zarządzania wiedzą, która była na poziomie 1 w organizacjach B, C oraz D, przy

czym w organizacjach B i C była to jedyna praktyka na tym poziomie, uwzględniając wszystkie wymiary. Szczególnie warty uwagi jest przypadek organizacji B, która mimo braku formalnego planu zarządzania wiedzą, wykorzystuje zaawansowane techniki zarządzania wiedzą głównie na poziomie czwartym i piątym. Ten paradoks sugeruje, że formalne planowanie wiedzy może nie być warunkiem koniecznym do efektywnego wykorzystania zasobów wiedzy w organizacji. Fakt ten rodzi pytanie o zasadność włączenia tego parametru do modelu, mimo braku sprzeciwu ekspertów podczas jego walidacji – konieczne są badania na większej liczbie organizacji w celu potwierdzenia. Analiza wykazała także, że praktyki na poziomie piątym występują stosunkowo rzadko, co również stawia pytanie, czy praca, jaką organizacja musi wykonać, aby przejść z danego poziomu na kolejny, nie jest zbyt duża i zbyt ambitnie odwzorowana w modelu. Jednocześnie pełna rozpiętość praktyk od poziomu pierwszego do piątego w obrębie pojedynczego wymiaru, która mogłaby wskazywać, że poziomy praktyk w ramach jednego wymiaru różnią się od siebie stopniem zaawansowania, jest zjawiskiem niezwykle rzadkim (dotyczy tylko organizacji D w wymiarze „Oprogramowanie”). Innym punktem jest obserwacja dotycząca wskazywania danych wymiarów dotyczących ludzi czy infrastruktury jako najistotniejszych z perspektywy organizacji w modelu OLIMP, gdzie jednocześnie wymiarem z najwyższą lub bliską najwyższej średniej jest wymiar „Etyka i regulacje”. Organizacje stawiają na etykę być może nie będąc w pełni świadomymi tej tendencji. Kolejnym punktem jest przypadek organizacji D, która mimo braku oficjalnego procesu rozwoju produktu może osiągnąć w modelu OLIMP wyniki wyższe niż organizacje posiadające sformalizowane procedury. Ta obserwacja potwierdza głosy ekspertów zebrane podczas walidacji modelu, że badanie modelem OLIMP ma sens nawet w przypadku organizacji z wieloma praktykami na poziomie pierwszym w modelu CLIMB2, ponieważ może prowadzić do odkrycia nieoczekiwanych zależności i cennych wniosków na temat rzeczywistej dojrzałości organizacyjnej wykraczającej poza formalne struktury i procedury. Innym punktem jest prezentacja wyników organizacji. Użycie średniej ważonej w celach porównawczych wydaje się zasadne, gdyż niekiedy jedna praktyka (jak w przypadku organizacji B czy C) może decydować o tym, że organizacja znajduje się np. na poziomie pierwszym w danym modelu (jak organizacja B w modelu CLIMB2), podczas gdy średnia ważona wskazuje, że organizacja znajduje się np. między poziomem trzecim a czwartym (organizacja B w modelu CLIMB2 – średnia ważona 3,37). Wskazywanie wyniku organizacji jedynie jako liczby całkowitej może być mylące, szczególnie gdy dane praktyki nie przekładają się bezpośrednio na wyniki organizacyjne. Jest to o tyle

istotniejsze, że w artykułach naukowych rzadko pojawiają się kwestionariusze z odpowiedziami organizacji lub z informacją, ile praktyk było na danym poziomie. Ostatnim punktem są uwagi dotyczące budowy narzędzia rekomendacyjnego. Niewiele zidentyfikowanych w literaturze modeli można uznać za preskryptywne, a te, które chociaż częściowo spełniają kryteria dla tego typu modeli, nie używały rozwiązań generatywnej sztucznej inteligencji do generowania rekomendacji. Stąd sugestie praktyków dotyczące rozbudowy narzędzia są niezwykle istotne. Na podstawie otrzymanych informacji zwrotnych przyszły rozwój modelu powinien koncentrować się na wzmocnieniu mechanizmów personalizacji rekomendacji, uwzględniających specyfikę branżową, wielkość organizacji oraz jej aktualne możliwości implementacyjne.

5.4. Podsumowanie oceny dojrzałości

Przeprowadzone badania wskazują, że przygotowany model CLIMB2-OLIMP jest przydatnym narzędziem diagnostycznym, umożliwiającym identyfikację stanu aktualnego, mocnych stron, jak i obszarów wymagających poprawy. W tym rozdziale odniesiono się także do krytyki modeli dotyczącej braku ewaluacji i badania użyteczności, tym samym realizując wszystkie punkty krytyki zidentyfikowane w literaturze.

Porównanie ujawnia, że organizacje stoją przed fundamentalnym wyzwaniem transformacyjnym. Pomimo solidnych podstaw w tradycyjnych procesach rozwoju produktu, praktycznie wszystkie borykają się z integracją generatywnej AI ze swoimi procesami. Ta luka może mieć dramatyczne konsekwencje strategiczne, ponieważ organizacje, które skutecznie zintegrują AI ze swoimi procesami innowacyjnymi, mogą uzyskać znaczącą przewagę konkurencyjną. Szczególnie niepokojące są wyniki w wymiarach „Ludzie i kompetencje” oraz „Organizacja i procesy” w kontekście generatywnej AI. Te fundamentalne słabości sugerują, że problem nie leży w technologii samej w sobie, ale w zdolności organizacji do adaptacji swoich struktur, procesów i kompetencji do nowych możliwości technologicznych. Organizacje mogą potrzebować głębokiej transformacji kulturowej i organizacyjnej, aby skutecznie wykorzystać potencjał generatywnej sztucznej inteligencji. Jednocześnie relatywnie wysokie wyniki w „Etyce i regulacjach” w kontekście AI sugerują, że organizacje są świadome ryzyka i wyzwań związanych z tą technologią. To może stanowić solidną podstawę do budowania zaufania i odpowiedzialnego podejścia do

implementacji AI, co będzie kluczowe dla długoterminowego sukcesu. Istotnym wnioskiem z porównania jest to, że organizacje nie mogą traktować generatywnej sztucznej inteligencji jako kolejnego narzędzia technologicznego, które można po prostu dodać do istniejących procesów. Zamiast tego potrzebują holistycznego podejścia do transformacji, które zintegruje AI z istniejącymi mocnymi stronami w procesach rozwoju produktu. Analiza wyników badań ujawniła także aspekty mogące wpłynąć na udoskonalenie przedstawionego modelu lub ogólne doskonalenie modeli dojrzałości organizacyjnej. Rzadkie występowanie praktyk na poziomie piątym oraz ograniczona rozpiętość praktyk w obrębie wymiarów sugerują możliwe nadmierne wymagania progresji między poziomami. Innym wnioskiem jest potrzeba odpowiedniej prezentacji wyników organizacji (np. średnia ważona), co może lepiej odzwierciedlać rzeczywistą dojrzałość organizacyjną. Dalsze badania powinny skupić się na analizie długoterminowych efektów wdrażania GenAI w różnych sektorach przemysłowych. Ponadto warto rozważyć badanie innych organizacji, aby zbadać, czy obserwowane rozbieżności są specyficzne dla czterech badanych organizacji, czy mają charakter ogólny w obrębie badanej grupy przedsiębiorstw.

Przeprowadzone badanie potwierdza także użyteczność opracowanego modelu dojrzałości GenAI, jednocześnie identyfikując kluczowe wymiary wymagające dalszego rozwoju. Narzędzie odpowiadające za część preskryptywną skutecznie pełni rolę narzędzia strategicznego, wspierającego organizacje w strukturyzowaniu podejścia do implementacji GenAI. Jednocześnie komentarze organizacji wskazują na potrzebę dalszej adaptacji narzędzia do specyficznych potrzeb różnych segmentów organizacyjnych. Kluczowym wnioskiem jest konieczność opracowania mechanizmów umożliwiających dostosowanie złożoności i szczegółowości rekomendacji do możliwości percepcyjnych i implementacyjnych konkretnych organizacji. Przyszły rozwój narzędzia powinien koncentrować się na wzmocnieniu jego adaptacyjności, zachowując jednocześnie kompleksowość i holistyczne podejście, które zostały pozytywnie ocenione przez wszystkie badane organizacje.

Rozdział 5 odpowiada przede wszystkim na pytanie badawcze 5. Ewaluacja empiryczna potwierdza przydatność modelu CLIMB2-OLIMP jako narzędzia diagnozy i planowania (pytanie badawcze 5), a zebrany feedback zasila pętlę ciągłego doskonalenia modelu i jego warstwy preskryptywnej (pytania badawcze 3 i 4), domykając cykl badawczy zapoczątkowany przez przeglądy literatury i wywiady (pytania badawcze 1 i 2).

Podsumowanie

Głównym celem niniejszej rozprawy doktorskiej było opracowanie modelu dojrzałości w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji (*Generative Artificial Intelligence – GenAI*) w procesie rozwoju nowego produktu (*New Product Development – NPD*). W tej części zostaną podsumowane przeprowadzone badania, w tym przedstawione kluczowe wnioski. Na koniec przedstawione zostaną ograniczenia oraz sugestie dotyczące kierunków przyszłych badań w tym obszarze.

Odpowiedzi na szczegółowe pytania badawcze – zbiorcze zestawienie

- *PB1. W jaki sposób mierzona jest dojrzałość procesu rozwoju nowego produktu i dojrzałość w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji?*

Z przeprowadzonych analiz literaturowych i badań własnych wynika, że dojrzałość procesu NPD można ocenić za pomocą istniejących modeli dojrzałości procesowej, takich jak CLIMB (rozszerzony w rozprawie do wersji CLIMB2). Z kolei w obszarze sztucznej inteligencji, a w szczególności generatywnej AI, brakowało dotąd uniwersalnego modelu dojrzałości uwzględniającego specyfikę procesu NPD. W odpowiedzi na tę lukę zaproponowano nowy model OLIMP, który – w połączeniu z CLIMB2 – tworzy dwuczęściowe narzędzie CLIMB2-OLIMP. Model ten uwzględnia zarówno tradycyjne praktyki NPD, jak i nowe praktyki charakterystyczne dla wdrożeń GenAI.

- *PB2. Jakie są potencjalne i aktualne zastosowania generatywnej sztucznej inteligencji w procesach rozwoju nowego produktu oraz wyzwania i czynniki sukcesu wdrożeń tego typu rozwiązań w organizacjach?*

W wyniku systematycznego przeglądu literatury oraz wywiadów z ekspertami stwierdzono, że GenAI może wspierać cały cykl NPD: od generowania pomysłów (np. analiza sentymentu, tworzenie prototypów koncepcji), poprzez projektowanie i testowanie (np. automatyczne projektowanie komponentów, wykrywanie anomalii), aż po marketing (np. generowanie

materiałów reklamowych). Główne wyzwania związane z wdrożeniem GenAI obejmują: niedostateczną jakość i ilość danych, niejasne zasady etyczne, brak wypracowanych metodologii wdrożeń oraz ograniczoną wiedzę pracowników na temat AI. Z kolei kluczowe czynniki sukcesu to m.in. efektywne zarządzanie danymi, współpraca międzydziałowa, odpowiednie kompetencje zespołów oraz czytelne wskaźniki sukcesu (np. metryki finansowe).

- *PB3. W jaki sposób można zaprojektować (uwzględniając aktualną krytykę modeli) model dojrzałości w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesach rozwoju nowego produktu, tak, aby uzależnić dojrzałość organizacji w wykorzystaniu rozwiązań GenAI od dojrzałości procesu rozwoju produktu?*

Przedstawione w rozprawie połączenie modelu CLIMB2 z nowym modelem OLIMP (nazwane CLIMB2-OLIMP) dowodzi, że jest to możliwe w oparciu o podejście nauk o projektowaniu (*Design Science Research – DSR*). Model CLIMB2-OLIMP zakłada najpierw ocenę dojrzałości organizacji w zakresie tradycyjnego procesu NPD (model CLIMB2), a następnie – w zależności od oceny badacza – przejście do oceny dojrzałości w wykorzystaniu GenAI (model OLIMP). W ten sposób uwzględniono postulat, by organizacja dysponowała wystarczająco ugruntowanymi procesami NPD przed wdrażaniem rozwiązań AI.

- *PB4. W jaki sposób zaprojektować część preskryptywną modelu dojrzałości w oparciu o duże modele językowe?*

W ramach rozprawy opracowano narzędzie wspierające część preskryptywną modelu, oparte o duże modele językowe (LLM). Opracowano system, który wykorzystuje dane z ankiet organizacyjnych i funkcjonuje na bazie trzech niezależnych agentów sztucznej inteligencji - każdy z nich wykorzystuje modele językowe różnych dostawców: OpenAI, Anthropic oraz Google. Wszyscy agenci przeprowadzają ocenę kondycji organizacji na podstawie udzielonych w kwestionariuszu odpowiedzi, po czym finalny model (Gemini 2.5 Pro) syntetyzuje te analizy i opracowuje zalecenia mające na celu podniesienie poziomu dojrzałości organizacyjnej, uwzględniając rekomendowane ścieżki rozwoju, a w tym m.in. relację koszt-korzyść czy metryki.

Użytkownicy otrzymują tym samym nie tylko informację o aktualnym poziomie dojrzałości, lecz także wskazówki i scenariusze przejścia na wyższe poziomy.

- *PB5. Jaki jest poziom dojrzałości wybranych organizacji w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesach rozwoju nowego produktu?*

Badania empiryczne przeprowadzone na czterech organizacjach z sektora produkcyjnego (studia przypadków) wykazały, że – choć wszystkie firmy osiągnęły przynajmniej średni poziom dojrzałości w większości wymiarów w zakresie tradycyjnego procesu NPD (średnia ważona powyżej 2,53 dla wszystkich badanych organizacji w modelu CLIMB2) – poziom integracji rozwiązań GenAI w tych procesach był raczej niski (maksymalna średnia ważona wynosząca 2,19). Wyniki te wskazują, że wiele przedsiębiorstw wciąż stoi przed wyzwaniem skutecznego wdrożenia GenAI, mimo bardziej dojrzałych praktyk NPD.

Model dojrzałości w wykorzystaniu rozwiązań generatywnej AI w procesie rozwoju produktu – realizacja celu głównego

Główny cel rozprawy brzmiał:

- *Opracowanie preskryptywnego modelu dojrzałości organizacji w wykorzystaniu rozwiązań generatywnej sztucznej inteligencji w procesie rozwoju nowego produktu i metodyki jej pomiaru.*

Został on zrealizowany poprzez:

1. **Rozszerzenie modelu dojrzałości NPD CLIMB do wersji CLIMB2**, w której doprecyzowano poszczególne praktyki i poziomy dojrzałości oraz przygotowano kwestionariusz.
2. **Opracowanie modelu OLIMP**, skupionego na dojrzałości w wykorzystaniu rozwiązań GenAI. Model ten zawiera osiem wymiarów (Technologie i infrastruktura, Dane, Ludzie i kompetencje, Organizacja i procesy, Strategia i zarządzanie, Budżet, Produkty i usługi oraz

Etyka i regulacje) i pięć poziomów dojrzałości, z uwzględnieniem praktyk specyficznych dla generatywnej AI.

3. **Połączenie obu modeli** (CLIMB2 i OLIMP) w zintegrowane narzędzie CLIMB2-OLIMP, umożliwiające najpierw ocenę dojrzałości NPD, a następnie – przy spełnieniu warunków – pomiar dojrzałości w wykorzystaniu GenAI.
4. **Stworzenie części preskryptywnej** z wykorzystaniem dużych modeli językowych (LLM). Dzięki temu organizacja otrzymuje rekomendacje dotyczące ścieżek przejścia z aktualnego na wyższy poziom dojrzałości, z uwzględnieniem m.in. relacji koszt-korzyść.

Realizacja powyższych kroków pozwoliła na pozytywne zweryfikowanie przyjętej na początku pracy tezy, że możliwe jest opracowanie modelu dojrzałości organizacji w wykorzystaniu generatywnej sztucznej inteligencji w procesie rozwoju produktu, uwzględniając aktualną krytykę modeli, część preskryptywną modelu oraz dojrzałość samego procesu rozwoju produktu.

Główne wnioski z badań – synteza

Poniżej przedstawiono pięć głównych wniosków z badań:

1. *Organizacje o relatywnie dojrzałych procesach NPD nie zawsze mają dojrzałe procesy dotyczące wdrażania rozwiązań GenAI*

Z badanych przypadków wynika, że mimo ugruntowanych praktyk w zakresie NPD (poziomy 2-3 w modelu CLIMB2), przedsiębiorstwa często nie mają odpowiednich zasobów danych, kompetencji pracowników ani jasno zdefiniowanej strategii AI. Przekłada się to na niski poziom dojrzałości w modelu OLIMP.

2. *Kluczową barierą w integracji rozwiązań GenAI są kwestie organizacyjne i kompetencyjne*

Choć ograniczenia techniczne (moc obliczeniowa, jakość danych) pozostają istotne, respondenci często wskazywali na brak wykwalifikowanych specjalistów AI w zespołach produktowych, niejasne role i brak spójnej strategii wdrożeń. Wdrożenie GenAI wymaga interdyscyplinarnej współpracy i zrozumienia korzyści, jakie AI może wnieść w cały proces NPD.

3. Brak wypracowanych metodologii wdrażania GenAI w NPD utrudnia osiągnięcie wyższych poziomów dojrzałości

Organizacje często eksperymentują z pojedynczymi narzędziami opartymi o GenAI (np. ChatGPT), lecz brakuje im systemowego podejścia, które integrowałoby AI z procesami, strukturami i strategią przedsiębiorstwa. Model CLIMB2-OLIMP, dzięki diagnozie aktualnego stanu i rekomendacjom działań, może stanowić ważne wsparcie dla firm stojących przed taką transformacją.

4. Etyka i regulacje są koniecznym filarem, ale nie głównym „wąskim gardłem”

O ile w tradycyjnych modelach dojrzałości AI często aspekt etyki jest marginalizowany, to generatywna AI niesie dodatkowe ryzyka, takie jak halucynacje modelu, kwestie praw autorskich i odpowiedzialności za wygenerowane treści. Z tego względu w modelu OLIMP uwzględniono oddzielny wymiar „Etyka i regulacje” oraz zestaw praktyk dedykowanych zapewnieniu bezpieczeństwa i przejrzystości systemów GenAI. Jednocześnie w badanych organizacjach ten obszar nie był najsłabszy na tle innych wymiarów; większe luki dotyczyły ludzi, procesów i operacjonalizacji danych. Aspekty etyczne muszą być wbudowane w model, lecz realne hamulce adopcji leżą gdzie indziej.

5. Preskryptywny charakter modelu, wsparty narzędziem LLM, stanowi istotną wartość praktyczną

Przedstawione narzędzie generatywne sugeruje organizacjom możliwe kroki w procesie poprawy dojrzałości, uwzględniając różne rekomendacje. Rozwiązanie to jest szczególnie cenne w środowiskach, w których zespoły menedżerów produktu nie mają wystarczającego doświadczenia w projektach AI i potrzebują wsparcia w podejmowaniu decyzji.

Wkład do nauki i praktyki zarządzania, ograniczenia oraz rekomendacje dla dalszych badań

Wkład opracowanego modelu CLIMB2-OLIMP w naukę o zarządzaniu jest wieloaspektowy, obejmując zarówno nowatorskie podejście do integracji dwóch obszarów dojrzałości organizacyjnej, jak i solidne podstawy teoretyczne w zakresie metodologii badawczej oraz praktyczne aspekty wdrożeniowe.

Model wypełnia lukę w literaturze naukowej, gdzie dotychczas brakowało kompleksowego narzędzia pozwalającego na jednoczesną ocenę dojrzałości procesów rozwoju nowego produktu (NPD) oraz wykorzystania sztucznej inteligencji, w szczególności generatywnej AI (*GenAI*). Zestawienie dwóch podejść – dojrzałości procesów NPD (model CLIMB2) oraz dojrzałości w obszarze generatywnej sztucznej inteligencji (model OLIMP) – stanowi istotny punkt wyjścia do holistycznej oceny dojrzałości organizacji we wdrażaniu nowoczesnych rozwiązań technologicznych w procesie rozwoju produktu. Dzięki połączeniu tych dwóch perspektyw model oferuje kompleksową i jednoczesną analizę poziomu dojrzałości w obu obszarach, umożliwiając organizacjom identyfikację sfer wymagających usprawnień. Tego rodzaju strategia badawcza stwarza nową przestrzeń do dalszych badań, które mogą przyczynić się do głębszego zrozumienia korelacji pomiędzy rozwojem procesów NPD a integracją zaawansowanych technologii, w tym generatywnej sztucznej inteligencji. Model CLIMB2-OLIMP bazuje na paradygmacie nauk o projektowaniu (*Design Science Research – DSR*), co stanowi fundament metodologiczny opracowanego narzędzia. Zastosowanie tej koncepcji gwarantuje rzetelność w tworzeniu narzędzi badawczych, a także zapewnia ich elastyczność, umożliwiając dalszą ewaluację i dostosowanie w odpowiedzi na zmieniające się warunki kontekstowe i organizacyjne. Dzięki zastosowaniu metodycznego podejścia do rozwoju modelu, możliwe jest zarówno ciągłe doskonalenie narzędzia, jak i jego adaptacja do specyficznych potrzeb branżowych oraz kontekstów działalności organizacji.

Kolejnym kluczowym wkładem do nauki o zarządzaniu jest uwzględnienie w modelu preskryptywności, co wyróżnia go spośród wielu tradycyjnych modeli dojrzałości, które ograniczają się tylko do opisu aktualnego stanu organizacji. Co więcej, jest to też jedyne znane Autorowi w momencie pisania tej rozprawy (na podstawie wykonanego wcześniej porównania modeli dojrzałości z literatury) wykorzystanie dużych modeli językowych do opracowania części preskryptywnej modelu. W przypadku modelu CLIMB2-OLIMP, organizacja, po dokonaniu

samooceny za pomocą kwestionariusza, otrzymuje nie tylko opis bieżącego poziomu dojrzałości, ale także rekomendacje, które wskazują możliwe ścieżki rozwoju i usprawnienia, a także przykłady najlepszych praktyk. Dzięki temu menedżerowie mogą podejmować bardziej świadome decyzje strategiczne i operacyjne, łatwiej planować dalsze inwestycje oraz wytyczać realistyczne cele w ramach przejścia na wyższy poziom dojrzałości. Dodatkowo, dotychczas badania nad dojrzałością organizacyjną najczęściej skupiały się na takich aspektach AI, jak uczenie maszynowe, analityka predykcyjna czy automatyzacja procesów roboczych. Model CLIMB2-OLIMP uwypukla specyficzną rolę generatywnej AI w procesach tworzenia i rozwoju nowych produktów, wskazując, jak technologie takie jak generowanie prototypów, wspomaganie analizy rynku czy wspieranie procesu projektowania, mogą zostać wykorzystane w praktyce. Dzięki temu przyczynia się do rozwoju badań z zakresu implementacji nowoczesnych narzędzi AI w tak złożonym procesie jak rozwój nowych produktów.

Należy jednak zauważyć, że opracowanie modelu wiąże się z pewnymi ograniczeniami. Przeprowadzone studia przypadków opierają się na danych z ograniczonej liczby organizacji z sektora produkcyjnego. Aby uzyskać pełniejszy obraz użyteczności modelu i potwierdzić jego uniwersalność, konieczne byłoby przeprowadzenie badań w większej liczbie organizacji, w tym w sektorach usługowych, IT czy e-commerce, gdzie procesy rozwoju nowego produktu mogą znacznie różnić się od tych spotykanych w przemyśle produkcyjnym. Dodatkowym ograniczeniem jest specyfika branż, w których badano model. Wszystkie analizowane organizacje charakteryzują się długim cyklem życia produktów. W sektorach, gdzie innowacje pojawiają się znacznie szybciej, na przykład w startupach programistycznych, niektóre wymiary lub praktyki zawarte w modelu mogłyby wymagać modyfikacji lub uproszczenia, aby lepiej odpowiadać dynamicznym warunkom rynkowym i krótszym cyklom życia produktów. Należy również uwzględnić dynamiczny charakter rozwoju technologii, w szczególności generatywnej sztucznej inteligencji, która rozwija się w bardzo szybkim tempie. W związku z tym pewne praktyki, zwłaszcza te związane z określonymi narzędziami czy technologiami, mogą z czasem tracić na aktualności. Aby model pozostawał adekwatny i skuteczny, konieczne jest jego regularne aktualizowanie oraz dostosowywanie do pojawiających się rozwiązań technologicznych i zmieniających się wyzwań rynkowych.

Kolejnym aspektem, który należy brać pod uwagę, jest wymóg zasobów i zaangażowania. Choć model CLIMB2-OLIMP jest stosunkowo mniej skomplikowany niż tradycyjne narzędzia, takie jak

CMMI, to jego wdrożenie oraz samoocena wymagają znacznego zaangażowania pracowników. Proces ten wiąże się z koniecznością przeprowadzenia szczegółowych wywiadów oraz wypełnienia kwestionariuszy, co może stanowić barierę dla organizacji dysponujących ograniczonymi zasobami, zwłaszcza kadrowymi. W praktyce, dla przedsiębiorstw o mniejszej liczbie pracowników lub z ograniczonym budżetem przeprowadzenie kompleksowej oceny może być trudniejsze niż w większych organizacjach.

W celu dalszego udoskonalenia i walidacji opracowanego modelu rekomenduje się przeprowadzenie badań na znacznie większej liczbie przedsiębiorstw oraz o zróżnicowanej skali działalności. Poszerzenie bazy empirycznej pozwoli na dokładniejsze zbadanie elastyczności modelu i ocenę, czy wymaga on specyficznej adaptacji do unikalnych warunków funkcjonowania poszczególnych sektorów gospodarki. Równocześnie istotne byłoby przeprowadzenie długoterminowych badań, których celem byłaby analiza wpływu wdrożeń generatywnej sztucznej inteligencji na efektywność procesów rozwoju nowego produktu. Badania podłużne, realizowane na przestrzeni kilku lat, umożliwiłyby ustalenie czy organizacje osiągające wyższe poziomy dojrzałości rzeczywiście czerpią trwałe korzyści finansowe, operacyjne oraz innowacyjne. Kolejnym interesującym kierunkiem badań jest porównanie wyników uzyskanych za pomocą modelu CLIMB2-OLIMP z efektami ocen przeprowadzonych przy użyciu innych modeli dojrzałości, na przykład modeli związanych z cyfrową transformacją czy Przemysłem 4.0. Takie zestawienie pozwoliłoby zbadać zbieżność wniosków dotyczących stanu dojrzałości organizacji oraz wskazać ewentualne sfery wymagające dalszych modyfikacji. Ostatnim rekomendowanym obszarem dalszych badań jest rozwój narzędzi wspierających część preskryptywną modelu. Obecna wersja narzędzia opiera się na dużych modelach językowych, co umożliwia generowanie rekomendacji i alternatywnych scenariuszy rozwoju. W przyszłości warto rozważyć rozbudowę tej funkcjonalności o dodatkowe moduły symulacyjne czy o pulpity wizualne. Takie rozszerzenia mogłyby znacząco ułatwić zespołom menedżerskim ocenę różnych scenariuszy wdrożeń generatywnej AI, a dzięki temu także przyczynić się do bardziej świadomego i efektywnego zarządzania procesem rozwoju nowego produktu.

Bibliografia

- Abadi, A. N., Nayeem, M. T. i Rafiei, D. (2023). Product Entity Matching via Tabular Data. *Proceedings of the 32nd ACM International Conference on Information and Knowledge Management*, 4215–4219. ACM. <https://doi.org/10.1145/3583780.3615172>
- Adamopoulou, E. i Moussiades, L. (2020). An Overview of Chatbot Technology. *Artificial Intelligence Applications and Innovations*, 584, 373–383. https://doi.org/10.1007/978-3-030-49186-4_31
- Adams, W. C. (2015). Conducting Semi-Structured Interviews. W *Handbook of Practical Program Evaluation* (s. 492–505). John Wiley i Sons, Ltd. <https://doi.org/10.1002/9781119171386.ch19>
- Aguilar, M. F. i Jugend, D. (2022). Circular product design maturity matrix: A guideline to evaluate new product development in light of the circular economy transition. *Journal of Cleaner Production*, 365, 132732. <https://doi.org/10.1016/j.jclepro.2022.132732>
- Aguwa, C., Olya, M. H. i Monplaisir, L. (2017). Modeling of fuzzy-based voice of customer for business decision analytics. *Knowledge-Based Systems*, 125, 136–145. Scopus. <https://doi.org/10.1016/j.knsys.2017.03.019>
- Ahmed, F., Capretz, L. F. i Samarabandu, J. (2008). Fuzzy inference system for software product family process evaluation. *Information Sciences*, 178(13), 2780–2793. <https://doi.org/10.1016/j.ins.2008.03.002>
- Akbari, F., Saberi, M. i Hussain, O. K. (2020). Social network structure-based framework for innovation evaluation and propagation for new product development. *Service Oriented Computing and Applications*, 14(3), 189–201. Scopus. <https://doi.org/10.1007/s11761-020-00289-8>
- Alaa, A. M., van Breugel, B., Saveliev, E. i van der Schaar, M. (2022). How Faithful is your Synthetic Data? Sample-level Metrics for Evaluating and Auditing Generative Models. *Proceedings of the 39th International Conference on Machine Learning (ICML 2022)*, 162, 290–306. Scopus. <https://doi.org/10.48550/arXiv.2102.08921>
- Albliwi, S. A., Antony, J. i Arshed, N. (2014). Critical literature review on maturity models for business process excellence. *2014 IEEE International Conference on Industrial Engineering and Engineering Management*, 79–83. <https://doi.org/10.1109/IEEM.2014.7058604>
- Al-Busaidi, A. S., Raman, R., Hughes, L., Albashrawi, M. A., Malik, T., Dwivedi, Y. K., Al-Alawi, T., AlRizeiqi, M., Davies, G., Fenwick, M., Gupta, P., Gupur, S., Hooda, A., Jurcys, P., Lim, D., Lucchi, N., Misra, T., Raman, R., Shirish, A. i Walton, P. (2024). Redefining boundaries in innovation and knowledge domains: Investigating the impact of generative artificial intelligence on copyright and intellectual property rights. *Journal of Innovation i Knowledge*, 9(4), 100630. <https://doi.org/10.1016/j.jik.2024.100630>
- Ali Zaidi, S. S., Fraz, M. M., Shahzad, M. i Khan, S. (2022). A multiapproach generalized framework for automated solution suggestion of support tickets. *International Journal of Intelligent Systems*, 37(6), 3654–3681. Scopus. <https://doi.org/10.1002/int.22701>
- Allal-Chérif, O., Simón-Moya, V. i Ballester, A. C. C. (2021). Intelligent purchasing: How artificial intelligence can redefine the purchasing function. *Journal of Business Research*, 124, 69–76. Scopus. <https://doi.org/10.1016/j.jbusres.2020.11.050>
- Alsheiabni, S., Cheung, Y. i Messom, C. (2019). Towards An Artificial Intelligence Maturity Model: From Science Fiction To Business Facts. *PACIS 2019 Proceedings*. <https://aisel.aisnet.org/pacis2019/46>
- Alsheibani, S., Cheung, Y. i Messom, C. (2018). Artificial intelligence adoption: AI-readiness at firm-level. *Proceedings of PACIS2018: Pacific Asia Conference in Information Systems (PACIS)*, 37. <https://aisel.aisnet.org/pacis2018/37/>
- Alsufyani, N. i Gill, A. Q. (2021). A Review of Digital Maturity Models from Adaptive Enterprise Architecture Perspective: Digital by Design. *2021 IEEE 23rd Conference on Business Informatics (CBI)*, 01, 121–130. <https://doi.org/10.1109/CBI52690.2021.00023>
- Amankwah-Amoah, J., Abdalla, S., Mogaji, E., Elbanna, A. i Dwivedi, Y. K. (2024). The impending disruption of creative industries by generative AI: Opportunities, challenges, and research agenda. *International Journal of Information Management*, 79, 102759. <https://doi.org/10.1016/j.ijinfomgt.2024.102759>
- Amaral, D. C. i Rozenfeld, H. (2007). Integrating New Product Development Process References With Maturity and Change Management Models. *DS 42: Proceedings of ICED 2007, the 16th International Conference on Engineering Design*, 631–632.
- Ameri, F. i Dutta, D. (2005). Product Lifecycle Management: Closing the Knowledge Loops. *Computer-Aided Design and Applications*, 2(5), 577–590. <https://doi.org/10.1080/16864360.2005.10738322>

- Andersen, E. S. i Jessen, S. A. (2003). Project maturity in organisations. *International Journal of Project Management*, 21(6), 457–461. [https://doi.org/10.1016/S0263-7863\(02\)00088-1](https://doi.org/10.1016/S0263-7863(02)00088-1)
- Angreani, L. S., Vijaya, A. i Wicaksono, H. (2020). Systematic Literature Review of Industry 4.0 Maturity Model for Manufacturing and Logistics Sectors. *Procedia Manufacturing*, 52, 337–343. <https://doi.org/10.1016/j.promfg.2020.11.056>
- Annacchino, M. (2003). *New Product Development: From Initial Idea to Product Management*. Elsevier.
- Aref, M. M., Elbagoury, B. M. i Hassanin, W. (2022). Designing an Intelligent Agents for E-Bookstore System Web-Based System. W X.-S. Yang, S. Sherratt, N. Deyi A. Joshi (Red.), *Proceedings of Sixth International Congress on Information and Communication Technology* (s. 321–330). Springer. https://doi.org/10.1007/978-981-16-2102-4_30
- Bai, Y., Li, Y. i Wang, L. (2021). A joint summarization and pre-trained model for review-based recommendation. *Information (Switzerland)*, 12(6). Scopus. <https://doi.org/10.3390/info12060223>
- Bandi, A., Adapa, P. V. S. R. i Kuchi, Y. E. V. P. K. (2023). The Power of Generative AI: A Review of Requirements, Models, Input–Output Formats, Evaluation Metrics, and Challenges. *Future Internet*, 15(8). Scopus. <https://doi.org/10.3390/fi15080260>
- Barczak, G., Griffin, A. i Kahn, K. B. (2009). PERSPECTIVE: Trends and Drivers of Success in NPD Practices: Results of the 2003 PDMA Best Practices Study. *Journal of Product Innovation Management*, 26(1), 3–23. <https://doi.org/10.1111/j.1540-5885.2009.00331.x>
- Barczak, G. i Kahn, K. B. (2012). Identifying new product development best practice. *Business Horizons*, 55(3), 293–305. <https://doi.org/10.1016/j.bushor.2012.01.006>
- Basl, J. (2018). Analysis of Industry 4.0 Readiness Indexes and Maturity Models and Proposal of the Dimension for Enterprise Information Systems. *Lecture Notes in Business Information Processing*, 327, 57. https://doi.org/10.1007/978-3-319-99040-8_5
- Batenburg, R., Helms, R. W. i Versendaal, J. (2005). The maturity of product lifecycle management in dutch organizations: A strategic alignment perspective. *International Conference on Product Lifecycle Management*, 436–450.
- Batenburg, R. S., Helms, R. W. i Versendaal, J. (2006). PLM roadmap: Stepwise PLM implementation based on the concepts of maturity and alignment. *International Journal of Product Lifecycle Management*, 1(4), 333–351. <https://doi.org/10.1504/IJPLM.2006.011053>
- Becker, J., Knackstedt, R. i Pöppelbuß, J. (2009). Developing Maturity Models for IT Management. *Business i Information Systems Engineering*, 1(3), 213–222. <https://doi.org/10.1007/s12599-009-0044-5>
- Benbya, H., Strich, F. i Tamm, T. (2024). Navigating Generative Artificial Intelligence Promises and Perils for Knowledge and Creative Work. *Journal of the Association for Information Systems*, 25(1), 23–36. Scopus. <https://doi.org/10.17705/1jais.00861>
- Bendoly, E., Chandrasekaran, A., Lima, M. do R. F., Handfield, R., Khajavi, S. H. i Roscoe, S. (2024). The role of generative design and additive manufacturing capabilities in developing human–AI symbiosis: Evidence from multiple case studies. *Decision Sciences*, 55(4), 325–345. <https://doi.org/10.1111/deci.12619>
- Bengio, Y., Ducharme, R., Vincent, P. i Janvin, C. (2003). A Neural Probabilistic Language Model. *Journal of Machine Learning Research*.
- Benham, N., Gao, S. i Ng, Y.-K. (2022). A Hybrid Approach for Summarizing User Reviews Based on KL-Divergence and Deep Learning. *2022 IEEE 34th International Conference on Tools with Artificial Intelligence (ICTAI)*, 325–333. Scopus. <https://doi.org/10.1109/ICTAI56018.2022.00054>
- Berg, P., Pihlajamaa, J., Poskela, J. i Smedlund, A. (2006). Benchmarking of quality and maturity of innovation activities in a networked environment. *International Journal of Technology Management*, 33(2–3), 255–278. <https://doi.org/10.1504/IJTM.2006.008314>
- Bernijazov, R., Dicks, A., Dumitrescu, R., Foullois, M., Hanselle, J. i Malatyali, M. (2021). A Meta-Review on Artificial Intelligence in Product Creation. *AI and Product Design Workshop, 30th International Joint Conference on Artificial Intelligence (IJCAI-21)*
- Bertolini, A. i Aiello, G. (2018). Robot companions: A legal and ethical analysis. *Information Society*, 34(3), 130–140. Scopus. <https://doi.org/10.1080/01972243.2018.1444249>
- Bilgram, V. i Laarmann, F. (2023). Accelerating Innovation With Generative AI: AI-Augmented Digital Prototyping and Innovation Methods. *IEEE Engineering Management Review*, 51(2), 18–25. <https://doi.org/10.1109/EMR.2023.3272799>
- Birjali, M., Kasri, M. i Beni-Hssane, A. (2021). A comprehensive survey on sentiment analysis: Approaches, challenges and trends. *Knowledge-Based Systems*, 226. Scopus. <https://doi.org/10.1016/j.knosys.2021.107134>

- Blöcher, K. i Alt, R. (2021). AI and robotics in the European restaurant sector: Assessing potentials for process innovation in a high-contact service industry. *Electronic Markets*, 31(3), 529–551. Scopus. <https://doi.org/10.1007/s12525-020-00443-2>
- Blut, M. i Wang, C. (2020). Technology readiness: A meta-analysis of conceptualizations of the construct and its impact on technology usage. *Journal of the Academy of Marketing Science*, 48(4), 649–669. <https://doi.org/10.1007/s11747-019-00680-8>
- Borji, A. (2019). Pros and cons of GAN evaluation measures. *Computer Vision and Image Understanding*, 179, 41–65. Scopus. <https://doi.org/10.1016/j.cviu.2018.10.009>
- Borsci, S., Malizia, A., Schmettow, M., van der Velde, F., Tariverdiyeva, G., Balaji, D. i Chamberlain, A. (2022). The Chatbot Usability Scale: The Design and Pilot of a Usability Scale for Interaction with AI-Based Conversational Agents. *Personal and Ubiquitous Computing*, 26(1), 95–119. Scopus. <https://doi.org/10.1007/s00779-021-01582-9>
- Botega, L. F. C. i da Silva, J. C. (2020). An artificial intelligence approach to support knowledge management on the selection of creativity and innovation techniques. *Journal of Knowledge Management*, 24(5), 1107–1130. Scopus. <https://doi.org/10.1108/JKM-10-2019-0559>
- Bouschery, S. G., Blazevic, V. i Piller, F. T. (2023). Augmenting human innovation teams with artificial intelligence: Exploring transformer-based language models. *Journal of Product Innovation Management*, 40(2), 139–153. Scopus. <https://doi.org/10.1111/jpim.12656>
- Boutyour, Y. i Idrissi, A. (2024). Adaptive Decentralized Policies With Attention for Large-Scale Multiagent Environments. *IEEE Transactions on Artificial Intelligence*, 5(10), 4905–4914. <https://doi.org/10.1109/TAI.2024.3415550>
- Brajer-Marczak, R. (2014). Dojrzałość procesowa w przestrzeni wewnątrzorganizacyjnej. *Marketing i Rynek*, 5 [CD].
- Brand, J., Israeli, A. i Ngwe, D. (2023). Using GPT for Market Research [dostęp 11 stycznia 2024], Dostępny w Internecie: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4395751
- Braun, V. i Clarke, V. (2012). Thematic analysis. W *APA handbook of research methods in psychology, Vol 2: Research designs: Quantitative, qualitative, neuropsychological, and biological* (s. 57–71). American Psychological Association. <https://doi.org/10.1037/13620-004>
- Brocke, J., Simons, A., Niehaves, B., Niehaves, B., Reimer, K., Plattfaut, R. i Cleven, A. (2009). Reconstructing the giant: on the importance of rigour in documenting the literature search process. *ECIS 2009 Proceedings*. <https://aisel.aisnet.org/ecis2009/161>
- Bulut, A. i Mahmoud, A. (2023). Generating Campaign Ads i Keywords for Programmatic Advertising. *IEEE Access*, 11, 43557–43565. Scopus. <https://doi.org/10.1109/ACCESS.2023.3269505>
- Burgess, A. (2018b). *The Executive Guide to Artificial Intelligence*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-63820-1>
- Byrd, M. i Darrow, R. (2021). A note on the advantage of context in Thompson sampling. *Journal of Revenue and Pricing Management*, 20(3), 316–321. Scopus. <https://doi.org/10.1057/s41272-021-00314-1>
- Cao, H. i Folan, P. (2012). Product life cycle: The evolution of a paradigm and literature review from 1950–2009. *Production Planning i Control*, 23(8), 641–662. <https://doi.org/10.1080/09537287.2011.577460>
- Cao, X. i Zhang, J. (2021). Preference learning and demand forecast. *Marketing Science*, 40(1), 62–79. Scopus. <https://doi.org/10.1287/mksc.2020.1238>
- Chakraborty, S. i Boral, S. (2017). A developed case-based reasoning system for machine tool selection. *Benchmarking*, 24(5), 1364–1385. Scopus. <https://doi.org/10.1108/BIJ-07-2016-0103>
- Chaldun, E. R., Yudoko, G., Maryunani, S. R., Kautsar, F. F. K. i Walidayni, C. T. (2024). Influencing factors of Indonesian coffee product customer experience in international market: An aspect-based sentiment analysis with GPT-3 Davinci model. *Cogent Business and Management*, 11(1). Scopus. <https://doi.org/10.1080/23311975.2024.2429796>
- Chanias, S. i Hess, T. (2016). How digital are we? Maturity models for the assessment of a company's status in the digital transformation. *Management Report / Institut Für Wirtschaftsinformatik Und Neue Medien*, 2, Article 2.
- Cheema, F. i Urner, R. (2023). Precision Recall Cover: A Method for Assessing Generative Models. *Proceedings of the 26th International Conference on Artificial Intelligence and Statistics*, 206, 6571–6594. Scopus.
- Chen, C., Carroll, C. i Morkos, B. (2023). From text to images: linking system requirements to images using joint embedding. *Proceedings of the Design Society*, 3, 1985–1994. Scopus. <https://doi.org/10.1017/pds.2023.199>
- Chen, C. i Morkos, B. (2023). Exploring topic modelling for generalising design requirements in complex design. *Journal of Engineering Design*, 34(11), 922–940. Scopus. <https://doi.org/10.1080/09544828.2023.2268850>

- Chen, J.-S., Le, T.-T.-Y. i Florence, D. (2021). Usability and responsiveness of artificial intelligence chatbot on online customer experience in e-retailing. *International Journal of Retail and Distribution Management*, 49(11), 1512–1531. Scopus. <https://doi.org/10.1108/IJRDM-08-2020-0312>
- Chen, W., Liu, C., Xing, F., Peng, G. i Yang, X. (2021). Establishment of a maturity model to assess the development of industrial AI in smart manufacturing. *Journal of Enterprise Information Management*. Scopus. <https://doi.org/10.1108/JEIM-10-2020-0397>
- Chen, W., You, Z., Li, R., Guan, Y., Qian, C., Zhao, C., Yang, C., Xie, R., Liu, Z. i Sun, M. (2024). Internet of Agents: Weaving a Web of Heterogeneous Agents for Collaborative Intelligence [dostęp 17 września 2024], Dostępny w Internecie: <https://arxiv.org/abs/2407.07061>
- Chen, X., Roberts, R., Tong, W. i Liu, Z. (2022). Tox-GAN: An Artificial Intelligence Approach Alternative to Animal Studies - A Case Study with Toxicogenomics. *Toxicological Sciences*, 186(2), 242–259. Scopus. <https://doi.org/10.1093/toxsci/kfab157>
- Chen, X., Zhang, Y., Xu, H., Qin, Z. i Zha, H. (2019). Adversarial distillation for efficient recommendation with external knowledge. *ACM Transactions on Information Systems*, 37(1). Scopus. <https://doi.org/10.1145/3281659>
- Chia, P. J., Attanasio, G., Bianchi, F., Terragni, S., Magalhães, A. R., Goncalves, D., Greco, C. i Tagliabue, J. (2022). Contrastive language and vision learning of general fashion concepts. *Scientific Reports*, 12(1). Scopus. <https://doi.org/10.1038/s41598-022-23052-9>
- Choi, J., Oh, S., Yoon, J., Lee, J.-M. i Coh, B.-Y. (2020). Identification of time-evolving product opportunities via social media mining. *Technological Forecasting and Social Change*, 156. Scopus. <https://doi.org/10.1016/j.techfore.2020.120045>
- Choi, J., Yoon, J., Chung, J., Coh, B.-Y. i Lee, J.-M. (2020). Social media analytics and business intelligence research: A systematic review. *Information Processing and Management*, 57(6). Scopus. <https://doi.org/10.1016/j.ipm.2020.102279>
- Choi, W., Jang, S., Kim, H. Y., Lee, Y., Lee, S.-G., Lee, H. i Park, S. (2023). Developing an AI-based automated fashion design system: Reflecting the work process of fashion designers. *Fashion and Textiles*, 10(1). Scopus. <https://doi.org/10.1186/s40691-023-00360-w>
- Chong, M. J. i Forsyth, D. (2020). Effectively unbiased FID and inception score and where to find them. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 6069–6078. Scopus. <https://doi.org/10.1109/CVPR42600.2020.00611>
- Chrissis, M. B., Konrad, M. i Shrum, S. (2011). *CMMI for Development: Guidelines for Process Integration and Product Improvement, 3rd Edition*. Carnegie Mellon University, Software Engineering Institute's Digital Library.
- Chukhlomin, V. (2024). Generative AI Capability Maturity Model for Online and Adult Learning: Introducing the EMERALD-GenAI-CMM-OAL Framework. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4769557>
- Cillo, P. i Rubera, G. (2024). Generative AI in innovation and marketing processes: A roadmap of research opportunities. *Journal of the Academy of Marketing Science*. <https://doi.org/10.1007/s11747-024-01044-7>
- Clausing, D. i Holmes, M. (2010). Technology Readiness. *Research-Technology Management*, 53, 52-59. <https://doi.org/10.1080/08956308.2010.11657640>
- Coates, D. L. i Martin, A. (2019). An instrument to evaluate the maturity of bias governance capability in artificial intelligence projects. *IBM Journal of Research and Development*, 63(4/5), 7:1-7:15. <https://doi.org/10.1147/JRD.2019.2915062>
- Colado, I. J. P., Colado, V. M. P., Morata, A. C., Píriz, R. S. C. i Manjón, B. F. (2023). Using New AI-Driven Techniques to Ease Serious Games Authoring. *Proceedings - Frontiers in Education Conference*. Scopus. <https://doi.org/10.1109/FIE58773.2023.10343021>
- Colangelo, E., Fries, C., Hinrichsen, T.-F., Szaller, Á. i Nick, G. (2022). Maturity Model for AI in Smart Production Planning and Control System. *Procedia CIRP*, 107, 493–498. <https://doi.org/10.1016/j.procir.2022.05.014>
- Cooper, R. G. (2010). The Stage-Gate Idea to Launch System. W *Wiley International Encyclopedia of Marketing*. John Wiley i Sons, Ltd. <https://doi.org/10.1002/9781444316568.wiem05014>
- Cooper, R. G. (2016). Agile-stage-gate hybrids. *Research Technology Management*, 59(1), 21–29. Scopus. <https://doi.org/10.1080/08956308.2016.1117317>
- Cooper, R. G. i Edgett, S. J. (2008). *Ideation for Product Innovation*. PDMA Visions Magazine.
- Cooper, R. G. (2023a). The Artificial Intelligence Revolution in New-Product Development. *Penn State Institute for the Study of Business Markets Members Conference*.

- Cooper, R. G. i Furst, P. (2023b). Agile Development in Manufacturing Companies: Best Practices and Pitfalls. *IEEE Engineering Management Review*, 51(4), 65–76. Scopus. <https://doi.org/10.1109/EMR.2023.3304792>
- Crawford, M. i Di Benedetto, A. (2010). *New Products Management*. McGraw-Hill.
- Cronemyr, P. i Danielsson, M. (2013). Process Management 1-2-3 – a maturity model and diagnostics tool. *Total Quality Management i Business Excellence*, 24(7–8), 933–944. <https://doi.org/10.1080/14783363.2013.791114>
- Crosby, P. B. (1979). *Quality is Free: The Art of Making Quality Certain*. McGraw-Hill.
- Crossan, M. M., Lane, H. W. i White, R. E. (1999). An Organizational Learning Framework: From Intuition to Institution. *The Academy of Management Review*, 24(3), 522–537. <https://doi.org/10.2307/259140>
- Cubric, M. (2020). Drivers, barriers and social considerations for AI adoption in business and management: A tertiary study. *Technology in Society*, 62. Scopus. <https://doi.org/10.1016/j.techsoc.2020.101257>
- Cunha, T., Soares, C. i de Carvalho, A. C. P. L. F. (2018). Metalearning and Recommender Systems: A literature review and empirical study on the algorithm selection problem for Collaborative Filtering. *Information Sciences*, 423, 128–144. Scopus. <https://doi.org/10.1016/j.ins.2017.09.050>
- Dalmarco, G., Ramalho, F. R., Barros, A. C. i Soares, A. L. (2019). Providing industry 4.0 technologies: The case of a production technology cluster. *Journal of High Technology Management Research*, 30(2). Scopus. <https://doi.org/10.1016/j.hitech.2019.100355>
- Das, S. D., Bala, P. K. i Mishra, A. N. (2023). Towards Defining a Trustworthy Artificial Intelligence System Development Maturity Model. *Journal of Computer Information Systems*, 0(0), 1–22. <https://doi.org/10.1080/08874417.2023.2251443>
- Datta, S. P. A. (2018). Unleashing the new Wealth Of Nations. *Journal of Innovation Management*, 6(2), Article 2. https://doi.org/10.24840/2183-0606_006.002_0003
- Dayan, R. i Evans, S. (2006). KM your way to CMMI. *Journal of Knowledge Management*, 10(1), 69–80. <https://doi.org/10.1108/13673270610650111>
- De Bruin, T., Rosemann, M., Freeze, R. i Kaulkarni, U. (2005). Understanding the Main Phases of Developing a Maturity Assessment Model. W D. Bunker, B. Campbelli J. Underwood (Red.), *Australasian Conference on Information Systems (ACIS)* (s. 8–19). <https://eprints.qut.edu.au/25152/>
- Demir, F. (2018). A Strategic Management Maturity Model for Innovation. *Technology Innovation Management Review*, 8(11), 13–21. <https://doi.org/10.22215/timreview/1196>
- Deng, X., Zhong, Y., Lü, L., Xiong, N. i Yeung, C. (2017). A general and effective diffusion-based recommendation scheme on coupled social networks. *Information Sciences*, 417, 420–434. Scopus. <https://doi.org/10.1016/j.ins.2017.07.021>
- Deng, Z. G., Lv, J., Liu, X. i Hou, Y. K. (2023). Bionic Design Model for Co-creative Product Innovation Based on Deep Generative and BID. *International Journal of Computational Intelligence Systems*, 16(1). Scopus. <https://doi.org/10.1007/s44196-023-00187-9>
- Denning, P. J. (1997). A new social contract for research. *Communications ACM*, 40(2), 132–134. <https://doi.org/10.1145/253671.253755>
- Dey, R. i Salem, F. M. (2017). Gate-variants of Gated Recurrent Unit (GRU) neural networks. *2017 IEEE 60th International Midwest Symposium on Circuits and Systems (MWSCAS)*, 1597–1600. <https://doi.org/10.1109/MWSCAS.2017.8053243>
- Diamantopoulos, T., Nastos, D.-N. i Symeonidis, A. (2023). *Semantically-enriched Jira Issue Tracking Data*. 218–222. Scopus. <https://doi.org/10.1109/MSR59073.2023.00039>
- Dilberoglu, U. M., Gharehpapagh, B., Yaman, U. i Dolen, M. (2017). The Role of Additive Manufacturing in the Era of Industry 4.0. *Procedia Manufacturing*, 11, 545–554. <https://doi.org/10.1016/j.promfg.2017.07.148>
- Doanh, D. C., Dufek, Z., Ejdys, J., Ginevičius, R., Korzynski, P., Mazurek, G., Paliszkievicz, J., Wach, K. i Ziemba, E. (2023). Generative AI in the Manufacturing Process: Theoretical Considerations. *Engineering Management in Production and Services*, 15(4), 76–89.
- Dombi, J., Jónás, T. i Tóth, Z. E. (2018). Modeling and long-term forecasting demand in spare parts logistics businesses. *International Journal of Production Economics*, 201, 1–17. Scopus. <https://doi.org/10.1016/j.ijpe.2018.04.015>
- Donthu, N., Kumar, S., Mukherjee, D., Pandey, N. i Lim, W. M. (2021). How to conduct a bibliometric analysis: An overview and guidelines. *Journal of Business Research*, 133, 285–296. <https://doi.org/10.1016/j.jbusres.2021.04.070>
- Dooley, K., Subra, A. i Anderson, J. (2001). Maturity and its impact on new product development project performance. *Research in Engineering Design - Theory, Applications, and Concurrent Engineering*, 13(1), 23–29. <https://doi.org/10.1007/s001630100003>

- Dorri, A., Kanhere, S. S. i Jurdak, R. (2018). Multi-Agent Systems: A Survey. *IEEE Access*, 6, 28573–28593. IEEE Access. <https://doi.org/10.1109/ACCESS.2018.2831228>
- Duarte, F. (2024). *Number of ChatGPT Users*. Exploding Topics [dostęp 7 grudnia 2024], Dostępny w Internecie: <https://explodingtopics.com/blog/chatgpt-users>
- Dwivedi, Y. K., Kshetri, N., Hughes, L., Slade, E. L., Jeyaraj, A., Kar, A. K., Baabdullah, A. M., Koohang, A., Raghavan, V., Ahuja, M., Albanna, H., Albashrawi, M. A., Al-Busaidi, A. S., Balakrishnan, J., Barlette, Y., Basu, S., Bose, I., Brooks, L., Buhalis, D., ... Wright, R. (2023). Opinion Paper: “So what if ChatGPT wrote it?” Multidisciplinary perspectives on opportunities, challenges and implications of generative conversational AI for research, practice and policy. *International Journal of Information Management*, 71, 102642. <https://doi.org/10.1016/j.ijinfomgt.2023.102642>
- Dzyabura, D., Jagabathula, S. i Muller, E. (2019). Accounting for discrepancies between online and offline product evaluations. *Marketing Science*, 38(1), 88–106. Scopus. <https://doi.org/10.1287/mksc.2018.1124>
- Ebert, C. i Louridas, P. (2023). Generative AI for Software Practitioners. *IEEE Software*, 40(4), 30–38. Scopus. <https://doi.org/10.1109/MS.2023.3265877>
- Efros, A. A. i Leung, T. K. (1999). Texture synthesis by non-parametric sampling. *Proceedings of the Seventh IEEE International Conference on Computer Vision*, 2, 1033–1038 t.2. <https://doi.org/10.1109/ICCV.1999.790383>
- Elibal, K. i Özceylan, E. (2020). A systematic literature review for industry 4.0 maturity modeling: State-of-the-art and future challenges. *Kybernetes*, 50(11), 2957–2994. <https://doi.org/10.1108/K-07-2020-0472>
- Ellefsen, A. P. T., Oleśków-Szłapka, J., Pawłowski, G. i Toboła, A. (2019). Striving for excellence in AI implementation: AI maturity model framework and preliminary research results. *LogForum*, Vol. 15(3). <https://doi.org/10.17270/J.LOG.2019.354>
- Eren, B. A. (2021). Determinants of customer satisfaction in chatbot use: Evidence from a banking application in Turkey. *International Journal of Bank Marketing*, 39(2), 294–311. Scopus. <https://doi.org/10.1108/IJBM-02-2020-0056>
- Escoffier, N., Tournois, N. i McKelvey, B. (2018). Using crowdsourcing to increase new product’s market value and positive comments for both the crowd involved and customers. *International Journal of Innovation Management*, 22(2). Scopus. <https://doi.org/10.1142/S1363919618500330>
- Eveleens, C. (2010). *Innovation management; a literature review of innovation process models and their implications* [dostęp 16 kwietnia 2023], Dostępny w Internecie: https://www.academia.edu/6375048/Innovation_management_a_literature_review_of_innovation_process_models_and_their_implications
- Exner, K., Balder, J. i Stark, R. (2018). A PSS maturity self-assessment tool. *Procedia CIRP*, 73, 86–90. <https://doi.org/10.1016/j.procir.2018.04.013>
- Felch, V. i Asdecker, B. (2020). Quo Vadis, Business Process Maturity Model? Learning from the Past to Envision the Future. W D. Fahland, C. Ghidini, J. Beckeri M. Dumas (Red.), *Business Process Management* (s. 368–383). Springer International Publishing. https://doi.org/10.1007/978-3-030-58666-9_21
- Feng, C., Rao, Y., Nazir, A., Wu, L. i He, L. (2020). Pre-trained Language Embedding-based Contextual Summary and Multi-scale Transmission Network for Aspect Extraction. *Procedia Computer Science*, 174, 40–49. Scopus. <https://doi.org/10.1016/j.procs.2020.06.054>
- Ferreira, K. J., Simchi-Levi, D. i Wang, H. (2018). Online network revenue management using Thompson sampling. *Operations Research*, 66(6), 1586–1602. Scopus. <https://doi.org/10.1287/opre.2018.1755>
- Feuerriegel, S., Hartmann, J., Janiesch, C. i Zschech, P. (2024). Generative AI. *Business i Information Systems Engineering*, 66(1), 111–126. <https://doi.org/10.1007/s12599-023-00834-7>
- Finlay, J. i Dix, A. (2002). *An Introduction to Artificial Intelligence*. Routledge.
- Flyvbjerg, B. (2011). *Case Study*. W Norman K. Denzin and Yvonna S. Lincoln (Red.), *The Sage Handbook of Qualitative Research*, Sage.
- Forstner, E., Kamprath, N. i Röglinger, M. (2014). Capability development with process maturity models – Decision framework and economic analysis. *Journal of Decision Systems*, 23(2), 127–150. <https://doi.org/10.1080/12460125.2014.865310>
- Frambach, R. T. i Schillewaert, N. (2002). Organizational innovation adoption: A multi-level framework of determinants and opportunities for future research. *Journal of Business Research*, 55(2), 163–176. [https://doi.org/10.1016/S0148-2963\(00\)00152-1](https://doi.org/10.1016/S0148-2963(00)00152-1)
- Fraser, P., Moultrie, J. i Gregory, M. (2002). The use of maturity models/grids as a tool in assessing product development capability. *IEEE International Engineering Management Conference*, 1, 244–249 t.1. <https://doi.org/10.1109/IEMC.2002.1038431>

- Fukas, P., Rebstadt, J., Remark, F. i Thomas, O. (2021). Developing an Artificial Intelligence Maturity Model for Auditing. *ECIS 2021 Research Papers*. https://aisel.aisnet.org/ecis2021_rp/133
- Fukas, P. i Thomas, O. (2023). Developing a Reference Model for Artificial Intelligence Management. *ECIS 2023 Research-in-Progress Papers*. https://aisel.aisnet.org/ecis2023_rip/89
- García-Mireles, G. A., Moraga, M. Á. i García, F. (2012). Development of maturity models: A systematic literature review. *2012 8th International Conference on the Quality of Information and Communications Technology*, 279–283. <https://doi.org/10.1049/ic.2012.0036>
- Garg, P., Patil, A., Soni, G., Keprate, A. i Arora, S. (2021). Machine learning-based abnormality detection approach for vacuum pump assembly line. *Reliability: Theory and Applications*, 16, 176–187. Scopus. <https://doi.org/10.24412/1932-2321-2021-264-176-187>
- Gaubinger, K., Rabl, M., Swan, S. i Werani, T. (2015). *Innovation and Product Management: A Holistic and Practical Approach to Uncertainty Reduction*. Springer. <https://doi.org/10.1007/978-3-642-54376-0>
- Geetha, K., Swarnalatha, K., Ananda Babu, J., Sudha, P. V. L. R. N. S. i Ramachandra, A. C. (2023). *Deep Learning and Sentiment Analysis Improve E-commerce Sales Prediction*. 2023 International Conference on Data Science and Network Security, ICDSNS 2023. Scopus. <https://doi.org/10.1109/ICDSNS58469.2023.10245916>
- Giannakis, M., Dubey, R., Yan, S., Spanaki, K. i Papadopoulos, T. (2022). Social media and sensemaking patterns in new product development: Demystifying the customer sentiment. *Annals of Operations Research*, 308(1–2), 145–175. Scopus. <https://doi.org/10.1007/s10479-020-03775-6>
- Gonçalves, J. N. C., Cortez, P., Carvalho, M. S. i Frazão, N. M. (2021). A multivariate approach for multi-step demand forecasting in assembly industries: Empirical evidence from an automotive supply chain. *Decision Support Systems*, 142. Scopus. <https://doi.org/10.1016/j.dss.2020.113452>
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. i Bengio, Y. (2014). Generative Adversarial Nets. *Advances in Neural Information Processing Systems*, 27.
- Goonatilleke, S. T. i Hettige, B. (2022). Past, Present and Future Trends in Multi-Agent System Technology. *Journal Europeen des Systemes Automatisés*, 55(6), 723–739. Scopus. <https://doi.org/10.18280/jesa.550604>
- Gorgoglione, M., Panniello, U. i Tuzhilin, A. (2019). Recommendation strategies in personalization applications. *Information and Management*, 56(6). Scopus. <https://doi.org/10.1016/j.im.2019.01.005>
- Grasler, I., Preus, D., Brandt, L. i Mohr, M. (2022). Efficient Extraction of Technical Requirements Applying Data Augmentation. *ISSE 2022 - 2022 8th IEEE International Symposium on Systems Engineering, Conference Proceedings*. Scopus. <https://doi.org/10.1109/ISSE54508.2022.10005452>
- Gräßler, I., Oleff, C. i Preuß, D. (2022). Proactive Management of Requirement Changes in the Development of Complex Technical Systems. *Applied Sciences (Switzerland)*, 12(4). Scopus. <https://doi.org/10.3390/app12041874>
- Graves, A. (2012). Long Short-Term Memory. W A. Graves (Red.), *Supervised Sequence Labelling with Recurrent Neural Networks* (s. 37–45). Springer. https://doi.org/10.1007/978-3-642-24797-2_4
- Greenstein-Messica, A. i Rokach, L. (2020). Machine learning and operation research based method for promotion optimization of products with no price elasticity history. *Electronic Commerce Research and Applications*, 40. Scopus. <https://doi.org/10.1016/j.elerap.2019.100914>
- Grela, G. (2013). Ocena poziomu dojrzałości procesowej organizacji. *Nierówności społeczne a wzrost gospodarczy*, 35, 169–182.
- Griffin, A. (1997). PDMA research on new product development practices: Updating trends and benchmarking best practices. *Journal of Product Innovation Management*, 14(6), 429–458. [https://doi.org/10.1016/S0737-6782\(97\)00061-1](https://doi.org/10.1016/S0737-6782(97)00061-1)
- Gružauskas, V., Gimžauskienė, E. i Navickas, V. (2019). Forecasting accuracy influence on logistics clusters activities: The case of the food industry. *Journal of Cleaner Production*, 240. Scopus. <https://doi.org/10.1016/j.jclepro.2019.118225>
- Guest, G., Bunce, A. i Johnson, L. (2006). How Many Interviews Are Enough?: An Experiment with Data Saturation and Variability. *Field Methods*, 18(1), 59–82. <https://doi.org/10.1177/1525822X05279903>
- Guo, L., Sharma, R., Yin, L., Lu, R. i Rong, K. (2017). Automated competitor analysis using big data analytics: Evidence from the fitness mobile app business. *Business Process Management Journal*, 23(3), 735–762. Scopus. <https://doi.org/10.1108/BPMJ-05-2015-0065>
- Gupta, R., Nair, K., Mishra, M., Ibrahim, B. i Bhardwaj, S. (2024). Adoption and impacts of generative artificial intelligence: Theoretical underpinnings and research agenda. *International Journal of Information Management Data Insights*, 4(1), 100232. <https://doi.org/10.1016/j.jjime.2024.100232>

- Gupta, S., Sharma, P., Chaudhary, S., Kumar, V., Singh, S. P., Lourens, M. i Beri, N. (2024). Study on the Beneficial Impacts and Ethical Dimensions of Generative AI in Software Product Management. *International Journal of Intelligent Systems and Applications in Engineering*, 12(8s), Article 8s.
- Gusenbauer, M. i Haddaway, N. R. (2020). Which academic search systems are suitable for systematic reviews or meta-analyses? Evaluating retrieval qualities of Google Scholar, PubMed, and 26 other resources. *Research Synthesis Methods*, 11(2), 181–217. <https://doi.org/10.1002/jrsm.1378>
- HajMirzaei, M., Ziarati, K. i Nikseresht, A. (2020). Discovering customer types using sales transactions and product availability data of 5 hotel datasets with genetic algorithm. *Journal of Revenue and Pricing Management*, 19(6), 386–400. Scopus. <https://doi.org/10.1057/s41272-020-00245-3>
- Hajoary, P. K., Balachandra, P. i Garza-Reyes, J. A. (2023). Industry 4.0 maturity and readiness assessment: An empirical validation using Confirmatory Composite Analysis. *Production Planning i Control*, 0(0), 1–18. <https://doi.org/10.1080/09537287.2023.2210545>
- Hammer, M. (2007). The Process Audit. *Harvard Business Review*.
- Hammer, M. i Stanton, S. (1999). How Process Enterprises Really Work. *Harvard Business Review*.
- Harter, D. E., Krishnan, M. S. i Slaughter, S. A. (2000). Effects of Process Maturity on Quality, Cycle Time, and Effort in Software Product Development. *Management Science*, 46(4), 451–466. <https://doi.org/10.1287/mnsc.46.4.451.12056>
- Heckbert, P. S. (1986). Survey of Texture Mapping. *IEEE Computer Graphics and Applications*, 6(11), 56–67. IEEE Computer Graphics and Applications. <https://doi.org/10.1109/MCG.1986.276672>
- Hellweg, F., Janhofer, D. i Hellgrath, B. (2023). Towards a maturity model for digital supply chains. *Logistics Research*, 16(1), 1–35. https://doi.org/10.23773/2023_5
- Heusler, W. i Kadija, K. (2018). Advanced design of complex façades. *Intelligent Buildings International*, 10(4), 220–233. Scopus. <https://doi.org/10.1080/17508975.2018.1493979>
- Hevner, A. R., March, S. T., Park, J. i Ram, S. (2004). Design Science in Information Systems Research. *MIS Quarterly*, 28(1), 75–105. <https://doi.org/10.2307/25148625>
- Höggerl, M., Schorz, B. i Pree, W. (2006). An Introduction to CMMI and its Assessment Procedure. W *Seminar for Computer Science*.
- Hollauer, C., Hornauer, L. A. i Lindemann, U. (2016). Process maturity models for the development of mechatronic products. *2016 International Conference on Industrial Engineering and Engineering Management, IEEM 2016*, 1200–1204. <https://doi.org/10.1109/IEEM.2016.7798068>
- Holmström, J. (2021). From AI to digital transformation: The AI readiness framework. *Business Horizons*, 65(3), 329–339. <https://doi.org/10.1016/j.bushor.2021.03.006>
- Hu, K. (2023). ChatGPT sets record for fastest-growing user base—Analyst note. *Reuters* [dostęp 5 marca 2024], Dostępny w Internecie: <https://www.reuters.com/technology/chatgpt-sets-record-fastest-growing-user-base-analyst-note-2023-02-01/>
- Huang, T., Bergman, D. i Gopal, R. (2019). Predictive and Prescriptive Analytics for Location Selection of Add-on Retail Products. *Production and Operations Management*, 28(7), 1858–1877. Scopus. <https://doi.org/10.1111/poms.13018>
- Hüsig, S. (2011). The CAI-NPD-Systems Maturity Model as Forecasting Method: From Closed CAI 1.0 to Holistic CAI 2.0 Solutions. W D. Cavallucci, R. de Guioi G. Cascini (Red.), *Building Innovation Pipelines through Computer-Aided Innovation* (s. 29–42). Springer. https://doi.org/10.1007/978-3-642-22182-8_4
- Hwang, E. H., Singh, P. V. i Argote, L. (2019). Jack of all, master of some: Information network and innovation in crowdsourcing communities. *Information Systems Research*, 30(2), 389–410. Scopus. <https://doi.org/10.1287/isre.2018.0804>
- Hynds, E. J., Brandt, V., Burek, S., Jager, W., Knox, P., Parker, J. P., Schwartz, L., Taylor, J. i Zietlow, M. (2014). A Maturity Model for Sustainability in New Product Development. *Research-Technology Management*, 57(1), 50–57. <https://doi.org/10.5437/08956308X5701143>
- Ibbs, C. W. i Kwak, Y. H. (2000). Assessing Project Management Maturity. *Project Management Journal*, 31(1), 32–43. <https://doi.org/10.1177/875697280003100106>
- Iii, A. L., Childerhouse, P., Disney, S. M., Towill, D. R. i McCormack, K. (2008). The impact of process maturity and uncertainty on supply chain performance: An empirical study. *International Journal of Manufacturing Technology and Management*, 15(1), 12–27.
- Işcan, C., Özkara, M. F., Çelik, A. E. i Akbulut, A. (2024). Evaluating Turkish BERT-based Language Models for Effective Customer Feedback Interpretation in CRM. *2024 9th International Conference on Computer Science and Engineering (UBMK)*, 227–232. Scopus. <https://doi.org/10.1109/UBMK63289.2024.10773436>

- Jain, S., Subzwari, S. W. A. i Subzwari, S. A. A. (2024). Generative AI for Healthcare Engineering and Technology Challenges. *IFIP Advances in Information and Communication Technology*, 697 AICT, 68–80. Scopus. https://doi.org/10.1007/978-3-031-50188-3_7
- Jain, T., Meenui Sardana, H. K. (2020). Quality edge extraction of mechanical CAD parts for intelligent manufacturing. *International Journal of Process Management and Benchmarking*, 10(1), 22–47. Scopus. <https://doi.org/10.1504/IJPMB.2020.104230>
- Jamjoom, A. A. (2021). The use of knowledge extraction in predicting customer churn in B2B. *Journal of Big Data*, 8(1). Scopus. <https://doi.org/10.1186/s40537-021-00500-3>
- Jeong, B., Yoon, J. i Lee, J.-M. (2019). Social media mining for product planning: A product opportunity mining approach based on topic modeling and sentiment analysis. *International Journal of Information Management*, 48, 280–290. Scopus. <https://doi.org/10.1016/j.ijinfomgt.2017.09.009>
- Jeston, J. (2014). *Business Process Management: Practical Guidelines to Successful Implementations* (3. wyd.). Routledge. <https://doi.org/10.4324/9780203081327>
- Jetter, A. J., Agrawal, A., Hongchai, D. M., Weber, C. M. i Tao, Y. (2024). *Training Practitioners for Real-time Product Development Using Generative Artificial Intelligence*. PICMET 2024 - 2024 Portland International Conference on Management of Engineering and Technology: Technology Management in the Artificial Intelligence Era, Proceedings. Scopus. <https://doi.org/10.23919/PICMET64035.2024.10653003>
- Jin, B. E. i Shin, D. C. (2020). Changing the game to compete: Innovations in the fashion retail industry from the disruptive business model. *Business Horizons*, 63(3), 301–311. Scopus. <https://doi.org/10.1016/j.bushor.2020.01.004>
- Jöhnik, J., Weißert, M. i Wyrtki, K. (2021). Ready or Not, AI Comes—An Interview Study of Organizational AI Readiness Factors. *Business i Information Systems Engineering*, 63(1), 5–20. <https://doi.org/10.1007/s12599-020-00676-7>
- Joosten, J., Bilgram, V., Hahn, A. i Totzek, D. (2024). Comparing the Ideation Quality of Humans With Generative Artificial Intelligence. *IEEE Engineering Management Review*, 1–10. <https://doi.org/10.1109/EMR.2024.3353338>
- Kahn, K. B., Barczak, G., Nicholas, J., Ledwith, A. i Perks, H. (2012). An Examination of New Product Development Best Practice. *Journal of Product Innovation Management*, 29(2), 180–192. <https://doi.org/10.1111/j.1540-5885.2011.00888.x>
- Kalam, K. T., Rahman, J. M., Islam, M. R. i Dewan, S. M. R. (2024). ChatGPT and mental health: Friends or foes? *Health Science Reports*, 7(2). Scopus. <https://doi.org/10.1002/hsr2.1912>
- Kalinowski, T. B. (2011). Modele oceny dojrzałości procesów. *Acta Universitatis Lodzensis. Folia Oeconomica*, 258 *Aktualne trendy w naukach o zarządzaniu, finansach i rachunkowości. Vol. 2*, 173–187.
- Kar, A. K., Varsha, P. S. i Rajan, S. (2023). Unravelling the Impact of Generative Artificial Intelligence (GAI) in Industrial Applications: A Review of Scientific and Grey Literature. *Global Journal of Flexible Systems Management*, 24(4), 659–689. <https://doi.org/10.1007/s40171-023-00356-x>
- Kärkkäinen, H., Pels, H. J. i Silventoinen, A. (2012). Defining the Customer Dimension of PLM Maturity. W L. Rivest, A. Bourasi B. Louhichi (Red.), *Product Lifecycle Management. Towards Knowledge-Rich Enterprises* (s. 623–634). Springer. https://doi.org/10.1007/978-3-642-35758-9_56
- Kasanen, E., Lukka, K. i Siitonen, A. (1993). The constructive approach in management accounting research. *Journal of Management Accounting Research*, 5, 243.
- Kharfan, M., Chan, V. W. K. i Firdolas Efendigil, T. (2021). A data-driven forecasting approach for newly launched seasonal products by leveraging machine-learning approaches. *Annals of Operations Research*, 303(1–2), 159–174. Scopus. <https://doi.org/10.1007/s10479-020-03666-w>
- Khatibian, N., Hasan gholi pour, T. i Abedi Jafari, H. (2010). Measurement of knowledge management maturity level within organizations. *Business Strategy Series*, 11(1), 54–70. <https://doi.org/10.1108/17515631011013113>
- Klincewicz, K., Żemigala, M. i Mijal, M. (2012). Bibliometria w zarządzaniu technologiami i badaniami naukowymi. *Ministerstwo Nauki i Szkolnictwa Wyższego* [dostęp 16 kwietnia 2023], Dostępny w Internecie: https://kpbc.umk.pl/Content/81392/PDF/bibliometria_klincewicz.pdf
- Knill, K. i Young, S. (1997). Hidden Markov Models in Speech and Language Processing. W S. Young i G. Bloothoof (Red.), *Corpus-Based Methods in Language and Speech Processing* (s. 27–68). Springer Netherlands. https://doi.org/10.1007/978-94-017-1183-8_2
- Ko, J. i Comuzzi, M. (2021). Detecting anomalies in business process event logs using statistical leverage. *Information Sciences*, 549, 53–67. Scopus. <https://doi.org/10.1016/j.ins.2020.11.017>
- Kose, T. i Sakata, I. (2019). Identifying technology convergence in the field of robotics research. *Technological Forecasting and Social Change*, 146, 751–766. Scopus. <https://doi.org/10.1016/j.techfore.2018.09.005>

- Kosieradzka, A. i Smagowicz, J. (2016). Analiza porównawcza modeli dojrzałości organizacji. W M. Ćwiklicki, M. Jabłoński i S. Mazur, *Współczesne koncepcje zarządzania publicznego. Wyzwania modernizacyjne sektora publicznego* (s. 283–296).
- Kotler, P. (Red.). (2006). *Principles of marketing*. Financial Times Prentice Hall.
- Kshetri, N., Dwivedi, Y. K., Davenport, T. H. i Panteli, N. (2024). Generative artificial intelligence in marketing: Applications, opportunities, challenges, and research agenda. *International Journal of Information Management*, 75, 102716. <https://doi.org/10.1016/j.ijinfomgt.2023.102716>
- Kuilboer, J. P. i Ashrafi, N. (2000). Software process and product improvement: An empirical assessment. *Information and Software Technology*, 42(1), 27–34. [https://doi.org/10.1016/S0950-5849\(99\)00054-3](https://doi.org/10.1016/S0950-5849(99)00054-3)
- Kumar, A., Shankar, R. i Aljohani, N. R. (2020). A big data driven framework for demand-driven forecasting with effects of marketing-mix variables. *Industrial Marketing Management*, 90, 493–507. Scopus. <https://doi.org/10.1016/j.indmarman.2019.05.003>
- Kumar, S., Singh, A. K., Bhushan, S. i Singh, V. K. (2023). A cross CNN-LSTM model for sarcasm identification in sentiment analysis. W *Artificial Intelligence, Blockchain, Computing and Security: Volume 1* (T. 1, s. 322–328). Scopus. <https://doi.org/10.1201/9781003393580-49>
- Kuo, J.-Y. i Xia, Z. (2023). Exploring Intelligent User Interfaces from Design Students' Perspectives on Smart Home Products Through Peer Assessment, Focus Group and ChatGPT. *Advances in Transdisciplinary Engineering* 41, 161–170. Scopus. <https://doi.org/10.3233/ATDE230608>
- Kupilas, K., Montequín, V., Álvarez-Pérez, C. i Balsera, J. (2021). Industry 4.0 and Digital Maturity. W *Industry 4.0 and Project Management and Engineering*, 66–102.
- Lai, X., Zhang, Q., Chen, Q., Huang, Y., Mao, N. i Liu, J. (2019). The analytics of product-design requirements using dynamic internet data: Application to Chinese smartphone market. *International Journal of Production Research*, 57(18), 5660–5684. Scopus. <https://doi.org/10.1080/00207543.2018.1541200>
- Langone, R., Cuzzocrea, A. i Skantzos, N. (2020). Interpretable Anomaly Prediction: Predicting anomalous behavior in industry 4.0 settings via regularized logistic regression tools. *Data and Knowledge Engineering*, 130. Scopus. <https://doi.org/10.1016/j.datak.2020.101850>
- Lasrado, L. A., Vatrappu, R. i Andersen, K. (2015). Maturity Models Development in IS Research: A Literature Review. *Selected Papers of the IRIS, Issue Nr 6 (2015)*. <https://aisel.aisnet.org/iris2015/6>
- Law, J. (2009). *A Dictionary of Business and Management*. Oxford University Press.
- Lee, D. i Hosanagar, K. (2019). How do recommender systems affect sales diversity? A cross-category investigation via randomized field experiment. *Information Systems Research*, 30(1), 239–259. Scopus. <https://doi.org/10.1287/isre.2018.0800>
- Lee, H., Choi, K., Yoo, D., Suh, Y., Lee, S. i He, G. (2018). Recommending valuable ideas in an open innovation community: A text mining approach to information overload problem. *Industrial Management and Data Systems*, 118(4), 683–699. Scopus. <https://doi.org/10.1108/IMDS-02-2017-0044>
- Lee, I. i Shin, Y. J. (2020). Machine learning for enterprises: Applications, algorithm selection, and challenges. *Business Horizons*, 63(2), 157–170. Scopus. <https://doi.org/10.1016/j.bushor.2019.10.005>
- Lee, J., Lee, D. i Kang, S. (2007). An Overview of the Business Process Maturity Model (BPMM). W K. C.-C. Chang, W. Wang, L. Chen, C. A. Ellis, C.-H. Hsu, A. C. Tsoi i H. Wang (Red.), *Advances in Web and Network Technologies, and Information Management* (s. 384–395). Springer. https://doi.org/10.1007/978-3-540-72909-9_42
- Lehmkuhl, T., Baumöl, U. i Jung, R. (2013). Towards a Maturity Model for the Adoption of Social Media as a Means of Organizational Innovation. *2013 46th Hawaii International Conference on System Sciences*, 3067–3076. <https://doi.org/10.1109/HICSS.2013.561>
- Lehr, J., Schlüter, M. i Krüger, J. (2020). Decentralised identification of used exchange parts with a mobile application. *International Journal of Sustainable Manufacturing*, 4(2–4), 150–164. Scopus. <https://doi.org/10.1504/IJSM.2020.107135>
- Li, G.-Y., Liu, B.-H., Yang, Y.-H. i Shao, D. (2023). Quality Attributes and Practices of Trustworthy Artificial Intelligence Systems: A Systematic Literature Review Based on Relevant Secondary Studies. *Ruan Jian Xue Bao/Journal of Software*, 34(9). Scopus. <https://doi.org/10.13328/j.cnki.jos.006875>
- Li, H., Wang, J., Lu, Y., Zhu, H. i Ma, J. (2023). Chinese Multicategory Sentiment of E-Commerce Analysis Based on Deep Learning. *Electronics (Switzerland)*, 12(20). Scopus. <https://doi.org/10.3390/electronics12204259>
- Li, J., Tao, F., Cheng, Y. i Zhao, L. (2015). Big Data in product lifecycle management. *The International Journal of Advanced Manufacturing Technology*, 81(1–4), 667–684. <https://doi.org/10.1007/s00170-015-7151-x>

- Li, M.-F., Zhang, G.-X., Zhao, L.-T. i Song, T. (2022). Extracting product competitiveness through user-generated content: A hybrid probabilistic inference model. *Journal of King Saud University - Computer and Information Sciences*, 34(6), 2720–2732. Scopus. <https://doi.org/10.1016/j.jksuci.2022.03.018>
- Li, N., Chiang, F., Down, D. G. i Heddle, N. M. (2021). A decision integration strategy for short-term demand forecasting and ordering for red blood cell components. *Operations Research for Health Care*, 29. Scopus. <https://doi.org/10.1016/j.orhc.2021.100290>
- Li, X., Wu, C. i Mai, F. (2019). The effect of online reviews on product sales: A joint sentiment-topic analysis. *Information and Management*, 56(2), 172–184. Scopus. <https://doi.org/10.1016/j.im.2018.04.007>
- Li, X., Yin, Y., Manrique, D. V. i Bäck, T. (2021). Lifecycle forecast for consumer technology products with limited sales data. *International Journal of Production Economics*, 239. Scopus. <https://doi.org/10.1016/j.ijpe.2021.108206>
- Li, Z., Ksibi, A. i Xu, X. (2024). Optimizing Inventory Management using a Multi-Agent LLM System. *Proceedings of the International Conference on Electronic Business (ICEB)* 24, 308–318. Scopus.
- Li, Z., Sayuti, N. ‘. A. i Wang, J. (2024). Exploring the Application of Artificial Intelligence-Generated Content (AIGC) in Modern Furniture Design Innovation. *Pakistan Journal of Life and Social Sciences*, 22(1), 4191–4199. Scopus. <https://doi.org/10.57239/PJLSS-2024-22.1.00307>
- Liao, Y., Ragai, I., Huang, Z. i Kerner, S. (2021). Manufacturing process monitoring using time-frequency representation and transfer learning of deep neural networks. *Journal of Manufacturing Processes*, 68, 231–248. Scopus. <https://doi.org/10.1016/j.jmapro.2021.05.046>
- Lichtenthaler, U. (2019). An Intelligence-Based View of Firm Performance: Profiting from Artificial Intelligence. *Journal of Innovation Management*, 7. https://doi.org/10.24840/2183-0606_007.001_0002
- Lichtenthaler, U. (2020). Five Maturity Levels of Managing AI: From Isolated Ignorance to Integrated Intelligence. *Journal of Innovation Management*, 8. https://doi.org/10.24840/2183-0606_008.001_0005
- Liebe, U. i Meyerhoff, J. (2021). Mapping potentials and challenges of choice modelling for social science research. *Journal of Choice Modelling*, 38. Scopus. <https://doi.org/10.1016/j.jocm.2021.100270>
- Lin, W., Zhang, Q., Wu, Y. J. i Chen, T.-C. (2023). Running a Sustainable Social Media Business: The Use of Deep Learning Methods in Online-Comment Short Texts. *Sustainability (Switzerland)*, 15(11). Scopus. <https://doi.org/10.3390/su15119093>
- Linhart, A., Klaus, C. i Röglinger, M. (2017). Maturing maturity models – a methodological extension using the analytical hierarchy process and Google PageRank. *Journal of Decision Systems*, 26(4), 307–327. <https://doi.org/10.1080/12460125.2017.1422317>
- Liu, C., Dong, Y., Yu, H., Shen, Z., Cui, L., Gao, Z., Wang, P., Zhang, C., Ren, P., Xie, X. i Miao, C. (2019). *Generating persuasive visual storylines for promotional videos*. 901–910. Scopus. <https://doi.org/10.1145/3357384.3357906>
- Liu, Y., Jiang, C. i Zhao, H. (2019). Assessing product competitive advantages from the perspective of customers by mining user-generated content on social media. *Decision Support Systems*, 123. Scopus. <https://doi.org/10.1016/j.dss.2019.113079>
- Liu, Y., Lu, J., Yang, J. i Mao, F. (2020). Sentiment analysis for e-commerce product reviews by deep learning model of Bert-BiGRU-Softmax. *Mathematical Biosciences and Engineering*, 17(6), 7819–7837. Scopus. <https://doi.org/10.3934/MBE.2020398>
- Lockamy, A. i McCormack, K. (2004). The development of a supply chain management process maturity model using the concepts of business process orientation. *Supply Chain Management: An International Journal*, 9(4), 272–278. <https://doi.org/10.1108/13598540410550019>
- Loisel, J., Duret, S., Cornuéjols, A., Cagnon, D., Tardet, M., Derens-Bertheau, E. i Laguerre, O. (2021). Cold chain break detection and analysis: Can machine learning help? *Trends in Food Science i Technology*, 112, 391–399. <https://doi.org/10.1016/j.tifs.2021.03.052>
- Lokuge, S., Sedera, D., Grover, V. i Dongming, X. (2019). Organizational readiness for digital innovation: Development and empirical calibration of a construct. *Information i Management*, 56(3), 445–461. <https://doi.org/10.1016/j.im.2018.09.001>
- López-Forniés, I. i Asión-Suñer, L. (2024). Co-creation Process with Generative Artificial Intelligence—An Experiment in Product Design. *Lecture Notes in Educational Technology, Part F2959*, 231–241. Scopus. https://doi.org/10.1007/978-981-97-2468-0_23
- Lu, J. K. i Hu, C. K. (2023). Named Entity Approach for Structured Management of Aeronautical Product Requirements. *Lecture Notes in Electrical Engineering*, 849, 135–146. Scopus. https://doi.org/10.1007/978-981-16-8154-7_11

- Lu, Y. (2017). Industry 4.0: A survey on technologies, applications and open research issues. *Journal of Industrial Information Integration*, 6, 1–10. <https://doi.org/10.1016/j.jii.2017.04.005>
- Luo, X., Tong, S., Fang, Z. i Qu, Z. (2019). Frontiers: Machines vs. humans: The impact of artificial intelligence chatbot disclosure on customer purchases. *Marketing Science*, 38(6), 937–947. Scopus. <https://doi.org/10.1287/mksc.2019.1192>
- Luo, Z., Huang, S. i Zhu, K. Q. (2019). Knowledge empowered prominent aspect extraction from product reviews. *Information Processing and Management*, 56(3), 408–423. Scopus. <https://doi.org/10.1016/j.ipm.2018.11.006>
- Luoma, J., Ruutu, S., King, A. W. i Tikkanen, H. (2017). Time delays, competitive interdependence, and firm performance. *Strategic Management Journal*, 38(3), 506–525. Scopus. <https://doi.org/10.1002/smj.2512>
- Madsen, D. Ø. (2020). The evolutionary trajectory of the agile concept viewed from a management fashion perspective. *Social Sciences*, 9(5). Scopus. <https://doi.org/10.3390/SOCSCI9050069>
- Maedche, A., Legner, C., Benlian, A., Berger, B., Gimpel, H., Hess, T., Hinz, O., Morana, S. i Söllner, M. (2019). AI-Based Digital Assistants. *Business i Information Systems Engineering*, 61(4), 535–544. <https://doi.org/10.1007/s12599-019-00600-8>
- Mahjour, B., Hoffstadt, J. i Cernak, T. (2023). Designing Chemical Reaction Arrays Using Phactor and ChatGPT. *Organic Process Research and Development*, 27(8), 1510–1516. Scopus. <https://doi.org/10.1021/acs.oprd.3c00186>
- Mahmood, B. i Alanezi, M. (2021). Structural-Spectral-Based Approach for Anomaly Detection in Social Networks. *International Journal of Computing and Digital Systems*, 10(1), 343–351. Scopus. <https://doi.org/10.12785/IJCDS/100134>
- Maier, A. M., Moultrie, J. i Clarkson, P. J. (2012). Assessing organizational capabilities: Reviewing and guiding the development of maturity grids. *IEEE Transactions on Engineering Management*, 59(1), 138–159. Scopus. <https://doi.org/10.1109/TEM.2010.2077289>
- Manotumruk, J., Macdonald, C. i Ounis, I. (2017). A deep recurrent collaborative filtering framework for venue recommendation. *Proceedings of the 2017 ACM on Conference on Information and Knowledge Management (CIKM '17)*, 1429–1438. Scopus. <https://doi.org/10.1145/3132847.3133036>
- March, S. T. i Smith, G. F. (1995). Design and natural science research on information technology. *Decision Support Systems*, 15(4), 251–266. [https://doi.org/10.1016/0167-9236\(94\)00041-2](https://doi.org/10.1016/0167-9236(94)00041-2)
- Mariani, M. i Dwivedi, Y. K. (2024). Generative artificial intelligence in innovation management: A preview of future research developments. *Journal of Business Research*, 175, 114542. <https://doi.org/10.1016/j.jbusres.2024.114542>
- Markowitz, D. M. i Hancock, J. T. (2024). Generative AI Are More Truth-Biased Than Humans: A Replication and Extension of Core Truth-Default Theory Principles. *Journal of Language and Social Psychology*, 43(2), 261–267. Scopus. <https://doi.org/10.1177/0261927X231220404>
- Martín-Martín, A., Orduna-Malea, E., Thelwall, M. i Delgado López-Cózar, E. (2018). Google Scholar, Web of Science, and Scopus: A systematic comparison of citations in 252 subject categories. *Journal of Informetrics*, 12(4), 1160–1177. <https://doi.org/10.1016/j.joi.2018.09.002>
- Matt, C., Hess, T. i Benlian, A. (2015). Digital Transformation Strategies. *Business i Information Systems Engineering*, 57(5), 339–343. <https://doi.org/10.1007/s12599-015-0401-5>
- Mattei, G., Canetta, L., Sorlini, M., Alberton, S. i Tito, F. (2019). Innovation Maturity Model for New Product and Services Development: A proposal. *2019 IEEE International Conference on Engineering, Technology and Innovation (ICE/ITMC)*, 1–9. <https://doi.org/10.1109/ICE.2019.8792581>
- Matuszczyk, D., Tschorn, N. i Weichert, F. (2022). Deep Learning Based Synthetic Image Generation for Defect Detection in Additive Manufacturing Industrial Environments. *2022 7th International Conference on Mechanical Engineering and Robotics Research (ICMERR)*, 209–218. Scopus. <https://doi.org/10.1109/ICMERR56497.2022.10097812>
- McKinsey. (2021). Global survey: The state of AI in 2021. *McKinsey* [dostęp 13 kwietnia 2023], Dostępny w Internecie: <https://www.mckinsey.com/capabilities/quantumblack/our-insights/global-survey-the-state-of-ai-in-2021>
- Mello, S. (2002). *Customer-centric Product Definition: The Key to Great Product Development*. AMACOM.
- Merk, D., Grisoni, F., Friedrich, L. i Schneider, G. (2018). Tuning artificial intelligence on the de novo design of natural-product-inspired retinoid X receptor modulators. *Communications Chemistry*, 1(1). Scopus. <https://doi.org/10.1038/s42004-018-0068-1>

- Mesbah, S., Arous, I., Yang, J. i Bozzon, A. (2023). HybridEval: A Human-AI Collaborative Approach for Evaluating Design Ideas at Scale. *Proceedings of the ACM Web Conference 2023*, 3837–3848. <https://doi.org/10.1145/3543507.3583496>
- Mettler, T. (2011). Maturity assessment models: A design science research approach. *International Journal of Society Systems Science*, 3(1–2), 81–98. <https://doi.org/10.1504/IJSSS.2011.038934>
- Mettler, T., Rohner, P. i Winter, R. (2010). Towards a Classification of Maturity Models in Information Systems. *Springer Books*, 333–340.
- Micu, A., Capatina, A., Cristea, D. S., Munteanu, D., Micu, A.-E. i Sarpe, D. A. (2022). Assessing an on-site customer profiling and hyper-personalization system prototype based on a deep learning approach. *Technological Forecasting and Social Change*, 174. Scopus. <https://doi.org/10.1016/j.techfore.2021.121289>
- Mikalef, P., Fjørtoft, S. O. i Torvatn, H. Y. (2019). Artificial Intelligence in the Public Sector: A Study of Challenges and Opportunities for Norwegian Municipalities. W I. O. Pappas, P. Mikalef, Y. K. Dwivedi, L. Jaccheri, J. Krogstie M. Mäntymäki (Red.), *Digital Transformation for a Sustainable Society in the 21st Century* (s. 267–277). Springer International Publishing. https://doi.org/10.1007/978-3-030-29374-1_22
- Mikolov, T., Karafiát, M., Burget, L., Černocký, J. i Khudanpur, S. (2010). Recurrent neural network based language model. *Interspeech 2010*, 1045–1048. <https://doi.org/10.21437/Interspeech.2010-343>
- Mohamed, K. B. N. R., Batra, D., Shivani, Molnar, V. i Raj, S. (2023). Artificial Intelligence in Fashion Design and IPRS. W *Artificial Intelligence and Knowledge Processing: Improved Decision-Making and Prediction* (s. 339–347). Scopus. <https://doi.org/10.1201/9781003328414-29>
- Molla, A., Cooper, V. i Pittayachawan, S. (2009). IT and Eco-sustainability: Developing and Validating a Green IT Readiness Model. *ICIS 2009 Proceedings*. <https://aisel.aisnet.org/icis2009/141>
- Morgan, J. i Liker, J. K. (2006). *The Toyota Product Development System: Integrating People, Process, and Technology*. Productivity Press. <https://doi.org/10.4324/9781482293746>
- Morizet, N., Desforges, P., Geissler, C., Pahon, E., Jemei, S. i Hissel, D. (2023). Time to market reduction for hydrogen fuel cell stacks using Generative Adversarial Networks. *Journal of Power Sources*, 579. Scopus. <https://doi.org/10.1016/j.jpowsour.2023.233286>
- Mosterman, P. J. i Zander, J. (2016). Industry 4.0 as a Cyber-Physical System study. *Software i System Modeling*, 15(1), 17–29. <https://doi.org/10.1007/s10270-015-0493-x>
- Moultrie, J., Sutcliffe, L. i Maier, A. (2016). A maturity grid assessment tool for environmentally conscious design in the medical device industry. *Journal of Cleaner Production*, 122, 252–265. <https://doi.org/10.1016/j.jclepro.2015.10.108>
- Mouludi, I., Rukun, K., Syah, N., Hafidana, S., Senjawati, M. I. i Hayadi, B. H. (2019). Expert system design as a quality control efforts in the packaging process tea Rgb 220 ml package bottle in Pt. Sinar sosro Kpb Deli Serdang. *International Journal of Scientific and Technology Research*, 8(6), 131–133. Scopus.
- M.P. 2021 poz. 23. (2021). *Polityka dla rozwoju sztucznej inteligencji w Polsce of roku 2020*. GovTech Polska [dostęp 5 listopada 2023], Dostępny w Internecie: <https://www.gov.pl/web/govtech/polityka-rozwoju-ai-w-polsce-przyjeta-przez-rade-ministrow-co-dalej>
- Muhammed, A., Singh, J., Zheng, S., Keivanloo, I., Perera, S., Mracek, J., Xu, Y., Cui, Q., Rajagopalan, S., Zeng, B. i Chilimbi, T. (2022). DCAF-BERT: A Distilled Cacheable Adaptable Factorized Model For Improved Ads CTR Prediction. *Companion Proceedings of the Web Conference 2022 (WWW '22)*, 110–115. Scopus. <https://doi.org/10.1145/3487553.3524206>
- Mukhopadhyay, S. (2018). Opinion mining in management research: The state of the art and the way forward. *OPSEARCH*, 55(2), 221–250. Scopus. <https://doi.org/10.1007/s12597-017-0328-3>
- Na, H. i Kim, W. (2021). A Study on The Practical Use of Generative Design in the Product Design Process. *Archives of Design Research*, 34(1), 85–98. Scopus. <https://doi.org/10.15187/adr.2021.02.34.1.85>
- Nasseri, M., Brandtner, P., Zimmermann, R., Falatouri, T., Darbanian, F. i Obinwanne, T. (2023). Applications of Large Language Models (LLMs) in Business Analytics – Exemplary Use Cases in Data Preparation Tasks. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 14059 LNCS, 182–198. Scopus. https://doi.org/10.1007/978-3-031-48057-7_12
- Nicholas, J. i Ledwith, A. (2006). *Development of a Best Practices Framework for New Product Development in Small to Medium Enterprises* [dostęp 17 maja 2023], Dostępny w Internecie: https://www.researchgate.net/profile/Ann-Ledwith/publication/228372687_Development_of_a_best_practices_framework_for_new_product_development_in_small_to_medium_enterprises/links/0c9605149f0742b7d4000000/Development-of-a-best-practices-framework-for-new-product-development-in-small-to-medium-enterprises.pdf?origin=scientificContributions

- Nickerson, R. C., Varshney, U. i Muntermann, J. (2013). A method for taxonomy development and its application in information systems. *European Journal of Information Systems*, 22(3), 336–359. <https://doi.org/10.1057/ejis.2012.26>
- Niemir, M. i Mrugalska, B. (2023). Data Science Challenges of Automated Quality Verification Process in Product Data Catalogues. *Materials Research Proceedings* 34, 390–399. Scopus. <https://doi.org/10.21741/9781644902691-45>
- Nikabadi, M. S. i Sani-Varjovi, H. K. (2021). Identifying new business areas in air transport industry using patent information. *International Journal of Business Innovation and Research*, 25(2), 184–207. Scopus. <https://doi.org/10.1504/IJBIR.2021.115454>
- Noori, H., Munro, H., Deszca, G. i Cohen, M. (1997). Managing the P/SDI process: Best-in class principles and leading practices. *International Journal of Technology Management*, 13(3), 245–268.
- Nowak, S. (2012). *Metodologia badań społecznych (wyd. II)*. Wydawnictwo Naukowe PWN.
- Noymanee, J., Iewwongcharoen, B. i Theeramunkong, T. (2022). Artificial Intelligence Maturity Model for Government Administration and Service. *2022 International Conference on Digital Government Technology and Innovation (DGTi-CON)*, 66–70. <https://doi.org/10.1109/DGTi-CON53875.2022.9849184>
- Nuraliza, H., Pratiwi, O. N. i Lubis, M. (2023). Metaverse Tweet Sentiment Text Classification Using Bert Algorithm and Tuning Hyperparameter. *2023 3rd International Conference on Electronic and Electrical Engineering and Intelligent System (ICE3IS)*, 207–212. Scopus. <https://doi.org/10.1109/ICE3IS59323.2023.10335255>
- Ochoa-Urrego, R.-L. i Peña-Reyes, J.-I. (2021). Digital Maturity Models: A Systematic Literature Review. *Management for Professionals*, 71–85.
- Okoli, C. i Schabram, K. (2010). *A Guide to Conducting a Systematic Literature Review of Information Systems Research* (SSRN Scholarly Paper 1954824). Social Science Research Network. <https://doi.org/10.2139/ssrn.1954824>
- Oliveira, A. C. dei Kaminski, P. C. (2012). A reference model to determine the degree of maturity in the product development process of industrial SMEs. *Technovation*, 32(12), 671–680. <https://doi.org/10.1016/j.technovation.2012.08.001>
- OMG. (2008). *Business Process Maturity Model Version 1.0*. [dostęp 13 marca 2024], Dostępny w Internecie: <https://www.omg.org/spec/BPM/1.0/About-BPM>
- Ooi, K.-B., Tan, G. W.-H., Al-Emran, M., Al-Sharafi, M. A., Capatina, A., Chakraborty, A., Dwivedi, Y. K., Huang, T.-L., Kar, A. K., Lee, V.-H., Loh, X.-M., Micu, A., Mikalef, P., Mogaji, E., Pandey, N., Raman, R., Rana, N. P., Sarker, P., Sharma, A., ... Wong, L.-W. (2023). The Potential of Generative Artificial Intelligence Across Disciplines: Perspectives and Future Directions. *Journal of Computer Information Systems*, 0(0), 1–32. <https://doi.org/10.1080/08874417.2023.2261010>
- Oppenlaender, J., Silvennoinen, J., Paananen, V. i Visuri, A. (2023). Perceptions and Realities of Text-to-Image Generation. *Proceedings of the 26th International Academic Mindtrek Conference*, 279–288. <https://doi.org/10.1145/3616961.3616978>
- Organisciak, P., Acar, S., Dumas, D. i Berthiaume, K. (2023). Beyond semantic distance: Automated scoring of divergent thinking greatly improves with large language models. *Thinking Skills and Creativity*, 49, 101356. <https://doi.org/10.1016/j.tsc.2023.101356>
- Overgoor, G., Chica, M., Rand, W. i Weishampel, A. (2019). Letting the Computers Take Over: Using AI to Solve Marketing Problems. *California Management Review*, 61(4), 156–185. <https://doi.org/10.1177/0008125619859318>
- Ozcan, S., Suloglu, M., Sakar, C. O. i Chatufale, S. (2021). Social media mining for ideation: Identification of sustainable solutions and opinions. *Technovation*, 107, 102322. <https://doi.org/10.1016/j.technovation.2021.102322>
- Ozkaya, I. (2023). The Next Frontier in Software Development: AI-Augmented Software Development Processes. *IEEE Software*, 40(4), 4–9. Scopus. <https://doi.org/10.1109/MS.2023.3278056>
- P. Rutkowski, I. (2011). *Strategie produktu. Koncepcje i metody zarządzania ofertą produktową*. Polskie Wydawnictwo Ekonomiczne.
- Paavel, M., Karjust, K. i Majak, J. (2017). PLM Maturity Model Development and Implementation in SME. *Procedia CIRP*, 63, 651–657. <https://doi.org/10.1016/j.procir.2017.03.144>
- Pacchini, A. P. T., Lucato, W. C., Facchini, F. i Mummolo, G. (2019). The degree of readiness for the implementation of Industry 4.0. *Computers in Industry*, 113, 103125. <https://doi.org/10.1016/j.compind.2019.103125>
- Paliwal, G., Donvir, A., Gujar, P. i Panyam, S. (2024). Low-Code/No-Code Meets GenAI: A New Era in Product Development. *2024 IEEE Eighth Ecuador Technical Chapters Meeting (ETCM)*, 1–9. <https://doi.org/10.1109/ETCM63562.2024.10746160>

- Paula, I. C., Fogliatto, F. S., Echeveste, M. E. S. i Cristofari, C. A. (2010). Product development management maturity assesment: proposal of a new method. *DS 60: Proceedings of DESIGN 2010, the 11th International Design Conference, Dubrovnik, Croatia*, 391–402.
- Păunescu, C. i Acatrinei (Pantea), C. (2012). Managing maturity in process-based improvement organizations: A perspective of the Romanian companies. *Journal of Business Economics and Management*, 13(2), 223–241. <https://doi.org/10.3846/16111699.2011.620149>
- Peffer, K., Tuunanen, T., Gengler, C. E., Rossi, M., Hui, W., Virtanen, V. i Bragge, J. (2006). The Design Science Research Process: A Model for Producing and Presenting Information Systems Research. *DESIST International Conference on Design Science Research in Information Systems and Technology*, 83–106.
- Pels, H. J. i Simons, K. (2008). PLM maturity assessment. *2008 IEEE International Technology Management Conference (ITMC)*, 1–8.
- Peng, X. i Xintong, B. (2022). An effective strategy for multi-modal fake news detection. *Multimedia Tools and Applications*, 81(10), 13799–13822. Scopus. <https://doi.org/10.1007/s11042-022-12290-8>
- Pfenning, P., Eibinger, H. C., Rohleder, C. i Eigner, M. (2020). A Comprehensive Maturity Model for Assessing the Product Lifecycle. W F. Nyffenegger, J. Rios, L. Rivesti A. Bouras (Red.), *Product Lifecycle Management Enabling Smart X* (s. 514–526). Springer International Publishing. https://doi.org/10.1007/978-3-030-62807-9_41
- Pigosso, D. C. A., Rozenfeld, H. i McAloone, T. C. (2013). Ecodesign maturity model: A management framework to support eco-design implementation into manufacturing companies. *Journal of Cleaner Production*, 59, 160–173. <https://doi.org/10.1016/j.jclepro.2013.06.040>
- Piller, F. T., Sroufe, M. i Marion, T. J. (2024). Generative AI, Innovation, and Trust. *Journal of Applied Behavioral Science*, 60(4), 613–622. Scopus. <https://doi.org/10.1177/00218863241285033>
- Pinheiro Cinelli, L., Araújo Marins, M., Barros da Silva, E. A. i Lima Netto, S. (2021). Variational Autoencoder. W L. P. Cinelli, M. A. Marins, E. A. Barros da Silva S. L. Netto (Red.), *Variational Methods for Machine Learning with Applications to Deep Networks* (s. 111–149). Springer International Publishing. https://doi.org/10.1007/978-3-030-70679-1_5
- Pinna, C., Galati, F., Rossi, M., Saidy, C., Harik, R. i Terzi, S. (2018). Effect of product lifecycle management on new product development performances: Evidence from the food industry. *Computers in Industry*, 100, 184–195. <https://doi.org/10.1016/j.compind.2018.03.036>
- Polska Agencja Rozwoju Przedsiębiorczości. (2023). *Raport tematyczny—Zastosowania Sztucznej Inteligencji w gospodarce. Przegląd wybranych inicjatyw i technologii z rekomendacjami dla przedsiębiorców opracowany na potrzeby realizacji usługi infobrokeringu dla Krajowej Inteligentnej Specjalizacji (KIS) opracowanej przez ekspertów Uniwersytetu SWPS na zlecenie Polskiej Agencji Rozwoju Przedsiębiorczości* [dostęp 5 listopada 2023], Dostępny w Internecie: https://www.parp.gov.pl/storage/publications/pdf/Raport-tematyczny_zastosowania_sztucznej_inteligencji_w_gospodarce_20230616.pdf
- Popay, J., Roberts, H., Sowden, A., Petticrew, M., Arai, L., Rodgers, M., Britten, N., Roen, K. i Duffy, S. (2006). *Guidance on the Conduct of Narrative Synthesis in Systematic Reviews A Product from the ESRC Methods Programme* [dostęp 12 grudnia 2023], Dostępny w Internecie: https://www.researchgate.net/publication/233866356_Guidance_on_the_conduct_of_narrative_synthesis_in_systematic_reviews_A_product_from_the_ESRC_Methods_Programme
- Porter, M. E. i Heppelmann, J. E. (2015). How Smart, Connected Products Are Transforming Companies. *Harvard Business Review*.
- Prasad Agrawal, K. (2024). Towards Adoption of Generative AI in Organizational Settings. *Journal of Computer Information Systems*, 64(5), 636–651. <https://doi.org/10.1080/08874417.2023.2240744>
- Przegalińska, A. i Jemielniak, D. (2023). Współpracująca Sztuczna Inteligencja w Zastosowaniach Biznesowych. W Ciszewska-Mlinarić, Mariola (red.). *Przyszłość Jest Dziś. Trendy Kształtujące Biznes, Społeczeństwo I Przywództwo. Akademia Leona Koźmińskiego* (s. 66–66).
- Pustokhina, I. V., Pustokhin, D. A., RH, A., Jayasankar, T., Jeyalakshmi, C., Díaz, V. G. i Shankar, K. (2021). Dynamic customer churn prediction strategy for business intelligence using text analytics with evolutionary optimization algorithms. *Information Processing and Management*, 58(6). Scopus. <https://doi.org/10.1016/j.ipm.2021.102706>
- Radford, A., Kim, J. W., Hallacy, C., Ramesh, A., Goh, G., Agarwal, S., Sastry, G., Askell, A., Mishkin, P., Clark, J., Krueger, G. i Sutskever, I. Learning Transferable Visual Models From Natural Language Supervision. *International Conference on Machine Learning*.

- Rae, A., Alexander, R. i McDermid, J. (2014). Fixing the cracks in the crystal ball: A maturity model for quantitative risk assessment. *Reliability Engineering i System Safety*, 125, 67–81. <https://doi.org/10.1016/j.ress.2013.09.008>
- Rafferty, A. E., Jimmieson, N. L. i Armenakis, A. A. (2013). Change Readiness: A Multilevel Review. *Journal of Management*, 39(1), 110–135. <https://doi.org/10.1177/0149206312457417>
- Rajaram, K. i Tinguely, P. N. (2024). Generative artificial intelligence in small and medium enterprises: Navigating its promises and challenges. *Business Horizons*, 67(5), 629–648. <https://doi.org/10.1016/j.bushor.2024.05.008>
- Rao, S. S., Nahm, A., Shi, Z., Deng, X. i Syamil, A. (1999). Artificial intelligence and expert systems applications in new product development—a survey. *Journal of Intelligent Manufacturing*, 10(3/4), 231–244. <https://doi.org/10.1023/A:1008943723141>
- Raschke, R. i Ingraham, L. (2010). Business Process Maturity's Effect on Performance. *AMCIS 2010 Proceedings*. <https://aisel.aisnet.org/amcis2010/402>
- Redmon, J., Divvala, S., Girshick, R. i Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. <https://doi.org/10.1109/CVPR.2016.91>
- Regenwetter, L., Srivastava, A., Gutfreund, D. i Ahmed, F. (2023). Beyond Statistical Similarity: Rethinking Metrics for Deep Generative Models in Engineering Design. *CAD Computer Aided Design*, 165. Scopus. <https://doi.org/10.1016/j.cad.2023.103609>
- Reid, S. E. i de Brentani, U. (2004). The Fuzzy Front End of New Product Development for Discontinuous Innovations: A Theoretical Model. *Journal of Product Innovation Management*, 21(3), 170–184. <https://doi.org/10.1111/j.0737-6782.2004.00068.x>
- Reifer, D. J. (2000). The CMMI: It's formidable. *Journal of Systems and Software*, 50(2), 97–98. [https://doi.org/10.1016/S0164-1212\(99\)00119-3](https://doi.org/10.1016/S0164-1212(99)00119-3)
- Ren, S., Chan, H.-L. i Ram, P. (2017). A Comparative Study on Fashion Demand Forecasting Models with Multiple Sources of Uncertainty. *Annals of Operations Research*, 257(1–2), 335–355. Scopus. <https://doi.org/10.1007/s10479-016-2204-6>
- Reynolds, D. (2009). Gaussian Mixture Models. W S. Z. Li i A. Jain (Red.) *Encyclopedia of Biometrics* (s. 659–663). Springer. https://doi.org/10.1007/978-0-387-73003-5_196
- Reznikov, R. (2024). Leveraging generative AI: strategic adoption patterns for enterprises. *Modeling the Development of the Economic Systems*, 1, 201–207. <https://doi.org/10.31891/mdes/2024-11-29>
- Ritchie, J., Ormston, R., McNaughton Nicholls, C. i Lewis, J. (2013). *Qualitative Research Practice: A Guide for Social Science Students and Researchers*. SAGE.
- Röglinger, M. i Pöppelbuß, J. (2011). What makes a useful maturity model? A framework for general design principles for maturity models and its demonstration in business process management. *19th European Conference on Information Systems (ECIS)*.
- Röglinger, M., Pöppelbuß, J. i Becker, J. (2012). Maturity models in business process management. *Business Process Management Journal*, 18(2), 328–346. <https://doi.org/10.1108/14637151211225225>
- Rohloff, M. (2009). Case Study and Maturity Model for Business Process Management Implementation. *Proceedings of the 7th International Conference on Business Process Management - Volume 5701*, 128–142.
- Rosemann, M. i De Bruin, T. (2005). Towards a Business Process Management Maturity Model. W F. Rajola, D. Avison, R. Winter, J. Becker, P. Ein-Dor, D. Bartmann, F. Bodendorf, C. Weinhardt J. Kallinikos (Red.), *ECIS 2005 Proceedings of the Thirteenth European Conference on Information Systems* (s. 1–12).
- Rosemann, M. i vom Brocke, J. (2015). The Six Core Elements of Business Process Management. W J. vom Brocke i M. Rosemann (Red.), *Handbook on Business Process Management 1: Introduction, Methods, and Information Systems* (s. 105–122). Springer. https://doi.org/10.1007/978-3-642-45100-3_5
- Rossi, M. i Terzi, S. (2017). CLIMB: Maturity assessment model for design and engineering processes. *International Journal of Product Lifecycle Management*, 10(1), 20–43. <https://doi.org/10.1504/IJPLM.2017.082998>
- Rudnicka, P., Pollak, A. i Chrupała-Pniak, M. (2016). Pojęcie i pomiar gotowości wobec technologii. *Społeczeństwo i Edukacja. Międzynarodowe Studia Humanistyczne*, 2(21), 127–137.
- Russell, S. J. i Norvig, P. (with Davis, E. i Edwards, D.). (2016). *Artificial intelligence: A modern approach* (Third edition, Global edition). Pearson.
- Rutkowski, I. P. (2017). The Method of Measuring the Progression of New Product Development Process Maturity and Introduction into the Market. *Handel Wewnêtrzny*, 5, 319–326.

- Rutter, R. N., Barnes, S. J., Roper, S., Nadeau, J. i Lettice, F. (2021). Social media influencers, product placement and network engagement: Using AI image analysis to empirically test relationships. *Industrial Management and Data Systems*, 121(12), 2387–2410. Scopus. <https://doi.org/10.1108/IMDS-02-2021-0093>
- Saaksvuori, A. i Immonen, A. (Red.). (2008). Deployment of the PLM system. W *Product Lifecycle Management* (s. 67–89). Springer. https://doi.org/10.1007/978-3-540-78172-1_6
- Sai, P. T., Sri, G. H. i Lakshmi Surekha, T. (2023). Extraction of Emojis and Texts to Intensify Opinion Mining using Machine Learning and Deep Learning Models. *2023 2nd International Conference on Automation, Computing and Renewable Systems (ICACRS)*, 829–837. Scopus. <https://doi.org/10.1109/ICACRS58579.2023.10404790>
- Salvato, J. J. i Laplume, A. O. (2020). Agile Stage-Gate Management (ASGM) for physical products. *R and D Management*, 50(5), 631–647. Scopus. <https://doi.org/10.1111/radm.12426>
- Samuelson, P. (2023). Generative AI meets copyright: Ongoing lawsuits could affect everyone who uses generative AI. *Science*, 381(6654), 158–161. Scopus. <https://doi.org/10.1126/science.adi0656>
- Sánchez, P. i Bellogin, A. (2019). Building user profiles based on sequences for content and collaborative filtering. *Information Processing and Management*, 56(1), 192–211. Scopus. <https://doi.org/10.1016/j.ipm.2018.10.003>
- Santu, S. K. K., Sondhi, P. i Zhai, C. (2016). Generative feature language models for mining implicit features from customer reviews. *CIKM '16: Proceedings of the 25th ACM International on Conference on Information and Knowledge Management*, 929–938. Scopus. <https://doi.org/10.1145/2983323.2983729>
- Sarangee, K., Schmidt, J. B., Srinath, P. B. i Wallace, A. (2022). Agile transformation in dynamic, high-technology markets: Drivers, inhibitors, and execution. *Industrial Marketing Management*, 102, 24–34. Scopus. <https://doi.org/10.1016/j.indmarman.2021.12.001>
- Sarno, R., Sinaga, F. i Sungkono, K. R. (2020). Anomaly detection in business processes using process mining and fuzzy association rule learning. *Journal of Big Data*, 7(1). Scopus. <https://doi.org/10.1186/s40537-019-0277-1>
- Sassanelli, C., Rossi, M. i Terzi, S. (2020). Evaluating the smart maturity of manufacturing companies along the product development process to set a PLM project roadmap. *International Journal of Product Lifecycle Management*, 12(3), 185–209. <https://doi.org/10.1504/IJPLM.2020.109789>
- Savino, M. M., Mazza, A. i Ouzrout, Y. (2012). PLM Maturity Model: A Multi-Criteria Assessment in Southern Italy Companies. *International Journal of Operations and Quantitative Management*, 18(3), 159–179.
- Schalkoff, R. J. (1990). *Artificial Intelligence: An Engineering Approach*. McGraw-Hill.
- Schiraldi, M., Marino, M. i Luozzo, S. (2021). Human Excellence Maturity Model: Leveraging Human Resource Management to achieve operational excellence. *International Journal of Business Excellence*. <https://doi.org/10.1504/IJBEX.2021.10043827>
- Schreckenberg, F. i Moroff, N. U. (2021). Developing a maturity-based workflow for the implementation of ML-applications using the example of a demand forecast. *Procedia Manufacturing*, 54, 31–38. <https://doi.org/10.1016/j.promfg.2021.07.006>
- Schultz, K. J., Colby, S. M., Yesiltepe, Y., Nuñez, J. R., McGrady, M. Y. i Renslow, R. S. (2021). Application and assessment of deep learning for the generation of potential NMDA receptor antagonists. *Physical Chemistry Chemical Physics*, 23(2), 1197–1214. Scopus. <https://doi.org/10.1039/d0cp03620j>
- Schumacher, A., Erol, S. i Sihn, W. (2016). A Maturity Model for Assessing Industry 4.0 Readiness and Maturity of Manufacturing Enterprises. *Procedia CIRP*, 52, 161–166. <https://doi.org/10.1016/j.procir.2016.07.040>
- Schuster, T., Waidelich, L. i Volz, R. (2021). Maturity Models for the Assessment of Artificial Intelligence in Small and Medium-Sized Enterprises. W S. Wrycza i J. Maślankowski (Red.), *Digital Transformation* (s. 22–36). Springer International Publishing. https://doi.org/10.1007/978-3-030-85893-3_2
- Schwenzow, J., Hartmann, J., Schikowsky, A. i Heitmann, M. (2021). Understanding videos at scale: How to extract insights for business research. *Journal of Business Research*, 123, 367–379. Scopus. <https://doi.org/10.1016/j.jbusres.2020.09.059>
- Şener, U. i Eren, P. E. (2017). Towards a maturity model for industry 4.0: A systematic literature review and a model proposal. *4th International Management Information Systems Conference 2017: Industry 4.0*.
- Shafiee, S., Haug, A., Shafiee Kristensen, S. i Hvam, L. (2021). Application of design thinking to product-configuration projects. *Journal of Manufacturing Technology Management*, 32(1), 219–241. Scopus. <https://doi.org/10.1108/JMTM-04-2020-0137>
- Shahin, M., Chen, F. F. i Hosseinzadeh, A. (2024). Harnessing customized AI to create voice of customer via GPT3.5. *Advanced Engineering Informatics*, 61, 102462. <https://doi.org/10.1016/j.aei.2024.102462>

- Shahin, M., Chen, F. F., Maghanaki, M. i Hosseinzadeh, A. (2024). Adapting the GPT engine for proactive customer insight extraction in product development. *Manufacturing Letters*, 41, 1376–1385. Scopus. <https://doi.org/10.1016/j.mfglet.2024.09.164>
- Sharma, A. (2005). Collaborative product innovation: Integrating elements of CPI via PLM framework. *Computer-Aided Design*, 37(13), 1425–1434. <https://doi.org/10.1016/j.cad.2005.02.012>
- Shi, Y., Ren, P., Wang, J., Han, B., ValizadehAslani, T., Agbavor, F., Zhang, Y., Hu, M., Zhao, L. i Liang, H. (2023). Leveraging GPT-4 for food effect summarization to enhance product-specific guidance development via iterative prompting. *Journal of Biomedical Informatics*, 148. Scopus. <https://doi.org/10.1016/j.jbi.2023.104533>
- Shin, W., Park, J., Woo, T., Cho, Y., Oh, K. i Song, H. (2022). e-CLIP: Large-Scale Vision-Language Representation Learning in E-commerce. *Proceedings of the 31st ACM International Conference on Information i Knowledge Management*, 3484–3494. <https://doi.org/10.1145/3511808.3557067>
- Shukla, P., James, H., Alter, A. i Lavieri, D. (2017). Machine reengineering: Robots and people working smarter together. *Strategy and Leadership*, 45(6), 50–54. Scopus. <https://doi.org/10.1108/SL-09-2017-0089>
- Sidaoui, K., Jaakkola, M. i Burton, J. (2020). AI feel you: Customer experience assessment via chatbot interviews. *Journal of Service Management*, 31(4), 745–766. Scopus. <https://doi.org/10.1108/JOSM-11-2019-0341>
- Silver, M. S., Markus, M. L. i Beath, C. M. (1995). The Information Technology Interaction Model: A Foundation for the MBA Core Course. *MIS Quarterly*, 19(3), 361–390. <https://doi.org/10.2307/249600>
- Simchi-Levi, D. i Wu, M. X. (2018). Powering retailers' digitization through analytics and automation. *International Journal of Production Research*, 56(1–2), 809–816. Scopus. <https://doi.org/10.1080/00207543.2017.1404161>
- Sira, M. (2023). Generative AI Takes Centre Stage: Revolutionizing Productivity and Reshaping Industries. *System Safety: Human - Technical Facility - Environment*, 5(1), 57–65. Scopus. <https://doi.org/10.2478/czoto-2023-0007>
- SJP PWN. (2024). *Dojrzałość — Definicja, synonimy, przykłady użycia* [dostęp 17 maja 2023], Dostępny w Internecie: <https://sjp.pwn.pl/slowniki/dojrza%C5%82o%C5%9B%C4%87.html>
- Sohn, K., Sung, C. E., Koo, G. i Kwon, O. (2020). Artificial intelligence in the fashion industry: Consumer responses to generative adversarial network (GAN) technology. *International Journal of Retail i Distribution Management*, 49(1), 61–80. <https://doi.org/10.1108/IJRDM-03-2020-0091>
- Sommer, A. F., Hedegaard, C., Dukovska-Popovska, I. i Steger-Jensen, K. (2015). Improved product development performance through agile/stage-gate hybrids: The next-generation stage-gate process? *Research Technology Management*, 58(1), 34–44. Scopus. <https://doi.org/10.5437/08956308X5801236>
- Soni, A. K. (2017). Multi-lingual sentiment analysis of Twitter data by using classification algorithms. *Proceedings of the 2017 2nd IEEE International Conference on Electrical, Computer and Communication Technologies, ICECCT 2017*. Scopus. <https://doi.org/10.1109/ICECCT.2017.8117884>
- Sonntag, M., Mehmman, S., Mehmman, J. i Teuteberg, F. (2024). Development and Evaluation of a Maturity Model for AI Deployment Capability of Manufacturing Companies. *Information Systems Management*, 0(0), 1–31. <https://doi.org/10.1080/10580530.2024.2319041>
- Sousa, D. (2014). Validation in Qualitative Research: General Aspects and Specificities of the Descriptive Phenomenological Method. *Qualitative Research in Psychology*, 11(2), 211 - 227. <https://doi.org/10.1080/14780887.2013.853855>
- Souza, R. F., Wanke, P. i Correa, H. (2020). Demand forecasting in the beauty industry using fuzzy inference systems. *Journal of Modelling in Management*, 15(4), 1389–1417. Scopus. <https://doi.org/10.1108/JM2-03-2019-0050>
- Stark, J. (2016). Product Lifecycle Management. W J. Stark (Red.), *Product Lifecycle Management (Volume 2): The Devil is in the Details* (s. 1–35). Springer International Publishing. https://doi.org/10.1007/978-3-319-24436-5_1
- Su, Z., Yu, S., Chu, J., Yu, M., Gong, J. i Huang, Y. (2021). Requirement-driven recognition method for key design features of products in cloud platform. *Jisuanji Jicheng Zhizao Xitong/Computer Integrated Manufacturing Systems, CIMS*, 27(12), 3604–3613. Scopus. <https://doi.org/10.13196/j.cims.2021.12.021>
- Subahi, A. F. (2023). BERT-Based Approach for Greening Software Requirements Engineering Through Non-Functional Requirements. *IEEE Access*, 11, 103001–103013. Scopus. <https://doi.org/10.1109/ACCESS.2023.3317798>
- Sun, X., Holm, H., Molavipour, S., Gebre, F. G., Pawar, Y., Radnosrati, K. i Shalmashi, S. (2023). Recommendation System for Product Test Failures Using BERT. *Proceedings of the 15th International Joint Conference on Knowledge Discovery, Knowledge Engineering and Knowledge Management*, 1, 206–213. Scopus. <https://doi.org/10.5220/0012160800003598>

- Tai, Y.-M. (2017). Effects of product lifecycle management systems on new product development performance. *Journal of Engineering and Technology Management*, 46, 67–83. <https://doi.org/10.1016/j.jengtecman.2017.06.001>
- Takeda, S., Hama, T., Hsu, H.-H., Piunova, V. A., Zubarev, D., Sanders, D. P., Pitera, J. W., Kogoh, M., Hongo, T., Cheng, Y., Bocanett, W., Nakashika, H., Fujita, A., Tsuchiya, Y., Hino, K., Yano, K., Hirose, S., Toda, H., Orii, Y. i Nakano, D. (2020). Molecular Inverse-Design Platform for Material Industries. *KDD '20: Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery i Data Mining*, 2961–2969. Scopus. <https://doi.org/10.1145/3394486.3403346>
- Tang, H., Gong, J. i Zhang, Y. (2024). Research on the Method of Constructing Product Innovation Demands Graph Based on Competitive Product Reviews. *Lecture Notes in Business Information Processing*, 515 LNBIP, 363–374. Scopus. https://doi.org/10.1007/978-3-031-60264-1_31
- Tarhan, A., Turetken, O. i Reijers, H. A. (2016). Business process maturity models: A systematic literature review. *Information and Software Technology*, 75, 122–134. <https://doi.org/10.1016/j.infsof.2016.01.010>
- Teichert, R. (2019). Digital Transformation Maturity: A Systematic Review of Literature. *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis*, 67(6), 1673–1687.
- Terzi, S., Bouras, A., Dutta, D., Garetti, M. i Kiritsis, D. (2010). Product lifecycle management—From its history to its new role. *International Journal of Product Lifecycle Management*, 4, 360–389. <https://doi.org/10.1504/IJPLM.2010.036489>
- Thordsen, T. i Bick, M. (2020). Towards a holistic digital maturity model. *ICIS 2020 Proceedings*. https://aisel.aisnet.org/icis2020/governance_is/governance_is/5
- Thordsen, T., Murawski, M. i Bick, M. (2020). How to Measure Digitalization? A Critical Evaluation of Digital Maturity Models. W M. Hattingh, M. Matthee, H. Smuts, I. Pappas, Y. K. Dwivedii M. Mäntymäki (Red.), *Responsible Design, Implementation and Use of Information and Communication Technology* (s. 358–369). Springer International Publishing. https://doi.org/10.1007/978-3-030-44999-5_30
- Tkachenko, N. (2023). Opportunities for synthetic data in nature and climate finance. *Frontiers in Artificial Intelligence*, 6. Scopus. <https://doi.org/10.3389/frai.2023.1168749>
- Trott, P. (2017). *Innovation Management and New Product Development*, 6th Edition. Pearson.
- Troya, A., Pillai, R. G., Rivero, C. R., Genc, Z., Kayal, S. i Araci, D. (2021). Aspect-Based Sentiment Analysis of Social Media Data with Pre-Trained Language Models. *NLPIR '21: Proceedings of the 2021 5th International Conference on Natural Language Processing and Information Retrieval*, 8–17. Scopus. <https://doi.org/10.1145/3508230.3508232>
- Tsiliyannis, C. A. (2018). Markov chain modeling and forecasting of product returns in remanufacturing based on stock mean-age. *European Journal of Operational Research*, 271(2), 474–489. Scopus. <https://doi.org/10.1016/j.ejor.2018.05.026>
- Van Bossuyt, D. L., Hale, B., Arlitt, R. i Papakonstantinou, N. (2023). Zero-Trust for the System Design Lifecycle. *Journal of Computing and Information Science in Engineering*, 23(6). Scopus. <https://doi.org/10.1115/1.4062597>
- van de Weerd, I., Bekkers, W. i Brinkkemper, S. (2010). Developing a Maturity Matrix for Software Product Management. W P. Tyrväinen, S. Janseni M. A. Cusumano (Red.), *Software Business* (s. 76–89). Springer. https://doi.org/10.1007/978-3-642-13633-7_7
- Van Looy, A., De Backer, M. i Poels, G. (2011). Defining business process maturity. A journey towards excellence. *Total Quality Management i Business Excellence*, 22(11), 1119–1137. <https://doi.org/10.1080/14783363.2011.624779>
- Van Nguyen, T., Zhou, L., Chong, A. Y. L., Li, B. i Pu, X. (2020). Predicting customer demand for remanufactured products: A data-mining approach. *European Journal of Operational Research*, 281(3), 543–558. Scopus. <https://doi.org/10.1016/j.ejor.2019.08.015>
- van Steenbergen, R. M. i Mes, M. R. K. (2020). Forecasting demand profiles of new products. *Decision Support Systems*, 139. Scopus. <https://doi.org/10.1016/j.dss.2020.113401>
- Vargas, D. S., Pessutto, L. R. C. i Moreira, V. P. (2022). Unsupervised Aspect Term Extraction for Sentiment Analysis through Automatic Labeling. *Proceedings of the 18th International Conference on Web Information Systems and Technologies*, 344–354. Scopus. <https://doi.org/10.5220/0011549100003318>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł. i Polosukhin, I. (2017). Attention is All you Need. *Advances in Neural Information Processing Systems*, 30.
- Verma, S. i Yadav, N. (2021). Past, Present, and Future of Electronic Word of Mouth (EWOM). *Journal of Interactive Marketing*, 53, 111–128. Scopus. <https://doi.org/10.1016/j.intmar.2020.07.001>

- Vezzetti, E., Alemanni, M. i Morelli, B. (2017). New product development (NPD) of 'family business' dealing in the luxury industry: Evaluating maturity stage for implementing a PLM solution. *International Journal of Fashion Design, Technology and Education*, 10(2), 219–229. <https://doi.org/10.1080/17543266.2016.1250286>
- Vial, G. (2019). Understanding digital transformation: A review and a research agenda. *The Journal of Strategic Information Systems*, 28(2), 118–144. <https://doi.org/10.1016/j.jsis.2019.01.003>
- Viswanandhne, S., Saran Kumar, A., Elwin, G. R., Priya, R., Praveen, V. i Priyanka, S. (2019). Improved decision making and enhanced recommendation systems in applications made possible through prescriptive analytics. *International Journal of Scientific and Technology Research*, 8(10), 2231–2233. Scopus.
- Wahsheh, F. R., Moaiad, Y. A., Baker El-Ebiary, Y. A., Amir Fazamin Wan Hamzah, W. M., Yusoff, M. H. i Pandey, B. (2023). *E-Commerce Product Retrieval Using Knowledge from GPT-4*. 2023 International Conference on Computer Science and Emerging Technologies, CSET 2023. Scopus. <https://doi.org/10.1109/CSET58993.2023.10346860>
- Walton, A. L. J., Tomovic, C. L. i Grieves, M. W. (2013). Product Lifecycle Management: Measuring What Is Important – Product Lifecycle Implementation Maturity Model. W A. Bernard, L. Rivesti D. Dutta (Red.), *Product Lifecycle Management for Society* (s. 406–421). Springer. https://doi.org/10.1007/978-3-642-41501-2_41
- Wang, H., Quan, H., Li, J., Chen, M. i Xu, J. (2023). *Long Text Relationship Extraction Method for Complex Productse*. 782–787. Scopus. <https://doi.org/10.1145/3603781.3603920>
- Wang, J. i Liu, Y.-L. (2023). Deep learning-based social media mining for user experience analysis: A case study of smart home products. *Technology in Society*, 73. Scopus. <https://doi.org/10.1016/j.techsoc.2023.102220>
- Wang, X., Anwer, N., Dai, Y. i Liu, A. (2023). ChatGPT for design, manufacturing, and education. *Procedia CIRP*, 119, 7–14. Scopus. <https://doi.org/10.1016/j.procir.2023.04.001>
- Wang, Y., Lu, X. i Tan, Y. (2018). Impact of product attributes on customer satisfaction: An analysis of online reviews for washing machines. *Electronic Commerce Research and Applications*, 29, 1–11. Scopus. <https://doi.org/10.1016/j.elerap.2018.03.003>
- Webster, J. i Watson, R. T. (2002). Analyzing the Past to Prepare for the Future: Writing a Literature Review. *MIS Quarterly*, 26(2), xiii–xxiii.
- Wei, W., Qunli, P., Xuan, L. i Manman, M. (2013). The establishment and application of CMM-IPD. *2013 6th International Conference on Information Management, Innovation Management and Industrial Engineering*, 3, 62–65. <https://doi.org/10.1109/ICIII.2013.6703662>
- Weidemann, D. (2017). Poziom dojrzałości projektowej a narzędzia IT wspomagające zarządzanie projektami. *Handel Wewnętrzny*, 3 (368) Tom II, 136–145.
- Wendler, R. (2012). The maturity of maturity model research: A systematic mapping study. *Information and Software Technology*, 54(12), 1317–1339. <https://doi.org/10.1016/j.infsof.2012.07.007>
- Wieder, C., Le Dain, M.-A. i Blanco, E. (2009). Proposition of a Maturity Grid to Assess NPD Agility. *DS 58-3: Proceedings of ICED 09, the 17th International Conference on Engineering Design*, 3, 85–96.
- Willems, J., Van den Bergh, J. i Deschoolmeester, D. (2012). Analyzing Employee Agreement on Maturity Assessment Tools for Organizations. *Knowledge and Process Management: The Journal of Corporate Transformation*, 19(3), 142–147. <https://doi.org/10.1002/kpm.1389>
- Wolkenfelt, M. R. J. i Situmeang, F. B. I. (2020). Effects of app pricing structures on product evaluations. *Journal of Research in Interactive Marketing*, 14(1), 89–110. Scopus. <https://doi.org/10.1108/JRIM-11-2018-0141>
- Wybrańczyk, K., Polok, G., Naramski, M. i Szromek, A. R. (2018). Przebieg procesu zmian w organizacji – przegląd wybranych koncepcji zmian. *Zeszyty Naukowe. Organizacja i Zarządzanie / Politechnika Śląska*, z. 131. <https://doi.org/10.29119/1641-3466.2018.131.49>
- Xi, Z., Chen, W., Guo, X., He, W., Ding, Y., Hong, B., Zhang, M., Wang, J., Jin, S., Zhou, E., Zheng, R., Fan, X., Wang, X., Xiong, L., Zhou, Y., Wang, W., Jiang, C., Zou, Y., Liu, X., ... Gui, T. (2023). *The Rise and Potential of Large Language Model Based Agents: A Survey* (arXiv:2309.07864). arXiv. <https://doi.org/10.48550/arXiv.2309.07864>
- Yaakobi, A., Goresch, M., Reychav, I., McHaney, R., Zhu, L., Sapozhnikov, H. i Lib, Y. (2019). Organisational project evaluation via machine learning techniques: An exploration. *Journal of Business Analytics*, 2(2), 147–159. Scopus. <https://doi.org/10.1080/2573234X.2019.1675478>
- Yablonsky, S. A. (2019). Multidimensional Data-Driven Artificial Intelligence Innovation. *Technology Innovation Management Review*. EBSCOhost. <https://doi.org/10.22215/timreview/1288>
- Yagci, I. A. i Das, S. (2018). Measuring design-level information quality in online reviews. *Electronic Commerce Research and Applications*, 30, 102–110. Scopus. <https://doi.org/10.1016/j.elerap.2018.05.010>

- Yams, N. B., Richardson, V., Shubina, G. E., Albrecht, S. i Gillblad, D. (2021). Integrated AI and innovation management: The beginning of a beautiful friendship. *Technology Innovation Management Review*, 10(11), 5–18. Scopus. <https://doi.org/10.22215/TIMREVIEW/1399>
- Yang, B., Liu, Y., Liang, Y. i Tang, M. (2019). Exploiting user experience from online customer reviews for product design. *International Journal of Information Management*, 46, 173–186. Scopus. <https://doi.org/10.1016/j.ijinfomgt.2018.12.006>
- Yang, C., Wu, L., Tan, K., Yu, C., Zhou, Y., Tao, Y. i Song, Y. (2021). Online user review analysis for product evaluation and improvement. *Journal of Theoretical and Applied Electronic Commerce Research*, 16(5), 1598–1611. Scopus. <https://doi.org/10.3390/jtaer16050090>
- Yin, C., Guo, Y., Yang, J. i Ren, X. (2018). A new recommendation system on the basis of consumer initiative decision based on an associative classification approach. *Industrial Management and Data Systems*, 118(1), 188–203. Scopus. <https://doi.org/10.1108/IMDS-02-2017-0057>
- Yin, R. K. (2003). *Case Study Research: Design and Methods*. SAGE.
- Yoon, B., Jeong, Y., Lee, K. i Lee, S. (2020). A systematic approach to prioritizing R&D projects based on customer-perceived value using opinion mining. *Technovation*, 98. Scopus. <https://doi.org/10.1016/j.technovation.2020.102164>
- You, X., Ma, J., Zhang, Y., Lv, X. i Han, J. (2020). Vdrf: Sensing the defect information to risk level of vehicle recall based on bert communication model. *Computer Science and Information Systems*, 17(3), 795–817. Scopus. <https://doi.org/10.2298/CSIS190903021Y>
- Younas, M. Z., Malik, M. S. I. i Ignatov, D. I. (2023). Automated defect identification for cell phones using language context, linguistic and smoke-word models. *Expert Systems with Applications*, 227. Scopus. <https://doi.org/10.1016/j.eswa.2023.120236>
- Yu, P. i Zhang, Y. (2024). From feature recognition to image generation: Miao ethnic costume design based on the AIGC paradigm. *Journal of Silk*, 61(3). Scopus. <https://doi.org/10.3969/j.issn.1001-7003.2024.03.001>
- Yuan, C., Marion, T. i Moghaddam, M. (2022). Leveraging End-User Data for Enhanced Design Concept Evaluation: A Multimodal Deep Regression Model. *Journal of Mechanical Design*, 144(2). Scopus. <https://doi.org/10.1115/1.4052366>
- Zan, W., Xiao, Y., Han, Y., Yang, Y., Chen, S., Jiang, X. i Chen, D. (2023). SPM: Structured Pretraining and Matching Architectures for Relevance Modeling in Meituan Search. *CIKM '23: Proceedings of the 32nd ACM International Conference on Information and Knowledge Management*, 4923–4929. Scopus. <https://doi.org/10.1145/3583780.3615500>
- Zhang, C. i Zhang, X. (2023). Multi-target domain-based hierarchical dynamic instance segmentation method for steel defects detection. *Neural Computing and Applications*, 35(10), 7389–7406. Scopus. <https://doi.org/10.1007/s00521-022-07990-z>
- Zhang, H., Zhang, Xiaotang i Song, M. (2021). Deploying AI for New Product Development Success. *Research-Technology Management*, 64(5), 50–57. <https://doi.org/10.1080/08956308.2021.1942646>
- Zhang, M., Fan, B., Zhang, N., Wang, W. i Fan, W. (2021). Mining product innovation ideas from online reviews. *Information Processing and Management*, 58(1). Scopus. <https://doi.org/10.1016/j.ipm.2020.102389>
- Zhang, Q., Wu, D., Lu, J., Liu, F. i Zhang, G. (2017). A cross-domain recommender system with consistent information transfer. *Decision Support Systems*, 104, 49–63. Scopus. <https://doi.org/10.1016/j.dss.2017.10.002>
- Zhang, W., Kang, L., Jiang, Q. i Pei, L. (2018). From buzz to bucks: The impact of social media opinions on the locus of innovation. *Electronic Commerce Research and Applications*, 30, 125–137. Scopus. <https://doi.org/10.1016/j.elerap.2018.04.004>
- Zhang, W., Zhang, J., Zhao, T. i Tong, W. (2023). A color style fusion design method based on generative adversarial networks. *2023 3rd International Conference on Frontiers of Electronics, Information and Computation Technologies (ICFEICT)*, 338–343. Scopus. <https://doi.org/10.1109/ICFEICT59519.2023.00063>
- Zhao, D., Xue, D., Wang, X. i Du, F. (2022). Adaptive vision inspection for multi-type electronic products based on prior knowledge. *Journal of Industrial Information Integration*. Scopus. <https://doi.org/10.1016/j.jii.2021.100283>
- Żemigła, M. (2018). Analiza bibliometryczna badań nad innowacjami w sektorach niskich technologii. *Zeszyty Naukowe. Organizacja i Zarządzanie / Politechnika Śląska*, z. 118 XL Jubileuszowe Śląskie Dni Organizacji Nowoczesność Przemysłu i Usług, 703–711. <https://doi.org/10.29119/1641-3466.2018.118.55>

Spis rysunków i tabel

Spis rysunków

Rysunek 1. Model procedury opracowywania modeli dojrzałości.	57
Rysunek 2. Proces systematycznego przeglądu literatury – modele dojrzałości procesowej.	79
Rysunek 3. Proces systematycznego przeglądu literatury – modele dojrzałości AI.	81
Rysunek 4. Liczba publikacji z bazy Scopus dla wybranych słów kluczowych z obszarów generatywnej sztucznej inteligencji oraz rozwoju nowego produktu z Tabeli 7 w latach 1973 – 2024.	123
Rysunek 5. Liczba publikacji według dziedziny badań (top 10 dziedzin) dla wybranych słów kluczowych z obszarów generatywnej sztucznej inteligencji oraz rozwoju nowego produktu z Tabeli 7.	123
Rysunek 6. Proces systematycznego przeglądu literatury – zastosowania, wyzwania i czynniki sukcesu wdrożeń generatywnej sztucznej inteligencji.	126
Rysunek 7. Podejście badawcze.	164
Rysunek 8. Model CLIMB2-OLIMP – wersja wstępna.	183
Rysunek 9. Model CLIMB2-OLIMP – wersja końcowa.	189
Rysunek 10. Ocena dojrzałości organizacji A modelem CLIMB2-OLIMP.	195
Rysunek 11. Ocena dojrzałości organizacji B modelem CLIMB2-OLIMP.	198
Rysunek 12. Ocena dojrzałości organizacji C modelem CLIMB2-OLIMP.	202
Rysunek 13. Ocena dojrzałości organizacji D modelem CLIMB2-OLIMP.	206

Spis tabel

Tabela 1. Szczegółowe pytania badawcze wraz z uzasadnieniem (PB – pytanie badawcze).	24
Tabela 2. Wybrane podejścia do procesu NPD na przestrzeni dekad (na żółto zaznaczono fazy związane z fuzzy front end, a na zielono fazę związaną z projektowaniem i budowaniem produktu).	33
Tabela 3. Model najlepszych praktyk w rozwoju produktów.	67
Tabela 4. Model referencyjny zarządzania sztuczną inteligencją.	73
Tabela 5. Modele dojrzałości uwzględniające proces rozwoju nowego produktu.	82
Tabela 6. Modele dojrzałości AI.	105
Tabela 7. Słowa kluczowe z obszarów generatywnej sztucznej inteligencji i rozwoju nowego produktu do analizy bibliometrycznej i przeglądu literatury w celu identyfikacji elementów modelu.	122
Tabela 8. Cele wykorzystania rozwiązań generatywnej AI w poszczególnych fazach procesu rozwoju nowego produktu.	131
Tabela 9. Wyzwania i czynniki sukcesu wdrożeń rozwiązań generatywnej AI.	135
Tabela 10. Profil uczestników wywiadów.	145
Tabela 11. Zastosowania, wyzwania i czynniki sukcesu zidentyfikowane na podstawie wywiadów. W nawiasach przedstawiono odniesienia do wywiadów, z których pochodzą dane elementy.	147
Tabela 12. Wymiary modelu dojrzałości procesu rozwoju nowego produktu i ich opisy.	172
Tabela 13. Wymiary modelu dojrzałości w wykorzystaniu rozwiązań generatywnej AI i ich opisy.	176
Tabela 14. Zidentyfikowane najlepsze praktyki razem ze źródłami – wersja wstępna.	178
Tabela 15. Zidentyfikowane najlepsze praktyki przy wykorzystaniu rozwiązań generatywnej AI – wersja końcowa.	187

Tabela 16. Liczba praktyk w danym wymiarze w modelu CLIMB2 dla organizacji A.	196
Tabela 17. Liczba praktyk w danym wymiarze w modelu OLIMP dla organizacji A.	198
Tabela 18. Liczba praktyk w danym wymiarze w modelu CLIMB2 dla organizacji B.	200
Tabela 19. Liczba praktyk w danym wymiarze w modelu OLIMP dla organizacji B.	201
Tabela 20. Liczba praktyk w danym wymiarze w modelu CLIMB2 dla organizacji C.	204
Tabela 21. Liczba praktyk w danym wymiarze w modelu OLIMP dla organizacji C.	205
Tabela 22. Liczba praktyk w danym wymiarze w modelu CLIMB2 dla organizacji D.	208
Tabela 23. Liczba praktyk w danym wymiarze w modelu OLIMP dla organizacji D.	208
Tabela 24. Średnie ważone i wynikowa średnia arytmetyczna w danym wymiarze w modelu CLIMB2 dla wszystkich organizacji (śr. ar. = średnia arytmetyczna).	210
Tabela 25. Średnie ważone i wynikowa średnia arytmetyczna w danym wymiarze w modelu OLIMP dla wszystkich organizacji (śr. ar. = średnia arytmetyczna).	210
Tabela 26. Porównanie organizacji A, B, C oraz D względem wyników pomiaru modelem CLIMB2....	215
Tabela 27. Porównanie organizacji A, B, C oraz D względem wyników pomiaru modelem OLIMP.	215

Spis załączników

Załącznik 1. Scenariusz indywidualnych wywiadów częściowo ustrukturyzowanych.	252
Załącznik 2. Kwestionariusz dla modelu CLIMB2.....	255
Załącznik 3. Kwestionariusz dla modelu OLIMP.....	273
Załącznik 4. Link do repozytorium.	282

Załączniki

Załącznik 1. Scenariusz indywidualnych wywiadów częściowo ustrukturyzowanych.

Sekcja 1: Wprowadzenie (5-10 min)

(MODERATOR przedstawia, jak będzie wyglądał wywiad, zapewnia respondentów o anonimowości oraz wyjaśnia, jak zebrane informacje będą przetwarzane)

1. Proszę opowiedzieć o sobie, w jakiej branży Pan/Pani pracuje i jakie stanowisko zajmuje?
2. Jak długo zajmuje się/zajmował(a) się Pan/Pani zarządzaniem produktem?
3. W jakim stopniu doświadczył(a) Pan/Pani pracy z rozwiązaniami sztucznej inteligencji w swojej karierze?

(MODERATOR decyduje, czy wywiad należy kontynuować; jeśli tak, to nawiązuje w kolejnych częściach do doświadczeń respondenta)

Sekcja 2: Wdrożenie Rozwiązań GenAI/AI (15-35 min)

1. Z jakimi rozwiązaniami GenAI/AI spotkał/a się Pan/Pani w obecnej lub wcześniejszych organizacjach?
 - a. Które z nich dotyczyły procesu rozwoju nowego produktu?
2. *(MODERATOR: jeśli dotyczy)* Czy może Pan/Pani opisać proces wdrażania tych rozwiązań? Jakiego były kluczowe kroki?
3. Jakiego potencjalne aplikacje GenAI/AI są rozważane do wdrożenia w przyszłości w Państwa organizacji przy procesie rozwoju nowego produktu? *(MODERATOR dopytuje o więcej informacji, jeśli respondent przedstawi jakieś zastosowanie)*
4. Jakiego inne potencjalne aplikacje GenAI/AI w procesie rozwoju nowego produktu jest Pan/Pani w stanie sobie wyobrazić, które mogłyby ulepszyć proces rozwoju nowego produktu? *(MODERATOR dopytuje o więcej informacji, jeśli respondent przedstawi jakieś zastosowanie)*
5. Jakiego konkretne aspekty rozwoju nowego produktu są lub mogą być ulepszone dzięki GenAI?

Sekcja 3: Wyzwania i Czynniki Sukcesu (15-35 min)

1. Jakiego wyzwania napotkała Pana/Pani (obecna lub wcześniejsza) organizacja podczas wdrażania rozwiązań GenAI/AI w procesie rozwoju nowego produktu? Czy były różnice między wyzwaniami związanymi z rozwiązaniami AI a GenAI?
2. Jakiego czynniki sukcesu udało się zidentyfikować w procesie wdrażania i eksploatacji GenAI?
3. Czy można opisać metody lub wskaźniki, które Państwa organizacja używa do mierzenia sukcesu wdrożeń AI/GenAI?
4. Jakiego lekcje zostały wyniesione z dotychczasowych doświadczeń z GenAI?

5. Czy wdrożenie GenAI wpłynęło na kulturę organizacyjną lub wymagało zmian w podejściu do pracy?

Sekcja 4: Dodatkowe Komentarze (5-10 min)

1. Czy jest coś, co chciałby Pan/Pani dodać na temat swoich doświadczeń z GenAI w rozwoju nowego produktu, czego nie poruszyliśmy?
2. Jakie wskazówki mógłby Pan/Pani dać innym kierownikom produktu rozważającym wdrożenie GenAI?
3. Czy są jakieś inne technologie lub trendy w rozwoju nowego produktu, które obserwuje Pan/Pani jako szczególnie wpływowe w najbliższej przyszłości?

Załącznik 2. Kwestionariusz dla modelu CLIMB2.

Kwestionariusz został przygotowany w taki sposób, że można za jego pomocą dokonać samooceny organizacji. Kwestionariusz zawiera 107 pytań podzielonych na 8 obszarów. Pod każdą z odpowiedzi jest puste pole do zaznaczenia tej odpowiedzi, która jest najbliższa prawdy, jeśli chodzi o dane pytanie. W przypadku gdy dana praktyka z jakiegoś powodu nie dotyczy organizacji, należy w środkowym polu wpisać „N/D”. Poniżej znajduje się słownik z wybranymi terminami, wspomagający uzupełnienie kwestionariusza:

Frontloading – Nierównomierne rozdzielenie lub przydzielenie zasobów (np. kosztów, wysiłku, itp.), z większym przydziałem na początku procesu rozwoju produktu, w celu uniknięcia wyższych kosztów zmian w późniejszych fazach procesu.

PDM/PLM – Systemy wspierające zarządzanie danymi produktowymi.

KBE – Zastosowanie technologii systemów opartych na wiedzy w dziedzinie projektowania i produkcji. KBE jest zasadniczo inżynierią opartą na modelach wiedzy. Model wiedzy wykorzystuje reprezentację wiedzy do reprezentowania artefaktów procesu projektowania zamiast lub oprócz konwencjonalnych technik programowania i baz danych. W tradycyjnych systemach CAD i systemach przemysłowych każda aplikacja często ma swój własny, nieco inny model. Posiadanie ustandaryzowanego modelu wiedzy ułatwia integrację między różnymi systemami i aplikacjami.

DFX – Pod etykietą „projektowanie pod kątem X” zawiera się szeroki zestaw konkretnych wytycznych projektowych. Każda wytyczna projektowa odnosi się do danej kwestii, która wpływa na cechy produktu. Pod zmienną X może być zawarte wiele różnych koncepcji np. projektowanie pod kątem możliwości produkcyjnych (*Design for Manufacturability*) zapewnia wytwarzanie pojedynczych części lub komponentów, które są oparte na integralnym projekcie w kategoriach inżynierii mechanicznej.

DTC/TCM – Techniki zarządzania kosztami, opisujące systematyczne podejście do kontrolowania kosztów rozwoju i wytwarzania produktu.

LCC/TCO – Całkowity koszt posiadania (TCO) to szacunek finansowy mający pomóc nabywcom i właścicielom określić bezpośrednie i pośrednie koszty produktu lub usługi. Koszt cyklu życia (LCC) to całkowity koszt posiadania w całym okresie życia składnika aktywów.

LCA&E – Metodologia oceny (*Life-Cycle Assessment/Analysis*) lub inżynierska (*Life-Cycle Engineering*) wpływu na środowisko związanego ze wszystkimi etapami cyklu życia produktu.

VA&E – Systematyczna analiza funkcji różnych komponentów i materiałów w celu obniżenia kosztów towarów, produktów i usług przy dopuszczalnej utracie wydajności lub funkcjonalności.

QFD – Metoda przekształcania jakościowych wymagań użytkownika w parametry ilościowe, wdrażania funkcji tworzących jakość oraz wdrażania metod osiągania jakości projektu w podsystemach i częściach składowych, a ostatecznie w określonych elementach procesu wytwarzania.

FMEA/FMECA – Proces przeglądu jak największej liczby komponentów, zespołów i podsystemów w celu zidentyfikowania potencjalnych trybów awarii w produkcie oraz ich przyczyn i skutków.

TRIZ – Teoria łącząca systematyczną metodę rozwiązywania problemów z technikami analizy i prognozowania wywodzącymi się z badania wzorców wynalazczości w światowej literaturze patentowej.

DMU – Przygotowanie cyfrowych modeli, czasem nazywane cyfrowym prototypowaniem. Cyfrowe modele mogą przypominać produkt końcowy, pozwalając na wczesne poprawki, a nie zmiany w późniejszych fazach procesu. Modele mogą być interaktywne, pokazując, w jaki sposób użytkownik będzie wchodził w interakcję z produktem.

CAD/CAE/CAS/CAM – Projektowanie wspomagane komputerowo (CAD) to wykorzystanie komputerów do pomocy w tworzeniu, modyfikacji, analizie lub optymalizacji projektu. CAD jest jednym z elementów całego cyfrowego rozwoju produktu i jako taki jest używany razem z innymi narzędziami, które są zintegrowanymi modułami lub samodzielnymi produktami, takimi jak komputerowe wspomaganie prac inżynierskich (CAE), komputerowe wspomaganie wytwarzania (CAM) czy komputerowe wspomaganie stylizacji (CAS).

FEA/FEM – Metoda elementów skończonych jest popularną metodą numerycznego rozwiązywania równań różniczkowych występujących w inżynierii i modelowaniu matematycznym. Typowe obszary zainteresowania obejmują tradycyjne dziedziny analizy strukturalnej, wymiany ciepła, przepływu płynów, transportu masy i potencjału elektromagnetycznego.

CFD – Gałąź mechaniki płynów, która wykorzystuje analizę numeryczną i struktury danych do analizy i rozwiązywania problemów związanych z przepływem płynów.

CAPP – Wspomagane komputerowo planowanie procesu to wykorzystanie technologii komputerowej do wspomagania planowania procesu części lub produktu w produkcji. CAPP jest łącznikiem między CAD i CAM, ponieważ zapewnia planowanie procesu, który ma być wykorzystany do wytworzenia zaprojektowanej części.

DES – Modelowanie działania systemu, produktu lub usługi jako (dyskretnej) sekwencji zdarzeń w czasie. Każde zdarzenie występuje w określonym momencie i oznacza zmianę stanu systemu. Powszechnym ćwiczeniem w nauce tworzenia symulacji zdarzeń dyskretnych jest modelowanie systemu kolejkowego, takiego jak klienci przybywający np. do sklepu.

VR/AR – Wirtualna rzeczywistość (VR) to symulowane doświadczenie, które wykorzystuje trójwymiarowe wyświetlacze bliskie oku i śledzenie pozycji, aby dać użytkownikowi wciągające poczucie wirtualnego świata. Rzeczywistość rozszerzona (AR) to interaktywne doświadczenie, które łączy świat rzeczywisty i generowane komputerowo treści 3D.

DMS – System zarządzania dokumentami (DMS) to zazwyczaj skomputeryzowany system używany do przechowywania, udostępniania, śledzenia i zarządzania plikami lub dokumentami. Niektóre systemy obejmują śledzenie historii, w którym rejestrowane są różne wersje utworzone i zmodyfikowane przez różnych użytkowników.

WMS – System zarządzania przepływem pracy (WMS) pozwala użytkownikowi definiować różne przepływy pracy dla różnych typów zadań lub procesów. Na przykład w środowisku produkcyjnym dokument projektowy może być automatycznie kierowany od projektanta do dyrektora technicznego, a następnie do inżyniera produkcji.

ERP / SCM / CRM / SRM – Planowanie zasobów przedsiębiorstwa (ERP) to zintegrowane zarządzanie głównymi procesami biznesowymi, często w czasie rzeczywistym i za pośrednictwem oprogramowania i technologii. ERP jest zwykle określane jako kategoria oprogramowania do zarządzania przedsiębiorstwem, które organizacja może wykorzystać do gromadzenia, przechowywania, zarządzania i interpretowania danych z wielu działań biznesowych. Często systemy zarządzania łańcuchem dostaw (SCM), zarządzania relacjami z klientami (CRM) czy dostawcami (SRM) są zintegrowane w ramach systemu ERP.

CMMS – Skomputeryzowany system zarządzania konserwacją to dowolny pakiet oprogramowania, który utrzymuje komputerową bazę danych informacji o operacjach konserwacyjnych organizacji.

OBSZAR – ROLA I WSPÓŁPRACA (7 PYTAŃ)					
PYTANIA	ODPOWIEDZI				
	A	B	C	D	E
Czy w proces rozwoju produktu jest zaangażowany zespół międzyfunkcyjny?	Zespół międzyfunkcyjny nie istnieje w procesie rozwoju produktu.	Zespół międzyfunkcyjny istnieje, ale nie jest regularnie angażowany w proces.	Zespół międzyfunkcyjny jest zaangażowany w większość etapów rozwoju produktu.	Zespół międzyfunkcyjny jest zaangażowany w cały proces rozwoju produktu, ale współpraca nie jest jeszcze optymalna.	Zespół międzyfunkcyjny jest w pełni zintegrowany i intensywnie zaangażowany na wszystkich etapach rozwoju produktu.
		OrgC: X	OrgB: X	OrgA: X, OrgD: X	
Czy wszyscy interesariusze są zaangażowani w zespół projektowy, nawet gdy są rozproszeni globalnie?	Interesariusze nie są zaangażowani w zespół projektowy.	Niektórzy interesariusze są zaangażowani, ale tylko lokalnie.	Większość interesariuszy jest zaangażowana, ale nie zawsze, szczególnie gdy są rozproszeni globalnie.	Interesariusze są angażowani, nawet gdy są rozproszeni globalnie, ale współpraca wymaga jeszcze usprawnień.	Wszyscy interesariusze są w pełni zaangażowani w zespół projektowy, niezależnie od lokalizacji geograficznej.
		OrgC: X	OrgA: X, OrgD: X	OrgB: X	
Czy role i obowiązki każdej osoby są jasno określone?	Role i obowiązki nie są jasno określone.	Role i obowiązki są określone, ale często nie są jasne lub zrozumiałe dla wszystkich.	Większość ról i obowiązków jest jasno określona, ale zdarzają się niejasności.	Role i obowiązki są dobrze określone dla większości członków zespołu.	Role i obowiązki są w pełni jasno określone, dobrze zrozumiane i przestrzegane przez wszystkich członków zespołu.
		OrgA: X, OrgD: X	OrgC: X	OrgB: X	
Czy w projekcie zapewniona jest wysoka elastyczność w wykonywaniu zadań?	Nie ma elastyczności w wykonywaniu zadań, wszystko jest ściśle zdefiniowane.	Elastyczność istnieje, ale jest ograniczona i dotyczy tylko niektórych zadań.	Elastyczność w wykonywaniu zadań jest możliwa, ale nie dotyczy wszystkich członków zespołu.	Elastyczność w wykonywaniu zadań jest zapewniona, ale nie zawsze jest maksymalnie wykorzystywana.	Elastyczność w wykonywaniu zadań jest wysoka i wspiera efektywność zespołu na wszystkich etapach projektu.
		OrgB: X, OrgD: X	OrgA: X	OrgC: X	
Czy kierownicy produktu mają techniczne zaplecze i są w pełni zaangażowani w projekt?	Kierownicy produktu raczej nie mają technicznego zaplecza.	Niektórzy kierownicy produktu mają techniczne zaplecze, ale nie jest to standard.	Istnieje kierownik produktu z technicznym zapleczem na średnim poziomie lub tylko część kierowników produktu ma techniczne zaplecze.	Większość kierowników produktu ma odpowiednie techniczne zaplecze i jest zaangażowana w projekt.	Wszyscy kierownicy produktu mają techniczne zaplecze, potwierdzone doświadczeniem i są w pełni zaangażowani w rozwój.
		OrgD: X	OrgB: X, OrgC: X	OrgA: X	
Czy klient jest w pełni zaangażowany w rozwój produktu?	Klient nie jest angażowany w proces rozwoju produktu.	Klient jest angażowany tylko w wybrane projekty i rzadko w pełni.	Klient jest czasami angażowany w rozwój produktu, ale nie na każdym etapie.	Klient jest regularnie angażowany, ale współpraca nie jest optymalna na wszystkich etapach.	Klient jest w pełni zaangażowany na wszystkich etapach rozwoju produktu, niezależnie od produktu.
		OrgB: X, OrgD: X	OrgA: X, OrgC: X		
Czy doświadczeni projektanci są zaangażowani od najwcześniejszych etapów projektu?	Doświadczeni projektanci nie są angażowani na wczesnych etapach projektów.	Doświadczeni projektanci są angażowani, ale tylko sporadycznie na wczesnych etapach.	Doświadczeni projektanci są angażowani na wczesnych etapach w większości projektów.	Doświadczeni projektanci są angażowani na wczesnych etapach we wszystkich projektach, ale ich udział nie zawsze jest optymalny.	Doświadczeni projektanci są zawsze angażowani od najwcześniejszych etapów projektów i ich wkład jest kluczowy dla sukcesu projektu.
		OrgC: X, OrgD: X		OrgA: X, OrgB: X	
OBSZAR – SZKOLENIE (3 PYTANIA)					
PYTANIA	ODPOWIEDZI				
	A	B	C	D	E

Czy formalne programy wspierają rozwój umiejętności interdyscyplinarnych?	Brak formalnych programów szkoleniowych.	Programy istnieją, ale są ograniczone i sporadyczne.	Programy są wdrażane na średnim poziomie, ale nie obejmują wszystkich pracowników.	Programy są szeroko dostępne i regularnie stosowane.	Programy są systematyczne, dobrze zaplanowane i obejmują wszystkich pracowników.
		OrgA: X, OrgC: X, OrgD: X			OrgB: X
Czy oferowane są indywidualne korepetycje w ramach rozwoju umiejętności?	Indywidualne korepetycje nie są dostępne.	Korepetycje są dostępne w ograniczonym zakresie i dla wybranych pracowników.	Korepetycje są dostępne dla większości pracowników, ale rzadko są zindywidualizowane.	Korepetycje są dobrze rozwinięte, ale nie zawsze dostępne dla wszystkich pracowników.	Korepetycje są standardem, indywidualizowane i dostępne dla wszystkich pracowników.
		OrgA: X, OrgC: X, OrgD: X			OrgB: X
Czy używane są KPI do oceny wyników szkolenia?	KPI nie są stosowane do oceny wyników szkolenia.	KPI są czasami używane, ale nie są regularnie monitorowane.	KPI są stosowane, ale nie wszystkie wyniki szkoleniowe są dokładnie oceniane.	KPI są stosowane systematycznie i obejmują większość programów szkoleniowych.	KPI są używane kompleksowo do oceny wszystkich aspektów szkolenia i regularnie aktualizowane.
		OrgA: X, OrgC: X, OrgD: X		OrgB: X	
OBSZAR – DZIAŁANIA I PRZEPŁYW (8 PYTAŃ)					
PYTANIA	ODPOWIEDZI				
	A	B	C	D	E
W jakim stopniu formalny model rozwoju produktu jest przestrzegany i dokumentowany?	Nie ma formalnego modelu rozwoju produktu.	Model istnieje, ale jest rzadko przestrzegany i dokumentowany.	Model jest przestrzegany, ale nie zawsze dokumentowany.	Model jest przestrzegany i dokumentowany przez większość zespołów.	Model jest standardem, przestrzegany i dokumentowany w każdym projekcie.
	OrgD: X	OrgB: X	OrgC: X		OrgA: X
W jakim stopniu współpraca jest częścią procesu rozwoju produktu?	Współpraca jest minimalna i sporadyczna.	Współpraca istnieje, ale jest ograniczona do kilku kluczowych etapów.	Współpraca obejmuje większość etapów, ale nie jest systematyczna.	Współpraca obejmuje prawie wszystkie etapy rozwoju produktu.	Współpraca jest integralną częścią procesu, obejmującą wszystkie etapy.
			OrgD: X	OrgC: X	OrgA: X, OrgB: X
Jak skutecznie stosowany jest zestaw KPI do pomiaru wydajności rozwoju produktu?	Nie ma zestawu KPI.	Zestaw KPI istnieje, ale jest stosowany sporadycznie.	Zestaw KPI jest stosowany, ale nie we wszystkich fazach.	Zestaw KPI jest stosowany systematycznie w większości projektów.	Zestaw KPI jest stosowany we wszystkich projektach i fazach rozwoju produktu.
		OrgB: X, OrgC: X, OrgD: X	OrgA: X		
Na jakim poziomie frontloading jest wdrażany w procesie rozwoju produktu?	Frontloading nie jest stosowany.	Frontloading jest stosowany tylko w niektórych projektach.	Frontloading jest stosowany w większości projektów, ale nie zawsze w pełni skutecznie.	Frontloading jest skutecznie wdrażany we wszystkich projektach.	Frontloading jest wdrażany na bardzo wysokim poziomie we wszystkich projektach.
	OrgD: X	OrgA: X, OrgB: X, OrgC: X			
W jakim stopniu podejmowane są inicjatywy ciągłego doskonalenia?	Inicjatywy ciągłego doskonalenia nie są podejmowane.	Inicjatywy ciągłego doskonalenia są podejmowane, ale rzadko.	Inicjatywy ciągłego doskonalenia są podejmowane, ale ich wpływ jest ograniczony.	Inicjatywy ciągłego doskonalenia są regularnie podejmowane i mają realny wpływ na proces.	Inicjatywy ciągłego doskonalenia są standardem i mają duży wpływ na efektywność procesów.
		OrgC: X	OrgA: X, OrgD: X	OrgB: X	
Czy organizacja projektuje różne rozwiązania, a gorsze rozwiązania są eliminowane w miarę pojawiania się nowych informacji?	Różne rozwiązania nie są projektowane, proces jest sztywny.	Różne rozwiązania są projektowane, ale eliminowanie słabszych opcji jest niesystematyczne.	Różne rozwiązania są projektowane, ale eliminowanie gorszych opcji odbywa się niesystematycznie.	Różne rozwiązania są projektowane i gorsze rozwiązania są regularnie eliminowane.	Różne rozwiązania są projektowane w każdym projekcie, a gorsze opcje są regularnie i skutecznie eliminowane.

		OrgB: X, OrgC: X	OrgA: X, OrgD: X		
Na ile proces rozwoju produktu koncentruje się na wartości dla klienta?	Proces rozwoju produktu nie koncentruje się na wartości dla klienta.	Proces częściowo koncentruje się na wartości dla klienta, ale nie jest to priorytet.	Proces koncentruje się na wartości dla klienta, ale nie zawsze.	Proces konsekwentnie koncentruje się na wartości dla klienta.	Proces w pełni koncentruje się na maksymalizacji wartości dla klienta.
			OrgA: X, OrgD: X	OrgB: X, OrgC: X	
W jaki sposób wdrażany jest proces analizy konkurencji?	Proces analizy konkurencji nie jest wdrażany.	Proces analizy konkurencji jest wdrażany, ale w ograniczonym zakresie.	Proces analizy konkurencji jest wdrażany systematycznie, ale nie w pełni.	Proces analizy konkurencji jest skutecznie wdrażany we wszystkich projektach.	Proces analizy konkurencji jest kluczowym elementem rozwoju produktu i wdrażany w każdym projekcie.
		OrgA: X, OrgC: X, OrgD: X		OrgB: X	
OBSZAR – PODEJMOWANIE DECYZJI (22 PYTANIA)					
PYTANIA	ODPOWIEDZI				
	A	B	C	D	E
W jaki sposób uwzględniany jest proces projektowania i industrializacji części i modułów?	Proces projektowania i industrializacji nie jest uwzględniany.	Proces projektowania i industrializacji jest sporadycznie uwzględniany.	Proces projektowania i industrializacji jest regularnie uwzględniany, ale nie zawsze systematycznie.	Proces projektowania i industrializacji jest uwzględniany we wszystkich projektach i jest dobrze zorganizowany.	Proces projektowania i industrializacji jest w pełni uwzględniany i zintegrowany na każdym etapie rozwoju produktu.
			OrgA: X, OrgB: X, OrgC: X		OrgD: X
W jakim stopniu uwzględniany jest proces produkcji komponentów i półproduktów?	Proces produkcji komponentów i półproduktów nie jest uwzględniany.	Proces produkcji komponentów i półproduktów jest sporadycznie uwzględniany.	Proces produkcji komponentów i półproduktów jest uwzględniany w większości projektów.	Proces produkcji komponentów i półproduktów jest kluczowym elementem w każdym projekcie.	Proces produkcji komponentów i półproduktów jest priorytetem i uwzględniany w każdym projekcie.
		OrgA: X, OrgC: X	OrgB: X		OrgD: X
Na ile proces montażu komponentów jest brany pod uwagę w rozwoju produktu?	Proces montażu komponentów nie jest uwzględniany.	Proces montażu komponentów jest sporadycznie uwzględniany.	Proces montażu komponentów jest brany pod uwagę, ale nie zawsze zoptymalizowany.	Proces montażu komponentów jest zoptymalizowany i uwzględniany na wszystkich etapach.	Proces montażu komponentów jest kluczowym elementem rozwoju produktu i jest optymalizowany we wszystkich projektach.
		OrgB: X	OrgA: X	OrgC: X	OrgD: X
Jakie znaczenie ma proces testowania i eksperymentowania w rozwoju produktu?	Proces testowania i eksperymentowania nie jest uwzględniany.	Proces testowania i eksperymentowania jest sporadycznie uwzględniany.	Proces testowania i eksperymentowania jest uwzględniany w większości przypadków, ale jego znaczenie jest ograniczone.	Proces testowania i eksperymentowania jest systematycznie stosowany i ma duży wpływ na rozwój produktu.	Proces testowania i eksperymentowania ma największe znaczenie i wpływa na każdą decyzję.
				OrgA: X, OrgB: X, OrgC: X	OrgD: X
Na jakim poziomie uwzględniany jest proces pakowania i magazynowania?	Proces pakowania i magazynowania nie jest uwzględniany.	Proces pakowania i magazynowania jest sporadycznie uwzględniany.	Proces pakowania i magazynowania jest brany pod uwagę, ale nie we wszystkich projektach.	Proces pakowania i magazynowania jest uwzględniany i zoptymalizowany w większości projektów.	Proces pakowania i magazynowania jest kluczowy i w pełni uwzględniany w każdym projekcie.
			OrgA: X, OrgB: X, OrgD: X	OrgC: X	

W jaki sposób uwzględniany jest proces dostawy i dystrybucji?	Proces dostawy i dystrybucji nie jest uwzględniany.	Proces dostawy i dystrybucji jest sporadycznie uwzględniany.	Proces dostawy i dystrybucji jest uwzględniany, ale jego rola nie zawsze jest kluczowa.	Proces dostawy i dystrybucji jest skutecznie uwzględniany w każdym projekcie.	Proces dostawy i dystrybucji jest integralną częścią każdego procesu decyzyjnego.
		OrgA: X	OrgC: X, OrgD: X	OrgB: X	
Na ile proces użytkowania przez klienta jest uwzględniany w rozwoju produktu?	Proces użytkowania przez klienta nie jest uwzględniany.	Proces użytkowania przez klienta jest sporadycznie uwzględniany.	Proces użytkowania przez klienta jest brany pod uwagę, ale nie zawsze monitorowany.	Proces użytkowania przez klienta jest regularnie monitorowany i uwzględniany na wszystkich etapach.	Proces użytkowania przez klienta jest monitorowany na bieżąco i uwzględniany w pełni w decyzjach projektowych.
			OrgA: X, OrgC: X	OrgD: X	OrgB: X
W jaki sposób uwzględniany jest proces konserwacji i usług posprzedażowych?	Proces konserwacji i usług posprzedażowych nie jest uwzględniany.	Proces konserwacji i usług posprzedażowych jest sporadycznie uwzględniany.	Proces konserwacji i usług posprzedażowych jest uwzględniany, ale nie w pełnym zakresie.	Proces konserwacji i usług posprzedażowych jest kluczowy i zawsze brany pod uwagę.	Proces konserwacji i usług posprzedażowych jest priorytetem i brany pod uwagę na wszystkich etapach rozwoju.
		OrgA: X	OrgC: X, OrgD: X	OrgB: X	
Na jakim poziomie uwzględniany jest proces demontażu, recyklingu i utylizacji?	Proces demontażu, recyklingu i utylizacji nie jest uwzględniany.	Proces demontażu, recyklingu i utylizacji jest sporadycznie uwzględniany.	Proces demontażu, recyklingu i utylizacji jest brany pod uwagę, ale jego rola jest ograniczona.	Proces demontażu, recyklingu i utylizacji jest w pełni uwzględniany w każdym projekcie.	Proces demontażu, recyklingu i utylizacji jest zintegrowany z każdym projektem i regularnie monitorowany.
	OrgD: X	OrgA: X, OrgB: X		OrgC: X	
Na ile uwzględniany jest proces kontroli, ponownego użycia, aktualizacji i odnowienia?	Proces kontroli, ponownego użycia, aktualizacji i odnowienia nie jest uwzględniany.	Proces kontroli, ponownego użycia, aktualizacji i odnowienia jest sporadycznie uwzględniany.	Proces kontroli, ponownego użycia, aktualizacji i odnowienia jest uwzględniany, ale nie zawsze priorytetowo.	Proces kontroli, ponownego użycia, aktualizacji i odnowienia jest uwzględniany w większości projektów.	Proces kontroli, ponownego użycia, aktualizacji i odnowienia jest w pełni uwzględniany i zintegrowany z rozwojem produktu.
	OrgD: X	OrgA: X, OrgC: X	OrgB: X		
Jakie znaczenie ma końcowy koszt produktu / cena produktu w procesie decyzyjnym?	Końcowy koszt produktu nie jest uwzględniany.	Końcowy koszt produktu jest uwzględniany, ale w ograniczonym zakresie.	Końcowy koszt produktu jest uwzględniany, ale nie zawsze w pełnym zakresie.	Końcowy koszt produktu jest kluczowym elementem decyzji we wszystkich projektach.	Końcowy koszt produktu / cena produktu jest priorytetem w każdej decyzji projektowej.
			OrgA: X, OrgD: X	OrgB: X, OrgC: X	
W jakim stopniu koszty rozwoju / ROI są uwzględniane w procesie decyzyjnym?	Koszty rozwoju / ROI nie są uwzględniane.	Koszty rozwoju / ROI są sporadycznie brane pod uwagę.	Koszty rozwoju / ROI są regularnie monitorowane, ale nie zawsze uwzględniane w decyzjach.	Koszty rozwoju / ROI są dokładnie monitorowane i uwzględniane w każdym projekcie.	Koszty rozwoju / ROI są kluczowym elementem każdej decyzji i są dokładnie monitorowane.
			OrgA: X, OrgB: X	OrgC: X, OrgD: X	
Jakie znaczenie mają koszty użytkowania i cyklu życia, takie jak konserwacja, usługi, recykling, utylizacja w procesie decyzyjnym?	Koszty użytkowania i cyklu życia nie są brane pod uwagę.	Koszty użytkowania i cyklu życia są uwzględniane sporadycznie.	Koszty użytkowania i cyklu życia są uwzględniane, ale nie w pełnym zakresie.	Koszty użytkowania i cyklu życia są systematycznie uwzględniane i mają duży wpływ na decyzje.	Koszty użytkowania i cyklu życia są integralną częścią procesu decyzyjnego i mają największy wpływ na decyzje.
	OrgD: X	OrgA: X, OrgB: X	OrgC: X		
Jak w procesie decyzyjnym uwzględniany jest czas wprowadzenia na rynek (TTM) i termin dostawy?	TTM i termin dostawy nie są uwzględniane przy podejmowaniu decyzji.	TTM i termin dostawy są uwzględniane, ale tylko w niektórych projektach.	TTM i termin dostawy są brane pod uwagę, ale nie zawsze kluczowe.	TTM i termin dostawy są kluczowymi czynnikami w każdej decyzji projektowej.	TTM i termin dostawy są najważniejszymi kryteriami w każdej decyzji projektowej.
			OrgA: X, OrgC: X		OrgB: X, OrgD: X

Jak liczba różnych produktów wpływa na decyzje projektowe?	Liczba różnych produktów nie jest uwzględniana.	Liczba różnych produktów jest brana pod uwagę w ograniczonym zakresie.	Liczba różnych produktów jest uwzględniana, ale nie zawsze wpływa na ostateczne decyzje.	Liczba różnych produktów jest uwzględniana w większości projektów i ma bezpośredni wpływ na decyzje.	Liczba różnych produktów jest kluczowym czynnikiem w każdej decyzji i wpływa na wybory projektowe.
		OrgC: X	OrgA: X	OrgB: X, OrgD: X	
W jakim stopniu poziom dostosowania produktu jest uwzględniany w procesie decyzyjnym?	Poziom dostosowania produktu nie jest uwzględniany.	Poziom dostosowania produktu jest sporadycznie uwzględniany.	Poziom dostosowania produktu jest brany pod uwagę, ale nie zawsze w pełnym zakresie.	Poziom dostosowania produktu jest monitorowany i uwzględniany w każdym projekcie.	Poziom dostosowania produktu jest w pełni uwzględniany w każdym projekcie i jest priorytetem w decyzjach.
		OrgA: X, OrgC: X	OrgD: X	OrgB: X	
Jak uwzględniany jest poziom innowacyjności w podejmowanych decyzjach?	Poziom innowacyjności nie jest uwzględniany.	Poziom innowacyjności jest uwzględniany, ale nie systematycznie.	Poziom innowacyjności jest monitorowany, ale nie zawsze uwzględniany w pełni.	Poziom innowacyjności jest systematycznie monitorowany i uwzględniany we wszystkich projektach.	Poziom innowacyjności jest monitorowany i ma największy wpływ na każdą decyzję.
	OrgD: X		OrgA: X, OrgC: X		OrgB: X
W jaki sposób wizerunek marki wpływa na podejmowane decyzje?	Wizerunek marki nie jest brany pod uwagę.	Wizerunek marki jest brany pod uwagę w ograniczonym zakresie.	Wizerunek marki jest brany pod uwagę, ale nie we wszystkich decyzjach.	Wizerunek marki jest kluczowym czynnikiem w podejmowaniu decyzji projektowych.	Wizerunek marki jest priorytetem w każdej decyzji projektowej i jest ściśle monitorowany.
			OrgA: X, OrgC: X	OrgB: X, OrgD: X	
Jakie znaczenie ma wydajność funkcjonalna (np. produktywność, prędkość, dokładność, łatwość konserwacji) w decyzjach projektowych?	Wydajność funkcjonalna nie jest brana pod uwagę.	Wydajność funkcjonalna jest sporadycznie brana pod uwagę.	Wydajność funkcjonalna jest uwzględniana, ale nie zawsze w pełnym zakresie.	Wydajność funkcjonalna jest regularnie monitorowana i uwzględniana w każdej decyzji.	Wydajność funkcjonalna jest priorytetem i uwzględniana we wszystkich decyzjach projektowych.
			OrgA: X, OrgC: X, OrgD: X	OrgB: X	
Jak uwzględniana jest wydajność jakościowa (np. solidność, niezawodność, trwałość) w decyzjach projektowych?	Wydajność jakościowa nie jest uwzględniana.	Wydajność jakościowa jest sporadycznie uwzględniana.	Wydajność jakościowa jest uwzględniana, ale nie zawsze jest priorytetem.	Wydajność jakościowa jest kluczowa i uwzględniana we wszystkich decyzjach.	Wydajność jakościowa jest kluczowa i jest najważniejszym elementem każdej decyzji projektowej.
		OrgD: X	OrgA: X, OrgC: X	OrgB: X	
W jaki sposób zgodność z przepisami i normami wpływa na decyzje?	Zgodność z przepisami nie jest uwzględniana.	Zgodność z przepisami jest uwzględniana sporadycznie.	Zgodność z przepisami jest uwzględniana, ale nie zawsze w pełnym zakresie.	Zgodność z przepisami jest regularnie monitorowana i uwzględniana w każdej decyzji.	Zgodność z przepisami i normami jest integralną częścią każdej decyzji i jest regularnie monitorowana.
			OrgB: X, OrgD: X	OrgA: X, OrgC: X	
Jakie inne czynniki, takie jak zrównoważony rozwój środowiskowy, estetyka czy aspekty społeczne, są brane pod uwagę w procesie decyzyjnym?	Inne czynniki, takie jak zrównoważony rozwój, nie są uwzględniane.	Inne czynniki, takie jak zrównoważony rozwój, są czasami uwzględniane, ale nie systematycznie.	Inne czynniki, takie jak zrównoważony rozwój, są uwzględniane, ale nie zawsze priorytetowe.	Inne czynniki, takie jak zrównoważony rozwój, są regularnie uwzględniane i mają duży wpływ na decyzje.	Inne czynniki, takie jak zrównoważony rozwój, są kluczowe i priorytetowe w procesie decyzyjnym.
	OrgD: X		OrgA: X	OrgB: X, OrgC: X	
OBSZAR – PROCESY KM (22 PYTANIA)					
PYTANIA	ODPOWIEDZI				
	A	B	C	D	E

Czy wiedza z poprzednich projektów jest odzyskiwana w trakcie projektu koncepcyjnego?	Wiedza z poprzednich projektów nie jest wykorzystywana na etapie koncepcyjnym.	Wiedza z poprzednich projektów jest sporadycznie wykorzystywana na etapie koncepcyjnym.	Wiedza z poprzednich projektów jest regularnie wykorzystywana na etapie koncepcyjnym, ale nie w pełni systematycznie.	Wiedza z poprzednich projektów jest systematycznie wykorzystywana na etapie koncepcyjnym we wszystkich projektach.	Wiedza z poprzednich projektów jest w pełni zintegrowana z każdym etapem koncepcyjnym i jest priorytetem.
		OrgA: X, OrgC: X	OrgD: X	OrgB: X	
Czy wiedza z poprzednich projektów jest odzyskiwana podczas studium wykonalności?	Wiedza z poprzednich projektów nie jest wykorzystywana podczas studium wykonalności.	Wiedza z poprzednich projektów jest rzadko wykorzystywana podczas studium wykonalności, ale nie jest systematyczna.	Wiedza z poprzednich projektów jest regularnie wykorzystywana podczas studium wykonalności, ale nie zawsze we wszystkich przypadkach.	Wiedza z poprzednich projektów jest uwzględniana podczas studium wykonalności w każdym projekcie.	Wiedza z poprzednich projektów jest wykorzystywana w każdym projekcie i ma kluczowy wpływ na studium wykonalności.
		OrgC: X, OrgD: X	OrgA: X	OrgB: X	
Czy wiedza z poprzednich projektów jest odzyskiwana w trakcie szczegółowego projektowania produktu i jego komponentów?	Wiedza z poprzednich projektów nie jest systematycznie odzyskiwana w trakcie szczegółowego projektowania.	Wiedza z poprzednich projektów jest wykorzystywana, ale niesystematycznie, podczas szczegółowego projektowania.	Wiedza z poprzednich projektów jest systematycznie odzyskiwana, ale nie zawsze w pełnym zakresie.	Wiedza z poprzednich projektów jest systematycznie odzyskiwana i wykorzystywana w trakcie szczegółowego projektowania.	Wiedza z poprzednich projektów jest w pełni odzyskiwana i wykorzystywana podczas szczegółowego projektowania.
		OrgA: X, OrgC: X	OrgD: X	OrgB: X	
Czy wiedza z poprzednich projektów jest odzyskiwana podczas testowania, prototypowania i eksperymentowania?	Wiedza z poprzednich projektów nie jest odzyskiwana podczas testowania, prototypowania i eksperymentowania.	Wiedza z poprzednich projektów jest czasami odzyskiwana podczas testowania i prototypowania.	Wiedza z poprzednich projektów jest regularnie odzyskiwana podczas testowania, prototypowania i eksperymentowania, ale nie zawsze.	Wiedza z poprzednich projektów jest w pełni odzyskiwana podczas testowania i prototypowania.	Odzyskiwanie wiedzy z poprzednich projektów jest integralną częścią testowania, prototypowania i eksperymentowania.
		OrgA: X, OrgC: X	OrgD: X	OrgB: X	
Czy wiedza z poprzednich projektów jest odzyskiwana podczas końcowej weryfikacji projektu?	Wiedza z poprzednich projektów nie jest odzyskiwana podczas końcowej weryfikacji projektu.	Wiedza z poprzednich projektów jest sporadycznie odzyskiwana w końcowej weryfikacji projektu.	Wiedza z poprzednich projektów jest odzyskiwana podczas końcowej weryfikacji, ale nie w pełnym zakresie.	Wiedza z poprzednich projektów jest odzyskiwana podczas końcowej weryfikacji projektu w większości przypadków.	Odzyskiwanie wiedzy z poprzednich projektów jest priorytetem w procesie końcowej weryfikacji projektu.
		OrgA: X, OrgC: X	OrgB: X	OrgD: X	
Czy istnieje formalny plan zarządzania wiedzą wspierający proces rozwoju produktu?	Formalny plan zarządzania wiedzą nie istnieje lub nie jest stosowany.	Formalny plan zarządzania wiedzą istnieje, ale nie jest powszechnie stosowany.	Formalny plan zarządzania wiedzą istnieje i jest wdrażany, ale nie we wszystkich przypadkach.	Formalny plan zarządzania wiedzą jest w pełni wdrażany i wspiera rozwój produktu we wszystkich projektach.	Formalny plan zarządzania wiedzą jest w pełni wdrażany i systematycznie stosowany we wszystkich projektach.
	OrgB: X, OrgC: X, OrgD: X	OrgA: X			
W jakim stopniu firma korzysta z zasobów wiedzy pochodzących z poprzednich projektów?	Firma rzadko korzysta z zasobów wiedzy z poprzednich projektów.	Firma sporadycznie korzysta z zasobów wiedzy z poprzednich projektów.	Firma korzysta z zasobów wiedzy, ale nie wszystkie projekty są objęte systematycznym procesem KM.	Firma regularnie korzysta z zasobów wiedzy z poprzednich projektów i stosuje je w nowych projektach.	Firma w pełni korzysta z zasobów wiedzy z poprzednich projektów i regularnie aktualizuje proces KM.
		OrgA: X	OrgC: X, OrgD: X	OrgB: X	
	Zasady projektowania zdefiniowane przez firmę nie	Zasady projektowania zdefiniowane przez firmę są	Zasady projektowania zdefiniowane przez firmę	Zasady projektowania zdefiniowane przez firmę są	Zasady projektowania zdefiniowane przez firmę są stale

Czy zasady projektowania zdefiniowane przez firmę są stale przeglądane i aktualizowane?	są przeglądane ani aktualizowane.	rzadko przeglądane i aktualizowane.	wspierają proces KM, ale nie zawsze są w pełni aktualizowane.	regularnie aktualizowane i wspierają proces KM.	aktualizowane i w pełni wspierają proces KM.
		OrgA: X, OrgB: X, OrgC: X, OrgD: X			
Czy zasady projektowania zdefiniowane przez zewnętrzne podmioty (np. klientów, dostawców) są stale przeglądane i aktualizowane?	Zewnętrzne zasady projektowania nie są uwzględniane w procesie KM.	Zewnętrzne zasady projektowania są przeglądane i aktualizowane, ale w ograniczonym zakresie.	Zewnętrzne zasady projektowania są przeglądane, ale nie we wszystkich projektach.	Zewnętrzne zasady projektowania są regularnie przeglądane i aktualizowane i mają kluczowy wpływ na niektóre projekty.	Zewnętrzne zasady projektowania są kluczowe i są systematycznie uwzględniane we wszystkich projektach.
		OrgB: X, OrgC: X	OrgA: X	OrgD: X	
Czy zasady projektowania w formie podręczników i standardów są stale przeglądane i aktualizowane?	Podręczniki i standardy nie są przeglądane ani aktualizowane.	Podręczniki i standardy są sporadycznie aktualizowane.	Podręczniki i standardy są przeglądane i aktualizowane, ale nie w pełnym zakresie.	Podręczniki i standardy są regularnie aktualizowane i obejmują większość projektów.	Podręczniki i standardy są stale aktualizowane i w pełni wspierają wszystkie projekty.
	OrgD: X	OrgB: X, OrgC: X	OrgA: X		
Czy istnieją główne źródła wiedzy uwzględniające końcowe koszty produktu?	Nie istnieją źródła wiedzy uwzględniające końcowe koszty produktu.	Istnieją pewne ogólne wytyczne uwzględniające końcowe koszty produktu, ale nie są one konsekwentnie stosowane.	Organizacja posiada formalne źródła wiedzy uwzględniające końcowe koszty produktu, ale ich stosowanie nie jest systematyczne.	Istnieją dobrze zdefiniowane wytyczne uwzględniające końcowe koszty produktu, które są konsekwentnie stosowane.	Organizacja w pełni opiera się na formalnych źródłach wiedzy uwzględniających końcowe koszty produktu, które są stosowane we wszystkich projektach.
		OrgA: X, OrgC: X, OrgD: X	OrgB: X		
Czy istnieją główne źródła wiedzy w procesie rozwoju produktu uwzględniające koszty rozwoju i ROI?	Nie istnieją źródła wiedzy uwzględniające koszty rozwoju i ROI.	Istnieją pewne ogólne wytyczne uwzględniające koszty rozwoju i ROI, ale nie są one konsekwentnie stosowane.	Organizacja posiada formalne źródła wiedzy uwzględniające koszty rozwoju i ROI, ale ich stosowanie nie jest systematyczne.	Istnieją dobrze zdefiniowane wytyczne uwzględniające koszty rozwoju i ROI, które są konsekwentnie stosowane.	Organizacja w pełni opiera się na formalnych źródłach wiedzy uwzględniających koszty rozwoju i ROI, które są stosowane we wszystkich projektach.
		OrgA: X, OrgC: X	OrgB: X, OrgD: X		
Czy istnieją główne źródła wiedzy w procesie rozwoju produktu uwzględniające koszty użytkowania i cyklu życia (np. konserwacja, recykling)?	Nie istnieją źródła wiedzy uwzględniające koszty użytkowania i cyklu życia.	Istnieją pewne ogólne wytyczne uwzględniające koszty użytkowania i cyklu życia, ale nie są one konsekwentnie stosowane.	Organizacja posiada formalne źródła wiedzy uwzględniające koszty użytkowania i cyklu życia, ale ich stosowanie nie jest systematyczne.	Istnieją dobrze zdefiniowane wytyczne uwzględniające koszty użytkowania i cyklu życia, które są konsekwentnie stosowane.	Organizacja w pełni opiera się na formalnych źródłach wiedzy uwzględniających koszty użytkowania i cyklu życia, które są stosowane we wszystkich projektach.
	OrgD: X	OrgA: X, OrgC: X	OrgB: X		
Czy istnieją główne źródła wiedzy w procesie rozwoju produktu uwzględniające czas wprowadzenia produktu na rynek i termin dostawy?	Nie istnieją źródła wiedzy uwzględniające czas wprowadzenia produktu na rynek i termin dostawy.	Istnieją pewne ogólne wytyczne uwzględniające czas wprowadzenia produktu na rynek i termin dostawy, ale nie są one konsekwentnie stosowane.	Organizacja posiada formalne źródła wiedzy uwzględniające czas wprowadzenia produktu na rynek i termin dostawy, ale ich stosowanie nie jest systematyczne.	Istnieją dobrze zdefiniowane wytyczne uwzględniające czas wprowadzenia produktu na rynek i termin dostawy, które są konsekwentnie stosowane.	Organizacja w pełni opiera się na formalnych źródłach wiedzy uwzględniających czas wprowadzenia produktu na rynek i termin dostawy, które są stosowane we wszystkich projektach.
	OrgD: X	OrgA: X, OrgC: X	OrgB: X		
Czy istnieją główne źródła wiedzy w procesie rozwoju produktu	Nie istnieją źródła wiedzy uwzględniające liczbę	Istnieją pewne ogólne wytyczne uwzględniające	Organizacja posiada formalne źródła wiedzy uwzględniające	Istnieją dobrze zdefiniowane wytyczne uwzględniające	Organizacja w pełni opiera się na formalnych źródłach wiedzy

uwzględniające liczbę różnych produktów w ofercie firmy?	różnych produktów w ofercie.	liczbę różnych produktów w ofercie, ale nie są one konsekwentnie stosowane.	liczbę różnych produktów w ofercie, ale ich stosowanie nie jest systematyczne.	liczbę różnych produktów w ofercie, które są konsekwentnie stosowane.	uwzględniających liczbę różnych produktów w ofercie, które są stosowane we wszystkich projektach.
		OrgA: X, OrgC: X, OrgD: X		OrgB: X	
Czy istnieją główne źródła wiedzy w procesie rozwoju produktu uwzględniające poziom dostosowania produktu do potrzeb klientów?	Nie istnieją źródła wiedzy uwzględniające poziom dostosowania produktu.	Istnieją pewne ogólne wytyczne uwzględniające poziom dostosowania produktu, ale nie są one konsekwentnie stosowane.	Organizacja posiada formalne źródła wiedzy uwzględniające poziom dostosowania produktu, ale ich stosowanie nie jest systematyczne.	Istnieją dobrze zdefiniowane wytyczne uwzględniające poziom dostosowania produktu, które są konsekwentnie stosowane.	Organizacja w pełni opiera się na formalnych źródłach wiedzy uwzględniających poziom dostosowania produktu, które są stosowane we wszystkich projektach.
		OrgA: X, OrgC: X	OrgB: X	OrgD: X	
Czy istnieją główne źródła wiedzy w procesie rozwoju produktu uwzględniające poziom innowacyjności produktu?	Nie istnieją źródła wiedzy uwzględniające poziom innowacyjności produktu.	Istnieją pewne ogólne wytyczne uwzględniające poziom innowacyjności produktu, ale nie są one konsekwentnie stosowane.	Organizacja posiada formalne źródła wiedzy uwzględniające poziom innowacyjności produktu, ale ich stosowanie nie jest systematyczne.	Istnieją dobrze zdefiniowane wytyczne uwzględniające poziom innowacyjności produktu, które są konsekwentnie stosowane.	Organizacja w pełni opiera się na formalnych źródłach wiedzy uwzględniających poziom innowacyjności produktu, które są stosowane we wszystkich projektach.
	OrgD: X	OrgA: X, OrgC: X	OrgB: X		
Czy istnieją główne źródła wiedzy w procesie rozwoju produktu uwzględniające wizerunek marki?	Nie istnieją źródła wiedzy uwzględniające wizerunek marki.	Istnieją pewne ogólne wytyczne uwzględniające wizerunek marki, ale nie są one konsekwentnie stosowane.	Organizacja posiada formalne źródła wiedzy uwzględniające wizerunek marki, ale ich stosowanie nie jest systematyczne.	Istnieją dobrze zdefiniowane wytyczne uwzględniające wizerunek marki, które są konsekwentnie stosowane.	Organizacja w pełni opiera się na formalnych źródłach wiedzy uwzględniających wizerunek marki, które są stosowane we wszystkich projektach.
		OrgA: X, OrgC: X, OrgD: X	OrgB: X		
Czy istnieją główne źródła wiedzy w procesie rozwoju produktu uwzględniające wydajność funkcjonalną produktów (np. produktywność, prędkość, dokładność)?	Nie istnieją źródła wiedzy uwzględniające wydajność funkcjonalną produktów.	Istnieją pewne ogólne wytyczne uwzględniające wydajność funkcjonalną produktów, ale nie są one konsekwentnie stosowane.	Organizacja posiada formalne źródła wiedzy uwzględniające wydajność funkcjonalną produktów, ale ich stosowanie nie jest systematyczne.	Istnieją dobrze zdefiniowane wytyczne uwzględniające wydajność funkcjonalną produktów, które są konsekwentnie stosowane.	Organizacja w pełni opiera się na formalnych źródłach wiedzy uwzględniających wydajność funkcjonalną produktów, które są stosowane we wszystkich projektach.
	OrgD: X	OrgA: X, OrgC: X		OrgB: X	
Czy istnieją główne źródła wiedzy w procesie rozwoju produktu uwzględniające wydajność jakościową produktów (np. solidność, niezawodność)?	Nie istnieją źródła wiedzy uwzględniające wydajność jakościową.	Istnieją pewne ogólne wytyczne uwzględniające wydajność jakościową, ale nie są one konsekwentnie stosowane.	Organizacja posiada formalne źródła wiedzy uwzględniające wydajność jakościową, ale ich stosowanie nie jest systematyczne.	Istnieją dobrze zdefiniowane wytyczne uwzględniające wydajność jakościową, które są konsekwentnie stosowane.	Organizacja w pełni opiera się na formalnych źródłach wiedzy uwzględniających wydajność jakościową, które są stosowane we wszystkich projektach.
		OrgA: X, OrgC: X	OrgD: X	OrgB: X	
Czy istnieją główne źródła wiedzy w procesie rozwoju produktu uwzględniające zgodność z przepisami i normami prawnymi?	Nie istnieją źródła wiedzy uwzględniające zgodność z przepisami i normami.	Istnieją pewne ogólne wytyczne uwzględniające zgodność z przepisami i normami, ale nie są one konsekwentnie stosowane.	Organizacja posiada formalne źródła wiedzy uwzględniające zgodność z przepisami i normami, ale ich stosowanie nie jest systematyczne.	Istnieją dobrze zdefiniowane wytyczne uwzględniające zgodność z przepisami i normami, które są konsekwentnie stosowane.	Organizacja w pełni opiera się na formalnych źródłach wiedzy uwzględniających zgodność z przepisami i normami, które są stosowane we wszystkich projektach.
			OrgA: X, OrgD: X	OrgB: X, OrgC: X	

Czy istnieją główne źródła wiedzy w procesie rozwoju produktu uwzględniające inne aspekty (np. zrównoważony rozwój, estetyka, aspekty moralne)?	Nie istnieją źródła wiedzy uwzględniające inne aspekty, takie jak zrównoważony rozwój.	Istnieją pewne ogólne wytyczne uwzględniające inne aspekty, takie jak zrównoważony rozwój, ale nie są one konsekwentnie stosowane.	Organizacja posiada formalne źródła wiedzy uwzględniające inne aspekty, takie jak zrównoważony rozwój, ale ich stosowanie nie jest systematyczne.	Istnieją dobrze zdefiniowane wytyczne uwzględniające inne aspekty, takie jak zrównoważony rozwój, które są konsekwentnie stosowane.	Organizacja w pełni opiera się na formalnych źródłach wiedzy uwzględniających inne aspekty, takie jak zrównoważony rozwój, które są stosowane we wszystkich projektach.
	OrgD: X	OrgA: X, OrgB: X		OrgC: X	
OBSZAR – TECHNIKI KM (11 PYTAŃ)					
PYTANIA	ODPOWIEDZI				
	A	B	C	D	E
W jakim stopniu werbalna komunikacja z kolegami jest wykorzystywana do dzielenia się wiedzą?	Werbalna komunikacja z kolegami rzadko jest wykorzystywana do dzielenia się wiedzą.	Werbalna komunikacja z kolegami jest sporadycznie wykorzystywana do dzielenia się wiedzą.	Werbalna komunikacja z kolegami jest regularnie wykorzystywana do dzielenia się wiedzą, ale nie we wszystkich przypadkach.	Werbalna komunikacja z kolegami jest skutecznie wykorzystywana do dzielenia się wiedzą we wszystkich projektach.	Werbalna komunikacja z kolegami jest priorytetem i wykorzystywana w pełni do dzielenia się wiedzą na wszystkich etapach projektów.
			OrgD: X	OrgA: X, OrgB: X, OrgC: X	
Jak często dokumenty z wnioskami wyciągniętymi z doświadczeń są tworzone i wykorzystywane?	Dokumenty z wnioskami wyciągniętymi z doświadczeń nie są regularnie tworzone ani wykorzystywane.	Dokumenty z wnioskami wyciągniętymi z doświadczeń są czasami tworzone, ale rzadko wykorzystywane.	Dokumenty z wnioskami wyciągniętymi z doświadczeń są regularnie tworzone i wykorzystywane w niektórych projektach.	Dokumenty z wnioskami wyciągniętymi z doświadczeń są systematycznie tworzone i wykorzystywane w większości projektów.	Dokumenty z wnioskami wyciągniętymi z doświadczeń są w pełni zintegrowane z procesem i regularnie wykorzystywane we wszystkich projektach.
		OrgA: X, OrgC: X		OrgB: X, OrgD: X	
Na ile specyfikacje projektowe są używane w procesach zarządzania wiedzą?	Specyfikacje projektowe są rzadko wykorzystywane do udostępniania wiedzy.	Specyfikacje projektowe są czasami używane do udostępniania wiedzy, ale nie systematycznie.	Specyfikacje projektowe są systematycznie wykorzystywane do udostępniania wiedzy, ale nie zawsze we wszystkich projektach.	Specyfikacje projektowe są w pełni wykorzystywane do udostępniania wiedzy we wszystkich projektach.	Specyfikacje projektowe są w pełni i systematycznie wykorzystywane do dzielenia się wiedzą w każdym projekcie.
		OrgA: X, OrgC: X, OrgD: X			OrgB: X
Jak skutecznie kwestionariusze i listy kontrolne wspierają zarządzanie wiedzą?	Kwestionariusze i listy kontrolne nie są skutecznie stosowane w zarządzaniu wiedzą.	Kwestionariusze i listy kontrolne są wykorzystywane, ale ich skuteczność jest ograniczona.	Kwestionariusze i listy kontrolne są skutecznie wykorzystywane, ale nie są priorytetem w zarządzaniu wiedzą.	Kwestionariusze i listy kontrolne są skutecznie stosowane i mają duży wpływ na zarządzanie wiedzą.	Kwestionariusze i listy kontrolne są priorytetem i skutecznie wspierają zarządzanie wiedzą na każdym etapie.
	OrgD: X	OrgA: X, OrgC: X	OrgB: X		
W jakim stopniu pokoje do obrad, plakaty i zarządzanie wizualne są wykorzystywane do dzielenia się wiedzą?	Pokoje do obrad, plakaty i zarządzanie wizualne są rzadko wykorzystywane do dzielenia się wiedzą.	Pokoje do obrad, plakaty i zarządzanie wizualne są sporadycznie wykorzystywane w celu dzielenia się wiedzą.	Pokoje do obrad, plakaty i zarządzanie wizualne są regularnie wykorzystywane do dzielenia się wiedzą, ale nie we wszystkich przypadkach.	Pokoje do obrad, plakaty i zarządzanie wizualne są w pełni wykorzystywane do dzielenia się wiedzą.	Pokoje do obrad, plakaty i zarządzanie wizualne są kluczowym elementem procesu dzielenia się wiedzą i są w pełni wykorzystywane.
	OrgD: X	OrgA: X, OrgC: X		OrgB: X	
Jak często wspólne foldery sieciowe są używane do przechowywania i udostępniania wiedzy?	Wspólne foldery sieciowe są rzadko wykorzystywane do przechowywania i udostępniania wiedzy.	Wspólne foldery sieciowe są czasami wykorzystywane do przechowywania i	Wspólne foldery sieciowe są systematycznie wykorzystywane do przechowywania i	Wspólne foldery sieciowe są regularnie wykorzystywane i wspierają proces zarządzania wiedzą.	Wspólne foldery sieciowe są priorytetem w przechowywaniu i udostępnianiu wiedzy, regularnie aktualizowane i wykorzystywane.

		udostępniania wiedzy, ale nie systematycznie.	udostępniania wiedzy, ale nie zawsze w pełnym zakresie.		
				OrgA: X, OrgC: X	OrgB: X, OrgD: X
Na ile intranet wspiera proces zarządzania wiedzą?	Intranet nie jest regularnie wykorzystywany do wspierania zarządzania wiedzą.	Intranet jest czasami wykorzystywany do wspierania zarządzania wiedzą, ale nie zawsze skutecznie.	Intranet jest regularnie wykorzystywany do wspierania zarządzania wiedzą, ale nie zawsze efektywnie.	Intranet jest skutecznie wykorzystywany do wspierania zarządzania wiedzą we wszystkich projektach.	Intranet jest integralnym narzędziem wspierającym zarządzanie wiedzą i jest wykorzystywany we wszystkich projektach.
		OrgC: X		OrgA: X, OrgD: X	OrgB: X
Jak wykorzystywane są strony internetowe do pracy nad wspólnymi projektami (np. Wiki) w zarządzaniu wiedzą?	Strony internetowe do pracy nad wspólnymi projektami nie są wykorzystywane do zarządzania wiedzą.	Strony internetowe do pracy nad wspólnymi projektami są wykorzystywane w ograniczonym zakresie w zarządzaniu wiedzą.	Strony internetowe do pracy nad wspólnymi projektami są wykorzystywane w większości przypadków, ale nie są jeszcze optymalne.	Strony internetowe do pracy nad wspólnymi projektami są skutecznie wykorzystywane do zarządzania wiedzą.	Strony internetowe do pracy nad wspólnymi projektami są w pełni zintegrowane z procesem zarządzania wiedzą i wspierają projekty na wszystkich etapach.
		OrgC: X	OrgA: X, OrgD: X	OrgB: X	
Jak wykorzystywane są blogi, fora i tablice ogłoszeń w zarządzaniu wiedzą?	Blogi, fora i tablice ogłoszeń nie są wykorzystywane do zarządzania wiedzą.	Blogi, fora i tablice ogłoszeń są wykorzystywane w ograniczonym zakresie w zarządzaniu wiedzą.	Blogi, fora i tablice ogłoszeń są wykorzystywane w większości przypadków, ale nie są jeszcze optymalne.	Blogi, fora i tablice ogłoszeń są skutecznie wykorzystywane do zarządzania wiedzą.	Blogi, fora i tablice ogłoszeń są w pełni zintegrowane z procesem zarządzania wiedzą i wspierają projekty na wszystkich etapach.
	OrgD: X	OrgC: X		OrgA: X	OrgB: X
W jaki sposób systemy PDM/PLM wspierają zarządzanie wiedzą?	Systemy PDM/PLM nie są skutecznie wykorzystywane do zarządzania wiedzą.	Systemy PDM/PLM są sporadycznie wykorzystywane do zarządzania wiedzą, ale nie systematycznie.	Systemy PDM/PLM są skutecznie wykorzystywane w większości projektów, ale nie zawsze w pełnym zakresie.	Systemy PDM/PLM są w pełni zintegrowane z procesem zarządzania wiedzą we wszystkich projektach.	Systemy PDM/PLM są w pełni wdrożone i wspierają zarządzanie wiedzą na każdym etapie rozwoju produktu.
	OrgD: X	OrgB: X, OrgC: X	OrgA: X		
Jakie korzyści wynikają z zastosowania oprogramowania KBE i automatyzacji projektowania w zarządzaniu wiedzą?	Oprogramowanie KBE i automatyzacja projektowania nie są wykorzystywane do zarządzania wiedzą.	Oprogramowanie KBE i automatyzacja projektowania są wykorzystywane w ograniczonym zakresie do zarządzania wiedzą.	Oprogramowanie KBE i automatyzacja projektowania są regularnie wykorzystywane, ale nie zawsze w pełnym zakresie.	Oprogramowanie KBE i automatyzacja projektowania są skutecznie wykorzystywane do zarządzania wiedzą w większości projektów.	Oprogramowanie KBE i automatyzacja projektowania są integralną częścią zarządzania wiedzą i są wykorzystywane we wszystkich projektach.
	OrgD: X	OrgA: X, OrgC: X		OrgB: X	
OBSZAR – METODY (11 PYTAŃ)					
PYTANIA	ODPOWIEDZI				
	A	B	C	D	E
W jakim stopniu zasady modularyzacji i standaryzacji części są wykorzystywane w procesie projektowania?	Zasady modularyzacji i standaryzacji części nie są wykorzystywane w procesie projektowania.	Zasady modularyzacji i standaryzacji części są stosowane sporadycznie.	Zasady modularyzacji i standaryzacji części są regularnie stosowane, ale nie we wszystkich projektach.	Zasady modularyzacji i standaryzacji części są skutecznie stosowane we wszystkich projektach.	Zasady modularyzacji i standaryzacji części są priorytetem i stosowane we wszystkich projektach na każdym etapie.
			OrgA: X, OrgC: X, OrgD: X	OrgB: X	

Na ile projektowanie dla X (DFX) jest stosowane w zakresie wydajności funkcjonalnej (np. projektowanie dla produkcji, dla montażu)?	Projektowanie dla X (DFX) nie jest stosowane w zakresie wydajności funkcjonalnej.	Projektowanie dla X (DFX) jest wykorzystywane, ale w ograniczonym zakresie w zakresie wydajności funkcjonalnej.	Projektowanie dla X (DFX) jest stosowane w większości projektów, ale nie w pełnym zakresie.	Projektowanie dla X (DFX) jest kluczowym elementem w projektach w zakresie wydajności funkcjonalnej.	Projektowanie dla X (DFX) jest integralną częścią każdego projektu i w pełni wspiera wydajność funkcjonalną.
		OrgC: X	OrgB: X, OrgD: X	OrgA: X	
Jak projektowanie dla X (DFX) wspiera wydajność jakościową produktów (np. projektowanie dla Six Sigma, dla utrzymania ruchu)?	Projektowanie dla X (DFX) nie wspiera wydajności jakościowej produktów.	Projektowanie dla X (DFX) wspiera wydajność jakościową produktów, ale nie jest to powszechne.	Projektowanie dla X (DFX) wspiera wydajność jakościową produktów w większości przypadków, ale nie zawsze.	Projektowanie dla X (DFX) w pełni wspiera wydajność jakościową produktów.	Projektowanie dla X (DFX) jest priorytetem i wspiera wydajność jakościową produktów w pełnym zakresie.
		OrgC: X	OrgB: X, OrgD: X	OrgA: X	
W jakim zakresie projektowanie dla X (DFX) uwzględnia inne czynniki odczuwalne przez klientów, takie jak estetyka czy eko-projektowanie?	Projektowanie dla X (DFX) rzadko uwzględnia inne czynniki odczuwalne przez klientów, takie jak estetyka czy eko-projektowanie.	Projektowanie dla X (DFX) czasami uwzględnia inne czynniki, takie jak estetyka czy eko-projektowanie, ale nie systematycznie.	Projektowanie dla X (DFX) regularnie uwzględnia inne czynniki odczuwalne przez klientów, takie jak estetyka czy eko-projektowanie, ale nie zawsze systematycznie.	Projektowanie dla X (DFX) uwzględnia inne czynniki, takie jak estetyka czy eko-projektowanie, w większości projektów.	Projektowanie dla X (DFX) uwzględnia wszystkie czynniki odczuwalne przez klientów, takie jak estetyka i eko-projektowanie i jest kluczowe w każdym projekcie.
	OrgD: X		OrgB: X, OrgC: X	OrgA: X	
Jak efektywnie stosowane jest projektowanie pod kątem kosztów (DTC) i zarządzanie kosztami docelowymi (TCM)?	Projektowanie pod kątem kosztów (DTC) i zarządzanie kosztami docelowymi (TCM) nie jest stosowane.	Projektowanie pod kątem kosztów (DTC) i zarządzanie kosztami docelowymi (TCM) są stosowane, ale rzadko.	Projektowanie pod kątem kosztów (DTC) i zarządzanie kosztami docelowymi (TCM) są stosowane w większości projektów, ale nie zawsze w pełnym zakresie.	Projektowanie pod kątem kosztów (DTC) i zarządzanie kosztami docelowymi (TCM) są skutecznie stosowane we wszystkich projektach.	Projektowanie pod kątem kosztów (DTC) i zarządzanie kosztami docelowymi (TCM) są integralną częścią każdego projektu i mają kluczowy wpływ na koszty.
		OrgB: X, OrgD: X	OrgA: X, OrgC: X		
Na ile analiza kosztów cyklu życia (LCC) i całkowity koszt posiadania (TCO) są uwzględniane w procesie projektowania?	Analiza kosztów cyklu życia (LCC) i całkowity koszt posiadania (TCO) nie są uwzględniane w procesie projektowania.	Analiza kosztów cyklu życia (LCC) i całkowity koszt posiadania (TCO) są sporadycznie uwzględniane w procesie projektowania.	Analiza kosztów cyklu życia (LCC) i całkowity koszt posiadania (TCO) są regularnie uwzględniane, ale nie w pełnym zakresie.	Analiza kosztów cyklu życia (LCC) i całkowity koszt posiadania (TCO) są w pełni uwzględniane w procesie projektowania.	Analiza kosztów cyklu życia (LCC) i całkowity koszt posiadania (TCO) są w pełni uwzględniane na każdym etapie projektowania.
		OrgB: X, OrgD: X		OrgC: X	OrgA: X
Jak skutecznie przeprowadzana jest analiza i inżynieria cyklu życia (LCA&E)?	Analiza i inżynieria cyklu życia (LCA&E) nie jest przeprowadzana.	Analiza i inżynieria cyklu życia (LCA&E) jest przeprowadzana, ale w ograniczonym zakresie.	Analiza i inżynieria cyklu życia (LCA&E) są przeprowadzane w większości projektów, ale nie zawsze.	Analiza i inżynieria cyklu życia (LCA&E) są skutecznie przeprowadzane we wszystkich projektach.	Analiza i inżynieria cyklu życia (LCA&E) są priorytetem w każdym projekcie i są systematycznie przeprowadzane.
		OrgB: X, OrgC: X, OrgD: X	OrgA: X		
Na ile analiza wartości i inżynieria wartości (VA&E) wspierają proces projektowania?	Analiza wartości i inżynieria wartości (VA&E) nie są stosowane w procesie projektowania.	Analiza wartości i inżynieria wartości (VA&E) są stosowane, ale ich wpływ jest ograniczony.	Analiza wartości i inżynieria wartości (VA&E) są stosowane, ale ich wpływ nie jest jeszcze maksymalny.	Analiza wartości i inżynieria wartości (VA&E) są stosowane we wszystkich projektach i mają znaczący wpływ na proces projektowania.	Analiza wartości i inżynieria wartości (VA&E) są kluczowymi elementami każdego projektu i mają znaczący wpływ na ostateczny wynik.
		OrgC: X, OrgD: X		OrgA: X, OrgB: X	

Jak skutecznie wdrażane są funkcje jakości (QFD) w procesie projektowania?	Funkcje jakości (QFD) nie są wdrażane w procesie projektowania.	Funkcje jakości (QFD) są wdrażane, ale nie we wszystkich projektach.	Funkcje jakości (QFD) są wdrażane systematycznie, ale nie zawsze na wszystkich etapach projektów.	Funkcje jakości (QFD) są regularnie wdrażane w każdym projekcie i wspierają cały proces rozwoju.	Funkcje jakości (QFD) są w pełni wdrażane na każdym etapie rozwoju produktów i są integralną częścią procesu.
	OrgD: X		OrgB: X	OrgC: X	OrgA: X
W jakim stopniu analiza ryzyka i awarii (FMEA/FMECA) wspiera proces rozwoju produktów?	Analiza ryzyka i awarii (FMEA/FMECA) nie jest stosowana.	Analiza ryzyka i awarii (FMEA/FMECA) jest stosowana, ale jej skuteczność jest ograniczona.	Analiza ryzyka i awarii (FMEA/FMECA) jest skutecznie stosowana w większości projektów.	Analiza ryzyka i awarii (FMEA/FMECA) jest stosowana systematycznie i ma duży wpływ na rozwój produktów.	Analiza ryzyka i awarii (FMEA/FMECA) jest stosowana we wszystkich projektach i ma kluczowy wpływ na decyzje projektowe.
			OrgC: X	OrgB: X	OrgA: X, OrgD: X
Na ile metody systematycznej innowacji, takie jak TRIZ, są stosowane w procesie projektowania?	Metody systematycznej innowacji, takie jak TRIZ, nie są stosowane.	Metody systematycznej innowacji, takie jak TRIZ, są stosowane w ograniczonym zakresie.	Metody systematycznej innowacji, takie jak TRIZ, są stosowane regularnie, ale nie zawsze w pełnym zakresie.	Metody systematycznej innowacji, takie jak TRIZ, są stosowane w większości projektów i wspierają innowacyjność.	Metody systematycznej innowacji, takie jak TRIZ, są w pełni zintegrowane z procesem projektowania i są stosowane we wszystkich projektach.
	OrgD: X	OrgB: X, OrgC: X	OrgA: X		
OBSZAR – OPROGRAMOWANIE (23 PYTANIA)					
PYTANIA	ODPOWIEDZI				
	A	B	C	D	E
W jakim stopniu automatyzacja biur (arkusze kalkulacyjne, edytory tekstu) wspiera proces rozwoju produktu?	Automatyzacja biur nie jest wykorzystywana do wspierania procesu rozwoju produktu.	Automatyzacja biur jest sporadycznie wykorzystywana do wspierania procesu rozwoju produktu.	Automatyzacja biur jest regularnie wykorzystywana do wspierania procesu rozwoju produktu, ale nie we wszystkich projektach.	Automatyzacja biur jest skutecznie wykorzystywana do wspierania procesu rozwoju produktu we wszystkich projektach.	Automatyzacja biur jest priorytetem i w pełni wspiera proces rozwoju produktu w każdym projekcie.
				OrgA: X, OrgB: X, OrgC: X	OrgD: X
Na ile systemy CAD 2D są stosowane w procesie projektowania?	Systemy CAD 2D nie są powszechnie stosowane w procesie projektowania.	Systemy CAD 2D są stosowane w ograniczonym zakresie w procesie projektowania.	Systemy CAD 2D są stosowane w większości projektów, ale nie zawsze w pełnym zakresie.	Systemy CAD 2D są w pełni stosowane we wszystkich projektach.	Systemy CAD 2D są w pełni zintegrowane z każdym projektem i wspierają cały proces projektowania.
		OrgC: X		OrgA: X	OrgB: X, OrgD: X
Jakie korzyści przynoszą systemy CAD 3D w rozwoju produktów?	Systemy CAD 3D są rzadko wykorzystywane w procesie rozwoju produktów.	Systemy CAD 3D są wykorzystywane, ale nie we wszystkich projektach.	Systemy CAD 3D są wykorzystywane w większości projektów i wspierają rozwój produktów, ale nie zawsze w pełnym zakresie.	Systemy CAD 3D są skutecznie wykorzystywane i wspierają rozwój produktów we wszystkich projektach.	Systemy CAD 3D są priorytetem i wspierają rozwój produktów na każdym etapie.
		OrgC: X	OrgA: X		OrgB: X, OrgD: X
W jakim stopniu cyfrowe modele (DMU) wspierają rozwój produktów?	Cyfrowe modele (DMU) nie są stosowane w procesie rozwoju produktów.	Cyfrowe modele (DMU) są stosowane, ale nie zawsze systematycznie.	Cyfrowe modele (DMU) są regularnie stosowane, ale nie zawsze systematycznie.	Cyfrowe modele (DMU) są stosowane we wszystkich projektach i mają duży wpływ na rozwój produktów.	Cyfrowe modele (DMU) są integralną częścią każdego projektu i w pełni wspierają rozwój produktów.
		OrgA: X, OrgC: X			OrgB: X, OrgD: X

W jakim stopniu komputerowe wspomaganie stylizacji (CAS) jest wykorzystywane w projektach rozwoju produktów?	Komputerowe wspomaganie stylizacji (CAS) nie jest wykorzystywane w projektach.	Komputerowe wspomaganie stylizacji (CAS) jest sporadycznie wykorzystywane w projektach.	Komputerowe wspomaganie stylizacji (CAS) jest stosowane w większości projektów, ale nie zawsze w pełnym zakresie.	Komputerowe wspomaganie stylizacji (CAS) jest skutecznie stosowane we wszystkich projektach.	Komputerowe wspomaganie stylizacji (CAS) jest kluczowym elementem każdego projektu.
	OrgD: X	OrgC: X	OrgA: X, OrgB: X		
Na ile komputerowe wspomaganie inżynierii (CAE) wspiera proces projektowy?	Komputerowe wspomaganie inżynierii (CAE) nie wspiera procesu projektowego.	Komputerowe wspomaganie inżynierii (CAE) jest wykorzystywane, ale nie we wszystkich projektach.	Komputerowe wspomaganie inżynierii (CAE) jest wykorzystywane w większości projektów, ale nie zawsze w pełnym zakresie.	Komputerowe wspomaganie inżynierii (CAE) jest w pełni wykorzystywane we wszystkich projektach.	Komputerowe wspomaganie inżynierii (CAE) jest w pełni zintegrowane z każdym projektem i wspiera cały proces rozwoju.
		OrgC: X	OrgA: X		OrgB: X, OrgD: X
W jakim stopniu metoda analizy elementów skończonych (FEA/FEM) jest wykorzystywana w procesie projektowania?	Metoda analizy elementów skończonych (FEA/FEM) nie jest wykorzystywana do projektowania.	Metoda analizy elementów skończonych (FEA/FEM) jest stosowana, ale nie we wszystkich przypadkach.	Metoda analizy elementów skończonych (FEA/FEM) jest regularnie stosowana, ale nie zawsze w pełnym zakresie.	Metoda analizy elementów skończonych (FEA/FEM) jest skutecznie stosowana we wszystkich projektach.	Metoda analizy elementów skończonych (FEA/FEM) jest priorytetem i stosowana w każdym projekcie.
		OrgA: X	OrgC: N/D		OrgB: X, OrgD: X
W jakim stopniu obliczeniowa dynamika płynów (CFD) jest stosowana w projektach?	Obliczeniowa dynamika płynów (CFD) nie jest stosowana w projektach.	Obliczeniowa dynamika płynów (CFD) jest stosowana, ale nie we wszystkich projektach.	Obliczeniowa dynamika płynów (CFD) jest stosowana w większości projektów, ale nie we wszystkich przypadkach.	Obliczeniowa dynamika płynów (CFD) jest stosowana w pełnym zakresie we wszystkich projektach.	Obliczeniowa dynamika płynów (CFD) jest w pełni stosowana we wszystkich projektach i wspiera procesy rozwojowe.
			OrgA: N/D, OrgB: X, OrgC: N/D		OrgD: X
W jakim stopniu zastosowanie KBE i automatyzacji projektowania wspiera proces projektowania?	KBE i automatyzacja projektowania nie są wykorzystywane w procesie projektowania.	KBE i automatyzacja projektowania są wykorzystywane, ale ich zastosowanie jest ograniczone.	KBE i automatyzacja projektowania są regularnie wykorzystywane, ale nie we wszystkich projektach.	KBE i automatyzacja projektowania są skutecznie wykorzystywane w większości projektów.	KBE i automatyzacja projektowania są priorytetem i są stosowane w pełnym zakresie w każdym projekcie.
	OrgD: X	OrgA: X	OrgC: N/D	OrgB: X	
Na ile komputerowe wspomaganie produkcji (CAM) jest używane w procesie wytwarzania?	Komputerowe wspomaganie produkcji (CAM) nie jest wykorzystywane w procesie wytwarzania.	Komputerowe wspomaganie produkcji (CAM) jest stosowane, ale nie zawsze systematycznie.	Komputerowe wspomaganie produkcji (CAM) jest stosowane w większości projektów, ale nie zawsze systematycznie.	Komputerowe wspomaganie produkcji (CAM) jest stosowane systematycznie we wszystkich projektach.	Komputerowe wspomaganie produkcji (CAM) jest stosowane w pełnym zakresie we wszystkich projektach.
		OrgC: X	OrgA: X, OrgB: X, OrgD: X		
W jakim zakresie komputerowe planowanie procesów (CAPP)/cyfrowa produkcja wspiera proces rozwoju produktu?	Komputerowe planowanie procesów (CAPP) nie wspiera procesu rozwoju produktu.	Komputerowe planowanie procesów (CAPP) jest sporadycznie stosowane w procesie rozwoju produktu.	Komputerowe planowanie procesów (CAPP) jest stosowane regularnie, ale nie we wszystkich projektach.	Komputerowe planowanie procesów (CAPP) jest w pełni stosowane w procesie rozwoju produktu.	Komputerowe planowanie procesów (CAPP) jest integralną częścią każdego procesu rozwoju produktu.
		OrgC: X, OrgD: X	OrgB: X	OrgA: X	
Na ile symulacja zdarzeń dyskretnych (DES) wspiera rozwój produktu?	Symulacja zdarzeń dyskretnych (DES) nie wspiera rozwoju produktów.	Symulacja zdarzeń dyskretnych (DES) jest stosowana, ale nie w pełnym zakresie.	Symulacja zdarzeń dyskretnych (DES) jest stosowana w większości projektów, ale nie zawsze systematycznie.	Symulacja zdarzeń dyskretnych (DES) jest stosowana we wszystkich projektach i wspiera procesy rozwoju produktów.	Symulacja zdarzeń dyskretnych (DES) jest priorytetem i w pełni wspiera wszystkie procesy rozwoju produktów.

		OrgC: X	OrgA: N/D, OrgD: N/D	OrgB: X	
W jakim stopniu wykorzystywane są rzeczywistość wirtualna (VR) i rozszerzona (AR) w rozwoju produktu?	Rzeczywistość wirtualna (VR) i rozszerzona (AR) nie są wykorzystywane w rozwoju produktu.	Rzeczywistość wirtualna (VR) i rozszerzona (AR) są wykorzystywane, ale nie we wszystkich projektach.	Rzeczywistość wirtualna (VR) i rozszerzona (AR) są wykorzystywane w większości projektów, ale nie zawsze w pełnym zakresie.	Rzeczywistość wirtualna (VR) i rozszerzona (AR) są skutecznie wykorzystywane we wszystkich projektach.	Rzeczywistość wirtualna (VR) i rozszerzona (AR) są w pełni zintegrowane z każdym projektem i mają kluczowy wpływ na rozwój produktów.
		OrgA: X, OrgB: X	OrgC: N/D, OrgD: N/D		
W jaki sposób systemy PDM/PLM wspierają zarządzanie danymi produktu?	Systemy PDM/PLM nie wspierają zarządzania danymi produktu.	Systemy PDM/PLM są stosowane, ale nie systematycznie we wszystkich projektach.	Systemy PDM/PLM są regularnie stosowane w większości projektów, ale nie zawsze w pełnym zakresie.	Systemy PDM/PLM są w pełni stosowane we wszystkich projektach i wspierają zarządzanie danymi produktu.	Systemy PDM/PLM są w pełni stosowane we wszystkich projektach i są kluczowym narzędziem zarządzania danymi produktu.
		OrgB: X, OrgC: X	OrgA: X, OrgD: X		
Jakie korzyści przynoszą systemy zarządzania dokumentami (DMS) w projektach rozwoju produktów?	Systemy zarządzania dokumentami (DMS) nie są wykorzystywane w projektach.	Systemy zarządzania dokumentami (DMS) są wykorzystywane, ale nie zawsze w pełnym zakresie.	Systemy zarządzania dokumentami (DMS) są stosowane regularnie, ale nie we wszystkich projektach.	Systemy zarządzania dokumentami (DMS) są w pełni stosowane we wszystkich projektach.	Systemy zarządzania dokumentami (DMS) są integralną częścią każdego projektu i w pełni wspierają zarządzanie dokumentacją.
		OrgC: X, OrgD: X	OrgB: X	OrgA: X	
Na ile system zarządzania przepływem pracy (WMS) wspiera zarządzanie projektami rozwoju produktów?	System zarządzania przepływem pracy (WMS) nie wspiera zarządzania projektami.	System zarządzania przepływem pracy (WMS) jest sporadycznie stosowany w projektach.	System zarządzania przepływem pracy (WMS) jest stosowany regularnie, ale nie zawsze w pełnym zakresie.	System zarządzania przepływem pracy (WMS) jest skutecznie stosowany we wszystkich projektach.	System zarządzania przepływem pracy (WMS) jest w pełni stosowany w każdym projekcie.
		OrgC: X, OrgD: X	OrgA: X, OrgB: X		
W jakim stopniu planowanie zasobów przedsiębiorstwa (ERP) jest stosowane w procesach rozwoju produktów?	Planowanie zasobów przedsiębiorstwa (ERP) nie jest stosowane w procesach rozwoju produktów.	Planowanie zasobów przedsiębiorstwa (ERP) jest sporadycznie stosowane w projektach.	Planowanie zasobów przedsiębiorstwa (ERP) jest stosowane regularnie, ale nie we wszystkich projektach.	Planowanie zasobów przedsiębiorstwa (ERP) jest stosowane we wszystkich projektach i wspiera procesy rozwoju produktów.	Planowanie zasobów przedsiębiorstwa (ERP) jest kluczowym narzędziem wspierającym procesy rozwoju produktów i jest stosowane w pełnym zakresie.
		OrgB: X, OrgC: X	OrgA: X		OrgD: X
Jak zarządzanie łańcuchem dostaw (SCM) wspiera rozwój produktu?	Zarządzanie łańcuchem dostaw (SCM) nie wspiera procesu rozwoju produktu.	Zarządzanie łańcuchem dostaw (SCM) wspiera proces rozwoju produktu, ale nie zawsze systematycznie.	Zarządzanie łańcuchem dostaw (SCM) wspiera proces rozwoju produktu, ale nie zawsze w pełnym zakresie.	Zarządzanie łańcuchem dostaw (SCM) wspiera rozwój produktu we wszystkich projektach.	Zarządzanie łańcuchem dostaw (SCM) jest integralną częścią każdego projektu i w pełni wspiera procesy rozwojowe.
		OrgB: X, OrgC: X		OrgA: X, OrgD: X	
W jakim zakresie systemy zarządzania relacjami z klientami (CRM) wpływają na rozwój produktu?	Systemy zarządzania relacjami z klientami (CRM) nie wpływają na rozwój produktu.	Systemy zarządzania relacjami z klientami (CRM) mają ograniczony wpływ na rozwój produktu.	Systemy zarządzania relacjami z klientami (CRM) są regularnie wykorzystywane, ale nie we wszystkich projektach.	Systemy zarządzania relacjami z klientami (CRM) są w pełni wykorzystywane we wszystkich projektach.	Systemy zarządzania relacjami z klientami (CRM) są kluczowe dla rozwoju produktów i są stosowane w pełnym zakresie.
	OrgD: X	OrgA: X, OrgC: X	OrgB: X		
Jak systemy zarządzania relacjami z dostawcami (SRM)	Systemy zarządzania relacjami z dostawcami	Systemy zarządzania relacjami z dostawcami	Systemy zarządzania relacjami z dostawcami (SRM) są stosowane	Systemy zarządzania relacjami z dostawcami	Systemy zarządzania relacjami z dostawcami (SRM) są

wspierają proces rozwoju produktów?	(SRM) nie wspierają procesu rozwoju produktów.	(SRM) są stosowane, ale nie we wszystkich przypadkach.	regularnie, ale nie we wszystkich projektach.	(SRM) są skutecznie stosowane we wszystkich projektach.	priorytetem i stosowane w pełnym zakresie w każdym projekcie.
		OrgA: X, OrgB: X, OrgC: X	OrgD: X		
Na ile skomputeryzowany system zarządzania konserwacją (CMMS) jest stosowany w procesach rozwoju produktów?	Skomputeryzowany system zarządzania konserwacją (CMMS) nie jest stosowany w procesach rozwoju produktów.	Skomputeryzowany system zarządzania konserwacją (CMMS) jest stosowany, ale w ograniczonym zakresie.	Skomputeryzowany system zarządzania konserwacją (CMMS) jest stosowany regularnie, ale nie zawsze w pełnym zakresie.	Skomputeryzowany system zarządzania konserwacją (CMMS) jest stosowany we wszystkich projektach.	Skomputeryzowany system zarządzania konserwacją (CMMS) jest integralną częścią każdego projektu i wspiera wszystkie procesy rozwoju produktów.
		OrgB: X	OrgA: N/D, OrgC: N/D, OrgD: N/D		
W jakim stopniu oprogramowanie do analizy cyklu życia (LCA) wspiera rozwój produktu?	Oprogramowanie do analizy cyklu życia (LCA) nie jest stosowane w procesach rozwoju produktów.	Oprogramowanie do analizy cyklu życia (LCA) jest stosowane, ale w ograniczonym zakresie.	Oprogramowanie do analizy cyklu życia (LCA) jest stosowane regularnie, ale nie zawsze w pełnym zakresie.	Oprogramowanie do analizy cyklu życia (LCA) jest stosowane we wszystkich projektach.	Oprogramowanie do analizy cyklu życia (LCA) jest integralną częścią każdego projektu i wspiera wszystkie procesy rozwoju produktów.
		OrgA: X, OrgB: X, OrgC: X, OrgD: X			
W jakim stopniu systemy zarządzania projektami oprogramowania wpływają na rozwój produktu?	Systemy zarządzania projektami oprogramowania nie wpływają na rozwój produktu.	Systemy zarządzania projektami oprogramowania mają ograniczony wpływ na rozwój produktu.	Systemy zarządzania projektami oprogramowania są regularnie wykorzystywane, ale nie we wszystkich projektach.	Systemy zarządzania projektami oprogramowania są w pełni wykorzystywane we wszystkich projektach.	Systemy zarządzania projektami oprogramowania są kluczowe dla rozwoju produktów i są stosowane w pełnym zakresie.
		OrgA: X, OrgC: X	OrgB: X, OrgD: X		

Załącznik 3. Kwestionariusz dla modelu OLIMP.

Kwestionariusz został przygotowany w taki sposób, że można za jego pomocą dokonać samooceny organizacji. Kwestionariusz zawiera 64 pytania podzielone na 8 obszarów. Pod każdą z odpowiedzi jest puste pole do zaznaczenia tej odpowiedzi, która jest najbliższa prawdy, jeśli chodzi o dane pytanie.

OBSZAR – TECHNOLOGIE I INFRASTRUKTURA (10 PYTAŃ)					
PYTANIA	ODPOWIEDZI				
	A	B	C	D	E
Czy Twoja organizacja posiada skalowalną infrastrukturę IT wspierającą generatywną AI (GenAI)?	Brak skalowalnej infrastruktury, brak uwzględnienia GenAI	Podstawowa infrastruktura, ale nie skalowalna	Infrastruktura istnieje, ale skalowalność jest ograniczona	Skalowalna infrastruktura, ograniczona integracja GenAI	W pełni skalowalna infrastruktura zoptymalizowana pod GenAI
		OrgD: X	OrgA: X, OrgB: X, OrgC: X		
Czy technologia generatywnej AI jest zintegrowana z innymi systemami (np. ERP, CRM)?	Brak integracji generatywnej AI z innymi systemami	Podstawowa integracja w jednym procesie lub systemie	Częściowa integracja z kluczowymi systemami (np. ERP)	Integracja z większością systemów, z pewnymi lukami	W pełni zintegrowana generatywna AI we wszystkich głównych systemach
	OrgB: X, OrgC: X, OrgD: X	OrgA: X			
Na ile zautomatyzowane jest wdrażanie modeli generatywnej AI?	Brak automatyzacji, ręczne wdrażanie	Podstawowa automatyzacja małych modeli	Częściowa automatyzacja z pewną ingerencją człowieka	W dużej mierze zautomatyzowane, sporadyczna ingerencja	W pełni zautomatyzowane wdrażanie modeli generatywnej AI
	OrgA: X, OrgB: X, OrgC: X, OrgD: X				
Czy organizacja korzysta z chmury do przechowywania i przetwarzania danych dla generatywnej AI?	Brak wykorzystania chmury dla GenAI, dane przechowywane lokalnie	Minimalne korzystanie z chmury do przechowywania danych	Częściowa adopcja chmury do przechowywania i przetwarzania danych	Większość danych dla GenAI przechowywana i przetwarzana w chmurze	Pełna adopcja chmury dla wszystkich działań związanych z GenAI
	OrgB: X	OrgC: X	OrgA: X, OrgD: X		
Czy organizacja korzysta z narzędzi do zarządzania cyklem życia modeli generatywnej AI?	Brak narzędzi do zarządzania cyklem życia modeli GenAI	Podstawowe narzędzia, ale niedostatecznie wykorzystywane	Niektóre narzędzia wykorzystywane, brak standaryzacji	Standaryzowane narzędzia dla większości procesów AI	W pełni wdrożone i zoptymalizowane narzędzia do zarządzania cyklem życia modeli AI
	OrgB: X, OrgC: X, OrgD: X	OrgA: X			
Czy infrastruktura organizacji jest przygotowana do obsługi dużych zbiorów danych dla generatywnej AI?	Nie jest w stanie obsłużyć dużych zbiorów danych	Podstawowa infrastruktura z ograniczoną pojemnością	Infrastruktura obsługuje umiarkowanie duże zbiory danych	Infrastruktura obsługuje większość dużych zbiorów danych	Zoptymalizowana infrastruktura do obsługi ogromnych zbiorów danych
	OrgD: X	OrgB: X	OrgA: X, OrgC: X		
Czy organizacja jest zdolna do przetwarzania danych w czasie rzeczywistym dla generatywnej AI?	Brak przetwarzania danych w czasie rzeczywistym	Podstawowe przetwarzanie danych w czasie rzeczywistym	Przetwarzanie danych w czasie rzeczywistym dla niektórych zadań	Przetwarzanie danych w czasie rzeczywistym, z niewielkimi opóźnieniami	W pełni zoptymalizowane przetwarzanie danych w czasie rzeczywistym dla wszystkich zadań GenAI
	OrgD: X	OrgB: X	OrgA: X, OrgC: X		
Czy Twoja organizacja posiada moc obliczeniową niezbędną do wdrażania i utrzymania modeli generatywnej AI?	Brak mocy obliczeniowej dla wdrożenia i utrzymania modeli GenAI	Podstawowa moc obliczeniowa, wystarczająca dla małych modeli	Umiarkowana moc obliczeniowa, wystarczająca dla niektórych modeli	Wysoka moc obliczeniowa, wystarczająca dla większości aplikacji GenAI	Zaawansowana moc obliczeniowa zoptymalizowana pod potrzeby GenAI
		OrgB: X, OrgD: X	OrgA: X, OrgC: X		

Czy w codziennej pracy wykorzystywane są wewnętrzne lub zewnętrzne narzędzia generatywnej AI (np. ChatGPT, MS Copilot)?	Brak narzędzi GenAI w codziennych zadaniach	Podstawowe wykorzystanie narzędzi GenAI do wybranych zadań	Niektóre narzędzia GenAI wykorzystywane, ale nie powszechnie	Narzędzia GenAI wykorzystywane w większości działów do różnych zadań	W pełni zintegrowane narzędzia GenAI w codziennej pracy w całej organizacji
		OrgC: X	OrgA: X, OrgB: X	OrgD: X	
Jak skalowalne są rozwiązania generatywnej AI w Twojej organizacji?	Brak skalowalności rozwiązań GenAI	Ograniczona skalowalność	Umiarkowana skalowalność dla niektórych rozwiązań	Większość rozwiązań GenAI jest skalowalna	W pełni skalowalne rozwiązania GenAI wdrożone w całej organizacji
	OrgD: X	OrgC: X	OrgA: X, OrgB: X		
OBSZAR – DANE (9 PYTAŃ)					
PYTANIA	ODPOWIEDZI				
	A	B	C	D	E
Czy Twoja organizacja buduje wysokiej jakości zbiory danych?	Brak systematycznego budowania zbiorów danych	Sporadyczne działania w kierunku poprawy jakości danych	Budowanie zbiorów danych z umiarkowaną jakością	Zbiory danych wysokiej jakości dla większości procesów	W pełni zoptymalizowane zbiory danych o najwyższej jakości
		OrgD: X	OrgA: X, OrgC: X	OrgB: X	
Na ile Twoja organizacja automatyzuje analizę i przetwarzanie danych?	Brak automatyzacji analiz i przetwarzania danych	Podstawowa automatyzacja w kilku obszarach	Częściowa automatyzacja dla niektórych procesów	Wysoka automatyzacja analiz i przetwarzania danych	W pełni zautomatyzowane procesy analizy i przetwarzania danych
		OrgA: X, OrgC: X, OrgD: X		OrgB: X	
Czy Twoja organizacja centralizuje zbiory danych (np. jeden słownik danych)?	Brak centralizacji zbiorów danych	Centralizacja w kilku wybranych obszarach	Częściowa centralizacja z danymi w różnych systemach	Większość danych zcentralizowana, kilka wyjątków	Pełna centralizacja danych, jeden słownik danych w całej organizacji
	OrgD: X	OrgA: X, OrgC: X		OrgB: X	
Czy organizacja korzysta z zaawansowanych narzędzi do oceny jakości danych?	Brak narzędzi do oceny jakości danych	Podstawowe narzędzia, ale rzadko używane	Częściowe wykorzystanie narzędzi do oceny jakości	Narzędzia do oceny jakości danych wykorzystywane w większości przypadków	W pełni zoptymalizowane narzędzia do oceny jakości danych
	OrgD: X	OrgB: X, OrgC: X	OrgA: X		
Czy Twoja organizacja ma strategię zarządzania danymi?	Brak strategii zarządzania danymi	Podstawowa strategia, ale niekompletnie wdrożona	Strategia zarządzania danymi stosowana w wybranych obszarach	Strategia zarządzania danymi wdrożona w większości procesów	W pełni wdrożona i zoptymalizowana strategia zarządzania danymi
	OrgB: X, OrgD: X		OrgA: X, OrgC: X		
Na ile Twoja organizacja automatyzuje proces zbierania i czyszczenia danych?	Brak automatyzacji, dane zbierane i czyszczone ręcznie	Podstawowa automatyzacja niektórych etapów procesu	Częściowa automatyzacja zbierania i czyszczenia danych	Automatyzacja dla większości procesów zbierania i czyszczenia danych	Pełna automatyzacja procesów zbierania i czyszczenia danych
	OrgD: X	OrgA: X, OrgB: X, OrgC: X			
Czy organizacja identyfikuje i integruje dane z wewnętrznych i zewnętrznych źródeł?	Brak identyfikacji i integracji danych z różnych źródeł	Dane zidentyfikowane, ale nie w pełni zintegrowane	Częściowa integracja danych z wybranych źródeł	Większość danych zidentyfikowana i zintegrowana	W pełni zintegrowane dane z wewnętrznych i zewnętrznych źródeł
		OrgA: X, OrgC: X, OrgD: X		OrgB: X	
Czy organizacja posiada jeden standardowy model danych i zestaw metadanych?	Brak standardowego modelu danych	Podstawowy model danych wdrożony w niektórych obszarach	Częściowe wdrożenie modelu danych i metadanych	Większość procesów oparta na jednym modelu danych	W pełni wdrożony jeden standardowy model danych i zbiór metadanych

	OrgD: X	OrgA: X	OrgB: X, OrgC: X		
Czy Twoja organizacja korzysta z generatywnej AI do wspomagania wizualizacji danych?	Brak użycia generatywnej AI do wizualizacji danych	Podstawowe wykorzystanie generatywnej AI do prostych wizualizacji	Częściowe wykorzystanie generatywnej AI w wybranych obszarach	Generatywna AI wykorzystywana do większości wizualizacji danych	W pełni zintegrowane narzędzia generatywnej AI do wspomagania wizualizacji danych
	OrgB: X, OrgC: X	OrgA: X	OrgD: X		
OBSZAR – LUDZIE I KOMPETENCJE (6 PYTAŃ)					
PYTANIA	ODPOWIEDZI				
	A	B	C	D	E
Czy Twoja organizacja rozwija świadomość i zrozumienie rozwiązań generatywnej AI?	Brak świadomości rozwiązań generatywnej AI	Podstawowa świadomość wśród wybranych zespołów	Częściowe zrozumienie i świadomość w wybranych obszarach	Świadomość i zrozumienie w większości działów	Pełne zrozumienie i świadomość generatywnej AI w całej organizacji
		OrgA: X, OrgC: X	OrgB: X, OrgD: X		
Czy organizacja szkoli zespoły w zakresie programowania (także promptingu) i analizy danych?	Brak szkoleń z programowania i analizy danych	Podstawowe szkolenia w wybranych zespołach	Częściowe szkolenia, ale ograniczone do kilku zespołów	Regularne szkolenia obejmujące większość zespołów	W pełni rozwinięty program szkoleń dla wszystkich zespołów w zakresie GenAI i analizy danych
		OrgA: X, OrgB: X, OrgC: X, OrgD: X			
Czy Twoja organizacja tworzy interdyscyplinarne zespoły ds. GenAI?	Brak interdyscyplinarnych zespołów ds. GenAI	Tworzenie zespołów w niektórych projektach	Częściowe tworzenie zespołów, ale nie w każdej inicjatywie	Większość projektów posiada interdyscyplinarne zespoły	W pełni zintegrowane interdyscyplinarne zespoły ds. GenAI we wszystkich projektach
	OrgA: X, OrgC: X, OrgD: X	OrgB: X			
Czy organizacja angażuje zewnętrznych konsultantów ds. generatywnej AI do zespołów?	Brak angażowania zewnętrznych konsultantów	Sporadyczne zaangażowanie konsultantów do pojedynczych projektów	Konsultanci zewnętrzni angażowani przy wybranych projektach	Regularne angażowanie konsultantów do kluczowych inicjatyw	W pełni zintegrowane wsparcie konsultantów ds. GenAI we wszystkich istotnych projektach
	OrgA: X, OrgC: X, OrgD: X	OrgB: X			
Czy Twoja organizacja szkoli w zakresie zarządzania projektami opartymi o generatywną AI?	Brak szkoleń z zarządzania projektami opartymi o generatywną AI	Podstawowe szkolenia dla wybranych osób	Częściowe szkolenia z zarządzania projektami dla wybranych zespołów	Regularne szkolenia w zakresie projektów opartych o generatywną AI	Pełny program szkoleń z zarządzania projektami opartymi o generatywną AI dla wszystkich odpowiednich zespołów
	OrgA: X, OrgB: X, OrgC: X, OrgD: X				
Czy istnieje zarządzanie wiedzą w dziedzinie generatywnej AI, aby ułatwić transfer wiedzy między wszystkimi pracownikami?	Pracownicy utrzymują własne bazy wiedzy i nie dzielą się nimi z innymi	Istnieją różne platformy, ale nie są one dobrze zorganizowane, co utrudnia pracownikom dostęp do istniejącej wiedzy	Centralna platforma jest w trakcie budowy i jest używana przez poszczególnych pracowników do zarządzania wiedzą	Scentralizowana platforma jest dostępna dla wszystkich pracowników, ale nie wszyscy z niej korzystają	Scentralizowana platforma do gromadzenia wiedzy jest używana przez wszystkich pracowników i jest stale rozbudowywana
	OrgA: X, OrgC: X, OrgD: X	OrgB: X			
OBSZAR – ORGANIZACJA I PROCESY (7 PYTAŃ)					

PYTANIA	ODPOWIEDZI				
	A	B	C	D	E
Czy Twoja organizacja integruje generatywną AI z istniejącymi procesami rozwoju nowego produktu?	Brak integracji GenAI w procesach rozwoju nowego produktu	Podstawowa integracja w procesach rozwoju wybranych produktów	Częściowa integracja w procesach rozwoju kilku produktów	Integracja GenAI w procesach rozwoju większości produktów	Pełna integracja GenAI w procesach rozwoju wszystkich produktów
	OrgA: X, OrgB: X, OrgC: X, OrgD: X				
Na ile Twoja organizacja automatyzuje procesy rozwoju produktu z wykorzystaniem generatywnej AI?	Brak automatyzacji procesów rozwoju produktu z GenAI	Podstawowa automatyzacja wybranych etapów rozwoju produktu	Częściowa automatyzacja procesów rozwoju produktu	Automatyzacja większości procesów rozwoju produktu	W pełni zautomatyzowane procesy rozwoju produktu z wykorzystaniem GenAI
	OrgA: X, OrgB: X, OrgC: X, OrgD: X				
Czy organizacja wykorzystuje generatywną AI do wsparcia podejmowania decyzji?	Brak wykorzystania GenAI do wsparcia podejmowania decyzji	Sporadyczne wykorzystanie GenAI w wybranych decyzjach	GenAI wspiera podejmowanie decyzji w ograniczonym zakresie	GenAI wspiera większość decyzji w kluczowych obszarach	GenAI zintegrowana we wszystkich procesach decyzyjnych organizacji
	OrgA: X, OrgD: X	OrgC: X	OrgB: X		
Czy organizacja wdraża narzędzia generatywnej AI wspierające pracę zespołów?	Brak narzędzi wspierających pracę zespołów	Podstawowe narzędzia, ale nie są powszechnie używane	Częściowe wdrożenie narzędzi wspierających pracę zespołów	Narzędzia wspierają pracę większości zespołów	W pełni wdrożone narzędzia generatywnej AI wspierające codzienną pracę zespołów
	OrgA: X, OrgB: X, OrgC: X, OrgD: X				
Czy organizacja wprowadza cykle ciągłego doskonalenia we wdrażaniu rozwiązań generatywnej AI?	Brak cykli ciągłego doskonalenia	Sporadyczne działania w kierunku doskonalenia procesów	Cykle doskonalenia w wybranych procesach GenAI	Doskonalenie wdrożeń GenAI w większości projektów	W pełni wdrożone cykle ciągłego doskonalenia dla wszystkich wdrożeń GenAI
	OrgD: X	OrgA: X, OrgB: X, OrgC: X			
Czy organizacja zdefiniowała proces zarządzania cyklem życia dla oprogramowania generatywnej AI?	Brak zdefiniowanego procesu zarządzania cyklem życia oprogramowania	Proces częściowo zdefiniowany, ale niespójnie realizowany	Zdefiniowany proces zarządzania cyklem życia w kilku projektach	Zdefiniowany proces zarządzania cyklem życia w większości projektów	Pełny proces zarządzania cyklem życia dla oprogramowania GenAI wdrożony we wszystkich projektach
	OrgB: X, OrgC: X, OrgD: X	OrgA: X			
Czy organizacja posiada przewodnik po procesie rozwoju produktu oparty o generatywną AI?	Brak przewodnika GenAI po procesie rozwoju produktu	Podstawowy przewodnik GenAI opracowany, ale rzadko używany	Przewodnik GenAI częściowo wdrożony w kilku projektach	Przewodnik GenAI po procesie rozwoju produktu stosowany w większości projektów	W pełni wdrożony przewodnik GenAI po procesie rozwoju produktu w całej organizacji
	OrgA: X, OrgB: X, OrgC: X, OrgD: X				
OBSZAR – STRATEGIA I ZARZĄDZANIE (6 PYTAŃ)					
PYTANIA	ODPOWIEDZI				
	A	B	C	D	E

Czy Twoja organizacja opracowała długoterminową strategię inwestycji w generatywną AI?	Brak strategii inwestycji w generatywną AI	Podstawowa strategia, ale ograniczona do krótkiego okresu	Strategia istnieje, ale nie jest w pełni wdrożona	Strategia długoterminowa jest wdrożona w większości obszarów	W pełni wdrożona, długoterminowa strategia inwestycji w generatywną AI
	OrgB: X	OrgC: X, OrgD: X	OrgA: X		
Czy strategia AI jest wdrożona w proces rozwoju produktu?	Brak wdrożenia strategii AI w proces rozwoju produktów	Wdrożenie tylko przy pojedynczych produktach	Częściowe wdrożenie strategii AI w procesie rozwoju produktu	Strategia AI wdrożona przy większości produktów	Pełne wdrożenie strategii AI w procesie rozwoju produktu dla wszystkich produktów organizacji
	OrgB: X, OrgD: X	OrgA: X, OrgC: X			
Czy Twoja organizacja określiła cele strategiczne dla generatywnej AI?	Brak celów strategicznych dla generatywnej AI	Podstawowe cele, ale bez precyzyjnej realizacji	Cele zdefiniowane, ale nie w pełni realizowane	Cele strategiczne dla generatywnej AI realizowane w większości obszarów	W pełni wdrożone i realizowane cele strategiczne dla generatywnej AI
	OrgB: X, OrgD: X	OrgA: X, OrgC: X			
Czy organizacja ocenia wpływ biznesowy i wykonalność rozwiązań generatywnej AI z wyprzedzeniem?	Brak oceny wpływu biznesowego i wykonalności rozwiązań GenAI	Ocena przeprowadzana jedynie w wybranych przypadkach	Częściowa ocena wpływu biznesowego i wykonalności	Regularna ocena dla większości projektów	W pełni systematyczna ocena wpływu biznesowego i wykonalności dla wszystkich rozwiązań GenAI
	OrgC: X, OrgD: X	OrgA: X, OrgB: X			
Czy Twoja organizacja opracowała system monitorowania wyników wdrożenia generatywnej AI?	Brak systemu monitorowania wyników wdrożenia GenAI	Podstawowy system monitorowania, ale niedostatecznie wdrożony	Częściowy system monitorowania wyników w wybranych projektach	System monitorowania wyników wdrożenia GenAI działa w większości obszarów	W pełni wdrożony, zaawansowany system monitorowania wyników GenAI
	OrgB: X, OrgC: X, OrgD: X	OrgA: X			
Czy organizacja analizuje konkurencję pod względem ich zdolności do wdrożeń generatywnej AI?	Brak analiz konkurencji dotyczących GenAI	Sporadyczne analizy konkurencji dotyczące GenAI	Częściowe analizy, ale nie regularne	Regularne analizy konkurencji pod kątem wdrożeń GenAI	W pełni zintegrowane analizy konkurencji dotyczące GenAI we wszystkich strategicznych obszarach
		OrgA: X, OrgB: X, OrgC: X, OrgD: X			
OBSZAR – BUDŻET (5 PYTAŃ)					
PYTANIA	ODPOWIEDZI				
	A	B	C	D	E
Czy Twoja organizacja prowadzi długoterminowe planowanie budżetu na rozwój rozwiązań i infrastruktury wspierającej generatywną AI?	Brak planowania budżetu na rozwój rozwiązań generatywnej AI	Krótkoterminowe planowanie budżetowe w wybranych projektach	Częściowe planowanie długoterminowe, ograniczone do niektórych projektów	Długoterminowe planowanie budżetowe w większości projektów	Pełne długoterminowe planowanie budżetu na wszystkie projekty i infrastrukturę generatywnej AI
		OrgA: X, OrgB: X, OrgC: X, OrgD: X			
Czy Twoja organizacja przeznacza środki na rozwój kompetencji pracowników w zakresie generatywnej AI?	Brak środków na rozwój kompetencji pracowników w zakresie GenAI	Sporadyczne finansowanie szkoleń dla wybranych pracowników	Częściowe przeznaczenie środków na rozwój kompetencji	Stale finansowanie rozwoju kompetencji większości pracowników	Pełne finansowanie rozwoju kompetencji w zakresie GenAI dla wszystkich pracowników
	OrgD: X	OrgA: X, OrgC: X	OrgB: X		

Czy Twoja organizacja finansuje projekty pilotażowe i innowacyjne związane z generatywną AI?	Brak finansowania projektów pilotażowych związanych z GenAI	Ograniczone finansowanie pojedynczych projektów	Częściowe finansowanie projektów pilotażowych i innowacyjnych	Regularne finansowanie większości projektów pilotażowych	Pełne wsparcie finansowe dla wszystkich projektów pilotażowych i innowacyjnych związanych z GenAI
		OrgA: X, OrgC: X, OrgD: X	OrgB: X		
Czy organizacja alokuje środki na zewnętrzne konsultacje dotyczące generatywnej AI?	Brak alokacji środków na zewnętrzne konsultacje dotyczące generatywnej AI	Sporadyczne alokowanie środków na konsultacje w wybranych projektach	Częściowa alokacja środków na zewnętrzne konsultacje	Regularna alokacja środków na konsultacje w większości projektów	Pełna alokacja środków na zewnętrzne konsultacje we wszystkich strategicznych projektach
	OrgA: X, OrgC: X	OrgB: X, OrgD: X			
Czy organizacja priorytetyzuje projekty generujące wysoką wartość dodaną dzięki generatywnej AI?	Brak priorytetyzacji projektów związanych z GenAI	Priorytetyzacja jedynie wybranych projektów	Częściowa priorytetyzacja projektów generujących wartość dodaną	Regularna priorytetyzacja większości projektów związanych z GenAI	Pełna priorytetyzacja projektów GenAI o najwyższej wartości dodanej
	OrgA: X, OrgD: X	OrgB: X, OrgC: X			
OBSZAR – PRODUKTY I USŁUGI (11 PYTAŃ)					
PYTANIA	ODPOWIEDZI				
	A	B	C	D	E
Czy Twoja organizacja wykorzystuje generatywną AI do wspomagania lub automatyzacji procesów projektowania i wytwarzania produktów?	Brak wykorzystania GenAI w procesach projektowania i wytwarzania produktów	Minimalne wykorzystanie GenAI w wybranych procesach	Częściowe wykorzystanie GenAI do automatyzacji procesów	GenAI wspiera większość procesów projektowania i wytwarzania	Pełne wykorzystanie GenAI w automatyzacji procesów projektowania i wytwarzania produktów
	OrgA: X, OrgD: X	OrgB: X, OrgC: X			
Czy Twoja organizacja korzysta z generatywnej AI do personalizacji produktów?	Brak wykorzystania GenAI do personalizacji produktów	Sporadyczne wykorzystanie GenAI do podstawowej personalizacji	GenAI stosowana do personalizacji w wybranych produktach	Personalizacja większości produktów z wykorzystaniem GenAI	Pełna personalizacja produktów przy wsparciu GenAI
	OrgA: X, OrgC: X, OrgD: X	OrgB: X			
Czy organizacja korzysta z generatywnej AI do generowania pomysłów związanych z produktami (np. analiza sentymentu, analiza opinii)?	Brak generowania pomysłów z wykorzystaniem GenAI	Sporadyczne generowanie pomysłów w wybranych projektach	Częściowe generowanie pomysłów z wykorzystaniem GenAI	Generowanie pomysłów w większości procesów rozwoju produktów	Pełne wykorzystanie GenAI do generowania pomysłów i analiz opinii dla produktów
	OrgA: X, OrgD: X	OrgC: X	OrgB: X		
Czy Twoja organizacja wykorzystuje generatywną AI do wspomaganie redukcji informacji (np. streszczenia tekstów)?	Brak wykorzystania GenAI do redukcji informacji	Sporadyczne wykorzystanie GenAI w wybranych przypadkach	Częściowe wykorzystanie GenAI do redukcji informacji	GenAI stosowana regularnie do redukcji informacji w większości projektów	Pełne wykorzystanie GenAI do redukcji informacji we wszystkich obszarach
	OrgC: X	OrgA: X	OrgD: X	OrgB: X	
Czy organizacja wspomaga ocenę koncepcji produktów przy użyciu generatywnej AI?	Brak wspomagania oceny koncepcji przy użyciu GenAI	Sporadyczne wsparcie oceny koncepcji w wybranych projektach	Częściowe wykorzystanie GenAI do oceny koncepcji	GenAI wspiera ocenę koncepcji w większości projektów	Pełne wsparcie oceny koncepcji produktów z wykorzystaniem GenAI
	OrgA: X, OrgC: X, OrgD: X	OrgB: X			
Czy Twoja organizacja wykorzystuje generatywną AI do skrócenia czasu testowania produktów?	Brak wykorzystania GenAI do skracania czasu testowania	GenAI sporadycznie wykorzystywana w wybranych testach	Częściowe wykorzystanie GenAI do skracania czasu testów	GenAI stosowana regularnie do skracania czasu testowania produktów	Pełne wykorzystanie GenAI do maksymalnego skrócenia czasu testowania produktów

	OrgA: X, OrgC: X, OrgD: X	OrgB: X			
Czy organizacja wspiera marketing produktowy z wykorzystaniem generatywnej AI (np. tworzenie reklam, słów kluczowych, filmów promocyjnych)?	Brak wykorzystania GenAI do marketingu produktowego	Sporadyczne wykorzystanie GenAI w pojedynczych kampaniach	Częściowe wykorzystanie GenAI w wybranych aspektach marketingu	GenAI wspiera marketing większości produktów	Pełne wykorzystanie GenAI do wspomagania marketingu produktowego (tworzenie reklam, kampanii, analiz)
		OrgA: X, OrgC: X, OrgD: X		OrgB: X	
Czy Twoja organizacja wykorzystuje generatywną AI do doskonalenia systemów rekomendacji produktów?	Brak wykorzystania GenAI w systemach rekomendacji produktów	Podstawowe wykorzystanie GenAI do rekomendacji w wybranych obszarach	Częściowe wykorzystanie GenAI do rekomendacji produktów	GenAI regularnie wspiera systemy rekomendacji w większości procesów	Pełne wykorzystanie GenAI do optymalizacji systemów rekomendacji produktów
	OrgD: X	OrgA: X, OrgB: X, OrgC: X			
Czy organizacja doskonała działanie baz danych produktów z wykorzystaniem generatywnej AI?	Brak doskonalenia baz danych produktów przy użyciu GenAI	Podstawowe wykorzystanie GenAI w wybranych obszarach	Częściowe doskonalenie baz danych produktów z wykorzystaniem GenAI	GenAI wspiera doskonalenie baz danych produktów w większości obszarów	Pełne wykorzystanie GenAI do doskonalenia baz danych produktów
	OrgA: X, OrgB: X, OrgD: X	OrgC: X			
Czy Twoja organizacja wykorzystuje generatywną AI jako komponent profesjonalnych aplikacji?	Brak wykorzystania GenAI jako komponentu aplikacji	GenAI wykorzystywana jedynie w podstawowych aplikacjach	Częściowe wykorzystanie GenAI w wybranych profesjonalnych aplikacjach	GenAI wspiera działanie większości profesjonalnych aplikacji	Pełne wykorzystanie GenAI jako kluczowego komponentu profesjonalnych aplikacji
	OrgA: X, OrgB: X, OrgC: X, OrgD: X				
Czy organizacja poszukuje nowych przypadków użycia rozwiązań generatywnej AI?	Brak poszukiwań nowych przypadków użycia GenAI	Sporadyczne poszukiwania nowych przypadków użycia	Częściowe poszukiwanie nowych przypadków użycia GenAI	Regularne poszukiwanie nowych przypadków użycia GenAI	Pełne zaangażowanie w poszukiwanie nowych przypadków użycia GenAI we wszystkich obszarach
		OrgA: X, OrgC: X	OrgD: X	OrgB: X	
OBSZAR – ETYKA I REGULACJE (10 PYTAŃ)					
PYTANIA	ODPOWIEDZI				
	A	B	C	D	E
Czy Twoja organizacja przestrzega zasad etyki w projektowaniu generatywnej AI?	Brak uwzględnienia zasad etyki w projektowaniu GenAI	Sporadyczne uwzględnienie etyki w wybranych projektach	Częściowe uwzględnienie zasad etyki w niektórych projektach	Większość projektów uwzględnia zasady etyki	W pełni uwzględnione zasady etyki we wszystkich projektach GenAI
	OrgB: X	OrgD: X	OrgC: X	OrgA: X	
Czy Twoja organizacja zapewnia bezpieczeństwo i prywatność danych związanych z rozwojem produktów?	Brak systemu zapewniającego bezpieczeństwo i prywatność danych	Podstawowe środki bezpieczeństwa wdrożone w wybranych projektach	Częściowe wdrożenie polityki bezpieczeństwa i prywatności danych	Większość projektów przestrzega polityk bezpieczeństwa i prywatności danych	W pełni wdrożone systemy bezpieczeństwa i prywatności danych dla wszystkich projektów
			OrgD: X	OrgA: X, OrgB: X, OrgC: X	
Czy Twoja organizacja dba o zaufanie do danych i możliwość ich wyjaśnienia?	Brak mechanizmów budowania zaufania do danych	Minimalne działania w zakresie zaufania i możliwości wyjaśnienia danych	Częściowe wdrożenie mechanizmów budujących zaufanie i możliwości wyjaśnienia	Większość danych posiada mechanizmy możliwości wyjaśnienia	Pełne zaufanie do danych i mechanizmy możliwości wyjaśnienia wdrożone we wszystkich procesach
		OrgD: X	OrgA: X	OrgB: X, OrgC: X	

Czy organizacja wdraża standardy ochrony i mechanizmy dotyczące kopii zapasowych danych?	Brak standardów ochrony i mechanizmów kopii zapasowych	Podstawowe mechanizmy wprowadzane w wybranych obszarach	Częściowe wdrożenie mechanizmów ochrony i kopii zapasowych	Większość obszarów objęta standardami ochrony i kopiami zapasowymi danych	W pełni wdrożone standardy ochrony i mechanizmy kopii zapasowych we wszystkich obszarach
	OrgD: X			OrgA: X, OrgC: X	OrgB: X
Czy Twoja organizacja przeciwdziała uprzedzeniom i niesprawiedliwości w algorytmach generatywnej AI?	Brak działań w zakresie przeciwdziałania uprzedzeniom	Podstawowe działania w zakresie eliminacji uprzedzeń	Częściowe wdrożenie działań przeciwdziałających uprzedzeniom w algorytmach	Większość algorytmów jest weryfikowana pod kątem uprzedzeń	Pełna eliminacja uprzedzeń i niesprawiedliwości
	OrgB: X, OrgD: X	OrgA: X	OrgC: X		
Czy organizacja regularnie ocenia zgodność algorytmów generatywnej AI z regulacjami prawnymi?	Brak oceny zgodności algorytmów z regulacjami	Sporadyczne oceny zgodności z przepisami w wybranych projektach	Częściowe wdrożenie procedur oceny zgodności algorytmów	Większość algorytmów jest regularnie weryfikowana pod kątem zgodności z regulacjami	W pełni wdrożone procedury regularnej oceny zgodności z przepisami
	OrgB: X	OrgA: X, OrgC: X, OrgD: X			
Czy Twoja organizacja tworzy systemy audytu decyzji podejmowanych przez generatywną AI?	Brak systemów audytu decyzji podejmowanych przez GenAI	Podstawowe systemy audytu wprowadzane w wybranych projektach	Częściowe wdrożenie systemów audytu decyzji GenAI	Systemy audytu funkcjonują dla większości decyzji GenAI	W pełni wdrożone systemy audytu i odpowiedzialności za decyzje podejmowane przez GenAI
	OrgB: X, OrgC: X, OrgD: X	OrgA: X			
Czy Twoja organizacja poszerza świadomość dotyczącą ochrony danych wśród pracowników?	Brak programów edukacyjnych dotyczących ochrony danych	Podstawowe programy szkoleniowe, ale ograniczone do wybranych zespołów	Częściowe programy szkoleniowe dla wybranych zespołów	Regularne szkolenia w zakresie ochrony danych w większości zespołów	Pełne programy edukacyjne dotyczące ochrony danych dla wszystkich pracowników
		OrgC: X		OrgA: X, OrgB: X, OrgD: X	
Czy organizacja wykorzystuje technologie dotyczące cyberbezpieczeństwa?	Brak wykorzystania technologii cyberbezpieczeństwa	Podstawowe technologie wdrożone w wybranych obszarach	Częściowe wdrożenie technologii cyberbezpieczeństwa	Większość obszarów objęta technologiami cyberbezpieczeństwa	W pełni wdrożone technologie cyberbezpieczeństwa we wszystkich obszarach organizacji
			OrgC: X	OrgA: X, OrgB: X, OrgD: X	
Czy Twoja organizacja utrzymuje dokumentację dotyczącą użycia generatywnej AI (np. przypadki użycia, logi systemowe, kontrola wersji)?	Brak dokumentacji dotyczącej użycia GenAI	Sporadyczne dokumentowanie wybranych przypadków użycia	Częściowa dokumentacja dla wybranych obszarów	Dokumentacja prowadzona regularnie w większości przypadków	Pełna i bieżąca dokumentacja dotycząca wszystkich przypadków użycia GenAI
	OrgC: X	OrgA: X, OrgB: X	OrgD: X		

Załącznik 4. Link do repozytorium.

Model, uwzględniający narzędzie odpowiadające za część preskryptywną, znajduje się w repozytorium GitHub pod linkiem: <https://github.com/vitkovski/CLIMB2OLIMP>

Raporty organizacji jako pliki Microsoft Word, są do pobrania pod powyższym linkiem w folderze „Raporty”. Podobnie, w folderze „Kwestionariusze” znajdują się szablony kwestionariuszy dla modeli CLIMB2 oraz OLIMP.