

POLITECHNIKA WARSZAWSKA

Rozprawa

doktorska

Dyscyplina naukowa inżynieria lądowa, geodezja i transport, dziedzina nauk inżynieryjno-technicznych

mgr inż.

Piotr Kotylak

Zastosowanie dwuwymiarowej struktury wektorowej do opracowania metody optymalizacji wskaźników ekonomicznych operatorów infrastruktury ładowania EV

Promotor

prof. dr hab. inż. **Marianna Jacyna**

Warszawa 2026

STRESZCZENIE

Zastosowanie dwuwymiarowej struktury wektorowej do opracowania metody optymalizacji wskaźników ekonomicznych operatorów infrastruktury ładowania EV

Rozprawa doktorska dotyczy problematyki optymalizacji wskaźników ekonomicznych stacji ładowania pojazdów elektrycznych. Punktem wyjścia jest założenie, że wynik ekonomiczny stacji zależy od wielu czynników rynkowych, popytowych, kosztowych, technicznych, marketingowych oraz makroekonomicznych, których wpływ zmienia się w czasie. Uwaga w pracy została skupiona na analizie wzajemnych zależności pomiędzy tymi czynnikami, ich wpływie na ekonomikę stacji ładowania oraz możliwościach oddziaływania za pomocą instrumentów biznesowych pozostających w dyspozycji operatora. Na tej podstawie sformułowano problem badawczy dotyczący potrzeby jednoczesnej analizy wpływu wielu czynników na oba wskaźniki.

Celem rozprawy było opracowanie metody wspomagania decyzji operacyjnych i biznesowych operatorów stacji ładowania, umożliwiającej ocenę wpływu parametrów na wskaźnik marżę i wskaźnik wykorzystanie infrastruktury stacji w odpowiedzi na zmienność warunków otoczenia. Teza pracy zakłada, że zastosowanie dwuwymiarowego modelu wektorowego do formalnej reprezentacji wpływu czynników egzogenicznych i endogenicznych na marżę handlową oraz wykorzystanie infrastruktury stacji ładowania EV umożliwia opracowanie algorytmu symulującego superpozycję ich oddziaływania w czasie i wyznaczającego trajektorię stanów ekonomicznych stacji, stanowiąc podstawę do wspomagania decyzji biznesowych operatora.

W części analitycznej przeprowadzono przegląd literatury i zidentyfikowano czynniki wpływu występujące w sześciu grupach: konkurencyjności, popytu, kosztów, techniki i infrastruktury, marketingu oraz uwarunkowań makroekonomicznych i regulacyjnych. Czynniki te przekształcono w parametry modelu i opisano ilościowo za pomocą atrybutów oraz funkcji odzwierciedlających nieliniowość każdego z czynników. W dalszym etapie zbudowano model w przestrzeni $\mathbb{R}^2$, pozwalający na wyznaczenie dla każdego z parametrów wynikowego wektora wpływu IMPACT VECTOR oddziałującego jednocześnie na wskaźniki marży i wykorzystania infrastruktury stacji ładowania.

Następnie opracowano autorski algorytm symulacyjny służący do wyznaczania zmian wartości obu wskaźników w czasie. Algorytm zaimplementowano w autorskiej aplikacji SIMVEC wspartej aplikacją SIMDATA wykorzystaną do kontroli danych wejściowych. Weryfikację przeprowadzono za pomocą scenariuszy symulacyjnych obejmujących ocenę zachowania, analizę wrażliwości, analizę korelacji parametrów, walidację obliczeń oraz ocenę stabilności numerycznej. Uzyskane wyniki potwierdziły zgodność kierunków oddziaływania wybranych parametrów z założeniami.

Rozprawa obejmuje zatem identyfikację czynników wpływu, ich formalizację w postaci parametrów i atrybutów, budowę modelu wektorowego 2D, opracowanie algorytmu symulacyjnego, implementację komputerową SIMVEC i SIMDATA oraz ich weryfikację w oparciu o scenariusze testowe. W części końcowej pracy wskazano kierunek dalszych badań obejmujących kalibrację modelu na rzeczywistych danych pochodzących od operatorów stacji ładowania, kontynuację prac nad sposobem kumulacji wpływów oraz rozszerzenie modelu do przestrzeni o większej ilości wymiarów.

Słowa kluczowe: *elektromobilność, infrastruktura ładowania pojazdów elektrycznych, operator infrastruktury ładowania, optymalizacja wskaźników ekonomicznych, model wektorowy, wspomaganie decyzji, wykorzystanie infrastruktury ładowania, marża stacji ładowania, symulacja stacji ładowania*

ABSTRACT

Application of a Two-Dimensional Vector Structure for Developing a Method to Optimize Economic Indicators of EV Charging Infrastructure Operators

The doctoral dissertation addresses the issue of optimizing the economic indicators of electric vehicle charging stations. Its point of departure is the assumption that a station's economic performance depends on numerous markets, demand-related, cost-related, technical, marketing, and macroeconomic factors, whose impact changes over time. The study focuses on analyzing the interrelationships among these factors, their influence on the economics of charging stations, and the possibilities of affecting them through business instruments available to the operator. On this basis, a research problem was formulated concerning the need to simultaneously analyze the impact of multiple factors on both indicators.

The aim of the dissertation was to develop a method for supporting the operational and business decisions of charging station operators, enabling the assessment of the impact of parameters on the margin indicator and the infrastructure utilization indicator of a charging station in response to changing environmental conditions. The dissertation thesis assumes that the application of a two-dimensional vector model for the formal representation of the influence of exogenous and endogenous factors on commercial margin and EV charging station infrastructure utilization makes it possible to develop an algorithm simulating the superposition of their effects over time and determining the trajectory of the station's economic states, thereby providing a basis for supporting the operator's business decisions.

In the analytical part, a literature review was conducted and influencing factors were identified in six groups: competitiveness, demand, costs, technology and infrastructure, marketing, and macroeconomic and regulatory conditions. These factors were transformed into model parameters and quantitatively described using attributes and functions reflecting the nonlinearity of each factor. In the next stage, a model was built in the $\mathbb{R}^2$ space, assigning to each parameter a final influence IMPACT VECTOR acting simultaneously on the margin and station infrastructure utilization indicators.

Subsequently, an original simulation algorithm was developed to determine changes in the values of both indicators over time. The algorithm was implemented in the proprietary SIMVEC application, supported by the SIMDATA application used to verify the input data. Verification was carried out by means of simulation scenarios covering behavioral assessment, sensitivity analysis, parameter correlation analysis, computational validation, and numerical stability evaluation. The obtained results confirmed that the directions of influence of the selected parameters were consistent with the assumptions adopted.

The dissertation therefore includes the identification of influencing factors, their formalization in the form of parameters and attributes, the construction of a two-dimensional vector model, the development of a simulation algorithm, the computer implementation of SIMVEC and SIMDATA, and their verification based on test scenarios. In the final part of the dissertation, directions for further research were indicated, including calibration of the model using real data from charging station operators, continuation of work on the method of cumulative impact aggregation, and extension of the model to a higher-dimensional space.

Keywords: *electromobility, electric vehicle charging infrastructure, charging point operator, economic optimization, vector model, decision support, charging infrastructure utilization, charging station margin, charging station simulation*

Spis treści

STRESZCZENIE	3
WSTĘP	9
1. WPROWADZENIE DO PROBLEMATYKI BADAWCZEJ ROZPRAWY	17
1.1. Istota i zakres problematyki badawczej	17
1.2. Wyzwania i problemy rozwoju elektromobilności w literaturze	24
1.3. Luka badawcza i praktyczny problem na jaki odpowiada rozprawa.....	26
2. CEL, TEZA I ZAKRES ROZPRAWY.....	31
2.1. Kontekst i motywacja badawcza	31
2.2. Cel główny i cele cząstkowe	34
2.3. Zakres pracy	37
2.4. Teza rozprawy	39
2.5. Znaczenie poznawcze i użyteczne	39
3. CZYNNIKI MAJĄCE WPŁYW NA EFEKTYWNOŚĆ STACJI ŁADOWANIA W LITERATURZE PRZEDMIOTU.....	41
3.1. Uwagi ogólne	41
3.2. Czynniki w obszarze konkurencyjności	41
3.3. Czynniki w obszarze popytu	44
3.4. Czynniki w obszarze kosztów	48
3.5. Czynniki w obszarze technicznym i infrastrukturalnym	50
3.6. Czynniki w obszarze marketingowym i produktowym.....	53
3.7. Czynniki w obszarze makroekonomicznym	55
3.8. Podsumowanie i ustalenie czynników wpływu na cenę energii	57
4. USTALENIE PARAMETRÓW WPŁYWU I ICH ATRYBUTÓW DLA OCENY WSKAŹNIKÓW STACJI ŁADOWANIA.....	59
4.1. Założenia ogólne	59
4.2. Opis parametrów i ich atrybutów w obszarze otoczenia konkurencyjnego	61
4.3. Opis parametrów i ich atrybutów w obszarze popytu	62
4.4. Opis parametrów i ich atrybutów w obszarze kosztów	66
4.5. Opis parametrów i ich atrybutów w obszarze technicznym i infrastrukturalnym.....	67
4.6. Opis parametrów i ich atrybutów w obszarze marketingowym i produktowym	70
4.7. Opis parametrów i ich atrybutów w obszarze makroekonomicznym	74
4.8. Podział na parametry zewnętrzne i wewnętrzne	76
5. MODEL WSKAŹNIKÓW EKONOMICZNYCH STACJI ŁADOWANIA W PRZESTRZENI WEKTOROWEJ 2D.....	79
5.1. Ustalenia dla elementów architektury modelu	79
5.1.1. Założenia ogólne architektury modelu	79
5.1.2. Elementy warstwy wejściowej modelu	80
5.1.3. Elementy warstwy wektorowej modelu	81
5.1.4. Elementy warstwy wyjściowej modelu - wskaźniki marży i wykorzystania	83
5.2. Ustalanie zależności funkcyjnych dla poszczególnych parametrów wpływu.....	85
5.3. Funkcje modelujące dla parametrów modelu.....	87
5.3.1. Funkcje modulujące dla parametrów otoczenia rynkowego i konkurencyjnego	87
5.3.2. Funkcje modulujące dla parametrów popytu	89

5.3.3. Funkcje modulujące dla parametrów z grupy kosztów	95
5.3.4. Funkcje modulujące dla parametrów technicznych i infrastrukturalnych.....	98
5.3.5. Funkcje modulujące dla parametrów marketingowych i produktowych	103
5.3.6. Funkcje modulujące dla parametrów makroekonomicznych i regulacji.....	110
6. ALGORYTM SYMULACYJNY.....	115
6.1. Założenia ogólne oraz słownik przyjętych symboli i oznaczeń.....	115
6.1.1. Słownik przyjętych symboli i oznaczeń.....	115
6.1.2. Założenia ogólne do algorytmu.....	117
6.2. Schemat blokowy algorytmu oraz opis realizacji obliczeń.....	118
7. IMPLEMENTACJA KOMPUTEROWA, SYMULACJA I OCENA MODELU ..	133
7.1. Aplikacja symulacyjna SIMVEC	133
7.1.1. Interfejs aplikacji.....	133
7.1.2. Architektura aplikacji.....	134
7.2. Wymienny silnik obliczeniowy.....	136
7.3. Architektura i źródła danych	137
7.3.1. Założenia ogólne dla pozyskania danych.....	137
7.3.2. Dane symulacyjne	140
7.3.3. Struktura i format danych.....	140
7.3.4. Struktura nagłówka dataset.json.....	141
7.3.5. Dane wejściowe dla kroku symulacji dataset.json	142
7.3.6. Definicja parametru w pliku parameters.json.....	143
7.4. Aplikacja kontroli danych wejściowych SIMDATA	143
7.4.1. Interfejs aplikacji.....	143
7.4.2. Architektura aplikacji.....	144
7.4.3. Funkcje użytkowe	145
7.5. Zasady przygotowanie danych dla realizacji scenariuszy symulacyjnych.....	147
7.5.1. Kontrola jakości danych wejściowych w SIMDATA dla scenariuszy	147
7.5.2. Właściwe uruchomienie symulacji w SIMVEC.....	148
7.5.3. Krzyżowa weryfikacja obliczeń (Jupyter Notebook/Python)	148
8. WERYFIKACJA MODELU Z ZASTOSOWANIEM APLIKACJI KOMPUTEROWYCH DLA USTALONYCH SCENARIUSZY SYMULACYJNYCH	150
8.1. Założenia metodologiczne.....	150
8.2. Przeprowadzenie symulacji dla scenariuszy i analiza wyników	151
8.2.1. Zdefiniowanie scenariuszy symulacyjnych.....	151
8.2.2. Przeprowadzenie symulacji i analiza wyników dla scenariusza SC1	152
8.2.3. Przeprowadzenie symulacji i analiza wyników dla scenariusza SC2	155
8.2.4. Przeprowadzenie symulacji i analiza wyników dla scenariusza SC3	157
8.2.5. Przeprowadzenie symulacji i analiza wyników dla scenariusza SC4	161
8.2.6. Przeprowadzenie symulacji i analiza wyników dla scenariusza SC5	163
8.2.7. Przeprowadzenie symulacji i analiza wyników dla scenariusza SC6	166
8.3. Analiza wrażliwości modelu metodą OAT	167
8.3.1. Założenia ogólne i wyniki analizy wrażliwości parametrów modelu	167
8.3.2. Analiza korelacji parametrów	171
8.3.3. Analiza wyników badań scenariuszowych.....	178
8.3.4. Walidacja obliczeń i stabilność numeryczna	178
8.4. Trafność behawioralna w scenariuszach hybrydowych	180
8.5. Znaczenie wyników dla zastosowania modelu i ograniczenia interpretacyjne.....	181

9. PODSUMOWANIE ROZPRAWY	183
9.1. Wnioski	183
9.2. Efekty rozprawy	184
9.3. Kierunki dalszych badań	186
BIBLIOGRAFIA.....	189
SPIS RYSUNKÓW	196
SPIS TABEL.....	199

WSTĘP

Rozwój rynku elektromobilności odbywa się w warunkach zmiennego otoczenia, w którym hurtowe ceny prądu w Europie potrafią wahać się o kilkadziesiąt procent w ciągu kilku tygodni. Popyt jest kształtowany przez sezonowość, tolerancja klientów na podwyżki cen jest względnie niska, a szybki rozwój technologii ładowania oraz eskalacja wymagań prawnych zmusza do ciągłych inwestycji i modernizacji. Podejmowanie decyzji biznesowych w takim środowisku wymaga starannej analizy czynników ekonomicznych i operacyjnych, co ma decydujący wpływ na długookresowy wynik ekonomiczny stacji ładowania i zwrot z inwestycji [2],[4].

Duża zmienność różnych czynników powoduje, że analiza powinna być prowadzona w oparciu o narzędzia podążające za szybkością tych zmian i adekwatne do złożoności problemu. Jako przykład można podać polityki cenowe, które były ustalane na kilka następnych dni w sposób uproszczony z zastosowaniem klasycznego modelu „koszt plus marża” [1]. Problem wynikający z takiego uproszczonego modelu cenowego zarysował się w ostatnim czasie, kiedy to zmiana kosztów zakupu energii w Europie zwiększyła swoją dynamikę bardzo znacząco. Spowodowało to, że po pierwszych ośmiu miesiącach 2024 roku odnotowano ponad 7800 godzin z cenami zerowymi lub ujemnymi, na które operatorzy powinni byli szybko reagować zmianą ceny lub doładowaniem magazynów energii w celu zbudowania bufora marży. Brak reakcji nie pozwalał skompensować skutków ich późniejszego wzrostu [7]. W efekcie operator stacji ładowania zarabiał mniej ze względu na niedostosowanie marży do szybkozmiennego i nieprzewidywalnego kosztu. Jak wskazuje Limmer [1], dynamiczne mechanizmy cenowe umożliwiają reagowanie na tak zmieniające się warunki funkcjonowania systemu elektroenergetycznego, w przeciwieństwie do podejść statycznych

Decyzja cenowa powinna uwzględniać nie tylko reakcje na wahania hurtowych cen energii, ale również konieczność utrzymania równowagi między marżą, a poziomem wykorzystania infrastruktury. Szybki wzrost ceny poprawia marżę z 1kWh, ale jednocześnie wywołuje negatywną reakcję popytu i spadek wolumenu sprzedanej energii. Zjawisko to potwierdzają analizy elastyczności cenowej dla usług ładowania pojazdów elektrycznych [6]. Zatem decyzje dotyczące zmiany cen powinny być podejmowane częściej i wymagają jednocześnie rozbudowanej bazy analizowanych czynników, aby uwzględnić wszystkie istotne czynniki jak m.in. przytoczoną elastyczność popytu. Dodatkowo mechanizmy takie mogą zredukować wykorzystanie mocy szczytowej (maksymalna ilość mocy wymagana przy pełnym

obciążeniu stacji) nawet o 9,8%, co przekłada się zarówno na niższe koszty operacyjne jak i lepsze wykorzystanie infrastruktury [8].

Należy też pamiętać, iż inwestycje w nowe technologie ładowania i szybkie ładowarki należą do bardzo kosztownych, a całkowite nakłady inwestycyjne, z uwzględnieniem modernizacji sieci mogą sięgać kwot rzędu milionów dolarów [85]. W tym kontekście prognozowanie potencjalnych przychodów stacji ładowania nabiera istotnego znaczenia dla oceny opłacalności nowych lokalizacji, dla których należy uwzględnić np. specyfikę bazy popytu czy odpowiednią politykę cenową. Decyzja o lokalizacji stacji powinna m.in. uwzględniać odmiennosć popytu przy trasach szybkiego ruchu, kiedy to kierowcy są skłonni zapłacić za szybkość ładowania, w odróżnieniu od kierowców ładujących pojazdy codziennie w miejscu zamieszkania, dla których cena jest decydującym czynnikiem. Aby zwiększyć prawdopodobieństwo podjęcia optymalnej decyzji o lokalizacji stacji oraz późniejszego utrzymania wskaźników ekonomicznych na odpowiednim poziomie należy też uwzględnić konieczność wdrożenia programów promocyjnych oraz lojalnościowych [10].

Kolejnym istotnym elementem modelu decyzyjnego powinno być uwzględnienie czynników zewnętrznych, takich jak pogoda czy udział OZE w profilu energetycznym stacji. Podaż energii z wiatru lub słońca często skutkuje zmianą cen hurtowych, co można wykorzystać np. do inwestowania nadwyżek w działania wizerunkowo budujące rozpoznawalność marki. Algorytmy wspomagające decyzje pomagają również zrównoważyć wykorzystania systemu i zapewnić ciągłość działania stacji np. w przypadku awarii sieci, fali upałów lub ekstremalnych mrozów. Można wówczas zastosować przesunięcie części popytu i utrzymanie nieprzerwanej pracy stacji, co wpływa pozytywnie na postrzeganie stabilności usługi ładowania przez klientów i ich decyzje zakupowe [11].

Innym czynnikiem wymagającym uwzględnienia jest konieczność rozkładania popytu między szczytami ładowań i okresami niższego zapotrzebowania. Mechanizm taki sprzyja redukcji opłat za poziom mocy umownej oraz kar za jej przekroczenie, które potrafią stanowić nawet 90% miesięcznego rachunku za energię stacji ładowania [12]. Taki mechanizm równocześnie podnosi wiarygodność wskaźników inwestycyjnych potrzebnych do oceny zwrotu z nowych lokalizacji, gdzie nakłady kapitałowe na pojedynczy punkt ładowania DC (ang. Direct Current - prąd stały) o mocy 150 kW przekraczają 120 tys. EUR, a rentowność w pierwszych latach zależy wprost od przewidywanego wykorzystania infrastruktury [13].

Zastosowanie modelu wektorowego może być istotnym wsparciem dla CPO (ang. Charge Point Operator - operator punktu ładowania) w podejmowaniu decyzji biznesowych uwzględniając m.in. opisane powyżej zależności i czynniki wpływające na poprawę wyników

ekonomicznych stacji ładowania. Praktycznym narzędziem może być aplikacja pozwalająca na przeprowadzenie symulacji skutków różnych scenariuszy, których wynikiem będzie predykcja wskaźników ekonomicznych stacji ładowania w założonej perspektywie czasowej i z założonym celem.

Na poglądowej ilustracji Rys. 0.1 przedstawiono potencjalną przestrzeń wyników ekonomicznych stacji ładowania, opisaną dwoma parametrami: marżą oraz poziomem wykorzystania infrastruktury. Celem symulacji jest znalezienie najlepszej ścieżki decyzyjnej (lub scenariusza pokazanego na Rys. 0.2) prowadzącej do osiągnięcia pożądanego regionu (strefy A-D) w przestrzeni marża - wykorzystanie infrastruktury lub zbliżenia się do określonego punktu docelowego w założonym czasie (Rys. 0.1).




Rys. 0.1. Symulacje - obszary decyzyjne i punkt docelowy wyniku ekonomicznego stacji

Źródło: opracowanie własne.

Symulacje mogą być wykonane dla różnych scenariuszy opisujących odmienne łańcuchy decyzji biznesowych dotyczących np. polityki cenowej, polityki promocyjnej, założeń w zakresie popytu, ograniczeń wynikających z dostępnej mocy przyłączeniowej, uwarunkowań technologicznych oraz innych czynników wpływających na funkcjonowanie infrastruktury (Rys. 0.2). Przestrzeń wyników odzwierciedla możliwe stany ekonomiczne stacji wynikające jednocześnie z założeń dot. zmienności czynników zewnętrznych i decyzji podejmowanych przez operatora.

W wyniku symulacji może powstać plan biznesowy wspierający zarządzanie stacją i umożliwiający wprowadzenie przejrzystych i przewidywalnych polityk. Należy dodać, że przejrzystość planów cenowych ułatwia również regulatorom ocenę zasadności stawek i zmniejsza ryzyko ingerencji w polityki cenowe, stosowane czasami na rynkach o niskiej konkurencji [14].



Rys. 0.2 Symulacja zmiany cen w różnych scenariuszach

Źródło: opracowanie własne.

Mając na uwadze złożoność opisanych problemów, potrzeby operatorów infrastruktury ładowania oraz zmienność wpływających na nich czynników, niniejsza rozprawa systematyzuje zbiór kluczowych parametrów i opisuje model ich jednoczesnego wpływu na funkcjonowanie stacji ładowania (patrz rozdziały 4 i 5).

W rozprawie doktorskiej poddano analizie aktualne uwarunkowania rynkowe oraz dominujące trendy, uwzględniając zróżnicowanie rynków kluczowych dla rozwoju infrastruktury ładowania, tj. Chin, USA oraz Europy, ze szczególnym uwzględnieniem specyfiki polskiego rynku.

Efektom przeprowadzonych badań jest opracowanie modelu wektorowego opisującego uwarunkowania konkurencyjne, popytowe, kosztowe, techniczne oraz marketingowe, a także ich skumulowany wpływ na kluczowe wskaźniki ekonomiczne istotne z punktu widzenia operatora stacji ładowania. Wskaźniki te to marża liczona od ceny sprzedanej energii oraz poziom wykorzystania infrastruktury ładowania nazywany w branży EV zamiennie pojęciami „stopień wykorzystania stacji”, „wykorzystanie stacji” lub „poziom utylizacji stacji”

(ang. Utilization - w znaczeniu “wykorzystanie”). W niniejszej rozprawie przyjęto termin „wykorzystanie infrastruktury stacji” jako pojęcie najpełniej oddające istotę analizowanego wskaźnika i ugruntowane w literaturze polskojęzycznej. W dalszej części pracy wskaźniki te są nazywane w uproszczeniu marżą i wykorzystaniem infrastruktury.

Główny cel badań rozprawy został sformułowany jako **opracowanie metody wspomagania decyzji operacyjnych i biznesowych operatorów infrastruktury ładowania EV, umożliwiającej ocenę wpływu wybranych parametrów na marżę i wykorzystanie infrastruktury stacji w odpowiedzi na zmienność warunków otoczenia.**

W związku z tym sformułowano również tezę rozprawy (patrz rozdział 2), zgodnie z którą zastosowanie **dwuwymiarowego modelu wektorowego do formalnej reprezentacji wpływu czynników egzogenicznych i endogenicznych na marżę handlową oraz wykorzystanie infrastruktury stacji ładowania EV umożliwia opracowanie algorytmu symulującego superpozycję ich oddziaływania w czasie i wyznaczającego trajektorię stanów ekonomicznych stacji, stanowiąc podstawę do wspomagania decyzji biznesowych operatora.**

Efektem użytecznym rozprawy jest algorytm pozwalający na symulację zmian wartości marży i wykorzystania infrastruktury modelowanej stacji ładowania w czasie. W celu weryfikacji tezy postawionej w rozprawie algorytm został zaimplementowany w autorskiej aplikacji, uruchomiony na wybranych scenariuszach symulacyjnych i oceniony w oparciu o uzyskane wyniki.

Rozprawa została podzielona na dziewięć rozdziałów, które tworzą spójny ciąg badań prowadzących od identyfikacji problemu badawczego do weryfikacji zaproponowanej metody oraz sformułowania wniosków końcowych.


Rozdział 1 pełni rolę wprowadzenia do problematyki badawczej rozprawy. Przedstawiono w nim aktualny stan wiedzy dotyczący rozwoju elektromobilności, funkcjonowania infrastruktury ładowania oraz wyzwań ekonomicznych, z jakimi mierzą się operatorzy stacji ładowania EV. Na podstawie analizy literatury naukowej i praktyki rynkowej zidentyfikowano lukę badawczą polegającą na braku zintegrowanych narzędzi analitycznych umożliwiających jednoczesną ocenę wpływu wielu dynamicznych czynników na marżę jednostkową i wykorzystanie infrastruktury stacji. Rozdział ten uzasadnia zasadność podjęcia badań oraz stanowi punkt wyjścia dla dalszej formalizacji modelu.

W rozdziale 2 przedstawiono kontekst i motywację badawczą rozprawy, sformułowano cel główny oraz cele cząstkowe, określono tezę pracy oraz precyzyjnie zdefiniowano zakres badań. W rozdziale tym uporządkowano również podstawowe pojęcia wykorzystywane

w dalszej części pracy oraz wskazano znaczenie poznawcze i użyteczne zaproponowanego podejścia. W szczególności podkreślono antagonistyczny charakter kluczowych wskaźników ekonomicznych stacji ładowania, tj. marży oraz poziomu wykorzystania infrastruktury.

W rozdziale 3 dokonano identyfikacji i systematyzacji czynników wpływu istotnych z punktu widzenia ekonomiki stacji ładowania pojazdów elektrycznych. Czynniki pogrupowano w sześć spójnych kategorii obejmujących czynniki rynkowe i konkurencyjne, popytowe, kosztowe, techniczne i infrastrukturalne, marketingowe oraz makroekonomiczne i regulacyjne (Rys. 0.4). Natomiast w rozdziale 4, w każdej z grup przynależne im parametry zostały opisane za pomocą zbioru atrybutów ilościowych, umożliwiających jednoznaczne określenie jego charakteru, zakresu zmienności oraz kierunku oddziaływania na analizowane wskaźniki ekonomiczne. Rozdział ten opisuje bazę parametrów (czynników wpływu) kluczowych dla opracowywanego modelu.

Rozdział 5 poświęcono opracowaniu dwuwymiarowego modelu wektorowego w przestrzeni $\mathbb{R}^2$, której współrzędne reprezentują odpowiednio marżę i poziom wykorzystania infrastruktury, oznaczonego w rozprawie symbolem M-U. Przedstawiono również architekturę modelu, sposób reprezentacji parametrów wpływu w postaci wektorów oraz rolę funkcji modulujących, które odwzorowują zależności pomiędzy atrybutami parametrów, a składowymi wektora wpływu. Rozdział ten formalizuje matematyczne podstawy zaproponowanego podejścia oraz definiuje własności i założenia modelu analitycznego.



Rys. 0.4 Kategorie czynników wpływających na marżę i wykorzystanie infrastruktury stacji

Źródło: opracowanie własne.

W rozdziale 6 zaprezentowano algorytm symulacyjny oparty na opracowanej strukturze wektorowej. Opisano założenia obliczeniowe modelu, procedurę normalizacji parametrów do

wspólnej przestrzeni decyzyjnej oraz sposób agregacji wektorów wpływu w postaci wektora wypadkowego. W rozdziale tym omówiono warstwę obliczeniową modelu stanowiącą podstawę do jego implementacji i realizacji testów symulacyjnych.

W rozdziale 7 przedstawiono implementację komputerową opracowanego algorytmu symulacyjnego oraz przyjętą strukturę danych. Zaprezentowano architekturę autorskiej aplikacji symulacyjnej SIMVEC, strukturę danych wejściowych oraz środowisko obliczeniowe. Opisano proces budowy zestawów danych, procedury kontroli jakości z wykorzystaniem stworzonej na potrzeby rozprawy autorskiej aplikacji SIMDATA oraz sposób realizacji symulacji w aplikacji SIMVEC.

Rozdział 8 poświęcono metodyce przygotowania danych wejściowych, konstrukcji scenariuszy symulacyjnych oraz analizie wyników. Na podstawie wybranych zestawów parametrów i instrumentów biznesowych przeprowadzono symulacje zmian marży i wykorzystania infrastruktury w czasie. Dokonano również oceny zachowania modelu, w tym jego stabilności, wrażliwości na zmiany danych wejściowych oraz spójności uzyskiwanych wyników z przyjętymi założeniami teoretycznymi. Przedstawiono wyniki symulacji, analizę wrażliwości modelu metodą OAT oraz analizę korelacji parametrów. W rozdziale tym, zidentyfikowano również ograniczenia modelu oraz potencjalne źródła błędów, co pozwala określić zakres jego poprawnego stosowania w praktyce.

W rozdziale 9 sformułowano wnioski końcowe wynikające z przeprowadzonych badań, dokonano oceny stopnia realizacji celu rozprawy oraz zweryfikowano postawioną tezę badawczą. Przedstawiono efekty poznawcze i użytkarne opracowanej metody, jako narzędzia wspomagania decyzji operatorów infrastruktury ładowania EV. Wskazano także kierunki dalszych badań, obejmujące rozwój modelu, jego kalibrację na danych rzeczywistych, rozszerzenie do przestrzeni wielowymiarowych oraz możliwość zastosowania w szerszym kontekście zarządzania infrastrukturą energetyczną i transportową.

Realizacja celu rozprawy obejmuje etapy badawcze, które przedstawiono w Tab. 0.1.

Tab. 0.1 Etapy badawcze realizowane w ramach rozprawy

Etap badawczy	Opis etapu
Analiza literatury przedmiotu	Przegląd literatury dotyczącej ekonomiki infrastruktury ładowania pojazdów elektrycznych, metod oceny efektywności ekonomicznej (KPI), dynamicznych uwarunkowań rynkowych oraz istniejących podejść do modelowania decyzji operacyjnych operatorów stacji ładowania EV.
Identyfikacja problemu i luki badawczej	Określenie problemu badawczego polegającego na braku zintegrowanych narzędzi analitycznych umożliwiających jednoczesną ocenę wpływu wielu czynników na marżę handlową i wykorzystanie infrastruktury.

Etap badawczy	Opis etapu
Analiza istniejących modeli decyzyjnych	Analiza stosowanych w praktyce modeli i strategii decyzyjnych operatorów infrastruktury ładowania, ze szczególnym uwzględnieniem polityki cenowej, zarządzania popytem oraz optymalizacji kosztów.
Identyfikacja kluczowych czynników wpływu	Wyodrębnienie i selekcja czynników mających istotny wpływ na kształtowanie wskaźników ekonomicznych stacji ładowania, obejmujących czynniki rynkowe, popytowe, kosztowe, techniczne, marketingowe oraz makroekonomiczne.
Formalizacja czynników w postaci parametrów	Przekształcenie zidentyfikowanych czynników w parametry modelu oraz przypisanie im zestawu atrybutów ilościowych umożliwiających jednoznaczny opis ich charakteru, zakresu zmienności i kierunku oddziaływania na wskaźniki ekonomiczne.
Normalizacja i skalowanie parametrów	Sprowadzenie parametrów modelu do wspólnej przestrzeni decyzyjnej poprzez normalizację i skalowanie, umożliwiające ich porównywanie oraz agregację w ramach struktury wektorowej.
Opracowanie modelu wektorowego 2D	Zaprojektowanie dwuwymiarowego modelu wektorowego w przestrzeni M-U, umożliwiającego geometryczną analizę kompromisu między antagonistycznymi wskaźnikami ekonomicznymi oraz ocenę skumulowanego efektu decyzji operatora.
Projekt algorytmu obliczeniowego	Opracowanie algorytmu realizującego superpozycję wektorów reprezentujących poszczególne parametry wpływu oraz umożliwiającego symulację zmian wartości wskaźników ekonomicznych w odpowiedzi na modyfikacje instrumentów decyzyjnych.
Implementacja komputerowa	Implementacja algorytmu w postaci aplikacji symulacyjnej umożliwiającej analizę scenariuszy decyzyjnych oraz ocenę ich wpływu na marżę handlową i poziom wykorzystania infrastruktury ładowania w zadanym horyzoncie czasowym.
Symulacje scenariuszowe	Przeprowadzenie symulacji dla wybranych zestawów parametrów i instrumentów biznesowych, w tym polityki cenowej, w celu oceny skuteczności zaproponowanej.
Weryfikacja tezy rozprawy	Weryfikacja postawionej tezy poprzez analizę wyników symulacji oraz porównanie uzyskanych rezultatów z efektami prostych strategii decyzyjnych, takich jak podejście koszt-plus-marża.
Ocena użyteczności metody	Ocena przydatności opracowanej metody z perspektywy operatorów infrastruktury ładowania EV oraz wskazanie potencjalnych obszarów jej zastosowania w praktyce operacyjnej i biznesowej.
Wnioski i kierunki dalszych badań	Sformułowanie wniosków końcowych oraz wskazanie kierunków dalszych badań, obejmujących możliwość rozszerzenia modelu do przestrzeni wielowymiarowych oraz jego adaptację do innych obszarów zarządzania infrastrukturą energetyczną i transportową.

Źródło: opracowanie własne.

1. WPROWADZENIE DO PROBLEMATYKI BADAWCZEJ ROZPRAWY

1.1. ISTOTA I ZAKRES PROBLEMATYKI BADAWCZEJ

Rozprawa dotyczy problematyki optymalizacji wskaźników ekonomicznych operatorów infrastruktury ładowania EV. Na wyniki stacji ma wpływ wiele czynników zarówno rynkowych, popytowych, ekonomicznych jak i technicznych, marketingowych czy makroekonomicznych. W kolejnych rozdziałach autor rozprawy starał się zidentyfikować różne czynniki oraz parametry mające wpływ na wskaźniki marży handlowej i wykorzystania infrastruktury stacji ładowania.

Ze względu na złożoność problematyki i dla jednoznaczności przekazu kontekstu całej rozprawy należy wyjaśnić kilka pojęć istotnych z punktu widzenia realizacji celu rozprawy i udowodnienia tezy. Wśród nich należy wymienić m.in. pojęcia elektromobilności, marży handlowej brutto, wykorzystanie infrastruktury stacji ładowania, czynników wpływu, parametrów modelu i atrybutów parametru. każde z tych pojęć zostanie precyzyjnie zdefiniowane w dalszej części rozdziału.

Pojęcie elektromobilności postrzegane jest powszechnie jako obszar rozwoju samochodów elektrycznych nieemitujących szkodliwych związków spalin do środowiska w miejscu ich użytkowania. Cały obszar zagadnień dotyczących transportu pojazdami elektrycznymi nazywanymi też jako zeroemisyjne stał się ważnym elementem ekonomicznym, społecznym i technologicznym w agendzie wielu krajów [79].


Jednym z kluczowych czynników warunkujących rozwój elektromobilności jest dostępność infrastruktury do ładowania pojazdów elektrycznych, a dokładniej rozbudowana i wydajna sieć stacji ładowania. Infrastruktura ta stanowi niezbędne ogniwo w łańcuchu wartości transportu zeroemisyjnego, umożliwiając praktyczne użytkowanie pojazdów elektrycznych w codziennej aktywności obywateli.

Stacje ładowania, podobnie jak inne elementy infrastruktury energetycznej, funkcjonują w oparciu o zasady rachunku ekonomicznego, w którym wynik finansowy determinowany jest relacją pomiędzy przychodami ze sprzedaży energii, a strukturą kosztów obejmującą m.in.: zakup energii elektrycznej, opłaty dystrybucyjne, koszty mocy zamówionej, amortyzację infrastruktury oraz koszty operacyjne. Rentowność stacji ładowania jest w dużej mierze

uzależniona od poziomu wykorzystania infrastruktury oraz zdolności operatora do kształtowania marży od sprzedaży na pożądanym poziomie.

Jednocześnie operatorzy stacji ładowania funkcjonują w środowisku charakteryzującym się wysoką zmiennością cen energii elektrycznej, nasilającą się konkurencją cenową pomiędzy operatorami oraz relatywnie niską lojalnością użytkowników końcowych, którzy podejmują decyzje zakupowe w oparciu o bieżącą dostępność i poziom cen. Uwarunkowania te powodują, że tradycyjne metody zarządzania ekonomiką stacji, w tym statyczne modele ustalania cen okazują się niewystarczające, wymuszając wdrażanie bardziej elastycznych i reaktywnych narzędzi, aby umożliwić adaptację do zmieniających się warunków rynkowych [79].

Jednym z przykładów takich narzędzi są nowe strategie kształtowania cen. Klasyczne modele oparte są głównie na kosztach zakupu energii i docelowej marży. Jednak w nowym kontekście okazują się one niewystarczające, ponieważ nie uwzględniają szeregu uwarunkowań takich jak elastyczność cenowa klientów, sezonowość, natężenie ruchu czy działania konkurencji [3]. Proponowane w literaturze rozwiązania tego problemu wskazują na koncepcje integrujące wpływ powyższych czynników w jeden spójny model wspierający automatyczne podejmowanie decyzji opartych usystematyzowane zbiory danych [5]. Mogą to być m.in. mechanizmy automatycznego ustalania dynamicznych cen, kampanii lojalnościowych, polityk flotowych itp. (Rys. 1.1) w celu utrzymania ekonomiki stacji na pożądanym trajektorii rozwoju i dochodowości.



Rys.1.1 Możliwość automatyzacji dynamicznych cen (potencjał rozwojowy modelu)

Źródło: opracowanie własne.

Fundament ekonomiki operatora infrastruktury ładowania pojazdów elektrycznych koncentruje się na trzech podstawowych komponentach determinujących efektywność funkcjonowania i długoterminową stabilność finansową: marży, stopniu wykorzystaniu infrastruktury ładowania oraz strukturze kosztowej [27],[28]. **Marża w rozprawie, jest**

rozumiana zgodnie z definicją Głównego Urzędu Statystycznego, który opisuje ją jako cenę usługi handlowej stanowiącą różnicę między ceną zakupu a ceną sprzedaży, przeznaczoną na pokrycie kosztów handlowych i osiągnięcie zysku [57].


Wysoka marża, choć korzystna z punktu widzenia wskaźników finansowych (np. EBITDA), może prowadzić do zmniejszenia liczby klientów w wyniku pogorszenia atrakcyjności cenowej stacji względem konkurencji. Zatem drugim istotnym elementem struktury ekonomicznej jest tzw. wskaźnik wykorzystania infrastruktury stacji ładowania. Wskaźnik ten może być określany według różnych interpretacji jednostką czasu, kwotą lub jednostką mocy [70].

W rozprawie wykorzystano definicję wykorzystania mocy produkcyjnych CU (Capacity Utilization), które należy rozumieć jako “poziom wykorzystania maksymalnej mocy infrastruktury”, a dokładniej jako relację pomiędzy ilością energii, którą można sprzedać poprzez infrastrukturę stacji, do faktycznego poziomu sprzedaży energii w mierzonym okresie. Zatem jest to wskaźnik poziomu wykorzystania potencjału infrastruktury ładowania z uwzględnieniem wydajności punktu ładowania i dostępnej mocy z sieci. Wysokie wykorzystanie infrastruktury świadczy o efektywnym zagospodarowaniu zasobów a wartość tego wskaźnika jest silnie zależna od szeregu czynników takich jak: lokalizacja, konkurencja, sezonowość, a także percepcja wartości usługi przez użytkowników końcowych.

Trzeci komponent to koszty operacyjne, które stanowią wieloskładnikową strukturę obejmującą zarówno koszty bezpośrednie, jak i pośrednie. Wśród najistotniejszych pozycji kosztowych wyróżnić należy zakup energii z dynamiczną ceną zależną od źródła i momentu zużycia, opłaty taryfowe OSD, nakłady na utrzymanie techniczne infrastruktury, amortyzację środków trwałych, a także koszty stałe związane z personelem, podatkami lokalnymi i administracją.

Złożoność czynników wpływających na ostateczny wynik ekonomiczny stacji ładowania powoduje, że decyzje podejmowane w tak niepewnym środowisku mogą prowadzić do niepożądanych efektów, na co wskazuje w swojej publikacji D. Mazurkiewicz [5]. Warto też podkreślić że opisane problemy decyzyjne są interdyscyplinarne i dotyczą również innych sektorów transportu [19]. W niniejszej rozprawie podjęto próbę opracowania narzędzia, które pozwoli zbadać zasadność przyjętej tezy, że (parafrazując tezę rozprawy) zastosowanie zaawansowanych metod i narzędzi analitycznych może poprawić wskaźnik zyskowności stacji [4]. Szczególnie trudnym wyzwaniem pozostaje pogodzenie sprzecznych celów: maksymalizacji marży z jednej strony i utrzymanie wysokiego wykorzystania infrastruktury


z drugiej. Z tego powodu marża i wykorzystanie infrastruktury są traktowane w pracy jako wskaźniki antagonistyczne (Rys. 1.2.).



Rys. 1.2 Antagonistyczny charakter marży i wykorzystania infrastruktury

Źródło: opracowanie własne.

Wsparcie w rozwiązaniu tego typu dylematów może stanowić model umożliwiający kompleksową analizę wpływu wielu parametrów oraz ich wzajemnych interakcji na oba wskaźniki jednocześnie (Rys. 1.3). Należy w tym miejscu podkreślić, że trzeci wskaźnik, tj. koszty operacyjne został uwzględniony jako jeden z parametrów pośrednich wpływających na wskaźniki końcowe.




Rys. 1.3 Wynik końcowy jako suma czynników składowych

Źródło: opracowanie własne.

Na podstawie analizy źródeł m.in. [64] - [69],[74] naukowych i branżowych, aktualnych trendów i potrzeb w obszarze elektromobilności oraz własnych doświadczeń zawodowych (wieloletnia praca przy projektach elektromobilności), została zidentyfikowana luka badawcza w zakresie rozwoju zaawansowanych narzędzi wsparcia CPO w decyzjach biznesowych, z uwzględnieniem szerokiego spektrum dynamicznych czynników m.in. rynkowych, popytowych, marketingowych, pogodowych, technicznych itp.

Na podstawie analizy dostępnych źródeł literaturowych m.in. [20], [62], [34], [37], [43], [48], [51] oraz własnych doświadczeń, zostały zidentyfikowane i wybrane czynniki, które w sposób istotny wpływają na końcową wartość marży i wykorzystania infrastruktury stacji. W toku systematycznej pracy analitycznej czynniki te zostały następnie mapowane na obiekty matematyczne nazywane dalej parametrami modelu. Natomiast wartości parametrów zostały opisane przez zbiory przypisanych im atrybutów stanowiących swego rodzaju ilościowy opis każdego z parametrów (Rys. 1.4). Mając na uwadze jednoznaczność rozumienia używanych pojęć oraz dla prawidłowego toku rozumowania, wymagają one dokładnego wyjaśnienia i opisu relacji między nimi.



Rys. 1.4 Relacje między głównymi elementami modelu

Źródło: opracowanie własne.

Pojęcie wskaźnika stosowane jest w niniejszej pracy zamiennie z akronimem KPI (ang. Key Performance Indicator - kluczowy wskaźnik efektywności), który odnosi się do miar służących ocenie efektywności. Wprowadzenie tej konwencji terminologicznej podyktowane jest potrzebą zapewnienia wysokiej czytelności warstwy graficznej oraz tabelarycznej opracowania, a także dbałością o ekonomię języka w toku prowadzonej analizy. W tym przypadku służy ocenie ekonomiki stacji ładowania. Potencjalny zbiór KPI jest szeroki, jednak w rozprawie przyjęto dwa kluczowe wskaźniki, uznane za fundamentalne z punktu widzenia operatora infrastruktury ładowania, tj. marżę jednostkową oraz wykorzystanie infrastruktury.


Pojęcie parametru może mieć charakter wieloznaczny semantycznie. W pracy przyjęto definicję według Wielkiego słownika języka polskiego PAN [53], w której parametr rozumiany jest jako wielkość wyrażona liczbowo, za pomocą, której charakteryzuje się i ocenia urządzenie, proces lub zjawisko. W rozprawie znaczenie tego terminu zostało użyte do oceny zjawiska i mapowane do “parametru modelu”, przez który rozumiany jest jeden z wielu czynników wpływających na wartości przyjętych wskaźników KPI.

Trzecim kluczowym pojęciem wykorzystywanym w rozprawie jest atrybut, definiowany jako cecha rzeczy, osoby lub zjawiska, wyróżniająca je spośród innych. W kontekście opracowanego modelu atrybuty są przypisywane poszczególnym parametrom i służą ilościowemu opisowi najistotniejszych właściwości zjawiska reprezentowanego przez dany parametr. Należy przy tym podkreślić, że pojedynczy parametr może być opisywany przez wiele atrybutów, które łącznie określają jego charakter i wpływ na analizowane wskaźniki.

Dla zilustrowania zależności pomiędzy pojęciami wskaźnika, parametru i atrybutu przytoczony został przykład zaczerpnięty wprost z opracowanego modelu. Na wartość wskaźnika wykorzystania infrastruktury wpływa wiele czynników, wśród których istotną rolę odgrywają uwarunkowania pogodowe oraz sezonowe. Warunki atmosferyczne, w tym szczególnie sezon wakacyjny, mają bezpośredni wpływ na intensywność podróży podejmowanych przez kierowców oraz na efektywny zasięg pojazdów elektrycznych, który w temperaturach letnich jest wyraźnie wyższy niż w okresach niskich temperatur.

W modelu obserwacje te zostały odwzorowane w postaci parametrów określonych jako sezonowość oraz warunki pogodowe. Parametry te poddano dalszej analizie ilościowej poprzez przypisanie im odpowiednich atrybutów, którymi w tym przypadku są m.in. temperatura otoczenia oraz miesiąc roku. W ten sposób, wychodząc od identyfikacji czynnika zewnętrznego (bodźca sezonowo-pogodowego) istotnego z punktu widzenia wpływu na badany wskaźnik (w tym przypadku: wykorzystanie infrastruktury), uzyskujemy fragment modelu w postaci parametru, którego właściwości są następnie precyzyjnie opisywane za pomocą zestawu atrybutów ilościowych. Analogiczna procedura stosowana jest w odniesieniu do pozostałych czynników wpływających na analizowane wskaźniki ekonomiczne. Każdy zidentyfikowany czynnik jest najpierw formalizowany w postaci parametru modelu, a następnie dekomponowany na zbiór przypisanych mu atrybutów. W rezultacie, dzięki identyfikacji możliwie szerokiego zbioru parametrów oraz odpowiadających im atrybutów, uzyskuje się syntetyczny, uporządkowany opis złożonych zjawisk biznesowych, które jako agregat tworzą opracowywany model analityczny.

Opisana w rozprawie dwuwymiarowa struktura w przestrzeni $\mathbb{R}^2$, której współrzędne reprezentują odpowiednio na osi odciętych wskaźnik marży, i na osi rzędnych wskaźnik poziomu wykorzystania infrastruktury. Przestrzeń ta oznaczona w rozprawie symbolem M-U stanowi w proponowanej postaci narzędzie do jednoczesnego opisu antagonistycznych wskaźników za pomocą powyższych zależności. W kolejnych krokach każdy parametr wpływu reprezentowany jest wektorem o określonym kierunku i normie, co pozwala algorytmowi na geometryczne analizowanie ich wzajemnych oddziaływań i uzyskanie syntetycznego wskaźnika umożliwiającego prognozowanie parametrów ekonomicznych stacji. Dzięki takiemu narzędziu operator otrzymuje możliwość symulacji skutków zmian cen oraz skutków zastosowania innych instrumentów biznesowych przed ich wprowadzeniem. Pozwala to następnie wdrożyć uzasadnione polityki cenowe, lojalnościowe lub inwestycyjne które przy udziale czynników zewnętrznych dobrze rokują w zakresie utrzymania stacji na oczekiwanej trajektorii marży i wykorzystania infrastruktury (Rys. 1.5).



Rys.1.5 Pożądana trajektoria rozwoju wskaźników ekonomicznych stacji

Źródło: opracowanie własne.

Zaletą modelu jest też jego skalowalność. Praca koncentruje się na przestrzeni dwuwymiarowej, jednak koncepcja bez przeszkód może zostać rozszerzona do wymiarów trzeciego i czwartego, co może otworzyć nowe perspektywy badawcze i pozwoli zwiększyć potencjał analityczny algorytmu. Z punktu widzenia polityki publicznej tak precyzyjnie opisane

narzędzie może służyć również regulatorom dostarczając potrzebnych wskaźników KPI do kształtowania środowiska prawnego i programów wsparcia [50], natomiast przedsiębiorcom będącym głównymi beneficjentami umożliwia lepsze zarządzanie polityką cenową.

Interdyscyplinarność proponowanego rozwiązania - łącząca inżynierię transportu, modelowanie matematyczne, ekonomię i informatykę - wnosi zarówno aspekt innowacyjności, jak i użyteczność praktyczną. Implementacja algorytmu w systemach typu ERP lub CMS może przełożyć się na wymierną poprawę wyników finansowych operatorów, a w szerszej perspektywie przynieść korzyści konsumentom poprzez obniżenie kosztów ładowania i zwiększenia dostępności usług. Tym samym praca tworzy fundament do dalszych badań nad zaawansowanymi modelami optymalizacyjnymi w branży elektromobilności i stanowi wkład w rozwój wiedzy o zarządzaniu infrastrukturą stacji ładowania pojazdów elektrycznych.

1.2. WYZWANIA I PROBLEMY ROZWOJU ELEKTROMOBILNOŚCI W LITERATURZE

Obecny rozwój elektromobilności odbywa się w warunkach bardzo dużej zmienności rynku energii, nowych regulacji i wymagań środowiskowych oraz konkurencji rynkowej. Jednym z kluczowych wyzwań są silne wahania hurtowych cen energii elektrycznej, które w Europie mogą sięgać nawet kilkudziesięciu procent w krótkich okresach. Zmienność ta bezpośrednio wpływa na koszty funkcjonowania infrastruktury ładowania oraz na stabilność ekonomiczną jej operatorów [79]. W takich realiach tradycyjne sztywne taryfy cenowe nie są dobrym rozwiązaniem, ponieważ każda decyzja cenowa automatycznie rzutuje na równowagę między marżą a poziomem wykorzystania infrastruktury operatora. Wzrost stawki poprawia jednostkowy zysk, ale wywołuje negatywną reakcję popytu i spadek wykorzystania spowodowany redukcją wolumenu sesji ładowania (ilości ładowań w badanym okresie). Zależność tą potwierdzają badania elastyczności cenowej w segmencie usług ładowania [6].

Dodatkowym problemem jest nieregularność i nieprzewidywalność przychodów wynikająca ze wspomnianej zmienności kosztu. W samej Europie w 2024 roku odnotowano tysiące godzin z cenami ujemnymi, co stwarza potencjalne okazje do chwilowego zwiększania marży, ale często stanowi narzędzie walki konkurencyjnej. Zmienność taka, wygląda na pozornie korzystną, ale w rzeczywistości utrudnia długoterminowe planowanie finansowe operatorów, ponieważ epizody korzystnych cen nie równoważą ryzyka nagłych wzrostów kosztów w warunkach sztywnych taryf [7]. Zagadnienie przewidywalności w zakresie finansowym oraz popytowym stanowi poważne wyzwanie dla branży elektromobilności.

W tak chwiejnej rzeczywistości algorytmiczne wspomaganie decyzji staje się coraz bardziej pożądanym rozwiązaniem, umożliwiającym np. przeniesienie popytu z godzin szczytu na okresy niższego zapotrzebowania i zwiększenie przewidywalności dla wszystkich uczestników rynku. Badania wykazały, że takie mechanizmy mogą zredukować wykorzystanie szczytowe sieci nawet o 9,8%, co przekłada się na niższe koszty operacyjne i lepsze wykorzystanie infrastruktury [8]. Redukcja tego zjawiska ma dodatkowy walor środowiskowy obniżający emisję CO₂ [18].

Rozwój elektromobilności wiąże się również z wysokimi barierami inwestycyjnymi. Infrastruktura szybkiego i ultraszybkiego ładowania należy do najbardziej kapitałochłonnych elementów systemu transportu zeroemisyjnego [25]. Koszt pojedynczego punktu ładowania prądem stałym może przekraczać 100 000 USD, a całkowite nakłady inwestycyjne, uwzględniające przyłącza energetyczne i modernizację sieci, często sięgają poziomu kilku milionów dolarów [85]. W konsekwencji decyzje lokalizacyjne oraz tempo rozbudowy sieci obarczone są znacznym ryzykiem finansowym. Wyzwania te wymagają wsparcia IT i podejścia algorytmicznego zarówno w zakresie oceny opłacalności nowych lokalizacji, jak i zarządzania obecnymi punktami.

Kolejnym istotnym problemem jest różnorodność użytkowników pojazdów elektrycznych oraz ich oczekiwań wobec infrastruktury ładowania. Na przykład kierowcy podróżujący na długich dystansach, wykazują się akceptacją do ponoszenia wyższych kosztów w zamian za szybkość i niezawodność usługi, podczas gdy użytkownicy ładujący pojazdy w codziennych dojazdach są znacznie bardziej wrażliwi cenowo [10]. Zróżnicowanie to komplikuje proces kształtowania jednolitych strategii taryfowych i operacyjnych.

Istotną rolę w rozwoju elektromobilności odgrywają również warunki pogodowe, które mają coraz większy wpływ na strukturę kosztową profilu energetycznego ze względu na rosnący wkład OZE. Z punktu widzenia ochrony środowiska jest to zjawisko pożądane, ale rośnie ryzyko zaburzeń podaży energii w przypadku niekorzystnych zjawisk pogodowych, które mogą powodować zarówno przeciążenia jak i niedobory sieci oraz spadek niezawodności infrastruktury. Zmienność tych uwarunkowań zwiększa niepewność operacyjną i inwestycyjną dla całego sektora. Aby zapewnić ciągłość działania stacji np. w przypadku fali upałów lub ekstremalnych mrozów potrzebne są nowe rozwiązania pozwalające np. na optymalizację rozkładu popytu, kompensowanie opisanych skrajności i utrzymanie stabilności finansowej stacji. Jednocześnie stosowanie tych metod wymaga uwzględnienia aspektu wizerunkowego w oczach klientów, co istotnie wpływa na ich końcowe decyzje zakupowe [11].

Na rynkach bez odpowiednich regulacji poważnym problemem są również bardzo wysokie opłaty związane z mocą zamówioną i szczytowym zapotrzebowaniem na energię (tzw. demand charges). W wielu taryfach koszty te mogą stanowić dominującą część miesięcznych rachunków za energię elektryczną, sięgając nawet 80-90% całkowitych opłat [12]. Wysokie i trudne do przewidzenia wykorzystania z tego tytułu stanowią istotną barierę ekonomiczną dla ekspansji infrastruktury ładowania. Jest to szczególnie dotkliwe w początkowych fazach rozwoju, gdzie nakłady kapitałowe na pojedynczy punkt DC o mocy 150 kW mogą przekraczać 100 tys. EUR, a rentowność w pierwszych latach zależy od przewidywanego wykorzystania infrastruktury [13].

Równolegle z tymi wyzwaniami pojawiają się również dylematy regulacyjne i standaryzujące dostęp do informacji. Z jednej strony instytucje regulujące rynek dążą do zwiększenia przejrzystości rynku oraz ochrony konsumentów, z drugiej zaś nadmierna ingerencja administracyjna może ograniczać elastyczność operatorów i hamować innowacje. Skuteczne zarządzanie rozwojem elektromobilności wymaga spójnych ram regulacyjnych, wspierających inwestycje, a jednocześnie umożliwiających adaptację do lokalnych warunków rynkowych [14]. Jednak stworzenie i upowszechnienie spójnych ram, wymaga przełamania problemów tzw. silosów danych. Zjawisko to jest częściowo neutralizowane poprzez powstawanie standardów interoperacyjności i wymiany danych. Rozwiązania te umożliwiają agregację informacji z rozproszonych źródeł w celu ich dalszej analizy, czego przykładem jest protokół OCPP [15].

Z powyższej analizy wypływa wniosek, że rozwój elektromobilności odbywa się w warunkach wysokiej niepewności inwestycyjnej. Złożoność uwarunkowań ekonomicznych, technologicznych i rynkowych sprawia, że operatorzy infrastruktury ładowania muszą mierzyć się z szeregiem dylematów związanych z opłacalnością inwestycji, stabilnością przychodów oraz dostosowaniem oferty do zmieniających się potrzeb użytkowników. Te wyzwania stanowią istotne tło dla dalszych rozważań prowadzonych w kolejnych częściach rozprawy.

1.3. LUKA BADAWCZA I PRAKTYCZNY PROBLEM NA JAKI ODPOWIADA ROZPRAWA

W literaturze przedmiotu zidentyfikowano liczne rozwiązania skupiające się na wybranych etapach procesu decyzyjnego operatora punktu ładowania (CPO - Charge Point Operator) oraz analizie wpływu podejmowanych decyzji na wyniki funkcjonowania stacji.

Poniżej zaprezentowano wybrane pozycje odzwierciedlające przekrojowo różne metody rozwiązywania analizowanego problemu.

Najczęściej spotykanym podejściem jest wprowadzanie dynamicznie kształtowanych cen. W roku 2024 Kazemtarghi przedstawił strategię dynamicznych cen, która zachęca kierowców EV do przenoszenia się z zatłoczonych stacji do mniej obciążonych poprzez odpowiednie różnicowanie stawek opłat [64]. Celem jest rozładowanie kongestii i maksymalizacja przychodu operatora. Inni autorzy rozwinęli koncepcję algorytmów cenowych czasu rzeczywistego i taryf czasowych (TOU), które uwzględniają krzywą popytu i koszty energii. Na przykład opracowano modele optymalizacji cen, które z jednej strony maksymalizują zysk operatora, a z drugiej minimalizują koszty ponoszone przez użytkowników i wykorzystanie sieci [74]. W literaturze można również odnaleźć metody uczenia maszynowego wyznaczające optymalne profile cen w zależności od pory dnia, lokalizacji i bieżącego wykorzystania stacji, rozkładając ruch pojazdów w czasie [64], [65].

Równolegle rozwijane są rozwiązania z zakresu tzw. smart charging, czyli inteligentnego sterowania procesem ładowania. Techniki takie jak harmonogramowanie ładowania EV są wykorzystywane również do przesuwania wykorzystania w czasie i uniknięcia przeciążeń sieci [66], [67]. Badania pokazują, że zapotrzebowanie na ładowanie silnie zmienia się w zależności od pory dnia i lokalizacji. Na przykład w dni robocze większość ładowań odbywa się w ciągu dnia, natomiast w weekendy profil jest odmienny, co przekłada się na okresy nadmiernego wykorzystania stacji oraz okresy przestojów.

Istnieją również narzędzia analityczne integrujące dane historyczne o sesjach ładowania, które pozwalają prognozować popyt i na tej podstawie sterować procesem ładowania (np. poprzez opóźnienie lub przyspieszenie rozpoczęcia ładowania pojazdów flotowych). Zwiększa to średnią wykorzystanie infrastruktury stacji i zapobiega kosztownym szczytom mocy [68],[69].

W niektórych krajach dużym wykorzystaniem dla operatorów punktów ładowania (CPO), są opłaty za szczytowe pobory mocy (tzw. demand charges), które mogą znacznie obniżyć marżę [74]. W odpowiedzi na ten problem pojawiają się rozwiązania integrujące infrastrukturę ładowania z rynkiem energii elektrycznej oraz magazynami energii. Sayarshad w pracy z 2024r. proponuje np. rozwiązanie, w którym operator stacji wyznacza strategię zakupu energii na rynku hurtowym i określa optymalną ilość energii do zakupu na rynku dzień wcześniej oraz cenę ofertową, minimalizując koszt zasilania stacji przy jednoczesnym pokryciu zapotrzebowania [69]. Dodatkowo model ten uwzględnia korekty w rynku dnia bieżącego, co pozwala dostosować się do zmiennych warunków i dalej optymalizować wynik finansowy.

Istnieją również analizy krajowe oceniające np. obłożenia stacji w różnych porach doby oraz dniach tygodnia, co ma pomóc operatorom w planowaniu zapotrzebowania na moc i lokalizacji nowych punktów.

Na rynku chińskim proponowane są metody analizy obwiedni danych (DEA). Np. Wang stosuje tą metodę do oceny efektywności stacji. [66]. W wynikach pracy wykazuje, że głównymi przyczynami niskiej efektywności są niedopasowanie podaży do popytu oraz nadmierne moce w źle dobranych lokalizacjach. Na podstawie tych wyników zaproponowano dostosowanie liczby i mocy ładowarek do rzeczywistego ruchu EV w danej okolicy.

Mimo znacznego rozwoju narzędzi wsparcia decyzyjnego istnieją wyraźne braki w zakresie praktycznych rozwiązań problemów i wyzwań z którymi mierzą się operatorzy punktów ładowania pojazdów elektrycznych (CPO). Dostępne narzędzia decyzyjne borykają się z wyzwaniami implementacyjnymi i akceptacją rynkową. Przekrojowa analiza przeprowadzona w roku 2025 przez Ghanbari [68] wskazuje, że brakuje obecnie spójnych metod uwzględniających wahania popytu i niepewności co do zachowań użytkowników oraz nieprzewidywalności co do profilu energetycznego w ramach OZE. Dotychczasowe prace pomijają dynamiczny charakter tych czynników, czyli np. zmienność liczby podłączanych pojazdów w czasie czy szybkie wahania cen energii. Niepewność popytu może skutkować niewłaściwymi decyzjami cenowymi, np. niedoszacowana cena w szczycie generuje falę popytu, która może powodować kolejki i frustrację klientów. Aktualne badania sygnalizują też potrzebę opracowania i wdrażania metod prognostycznych i adaptacyjnych, które mogłyby automatycznie podejmować decyzje w oparciu o bieżące dane [68].

Kolejna luka dotyczy braku połączenia celów ekonomicznych z zapewnieniem niezawodności usług i zadowolenia użytkowników. Wiele rozwiązań skupia się jedynie na maksymalizacji zysku operatora pomijając potencjalne konsekwencje tego uproszczenia. Stosowane przez operatorów strategie nastawione wyłącznie na maksymalizację marży powodują negatywne efekty uboczne m.in. w postaci przeciążeń i awarii, co w dłuższej perspektywie wpływa negatywnie na wolumen sprzedaży operatora. Zhang opisuje np. takie scenariusze, w których niekontrolowana jednowymiarowa optymalizacja pod kątem marży może prowadzić w konsekwencji do zaburzenia całej polityki cenowej [65]. Odwrotne skupienie wyłącznie na wydajności infrastruktury bez względu na marżę może również prowadzić do nieoptymalnych decyzji biznesowych. Są to typowe przykłady ignorowania szerszego kontekstu operacyjnego. Konieczne jest zatem wprowadzenie rozwiązań wspomagających równoważenie celów finansowych ze stabilnością i jakością usług.

Brakuje podejścia holistycznego, które łączy wszystkie aspekty efektywności operacyjnej, ponieważ większość prac adresuje je oddzielnie. Przykładem może być praca Bagherzadeh koncentrująca się na długoterminowej maksymalizacji zysku stacji w warunkach niepewności kosztów i popytu [67]. Natomiast Wang skupia się na ocenie efektywności wykorzystania zasobów stacji i identyfikacji strat spowodowanych niskim wykorzystaniem [66]. Są to typowe przykłady braku podejścia zintegrowanego, które wymaga analizy wzajemnego wpływu na siebie dużej ilości zmiennych w czasie czynników.

Ta luka staje się szczególnie widoczna w kontekście decyzji operacyjnych, a dostępne narzędzia nie oferują dedykowanej dla elektromobilności metody analizy i wsparcia menedżerów CPO w tym zakresie. W literaturze podkreśla się także niedobór badań uwzględniających aspekty prywatności i cyberbezpieczeństwa przy zbieraniu i przetwarzaniu danych z infrastruktury ładowania [68], co również stanowi lukę wymagającą zaadresowania.

Zidentyfikowana luka badawcza przekłada się wprost na problem biznesowy wielu menedżerów CPO, który skutkuje podejmowaniem nieoptymalnych decyzji biznesowych, często opartych na nieprecyzyjnych i nieaktualnych przesłankach lub po prostu opartych jedynie o intuicję menadżera. Problemy i wyzwania związane ze zmiennością czynników wpływających na sektor stacji ładowania EV, wymagają zaproponowania nowego holistycznego podejścia, które dałoby operatorom narzędzie do racjonalizacji procesów decyzyjnych [22], [17]. Według obserwacji autora istnieje realne zapotrzebowanie na systemy wsparcia decyzji, dzięki którym operator mógłby testować różnorodne strategie (np. wprowadzenie planów flotowych, inwestycje w magazyny energii i budowę stacji w nowych lokalizacjach o innej strukturze konkurencyjnej). W efekcie mógłby uzyskać oszacowanie skumulowanego wpływu takiego pakietu na marżę i wykorzystanie infrastruktury dla pojedynczej stacji lub grupy stacji. Jest to istotna nowość względem wcześniejszych badań, gdzie zwykle analizowano pojedyncze elementy w izolacji. Istotnym aspektem jest również uwzględnienie zmienności i dynamiki czynników zewnętrznych, których udział stanowi warunek sine qua non dla systemów o charakterze predykcyjnym lub adaptacyjnym. Problem ten ma naturę systemową i nie ogranicza się wyłącznie do elektromobilności, ale dotyczy szerokiego spektrum systemów wspomagania decyzji oraz szeroko rozumianego transportu, co znajduje odzwierciedlenie m.in. w publikacjach Z. Pietrzykowskiego [19].

Przeprowadzony przegląd literatury ujawnia, że operatorzy infrastruktury ładowania EV dysponują pewną bazą narzędzi wspierających optymalizację ekonomiczną, jednak nie udało się znaleźć metody zapewniającej zintegrowane podejście w jednym spójnym modelu z uwzględnieniem nieliniowego charakteru czynników wpływu. Potrzebne jest zatem


kompleksowe rozwiązanie pomagające operatorom szukać kompromisu między rentownością, a dostępnością usług oraz testować scenariusze biznesowe w różnorodnych konfiguracjach i warunkach zmiennego otoczenia [22].

2. CEL, TEZA I ZAKRES ROZPRAWY

2.1. KONTEKST I MOTYWACJA BADAWCZA

Dynamiczny rozwój elektromobilności, wymagania klimatyczne oraz idące za tym regulacje spowodowały wiele zmian na rynku elektromobilności. Generuje to szereg nowych wyzwań dla operatorów stacji ładowania EV i wymusza na nich konieczność redefinicji strategii operacyjnych, oraz adaptację mechanizmów sterowania infrastrukturą do dynamicznie zmiennych uwarunkowań systemowych. W szczególności dotyczy to innego podejścia do ustalania ceny energii dla klientów danej stacji ładowania. Strategia taryfy ustalonej na podstawie stałej marży naliczanej do aktualnej ceny energii jest nieadekwatna w warunkach zmienności opisanych we wprowadzeniu do rozprawy, na co wskazują m.in. badania D. Mazurkiewicza [5].

W konsekwencji decyzje biznesowe podejmowane przez menedżera wyłącznie na podstawie jego intuicji i doświadczenia w tak zmiennym i dynamicznym środowisku (Rys. 2.1), obarczone mogą być ryzykiem błędów. Struktura kosztów energii elektrycznej, opłat dystrybucyjnych i kosztów kapitałowych oraz rosnąca konkurencja między sieciami ładowania sprawiają, że to proste podejście do ustalania polityki biznesowej przestały być wystarczające.




Rys. 2.1. Złożoność czynników wpływających na decyzje biznesowe operatora stacji ładowania

Źródło: opracowanie własne.

W warunkach dynamicznej zmienności cen na rynku hurtowym, zmienności popytu oraz presji regulacyjnej na wyrównywanie zapotrzebowania sieci energetycznych, decyzje podejmowane wyłącznie na bazie intuicji menedżera, coraz częściej prowadzą do nieoptymalnego wykorzystania infrastruktury i obniżenia rentowności stacji.

Przedstawione w rozdziale 1 badania wskazują, że na wynik ekonomiczny stacji ładowania, wpływa w rzeczywistości wiele grup czynników: rynkowych, popytowych, kosztowych, technicznych, marketingowych lub makroekonomicznych (Rys. 2.1). Część z nich ma charakter egzogeniczny i pozostaje poza kontrolą operatora (np. hurtowa cena energii, regulacje, natężenie ruchu w danej lokalizacji) (Rys. 2.2). Czynniki te nazywane są w pracy parametrami zewnętrznymi. Natomiast druga część czynników o charakterze endogenicznym może być kształtowana przez operatora za pomocą instrumentów biznesowych, takich jak: poziom ceny detalicznej, struktura rabatów i abonamentów, moc udostępniana użytkownikom, czy działania lojalnościowe dla klientów. Ta grupa czynników jest nazywana w pracy parametrami wewnętrznymi.



Rys. 2.2 Dwie grupy czynników wpływających na wynik ekonomiczny stacji ładowania

Źródło: opracowanie własne.

Opisana złożoność sprawia, że ustalenie ceny energii dla klientów danej stacji ładowania jest złożonym problemem decyzyjnym. Złożoność i wzajemne sprzężenia wymienionych czynników tworzą wieloaspektowy problem decyzyjny, który wymaga pogłębionej analizy i formalnego uporządkowania, wsparcia decyzji i automatyzacji działań decyzyjnych. Znaczenie problemu wzrasta ze względu na jego odniesienie do szerokiego spektrum dziedzin

transportu, co znajduje odzwierciedlenie w badaniach prowadzonych przez Z. Pietrzykowskiego [19].

Przedstawiona w rozdziale 1 analiza literatury naukowej i praktyki rynkowej opisuje typową strategię cenową „koszt plus marża”, taryfy typu „time-of-use” lub strategię opartą o proste reguły „dynamic pricing”, w których zmiana ceny wynika z relacji jednego lub dwóch parametrów referencyjnych. Nie znaleziono w literaturze narzędzia, które w sposób jednoznaczny pozwalałoby uwzględnić wielowymiarowe i nieliniowe uwarunkowania ekonometryczne stacji i wpływ wielu parametrów oraz ich nieliniowej dynamiki na kluczowe wskaźniki: marży jednostkowej oraz wykorzystania infrastruktury. Marża dla właścicieli stacji stanowi istotny wskaźnik świadczący o opłacalności prowadzonego biznesu. Natomiast wykorzystanie potencjału jest wskaźnikiem pozwalającym ocenić, czy stacja jest prowadzona zgodnie z założeniami inwestora i czy jest ona na ścieżce do uzyskania oczekiwanego ROI.


Dlatego zasadnym jest poszukiwanie narzędzia, które będzie stanowiło wsparcie dla menedżerów ustalających jednocześnie wskaźniki: marży jednostkowej oraz wykorzystania infrastruktury z uwzględnieniem wspomnianego wcześniej szerokiego spektrum czynników: rynkowych, popytowych, kosztowych, technicznych, marketingowych, makroekonomicznych itp. W każdej grupie zidentyfikowanych czynników ustalono kilka istotnych parametrów, które mają wpływ na wskaźniki marży jednostkowej oraz wykorzystania infrastruktury. Problemem jest ustalenie zakresu tego wpływu, co jest istotne nie tylko z naukowego punktu widzenia, ale również z potrzeb praktyki gospodarczej.

Tak zidentyfikowana luka oraz realna potrzeba rynkowa stała się bezpośrednią motywacją do podjęcia badań. Zatem rozprawa ma na celu opracowanie dwuwymiarowego modelu wektorowego, w którym zostanie uwzględniony szeroki zakres czynników (parametry modelu pokazane na poglądowym Rys. 2.3), wpływających na ustalenia wyniku ekonomicznego danej stacji ładowania w wymiarze marży i wykorzystania infrastruktury.

Każdy ze zdefiniowanych parametrów, reprezentowany jest przez wektor o określonym kierunku i module wpływającym jednocześnie na marżę oraz wykorzystanie infrastruktury. Należy podkreślić, że wektor ten jest w modelu obiektem dynamicznym zmieniającym kierunek i moduł wraz ze zmianą charakterystyki parametrów w czasie.

Takie ujęcie wpływu każdego uwzględnianego parametru pozwala na analizę sumy oddziaływań pomiędzy nimi. Ponadto pozwala na obliczenie wypadkowego wektora wpływu będącego sumą geometryczną poszczególnych wektorów składowych (parametrów), opisując w efekcie przewidywaną zmianę marży i wykorzystania infrastruktury stacji. Podejście to

bazuje na modelu integrującym wieloobszarowy zakres nieliniowych czynników wpływu, zunifikowanych w obrębie wspólnej przestrzeni geometrycznej.



Rys. 2.3 Model wektorowy w przestrzeni M-U

Źródło: opracowanie własne.

Dzięki unifikacji, model może być traktowany jako spójny agregat geometryczny reprezentujący chwilowy układ sił w analizowanym układzie. Model wsparty algorytmem symulacyjnym, może stanowić odpowiedź na zidentyfikowaną lukę badawczą w obszarze symulacyjnej analizy systemów ładowania [76].


2.2. CEL GŁÓWNY I CELE CZĄSTKOWE

Jak wskazano we wstępie cel rozprawy został zdefiniowany jako:

opracowanie metody wspomagania decyzji operacyjnych i biznesowych operatorów infrastruktury ładowania EV, umożliwiającej ocenę wpływu wybranych parametrów na marżę i wykorzystanie infrastruktury stacji w odpowiedzi na zmienność warunków otoczenia.

Realizacja celu głównego wymaga realizacji kroków pokazanych na Rys. 2.4 i osiągnięcia związanych z nimi celów cząstkowych:

C1. Krytyczna analiza dostępnej literatury i raportów branżowych w zakresie ekonomii stacji ładowania pojazdów elektrycznych, metod ustalania cen w sektorze elektromobilności i paliw tradycyjnych, a także znanych czynników wpływu na wyniki obu typów stacji. Celem analizy jest pozyskanie wiedzy o tych czynnikach, przegląd stosowanych obecnie strategii cenowych, zapoznanie się ze specyfiką i możliwością transferu czynników znanych w branży paliw tradycyjnych do branży EV oraz rozpoznanie potencjalnych problemów.




Rys. 2.4 Cele częściowe realizacji rozprawy

Źródło: opracowanie własne.

C2. Identyfikacja i szczegółowe opisanie parametrów, klasyfikacja oraz ocena ich wpływu na wynik ekonomiczny stacji ładowania z uwzględnieniem podziału na parametry zewnętrzne, pozostające poza bezpośrednią kontrolą operatora, oraz parametry wewnętrzne, interpretowane jako instrumenty biznesowe. Dla każdego z parametrów zostanie zdefiniowany wektor atrybutów dla opisu jego cech charakterystycznych (Rys. 2.5). Przypisanie poszczególnym parametrom tzw. atrybutów umożliwia opisanie parametru wartościami zdeterminowanymi posiadającymi konkretne wartości i jednostki. Należy jednak podkreślić, że sam zbiór parametrów i atrybutów nie stanowi jeszcze modelu w rozumieniu tezy rozprawy.

C3. Opracowanie dwuwymiarowego modelu wektorowego w przestrzeni M-U infrastruktury, w którym każdy parametr wpływu od P1-P20, reprezentowany jest przez wektor modulowany funkcją zmienności wpływu atrybutów parametru na składowe marży i wykorzystania infrastruktury. Zakres celu częściowego C3 obejmuje wybór układu współrzędnych, przypisanie funkcji modulujących do parametru, mapowanie atrybutów

parametru na argumenty funkcji, określenie sposobu obliczania poszczególnych wektorów, normalizację wektorów do wspólnej przestrzeni metrycznej, algorytm obliczeń i opis warunków brzegowych, założeń oraz własności kompletnego modelu.



Rys. 2.5 Zależności między głównymi elementami modelu: parametrem, atrybutem, funkcją modulującą

Źródło: opracowanie własne.


C4. Opracowanie metody wyznaczania wskaźników ekonomicznych stacji oraz opracowanie algorytmu dynamicznego wyznaczania ceny energii na podstawie wypadkowego wektora wyniku ekonomicznego i przyjętych założeń. W ramach tego celu zostaną zdefiniowane wskaźniki celu ekonomicznego, reguły przejścia od wektora wyniku do rekomendowanej zmiany ceny z uwzględnieniem realnego wpływu operatora stacji na wynik poprzez parametry wewnętrzne (narzędzia biznesowe) i np. działania kompensujące oczekiwany spadek wykorzystania infrastruktury poprzez intensyfikację kampanii lojalnościowych lub inwestycje w technologie umożliwiające zwiększenie bazy popytowej.

C5. Implementacja komputerowa opracowanego modelu i algorytmu, przygotowanie scenariuszy symulacyjnych oraz ocena wyników symulacji na estymatorach danych. Obejmuje to wybór środowiska i technologii symulacji, implementację modułów przetwarzania danych i silnika symulacji, przeprowadzenie testów wrażliwości na zmiany parametrów i ewentualnej kalibracji modelu, porównanie uzyskanych wyników z wynikami bazowej strategii cenowej oraz ocenę potencjału wdrożeniowego modelu w warunkach operacyjnych.

Osiągnięcie każdego z celów cząstkowych stanowi warunek niezbędny do opracowania spójnego modelu oraz weryfikacji efektów działania algorytmu. Łącznie prowadzą one od krytycznej analizy stanu wiedzy, poprzez wyciągnięcie kluczowych wniosków, konstrukcję modelu, aż do implementacji algorytmu oraz oceny jego przydatności w rzeczywistym środowisku działania operatorów stacji ładowania.

2.3. ZAKRES PRACY

Cel główny i cele cząstkowe zostały zrealizowane w granicach wyznaczonych przez opisany niżej zakres przedmiotowy, podmiotowy, technologiczny, przestrzenny, czasowy i metodologiczny rozprawy (Rys. 2.6). Pozwoliło to na precyzyjną interpretację uzyskanych wyników oraz sformułowanie jednoznacznych wniosków z nich wypływających.



Rys. 2.6. Zakres rozprawy i jej główne wymiary

Źródło: opracowanie własne.

Zakres przedmiotowy pracy obejmuje biznesową analizę funkcjonowania komercyjnych stacji ładowania pojazdów elektrycznych, z naciskiem na antagonistyczną zależność pomiędzy marżą jednostkową operatora, a wskaźnikiem wykorzystania posiadanej infrastruktury. Przedmiotem badań jest zatem opracowanie modelu opisującego istotny wpływ parametrów ekonomicznych, technicznych, kosztowych, marketingowych, konkurencyjnych, popytowych na te dwa kluczowe wskaźniki oraz wykorzystanie modelu m.in. do wyznaczania rekomendowanej ceny energii.

Zakres podmiotowy pracy obejmuje operatorów infrastruktury ładowania CPO (Charge Point Operators), którzy prowadzą działalność komercyjną w oparciu o sieć stacji ładowania AC i DC dla pojazdów LDV (Light Duty Vehicles). Model przeznaczony jest do symulowania

pojedynczej stacji, jednak może być również stosowany dla całej sieci operatora poprzez odpowiednie dostosowanie parametrów charakterystycznych dla poszczególnych stacji (m.in. lokalizacja, ruch, otoczenie konkurencyjne, etc.). W rozważaniach pominięto szczegółowe modele zachowań pojedynczych użytkowników pojazdów elektrycznych, przyjmując ich wpływ w postaci zagregowanych zachowań klientów, takich jak preferencje dobowe i sezonowe popytu lub tolerancja na wzrost cen (elastyczność cenowa klienta).

Zakres technologiczny pracy obejmuje stacje ładowania AC, DC o dowolnym zakresie mocy i konfiguracji stanowisk. Uwzględniono typowe konfiguracje spotykane w nowo budowanych i modernizowanych punktach ładowania, zasilanych z sieci dystrybucyjnych. Praca nie obejmuje konkretnych modeli ładowarek, magazynów energii, instalacji OZE ani zachowania sieci elektroenergetycznej na poziomie przesyłowym. Ich wpływ ujmowany jest pośrednio poprzez wartości parametrów kosztowych i technicznych.

Zakres przestrzenny badań obejmuje przede wszystkim warunki funkcjonowania infrastruktury ładowania na rynku europejskim i USA, z uwzględnieniem otoczenia regulacyjnego oraz specyfiki taryf dystrybucyjnych właściwych dla tego rynku. W analizie literatury i identyfikacji parametrów uwzględniono jednak publikacje z innych krajów jak np. Chiny, co pozwala na lepsze uogólnienie części wniosków i szersze spojrzenie na badaną branżę.

Zakres czasowy analizy literaturowej obejmuje w szczególności publikacje i raporty opublikowane w latach 2015-2025, co odpowiada okresowi intensywnego rozwoju infrastruktury ładowania i pojawienia się pierwszych opracowań ilościowych, dotyczących popytu na usługi ładowania oraz efektywności ekonomicznej stacji. W warstwie symulacyjnej przyjęto horyzont nie krótszy niż 6 miesięcy, tak aby możliwe było uchwycenie zróżnicowania sezonowego oraz efektów wolnozmiennych takich jak np. zmiany lojalności klientów lub wpływu infrastruktury przyległej (kawiarnie, sklepy, etc.).

Zakres metodologiczny pracy obejmuje identyfikację parametrów w oparciu o analizę literatury, opisanie funkcji zmienności zgodnie z literaturą i doświadczeniem zawodowym autora, opracowanie logiki obliczeniowej w oparciu o zasady składania (sumowania) wektorów w przestrzeni dwuwymiarowej, klasyczne metody normalizacji i skalowania danych, podstawowe narzędzia analizy wrażliwości oraz symulacje komputerowe. Nie będą prowadzone formalne dowody optymalności algorytmu w sensie teorii sterowania lub teorii gier. Wynika to z faktu, że celem jest uzyskanie prototypu rozwiązania praktycznego i możliwego do implementacji i weryfikacji w środowisku symulacyjnym. Jednocześnie przyjmuje się szereg uproszczeń, m.in. brak modelowania ograniczeń sieciowych na poziomie

systemu energetycznego, estymacji danych i uproszczonego modelu zachowań użytkowników. Świadomie również uproszczono model w zakresie opóźnień bodźców (tzw. lag) co zostało szerzej opisane w punkcie dotyczącym podziału na parametry wewnętrzne i zewnętrzne.

2.4. TEZA ROZPRAWY

Teza pracy została sformułowana w oparciu o zdefiniowany w poprzednim punkcie cel główny oraz zakres badań i brzmi następująco:

Zastosowanie dwuwymiarowego modelu wektorowego do formalnej reprezentacji wpływu czynników egzogenicznych i endogenicznych na marżę handlową oraz wykorzystanie infrastruktury stacji ładowania EV umożliwia opracowanie algorytmu symulującego superpozycję ich oddziaływania w czasie i wyznaczającego trajektorię stanów ekonomicznych stacji, stanowiąc podstawę do wspierania decyzji biznesowych operatora.

Weryfikacja tezy została przeprowadzona za pomocą symulacji, w ramach której skonstruowany model wektorowy został przetestowany za pomocą 6 scenariuszy symulacyjnych. Badaniu podlegały: stabilność zachowania modelu i wrażliwość wyników na zaburzenia danych wejściowych i adekwatność odpowiedzi na zadane sygnały wejściowe.

2.5. ZNACZENIE POZNAWCZE I UTYLITARNE

Praca ma zarówno charakter poznawczy, jak i utylitarny. Znaczenie poznawcze polega przede wszystkim na zaproponowaniu i przetestowaniu modelu wektorowego dostosowanego do specyfiki ekonomiki stacji ładowania pojazdów elektrycznych oraz na systematyzacji zbioru parametrów wpływu wraz z ich atrybutami. Wprowadzenie przestrzeni M-U jako podstawy analizy, umożliwia jednocześnie analizowanie dwóch antagonistycznych celów operatora i stanowi alternatywę wobec tradycyjnych modeli jednowymiarowych, koncentrujących się wyłącznie na marży jednostkowej lub wolumenie sprzedaży.

Dodatkową wartością poznawczą jest prezentacja procedury przejścia od rozproszonej wiedzy literaturowej i doświadczeń praktycznych do sformalizowanego modelu matematycznego, który może być dalej rozwijany w kierunku modeli wielowymiarowych oraz zintegrowany z algorytmami decyzyjnymi opartymi o wstępnie wytrenowane autoregresywne modele transformerowe lub techniki uczenie maszynowego. Zaproponowane w pracy definicje parametrów, atrybutów i wskaźników celu oraz zasady ich reprezentacji wektorowej mogą

zostać wykorzystane w przyszłych badaniach dotyczących innych segmentów infrastruktury energetycznej lub usług sieciowych.

Znaczenie użytkowe rozprawy wynika z możliwości bezpośredniego zastosowania opracowanego modelu i algorytmu w systemach zarządzania stacjami ładowania. Algorytm może stanowić moduł wspomagania decyzji operatora, pozwalający na testowanie scenariuszy cenowych przed ich wdrożeniem, długookresową ocenę wpływu planowanych działań na marżę i wykorzystanie infrastruktury stacji, ocenę potencjalnych lokalizacji przed rozpoczęciem inwestycji oraz bardziej świadome kształtowanie oferty abonamentowej i rabatowej. Zastosowanie modelu sprzyja przejściu od reaktywnej polityki cenowej, opartej na prostym śledzeniu kosztów energii, do polityki proaktywnej, uwzględniającej szerszy kontekst rynkowy i popytowy oraz dłuższą perspektywę czasową.

3. CZYNNIKI MAJĄCE WPŁYW NA EFEKTYWNOŚĆ STACJI ŁADOWANIA W LITERATURZE PRZEDMIOTU

3.1. UWAGI OGÓLNE

Niniejszy rozdział stanowi usystematyzowanie pozyskanych z literatury informacji w celu identyfikacji czynników mających wpływ na ekonomię stacji ładowania pojazdów elektrycznych. Do celów porównawczych zostały wykorzystane również informacje z rynku stacji paliw tradycyjnych (ICE). Analiza opiera się na danych z rynków rozwiniętych USA, Chin, Europy z uwzględnieniem specyfiki rynku polskiego.

Dokonano analizy szerokiego spektrum czynników, które mają istotny wpływ na wskaźniki jednostkowe w zakresie marży i wykorzystania infrastruktury stacji ładowania. Analizę czynników przeprowadzono w wymienionych, wcześniej obszarach, tj.:

- konkurencyjności,
- popytu,
- kosztów,
- technologii i infrastruktury,
- marketingu i produktów,
- makroekonomii i uwarunkowań regulacyjnych.

W podrozdziałach 3.2 - 3.7 opisano charakterystyki zidentyfikowanych czynników, przypisując je do powyższych obszarów. Dla każdego z obszarów omówiono specyfikę oddziaływania czynników, wskazując jednocześnie wpływ tych zależności na wskaźniki ekonomiczne stacji ładowania. Takie ujęcie pozwoliło na zdefiniowanie w rozdziale 4 elementów modelu wektorowego i opisanie kluczowych 20 parametrów oznaczonych symbolami P1 - P20.

3.2. CZYNNIKI W OBSZARZE KONKURENCYJNOŚCI

Grupa czynników w obszarze konkurencyjności dotyczy uwarunkowań rynkowych związanych z obecnością innych operatorów stacji ładowania oraz dostępnością alternatywnych ofert dla użytkowników pojazdów elektrycznych. Czynniki te wpływają na możliwość kształtowania poziomu cen oraz zdolność operatora do utrzymania odpowiedniego poziomu wykorzystania infrastruktury. Wśród nich można wymienić:

- liczbę konkurencyjnych stacji w okolicy,
- ceny konkurencji.

A. Liczba konkurencyjnych stacji w okolicy

Konkurencja na rynku stacji ładowania nie ogranicza się jedynie do innych operatorów CPO, ale obejmuje również substytuty w postaci ładowarek domowych i biurowych. Według analiz McKinsey, docelowo, nawet w scenariuszach upowszechnienia publicznych ładowarek, znaczna część energii będzie dostarczana poza publiczną siecią [23].

Dodatkowo wprowadzenie regulacji AFIR (Alternative Fuels Infrastructure Regulation) wymusza zagęszczenie sieci wzdłuż korytarzy TEN-T (są to strefy wydzielone co 60 km), co prawdopodobnie sztucznie podniesie całkowitą podaż niezależnie od faktycznego popytu lokalnego. Może to prowadzić w krótkim okresie do zjawiska nadpodaży obniżającego rentowność pojedynczych lokalizacji. Z drugiej zaś strony, gęsta sieć ładowarek jest niezbędna do przełamania bariery psychologicznej braku zasięgu u potencjalnych nabywców EV.

Warto zauważyć, że stacje paliw tradycyjnych coraz częściej stają się również konkurencyjnymi hubami ładowania. Koncerny paliwowe, takie jak Shell czy BP, inwestują w budowę własnych sieci ładowania, co pozwala im na dywersyfikację przychodów i utrzymanie klienta [20]. Zjawisko to jest widoczne również w Polsce, gdzie Orlen rozwija sieć ładowarek Orlen Charge na swoich stacjach paliw, a także przejmuje istniejące sieci (np. Energa) [29].

B. Ceny konkurencji

Wojna cenowa na rynku EV jest bardziej złożona niż na rynku paliw ze względu na niejednorodność produktu zróżnicowanego m.in. mocą ładowania, kompatybilnością ze standardami, odmiennymi modelami abonamentowymi, etc. Na przykład operatorzy tacy jak Ionity, Tesla czy Fastned stosują programy lojalnościowo-abonamentowe, w których poza oficjalnym cennikiem na pylonie istnieje też stały rabat miesięczny, obniżający stawkę za kWh. Program abonamentowy "Passport" obecnego w Polsce operatora Ionity znacząco obniża koszt jednostkowy dla użytkowników pokonujących duże dystanse, budując w ten sposób lojalność i utrudniając przejęcie klienta przez konkurencję [30].

Model ten przypomina programy lojalnościowe w telekomunikacji, gdzie koszt zmiany operatora jest celowo zawyżony, aby utrzymać lojalność klienta. Użytkownik, który opłacił abonament w jednej sieci, będzie dążył do maksymalizacji korzyści, unikając ładowania

u konkurencji, nawet jeśli inna stacja jest bliżej. To zjawisko radykalnie różni się od rynku paliw, gdzie lojalność jest zazwyczaj niska i oparta głównie na cenie paliwa.

Opisane wyżej zaburzenie, które można by nazwać “zaciemnieniem obrazu” polityk cenowych konkurencji porządkują częściowo nowe regulacje unijne takie jak AFIR, które wymuszają pełną transparentność cen, m.in. końcową cenę za kWh za minutę postoju oraz stałych opłat za sesję. Ma to na celu zwiększenie przejrzystości konkurencyjnej oraz ułatwienie klientom porównywanie cen. Teoretycznie powinno to zaostrzyć konkurencję cenową i w dłuższym okresie upodobnić polityki cenowe CPO do tablic cenowych na stacjach benzynowych. Na stacjach EV cena może zależeć od wielu czynników, w tym m.in.:

- *Abonamentów.* Raport EAFO z 2024 roku wskazuje na systematyczne rozwarstwienie cen między ładowaniem ad-hoc a ładowaniem w ramach abonamentów lub subskrypcji. Dane EAFO potwierdzają, że w większości krajów UE średnia cena dla subskrybentów jest niższa o minimum 0,15-0,25 EUR/kWh względem użytkowników okazjonalnych [31].
- *Preferowanych pojazdów.* Producenci samochodów oferują preferencyjne stawki w sieciach partnerskich (np. BMW Charging w sieci Ionity) oraz premiąją pojazdy które są w stanie szybko się załadować i zwolnić miejsce postojowe, czyli pojazdy które mogą przyjąć dużą ilość energii w krótkim czasie [26].
- *Mocy ładowania.* Średnie ceny energii na stacjach dużej mocy są generalnie wyższe niż na stacjach niskiej mocy takich jak stacje AC. W analizowanych danych stawki DC sięgają 0.40-0.60 \$/kWh, podczas gdy stacje niskiej mocy takie jak np. AC plasują się zwykle niżej, co potwierdza praktykę biznesową operatorów, którzy żądają wyższej ceny za wyższą moc ładowania [62].

Dane w tabeli 3.1 pokazują, że rynek ładowania jest znacznie bardziej rozwarstwiony cenowo niż rynek paliw, co stwarza pole do optymalizacji kosztów przez świadomych CPO.

Tab. 3.1. Przykładowe stawki za ładowanie w Polsce (2025)

Operator	Moc AC (zł/kWh)	Moc DC (50-100 kW) (zł/kWh)	Moc HPC (>100 kW) (zł/kWh)	Uwagi
GreenWay	~1,60 - 1,95	~2,40 - 2,95	~2,70 - 3,25	Ceny zależne od planu abonamentowego
Orlen Charge	~1,95	~2,69	~3,19	Zniżki w aplikacji mobilnej

Operator	Moc AC (zł/kWh)	Moc DC (50-100 kW) (zł/kWh)	Moc HPC (>100 kW) (zł/kWh)	Uwagi
Tauron	~1,21	~1,89	~2,46	Stawki zróżnicowane terytorialnie
Ionity	-	-	~3,50 (ad-hoc) ~2,00 (Passport)	Jednolita stawka HPC, duża różnica subskrypcyjna
Tesla Supercharger	-	-	~1,60 - 2,20	Zmienne w zależności od godziny i lokalizacji

Źródło: opracowanie własne.

W tabeli 3.2 przedstawiono porównanie czynników popytu stacji paliw vs. stacji ładowania EV

Tab. 3.2. Porównanie czynników popytu stacji paliw vs. stacji ładowania EV

Cecha	Stacja paliw tradycyjnych	Stacja ładowania EV
Baza popytu	wszyscy kierowcy	kierowcy nie posiadający własnych lub firmowych punktów ładowania
Przewidywalność konwersji	niska - najczęściej klienci tankują na przypadkowych stacjach	wysoka - konieczność wybierania najbliższej stacji, która zapewni zasięg do celu
Promień oddziaływania	mały w miastach i punktowo na przy trasach tranzytowych	bardzo duży ze względu na niskie nasycenie stacjami ładowania EV
Wyłączenia popytowe	brak - obejmujące wszystkie pojazdy	technologiczne - tylko pojazdy spełniające kryteria kompatybilności złącz

Źródło: opracowanie własne.

3.3. CZYNNIKI W OBSZARZE POPYTU

Obszar czynników popytowych odzwierciedla potencjał zakupowy wśród użytkowników stacji ładowania pojazdów elektrycznych. Czynniki te kształtują głównie poziom wykorzystania infrastruktury ładowania, ale mają też wpływ na poziom możliwej do uzyskania marży. Wśród nich można wymienić:

- cenę i elastyczność cenową,
- porę dnia,

- warunki pogodowe i sezonowość,
- bazową liczbę samochodów EV.

A. Cena i elastyczność cenowa

Popyt na ładowanie publiczne wykazuje inną elastyczność cenową niż popyt na paliwo. Paliwo jest dobrem o sztywnym popycie w krótkim okresie, czyli kierowca musi zatankować na stacji paliw, aby dojechać do celu. W przypadku EV, kierowca często ma wybór: naładować się na drogiej szybkiej ładowarce, czy dojechać do domu i naładować się taniej w taryfie nocnej lub w pracy. Badania z rynku USA pokazują, że elastyczność cenowa popytu na ładowanie publiczne jest wysoka, a użytkownicy szybko reagują na zmiany cen, wybierając tańsze stacje lub zmieniając porę ładowania [34].

Jednakże, badania przeprowadzone w Europie wskazują na ciekawe zjawisko: użytkownicy EV są wrażliwi na cenę, ale jeszcze bardziej na niezawodność i dostępność. W ankietach Deloitte, kierowcy wskazywali, że są w stanie zapłacić wyższą cenę za gwarancję wolnego stanowiska i wysoką moc ładowania, co zmniejsza ich elastyczność cenową [35]. Sytuacja odменя się na autostradach i drogach szybkiego ruchu, gdzie alternatywą jest wielogodzinny postój lub ryzyko rozładowania baterii. Wówczas popyt się usztywnia pozwalając operatorom HPC na stosowanie wyższych marż.

B. Pora dnia (szczyt/poza szczytem)

Krzywa wykorzystania infrastruktury stacji ładowania różni się od stacji paliw tradycyjnych. Stacje paliw notują szczyty w godzinach porannych i popołudniowych spowodowane dojazdami do pracy i powrotami do domów. Stacje ładowania, szczególnie szybkie, są obciążone w sposób bardziej losowy w ciągu dnia, ale również z wyraźnymi pikami w porach wieczornych oraz w godzinach popołudniowych.

Zatem z perspektywy ekonomicznej, kluczowe staje się zarządzanie popytem w szczytach, aby uniknąć opłat za przekroczenie mocy zamówionej oraz optymalizować koszty zakupu energii. Wdrażanie taryf typu Time-of-Use (TOU) przez operatorów pozwala na optymalizację wykorzystania poprzez zachęty ekonomiczne dla użytkowników. Mechanizm ten, oparty na różnicowaniu stawek w zależności od podaży energii oraz dobowych krzywych wykorzystania, umożliwia redukcję kosztów ładowania w godzinach pozaszczytowych. W Polsce, taryfy G12 czy G12w z tańszą energią w nocy i w godzinach 13:00-15:00 stają się standardem, który potwierdza ten kierunek rozwoju [37].

Wprowadzenie inteligentnego ładowania pozwala na przesuwanie szczytowego poboru mocy w czasie bez ingerencji człowieka np. poprzez zmniejszenie mocy ładowania w szczytach (tzw. peak-shaving) lub optymalizację jej rozłożenia na poszczególne gniazda (tzw. balansowanie mocą). Badania wskazują, że takie dynamiczne sterowanie ceną może skutecznie przesuwać popyt na godziny nocne lub na momenty nadprodukcji z OZE. Jest to korzystne zarówno dla operatora ze względu na niższe koszty, jak i dla sieci ze względu na mniejsze wykorzystanie szczytowe [34].

C. Warunki pogodowe i sezonowość

Warunki pogodowe i sezonowość to czynnik względnie nieistotny dla stacji paliw, ale krytyczny dla hubów ładowania EV. Niskie temperatury wpływają na dwa aspekty ekonomiki stacji [38].

- zwiększony popyt na energię: Zużycie energii przez pojazd w zimie wzrasta o 20-30% (ogrzewanie kabiny, większe opory toczenia, gęstość powietrza), co teoretycznie zwiększa wolumen sprzedaży. Kierowcy muszą ładować auta częściej, generując większy ruch na stacjach.
- obniżona efektywność ładowania: Zimna bateria przyjmuje energię znacznie wolniej. Badania z Idaho National Laboratory wykazały, że w temperaturze 0°C czas ładowania DC może wydłużyć się nawet trzykrotnie w porównaniu do 25°C. Dzieje się tak, ponieważ system zarządzania baterią (BMS) ogranicza moc ładowania, aby chronić ogniwa przed uszkodzeniem.


W zimie rotacja na stanowiskach ładowania spada ze względu na dłuższy czas sesji, co może prowadzić do kolejek i utraty potencjalnych klientów, mimo że stacja pracuje przy dużej zajętości. Zmniejsza to przepustowość stacji, co jest zjawiskiem odmiennym do stacji paliw, na których mróz nie wpływa na czas tankowania. Operatorzy muszą zatem uwzględniać ten czynnik w planowaniu inwestycji, np. instalując więcej punktów ładowania w regionach o chłodniejszym klimacie. Ponadto nowoczesne EV wyposażone są w systemy preondycjonowania, czyli wstępnego podgrzewania baterii, co zużywa dodatkową energię, zwiększając wolumen sprzedaży.

D. Bazowa liczba samochodów EV

Popyt na usługi ładowania jest w oczywisty sposób bezpośrednią pochodną sprzedaży EV i w dużej mierze zależy od sposobu ładowania, poziomu ceny energii oraz dostępnych instrumentów wsparcia [16]. W 2024 roku zaobserwowano spowolnienie dynamiki wzrostu

sprzedaży EV w niektórych krajach po wycofaniu lub ograniczeniu dopłat, co budzi obawy operatorów o długoterminową stopę zwrotu z inwestycji (ROI) [35]. Pomimo tych zaburzeń flota EV wciąż rośnie, chociaż wolniej niż zakładały dotychczasowe scenariusze [61]. W Polsce, dzięki programom takim jak „Mój Elektryk” flota pojazdów EV rosła dynamicznie, ale należy mieć świadomość, że w naszym kraju rozwój EV startował ze stosunkowo niskiej bazy. Warty podkreślenia jest również zjawisko luki infrastrukturalnej wpływającej na stosunkowo niewielką bazową ilość pojazdów klasy eHDV w stosunku do klasy eLDV [50]. Kluczowe dla rozwoju rynku jest osiągnięcie parytetu cenowego zakupu między pojazdem elektrycznym, a pojazdem spalinowym. Do tego czasu, tempo poszerzania floty EV będzie silnie skorelowane z polityką subsydiów i regulacjami [50].

W tradycyjnym modelu stacji paliw, popyt zależy głównie od ogólnego natężenia ruchu. W modelu elektromobilności, kluczowym wskaźnikiem staje się lokalna liczba EV. Dane Międzynarodowej Agencji Energetycznej (IEA) wskazują, że globalna flota samochodów elektrycznych nieustannie rośnie (Rys. 3.1), co bezpośrednio przekłada się na zapotrzebowanie na infrastrukturę ładowania [20].



Rys. 3.1 Wzrost floty pojazdów elektrycznych, 2023-2035 wg IEA

Źródło: [21].

Według prognoz, do 2030 roku globalna flota EV wzrośnie do 250 milionów pojazdów w scenariuszu STEPS (Stated Policies Scenario), a w scenariuszu NZE (Net Zero Emissions) może osiągnąć poziom nawet 790 milionów [21]. Taki wzrost wymusza na operatorach infrastruktury CPO dynamiczne dostosowywanie liczby punktów ładowania. W Unii

Europejskiej, cel regulacji AFIR zakłada, że do 2030 roku wzdłuż głównych szlaków TEN-T strefy ładowania dla samochodów osobowych będą rozmieszczone co 60 km, eliminując obawy kierowców przed brakiem zasięgu co stanowi jedną z przeszkód masowego upowszechnienia pojazdów elektrycznych wśród kierowców [36].

Analiza danych rynkowych wskazuje, dojrzewanie rynku EV zmienia też profil użytkownika. O ile pierwsi użytkownicy tych pojazdów to często osoby zamożne, posiadające domy jednorodzinne z możliwością ładowania, o tyle masowe upowszechnienie wymaga rozwiązań dla mieszkańców bloków. W Polsce, gdzie duży odsetek populacji mieszka w budynkach wielorodzinnych, rozwój publicznej infrastruktury AC i DC w pobliżu osiedli mieszkaniowych będzie ważnym czynnikiem zwiększającym liczbę rejestrowanych EV. Zjawisko to jest już widoczne w strategiach takich operatorów jak Powerdot czy Elo City, którzy instalują ładowarki przy dyskontach (np. Biedronka), tworząc naturalne punkty ładowania dla mieszkańców okolicznych osiedli.

3.4. CZYNNIKI W OBSZARZE KOSZTÓW

Obszar czynników kosztowych odzwierciedla wpływ kosztu energii elektrycznej w hurcie oraz koszty operacyjne które musi ponosić CPO stacji ładowania. Wśród nich można wymienić:

- koszty energii elektrycznej,
- koszty operacyjne.

A. Koszty energii elektrycznej

Struktura kosztów stacji ładowania jest odwróceniem modelu paliwowego. W paliwach dominuje koszt zmienny, a w ładowarkach EV dominują koszty stałe (m.in. CAPEX, opłaty stałe za moc) pokazane na Rys. 3.2, a zmienny koszt energii ma relatywnie mniejszy udział, choć oczywiście rośnie wraz ze wzrostem wolumenu sprzedaży.

W Polsce i Europie operatorzy CPO borykają się też z dużą niestabilnością cen energii. Było to szczególnie dotkliwe w trakcie kryzysu energetycznego 2022-2024 i drastycznie wpłynęło na marże [39]. Operatorzy w naszym regionie muszą zatem balansować między kontraktami długoterminowymi, a niekorzystnym z punktu widzenia marży, zakupem na rynku krótkoterminowym tzw. „rynku spot” (np. TGE - Towarowa Giełda Energii).

Ważnym elementem kosztowym są opłaty za moc (Demand Charges). Dla stacji o mocy ponad 150 kW, opłata za zamówioną moc (kW) może stanowić nawet 40-50% całkowitych

kosztów operacyjnych, jeśli wykorzystanie infrastruktury stacji jest niska [40]. Oznacza to, że stacja, która „stoi pusta”, generuje gigantyczne koszty stałe, w przeciwieństwie do stacji paliw, gdzie niesprzedane paliwo po prostu leży w zbiorniku.




Figure A1. Example cost-to-charge breakdown (\$/kWh)

Source: NREL (2022)

Rys. 3.2 Przykład podziału kosztów ładowania w USA (\$/kWh)

Źródło: [40].

W niektórych częściach świata (np. w USA) instytucje regulujące rynek wprowadzają specjalne taryfy ograniczające wpływ opłat mocy w początkowej fazie rozwoju stacji ładowania, aby zachęcić operatorów punktów ładowania (CPO) do inwestycji [41]. W Polsce taką rolę pełni taryfa e-mobility oferowana przez kilku operatorów sieci, która ma na celu obniżenie kosztów przyłączeniowych i dystrybucyjnych, choć bariery biurokratyczne mocno to utrudniają w praktyce [42].

B. Koszty operacyjne stacji (OPEX)

Oprócz ceny zakupu energii, koszty CPO obejmuje również szereg innych pozycji, m.in.:

- *Utrzymanie i serwis.* Stacje DC są skomplikowanymi urządzeniami energoelektronicznymi, narażonymi na warunki atmosferyczne i wandalizm. Utrzymanie wysokiego wskaźnika dostępności usługi (np. w USA wymaganego przez NEVI aż do poziomu 97% uptime) wymaga kosztownego serwisu i szybkiej reakcji na usterki [43].
- *Dzierżawę gruntu.* Lokalizacje tzw. premium (np. MOP-y, centra handlowe) wymagają wysokich czynszów, często uzależnionych od obrotu lub stałej opłaty za miejsce parkingowe. W miastach, gdzie przestrzeń jest ograniczona, koszty te mogą być znaczącą pozycją budżetową.

- *Systemy IT i Back-end.* Opłaty za licencje oprogramowania do zarządzania siecią (OCPP), obsługę płatności, roaming i integrację z aplikacjami mobilnymi [43]. Koszty te rosną wraz ze skalą sieci i stopniem zaawansowania usług.
- *Opłaty transakcyjne.* Koszty obsługi płatności kartą kredytową wymuszane przez AFIR oraz prowizje dla dostawców usług roamingowych.

W Tab. 3.3 została pokazana przykładowa struktura kosztów OPEX publicznej stacji ładowania w County Durham, Anglia.

Tab. 3.3 Struktura kosztów OPEX przykładowej stacji ładowania

Składnik kosztu OPEX	Udział	Opis
Koszt energii elektrycznej	29,7 %	Koszt zakupu energii zużywanej przez stację
Czynsz / dzierżawa gruntu	45,4 %	Koszt użytkowania miejsca instalacji stacji
Koszty software i backoffice	22,7 %	Zarządzanie stacją, obsługa użytkowników, IT software , opłaty transakcyjne płatności
Utrzymanie i serwis	1 %	Rutynowe przeglądy i serwis planowy
Utrzymanie nieplanowe	1,3 %	Zdarzenia awaryjne, naprawy nieobjęte gwarancją

Źródło: opracowanie własne na podstawie [83].

3.5. CZYNNIKI W OBSZARZE TECHNICZNYM I INFRASTRUKTURALNYM

Obszar czynników technicznych i infrastrukturalnych odnosi się do uwarunkowań wynikających z technologicznych możliwości i ograniczeń stacji ładowania. Czynniki te wyznaczają ramy determinujące jej przepustowość, niezawodność oraz zdolność do obsługi grupy klientów posiadających kompatybilne pojazdy EV. Czynniki te mają charakter głównie ograniczający i wpływają bezpośrednio na wykorzystanie infrastruktury stacji ładowania oraz pośrednio na możliwość podnoszenia marży. Wśród nich można wymienić:

- awarie i niedostępność,
- ograniczenia sieci energetycznej,
- obsługiwane standardy ładowania,
- moc ładowania (szybkość ładowarek),

A. Awarie i niedostępność stacji

Niezawodność to istotny czynnik na rynku ładowania. Niektóre regulacje prawne np. NEVI narzucają wymóg aż 97% dostępności stacji jako warunek otrzymania i utrzymania dotacji [48]. Jednak doświadczenie biznesowe autora wskazuje, że znaczna część, nawet 20÷25% publicznych ładowarek bywa niesprawnych ze względu na błędy komunikacji, uszkodzone przewody, awarie płatności, problemy z oprogramowaniem. Dodatkowym czynnikiem zwiększającym ryzyko awarii jest ważny problem zidentyfikowany w badaniach P. Czecha, dotyczący niedostatecznych umiejętności części użytkowników w zakresie sprawnej obsługi procesu ładowania. Może to wprost prowadzić do blokowania stanowisk ładowania lub występowania awarii [33].

Dla stacji paliw awaria dystrybutora to rzadkość, natomiast dla stacji EV to częstsze zjawisko niszczące zaufanie klientów i lojalność wobec marki operatora. Zjawisko to wynika ze złożoności technologii ładowania, który obejmuje sprzęt, oprogramowanie, systemy płatności i komunikację z siecią. Poprawa niezawodności wymaga inwestycji w zdalny monitoring, diagnostykę predykcyjną oraz szybki serwis terenowy. Niektóre wymogi AFIR dotyczące właśnie raportowania dostępności w czasie rzeczywistym mają na celu poprawę w średnim okresie wskaźników dostępności usługi w Europie [87].

B. Ograniczenia sieci energetycznej

Ograniczenia sieciowe są największą barierą rozwoju infrastruktury HPC. Czas oczekiwania na przyłączenie w Polsce i Europie trwa nawet do 18-24 miesięcy, a koszty modernizacji sieci (np. transformatory SN/NN, linie kablowe) często przerzucane są na inwestora [44]. W wielu lokalizacjach moc przyłączeniowa jest w ogóle fizycznie niedostępna bez kosztownej rozbudowy sieci WN/SN.

Rozwiązaniem tego problemu stają się magazyny energii instalowane na stacjach. Działają one jako bufor, pobierając energię z sieci z małą mocą i oddając ją do pojazdu z dużą mocą. Pozwala to na instalację stacji HPC w miejscach ze słabą siecią oraz na obniżenie opłat za moc. Choć magazyn energii podnosi początkowy CAPEX, może obniżyć OPEX i przyspieszyć uruchomienie stacji, łagodząc długotrwałe procedury przyłączeniowe [45].


C. Obsługiwane standardy ładowania

Europa zdominowana jest przez standard CCS2 (Combined Charging System) i standard CHAdeMO promowany przez producentów japońskich. Z perspektywy inwestora, montowanie złączy CCS2 i CHAdeMO w 2026 roku jest ważną decyzją. Zwłaszcza gdy specyfika

lokalizacji koncentruje się na takiej flocie (np. taksówki Nissan Leaf) [46]. Nawet Tesla, rozszerza swoją sieć Superchargerów w Europie umożliwiając ładowanie w standardzie CCS/CCS2. W sektorze transportu ciężkiego (e-HDV) wdrażany jest obecnie standard MCS (ang. Megawatt Charging System - system ładowania bardzo dużymi mocami), który umożliwi ładowanie pojazdów ciężarowych w trakcie 45-minutowej pauzy postojowej. Wymaga on jednak zupełnie nowej infrastruktury i ogromnych mocy przyłączeniowych, co stanowi kolejne wyzwanie finansowe dla operatorów sieci przesyłowych [36]. Jednak operatorzy punktów CPO, którzy chcą utrzymać wysoki wskaźnik wykorzystania infrastruktury stacji, muszą zapewnić klientom obsługę najważniejszych standardów ładowania, ponieważ ich brak powoduje odcinanie części popytu, który mógłby być obsłużony.

D. Moc ładowania (szybkość ładowarek)

Rynek CPO przesuwają się w stronę ultraszybkiego ładowania (HPC - High Power Charging). Przy trasach szybkiego ruchu i autostradach wprowadzane są coraz częściej ładowarki o mocy 150-350 kW, a dla pojazdów ciężarowych MCS (Megawatt Charging System) w ramach, których planowane są moce ładowania rzędu megawatów [20]. Rynek europejski w tym zakresie dominuje nad konkurencyjnym rynkiem USA (Rys. 3.3).



Rys. 3.3 Procent autostrad wyposażonych w szybką lub ultraszybką ładowarką w USA i Europie, 2024

Źródło: [20].

Oczywistym jest, że inwestycja w stację o mocy 350 kW jest znacznie droższa niż w stację o mocy 50 kW, nie tylko ze względu na koszt urządzenia, ale przede wszystkim na koszt przyłącza energetycznego i transformatora [23]. Jednak klienci posiadający nowoczesne EV (architektura 800V, np. Hyundai Ioniq 5, Porsche Taycan, Kia EV6) omijają stacje o mocy

< 100 kW, które nie pozwalają na wykorzystanie pełnego potencjału ich pojazdów. Czyni to stare stacje 50 kW technicznie przestarzałymi i jest ryzykiem inwestycyjnym nieznanym w branży paliwowej, gdzie dystrybutor paliwa służy przez dekady. W konsekwencji zjawisko to wymusza na operatorach ciągłą modernizację lokalizacji podnosząc CAPEX, aby utrzymać wykorzystanie infrastruktury stacji.

3.6. CZYNNIKI W OBSZARZE MARKETINGOWYM I PRODUKTOWYM

Czynniki marketingowe i produktowe odnoszą się do sposobu kształtowania i postrzegania stacji ładowania przez użytkowników. Wpływają one na atrakcyjność oferty, decyzje zakupowe klientów oraz ich skłonność do regularnego korzystania ze stacji ładowania. Wśród nich można wymienić:

- lojalność klientów wobec marki,
- wartość dodana oferty stacji,
- widoczność i rzetelna informacja o stacji,
- UX użytkownika (wygoda),
- umowy flotowe i abonamenty.

A. Lojalność klientów wobec marki

Lojalność budowana jest przez niezawodność oraz ekosystem usług. Programy lojalnościowe ewoluują z prostego zbierania punktów (jak na stacjach paliw) w stronę zaawansowanych subskrypcji (np. Ionity Passport, Tesla Membership) tworzących trwałą lojalność poprzez rabaty w cenie energii dla subskrybentów i znacznie wyższe ceny dla klientów doraźnych [30]. Klienci flotowi są wiązani umowami ramowymi, które gwarantują jednolite ceny i zbiorcze fakturowanie, co jest ważne dla zarządzania kosztami w firmach [55].

Istotnym elementem budowania marki jest również branding i estetyka stacji. Zadaszenia, oświetlenie, czytelne oznaczenia i czystość otoczenia wpływają na poczucie bezpieczeństwa i komfortu, co jest szczególnie ważne w nocy i w miejscach oddalonych od zabudowań [86].

B. Wartość dodana oferty stacji (dodatkowe usługi)

Stacje ładowania pojazdów elektrycznych wymagają od klientów dłuższego postoju niż tradycyjne tankowanie paliwa. Z tego powodu dodatkowe usługi dostępne w miejscu ładowania mają znaczenie przy wyborze konkretnej stacji. Badania pokazują, że elementy zwiększające

komfort lub użyteczność są ważne dla części użytkowników i wpływać na to, którą stację wybiorą [86].

Dla operatora stacji, usługi dodatkowe nie są więc jedynie dodatkowym źródłem przychodu, lecz również narzędziem wspierającym popyt na sprzedawane usługi i produkty [46],[55]. Operatorzy tacy jak Shell czy BP (poprzez BP Pulse), przekształcają niektóre swoje stacje w centra usługowe z kawiarniami, Wi-Fi i strefami pracy, uzyskując dodatkowy przychód w czasie oczekiwania klienta na naładowanie pojazdu.

C. Widoczność i rzetelna informacja o stacji

Kierowca EV nie szuka stacji wzrokowo (jak pylonu cenowego przy drodze), lecz cyfrowo - poprzez aplikację (PlugShare, Google Maps, aplikacje operatorów). Dlatego kluczowa jest obecność w systemach nawigacji oraz poprawność danych (status zajętości w czasie rzeczywistym). Błędne dane o dostępności (tzw. ładowarki zombie) są głównym źródłem frustracji i obaw kierowców przed podróżą [51]. Operatorzy muszą też dbać o integrację swoich systemów z hubami roamingowymi (platformy koncentrujące wielu CPO w jednej sieci abonamentowej), aby być widocznym dla jak najszerszej grupy użytkowników.

D. UX użytkownika (wygoda)

Proces inicjowania ładowania (autoryzacja) oraz problemy wynikające z nieprecyzyjnych informacji, połączonych z brakiem umiejętności niektórych użytkowników w obsłudze procesu ładowania jest dla klientów realnym utrudnieniem i wydłuża czas oraz zwiększa ryzyko błędów, na co zwraca uwagę w swoich publikacjach P. Czech [33]. Konieczność posiadania wielu aplikacji, kart RFID i kont użytkownika jest barierą wejścia. Wdrożenie standardu Plug & Charge zgodnego z normą ISO 15118, gdzie auto samo autoryzuje płatność po podpięciu kabla, jest postrzegane jako docelowy model UX, eliminujący ważny problem w procesie zakupu [52].

Regulacja AFIR wymusza również montaż terminali płatniczych na stacjach > 50 kW, co upodabnia UX klienta do zakupu paliwa czy zakupów w sklepie - zbliżenie karty bankowej powoduje start ładowania. Jest to krok w stronę łatwego dostępu, pozwalający na ładowanie bez rejestracji u operatora, tym samym lepszej satysfakcji klienta (Tab.3.4). Badania wskazują, że prostota obsługi jest jednym z ważnych czynników wyboru stacji przez użytkowników, obok ceny i lokalizacji [54]. Oprócz wymienionych w tabeli 3.4 pokazano także inne czynniki z kategorii UX ważne dla klientów.

Tab. 3.4 Miary UX / zadowolenia klienta stacji ładowania

Element UX	Miary i czynniki wpływu
Dostęp do stacji	Dostępność fizyczna stacji (czytelne dojścia, ochrona przed pogodą, łatwe do zarządzania kable)
Start i finalizacja	Poprawne działanie sprzętu
	Poprawne działanie interfejsu ładowarki
	Płatność (inicjacja, dostępne opcje, łatwość)
Proces ładowania	Funkcjonalność stanowiska ładowania
	Efektywność ładowania
	Wskaźnik awarii pojazd-ładowarka (pojazd nie przyjmuje ładowania, EVSE działa poprawnie)
Uzyskanie pomocy	Średni czas reakcji pracownika
Poczucie komfortu	Estetyka stacji, porządek
	Lokalizacja (wygoda, dostępność usług w pobliżu, zajęcia na czas ładowania)

Źródło: opracowanie własne na podstawie [54].

E. Umowy flotowe i abonamenty

Segment B2B jest stabilizatorem przychodów wielu CPO. Umowy roamingowe i karty flotowe (np. Shell Recharge, DKV, Routex) zapewniają stały wolumen sprzedaży. Na popularyzację tego modelu wpływa m.in. fakt, że duże firmy elektryfikują floty w ramach strategii ESG, wymagając od operatorów jednolitego systemu rozliczeń, raportowania emisji CO₂ i gwarancji dostępności, na co odpowiedzią są właśnie umowy flotowe. Operatorzy w ramach takich umów oferują oczywiście klientom flotowym również dedykowane cenniki, brandowane aplikacje, znaczące zniżki wolumenowe i niższe opłaty postojowe.

3.7. CZYNNIKI W OBSZARZE MAKROEKONOMICZNYM

Grupa czynników w obszarze makroekonomicznym dotyczy zewnętrznych uwarunkowań gospodarczych, wpływających na funkcjonowanie stacji ładowania, które zasadniczo nie są bezpośrednio zależne od decyzji operatora. Wyjątkiem jest tutaj zgoda operatora na udział w programach DSR. Czynniki te oddziałują na koszty działalności, poziom przychodów oraz opłacalność prowadzenia infrastruktury ładowania. Wśród nich można wymienić:

- subwencje i ulgi podatkowe, wpływające na obniżenie kosztów inwestycyjnych i operacyjnych infrastruktury ładowania,
- udział w programach Demand Response (DSR), umożliwiający generowanie dodatkowych przychodów lub redukcję kosztów poprzez elastyczne zarządzanie poborem mocy,

- wskaźnik inflacji, oddziałujący na poziom kosztów operacyjnych oraz realną wartość marży uzyskiwanej ze sprzedaży energii.


A. Subwencje i ulgi podatkowe

W Polsce kluczową rolę odgrywa program NFOŚiGW „Wsparcie infrastruktury do ładowania pojazdów elektrycznych”, który pokrywa do 50% kosztów kwalifikowanych budowy stacji ogólnodostępnych [60]. Bez tego wsparcia, budowa stacji DC w lokalizacjach o mniejszym natężeniu ruchu byłaby ekonomicznie nieuzasadniona. Podobne mechanizmy funkcjonują w innych krajach, np. program NEVI w USA, który przeznaczają 5 mld USD na budowę sieci ładowarek wzdłuż autostrad [48]. Fundusze te są niezbędne do pokrycia luki finansowej w początkowej fazie rozwoju rynku, zanim wolumeny sprzedaży osiągną poziom gwarantujący samofinansowanie.

B. Udział w programach Demand Response

Inteligentne stacje ładowania mogą też pełnić funkcję stabilizatora sieci. Operatorzy mogą świadczyć usługi redukcji zapotrzebowania (tzw. DSR - Demand Side Response) na rzecz operatora systemu przesyłowego, co polega m.in. na czasowym ograniczeniu mocy ładowania w godzinach szczytowego wykorzystania sieci.

Dodatkowo wprowadzenie technologii V2G (Vehicle-to-Grid) pozwoli na jeszcze bardziej zaawansowane usługi DSR, gdzie samochody mogą oddawać energię do operatora, zarabiając na różnicach cen i stabilizacji sieci (Rys. 3.4) [58]. W Polsce nie są jeszcze wdrażane tego typu programy jednak pojawiają się pilotażowe projekty testujące ten mechanizm w Danii np. Parker Project który wykazał, że V2G może generować znaczące przychody dla flot, sięgające nawet 1800 EUR rocznie na pojazd [59].



Rys. 3.4 Współdzielenie mocy między pojazdami elektrycznymi za pośrednictwem funkcji V2G

Źródło: [58].

C. Wskaźnik inflacji

Inflacja wpływa na wyniki CPO dwutorowo. Drastyczny wzrost cen sprzętu, surowców i robocizny budowlanej w ostatnich latach, połączony z dwukrotnym wydłużeniem czasu oczekiwania na kluczowe komponenty oraz kilkudziesięcioprocentowymi podwyżkami ich cen [44], znacząco podniósł próg rentowności nowych inwestycji ze względu na wzrost CAPEX. Równocześnie, wysokie stopy procentowe często będące konsekwencją inflacji zwiększają koszt pozyskania kapitału dla inwestycji infrastrukturalnych o naturalnie długim okresie zwrotu (7-10 lat), co prowadzi do nierentowności wielu projektów bez wsparcia publicznego lub taniego finansowania (np. z programów rozwojowych) [56].

3.8. PODSUMOWANIE I USTALENIE CZYNNIKÓW WPŁYWU NA CENĘ ENERGII

Rozważania przeprowadzone w podrozdziałach 3.1÷3.7, poparte analizą literatury przedmiotu oraz przykładami z praktyki, pozwalają na wstępną ocenę zbioru czynników oddziałujących na funkcjonowanie stacji ładowania pojazdów elektrycznych. Wnioski płynące z przeprowadzonej analizy potwierdzają, że wynik ekonomiczny stacji nie jest kształtowany przez pojedynczy element, lecz stanowi efekt jednoczesnego oddziaływania wielu czynników wpływu o zróżnicowanym charakterze, skali oraz dynamice zmian.

W kolejnym etapie pracy została dokonana ekstrakcja czynników i ich zaszeregowanie do 6 grup w celu uporządkowania i opisu ich wpływu na stacje ładowania. Zbiór ten powinien obejmować zidentyfikowane i przeanalizowane czynniki, które w kolejnych krokach będą mapowane na parametry modelu.

Należy w tym miejscu zastrzec, że w niniejszym rozdziale podjęto próbę możliwie pełnego przeglądu czynników, które potencjalnie wpływają na wynik ekonomiczny stacji, przy czym wymaga podkreślenia, że ich dobór ma charakter częściowo subiektywny. Wynika to z obszerności zagadnienia, subiektywności percepcji poziomu ważności czynników i konieczności ograniczenia skali modelu na obecnym etapie jego rozwoju. W przypadku uzyskania wniosków potwierdzających postawioną tezę model będzie rozwijany m.in. w kierunku dywersyfikacji zbioru parametrów modelu i ich jeszcze bardziej precyzyjnego opisu.

Na podstawie wyników przeprowadzonej analizy wyróżniono 6 grup czynników podzielonych według obszaru oddziaływania na wyniki stacji ładowania (Tab. 3.5). Dla jednoznaczności dalszych rozważań należy podkreślić, że powyższa struktura grupowania

czynników pełni tylko charakter porządkowy w celu zapewnienia przejrzystości. Nie przesądza ona o ostatecznym kształcie zbioru parametrów modelu, tylko porządkuje dalsze prace i ma za zadanie poprawić percepcję treści.

Tab. 3.5 Identyfikacja grup parametrów

Grupa	Nazwa grupy	Opis grupy
PKN	Czynniki konkurencyjne	Obejmuje parametry opisujące otoczenie konkurencyjne stacji ładowania, w szczególności poziom cen oraz zagęszczenie infrastruktury konkurencyjnej w obszarze oddziaływania. Czynniki te określają warunki funkcjonowania stacji na rynku i wpływają na jej pozycję względem innych operatorów.
PPO	Czynniki popytowe	Opisuje parametry kształtujące wielkość popytu na usługę ładowania oraz jego zmienność w czasie. Czynniki te odzwierciedlają zachowania użytkowników, w tym ich reakcję na zmiany ceny oraz modelują uwarunkowania sezonowe.
PKO	Czynniki kosztowe	Definiuje podstawowe elementy kosztowe związane z funkcjonowaniem stacji ładowania, takie jak koszt energii i koszty operacyjne. Czynniki te stanowią podstawę do wyznaczania dolnej granicy ceny oraz marży jednostkowej.
PTI	Czynniki techniczne i infrastrukturalne	Obejmuje parametry opisujące techniczne ograniczenia stacji, niezawodność infrastruktury oraz ograniczenia w zakresie mocy. Czynniki te wyznaczają maksymalny poziom podaży usługi oraz wpływają na poziom wykorzystania infrastruktury stacji.
PMP	Czynniki marketingowe i produktowe	Opisuje parametry związane z ofertą stacji oraz sposobem jej postrzegania przez klientów. Czynniki te wpływają na decyzje zakupowe użytkowników, kształtują świadomość marki, lojalność klientów oraz skuteczność konwersji popytu w transakcje.
PMR	Czynniki makroekonomiczne i regulacyjne	Obejmuje czynniki zewnętrzne o charakterze systemowym, takie jak uwarunkowania makroekonomiczne, polityka publiczna oraz regulacje prawne. Czynniki te wyznaczają ramy funkcjonowania operatorów stacji ładowania i wpływają na opłacalność działalności w dłuższym horyzoncie czasowym.

Źródło: opracowanie własne.

4. USTALENIE PARAMETRÓW WPLYWU I ICH ATRYBUTÓW DLA OCENY WSKAŹNIKÓW STACJI ŁADOWANIA

4.1. ZAŁOŻENIA OGÓLNE

Przeprowadzona w trzecim rozdziale analiza czynników pozwoliła na wyodrębnienie kluczowych parametrów, które w istotny sposób oddziałują na wskaźniki marży oraz stopień wykorzystania stacji ładowania. Należy podkreślić, że proces szacowania marży ma charakter wieloaspektowy, co uzasadnia konieczność uwzględnienia szerokiego spektrum zmiennych. Infrastruktura ładowania funkcjonuje w złożonym otoczeniu, podlegając wpływom czynników mikroekonomicznych i makroekonomicznych, warunkom atmosferycznym, działaniom konkurencji oraz ograniczeniami uwarunkowań technologicznych. Każdy z tych obszarów ma wpływ na ostateczny wynik ekonomiczny stacji, a konkretne czynniki wpływu obejmują różnorodne zmienne takie jak m.in.: koszt zakupu energii w hurcie, potencjał popytowy wynikający z liczby pojazdów elektrycznych, nasycenie konkurencją, aż po kwestie techniczne, takie jak wpływ temperatury na pojemność baterii, awaryjność infrastruktury czy szybkość ładowania i związaną z maksymalną dostępną mocą.

W celu uporządkowania tego zróżnicowanego zbioru danych, w podrozdziale 3.8 dokonano kategoryzacji czynników na następujące grupy:

- czynniki konkurencyjne,
- czynniki popytowe,
- czynniki kosztowe,
- czynniki techniczne i infrastrukturalne,
- czynniki marketingowe i produktowe,
- czynniki makroekonomiczne i regulacyjne.

Przyjęto założenie, że wymienione czynniki stanowią zmienne wejściowe wpływające na efektywność funkcjonowania stacji. Zidentyfikowany zbiór parametrów stał się podstawą konstrukcji modelu wektorowego, opisanego szczegółowo w piątym rozdziale rozprawy. Na potrzeby badań zdefiniowano ostatecznie następującą listę parametrów:

- P1 - Cena sprzedaży,
- P2 - Ceny konkurencji,
- P3 - Liczba konkurencyjnych stacji w okolicy,

- P4 - Koszt energii elektrycznej,
- P5 - Pora dnia,
- P6 - Lojalność klientów wobec marki,
- P7 - Wartość dodana oferty stacji,
- P8 - Awarie i niedostępność,
- P9 - Koszty operacyjne stacji,
- P10 - Subwencje i ulgi podatkowe,
- P11 - Widoczność i rzetelna informacja o stacji,
- P12 - Ograniczenia sieci energetycznej,
- P13 - Warunki pogodowe i sezonowość,
- P14 - Obsługiwane standardy ładowania,
- P15 - Udział w programach Demand Response (DSR),
- P16 - Bazowa liczba samochodów EV,
- P17 - UX użytkownika (wWygoda),
- P18 - Moc ładowania,
- P19 - Umowy flotowe i abonamenty,
- P20 - Wskaźnik inflacji.

Dla potrzeb formalnego zapisu wymienione parametry zapisano jako zbiór $\mathbf{P}$ o N elementach:

$$\mathbf{P} = \{P_j; j = 1, \dots, N\}$$

gdzie: P_j reprezentuje elementarny czynnik wpływu nazywany w pracy **parametrem**, przy czym $j = 1, \dots, 20$, stanowią wymienione wyżej parametry modelu, które mają wpływ na ekonomikę stacji ładowania. Należy podkreślić, że formalna notacja w konwencji P_j jest wykorzystywana w rozdziałach dotyczących opisu matematycznego i algorytmu. Natomiast w pozostałej części pracy stosowana jest notacja czytelniejsza w konwencji P_j bez indeksu dolnego. Obie formy zapisu P_j i P_j należy rozumieć jako tożsame tj. $P_j \equiv P_j$.

Ze względu na zdefiniowane wcześniej grupy (obszary) formułowania czynników, a tym samym parametrów, zbiór $\mathbf{P}$ podzielono na sześć podzbiorów:

- Podzbiór $\mathbf{PKN}$ parametrów konkurencyjnych, obejmujący czynniki związane z bezpośrednim otoczeniem konkurencyjnym $\mathbf{PKN} = \{P_2, P_3\}$.
- Podzbiór $\mathbf{PPO}$ parametrów popytowych, dotyczy zachowań klientów, potencjału rynku oraz dynamiki zapotrzebowania dobowego $\mathbf{PPO} = \{P_1, P_5, P_{13}, P_{16}\}$.

- Podzbiór **PKO** parametrów kosztowych, który skupia się na wydatkach związanych z funkcjonowaniem stacji **PKO** = {P4, P9}.
- Podzbiór **PTI** parametrów technicznych i infrastrukturalnych, który obejmuje uwarunkowania technologiczne sprzętu, sieci energetycznej oraz warunki fizyczne wpływające na działanie infrastruktury **PTI** = {P8, P12, P14, P18}.
- Podzbiór **PMP** parametrów marketingowych i produktowych, który dotyczy konstrukcji oferty, budowania relacji z klientem i jakości obsługi **PMP** = {P6, P7, P11, P17, P19}.
- Podzbiór **PMR** parametrów makroekonomicznych, zawierający czynniki zewnętrzne o charakterze ogólnogospodarczym i regulacyjnym **PMR** = {P10, P15, P20}.

Ponadto, jak wskazano wcześniej każdy parametr charakteryzowany jest przez zestaw zmiennych opisujących go w sposób ilościowy nazywanych w pracy **atrybutami**. Oznaczając przez a_i numer atrybutu ($i = 1, \dots, n$), można formalnie zapisać zbiór A wszystkich numerów atrybutów jako:

$$A = \{a_i: i = 1, \dots, n\}$$

W kolejnych podrozdziałach poddano szczegółowej analizie poszczególne grupy parametrów wskazując na atrybuty niezbędne do ich wyznaczenia dla potrzeb budowy modelu.

4.2. OPIS PARAMETRÓW I ICH ATRYBUTÓW W OBSZARZE OTOCZENIA KONKURENCYJNEGO

W obszarze otoczenia konkurencyjnego wskazano dwa istotne parametry, tj.:

- P2 interpretowany jako ceny konkurencji,
- P3 interpretowany jako liczba konkurencyjnych stacji w okolicy.

Parametr P2 odzwierciedla poziom cen ładowania oferowanych przez inne stacje w okolicy i wpływ tej konkurencji cenowej na analizowaną stację. Silna konkurencja cenowa w okolicy zmusza operatora do utrzymywania niższych stawek. Jeśli konkurenci oferują niższą cenę, operator nie może znacząco jej podnieść bez spadku wskaźnika wykorzystania infrastruktury stacji.

Ponadto pojawienie się alternatywnych opcji (np. ładowarek przy supermarketach albo mobilnych ładowarek) dodatkowo obniża ceny i odbiera klientów [72]. Oznacza to, że kierowcy EV mogą wybierać spośród dostępnych punktów ładowania, stąd relacja ceny usługi na danej stacji do cen konkurencji wpływa na wykorzystanie infrastruktury stacji. Jeżeli

konkurenci oferują niższe stawki, część klientów może rezygnować z usług operatora, zmniejszając wykorzystanie infrastruktury danej stacji.

Jako atrybut parametru P2 przyjmuje się różnicę względną cen, który oznaczono a_3 . Oznaczenie atrybutu wraz z interpretacją zapisano poniżej.

a_3	$\Delta p_{rel} [-]$	Różnica względna cen	Stosunek między ceną na danej stacji, a średnią ceną u konkurencji w okolicy.
-------	----------------------	----------------------	---

Natomiast **parametr P3, tj. liczba konkurencyjnych stacji ładowania w regionie** determinuje stopień konkurencji na danym rynku. Wysoka dostępność stacji ładowania w regionie daje użytkownikom więcej możliwości. Im więcej punktów ładowania w pobliżu, tym bardziej rozproszony staje się popyt - kierowcy mają więcej opcji, co zmniejsza udział każdej pojedynczej stacji w obsłudze lokalnego ruchu EV. Rozproszenie popytu między wiele punktów obniża średnie obłożenie pojedynczej stacji. Brak możliwości podniesienia ceny przy stałych kosztach oznacza niższą marżę [73].

Jako atrybut dla parametru P3 przyjmuje się liczbę konkurentów, który oznaczono a_4 . Oznaczenie atrybutu wraz z interpretacją zapisano poniżej.

a_4	n_R [szt.]	Liczba konkurentów	Liczba stacji ładowania innych operatorów w zadanym promieniu (strefa oddziaływania).
-------	--------------	--------------------	---

W tabeli 4.1 zestawiono parametry i ich atrybuty dla obszaru PKN.

Tab. 4.1 Parametry i atrybuty otoczenia rynkowego i konkurencyjnego

Nr i nazwa parametru	Oznaczenie atrybutu	Nazwa atrybutu	Opis atrybutu
P2 Ceny konkurencji	$\Delta p_{rel} [-]$	Różnica względna cen	Stosunek między ceną na danej stacji, a średnią ceną u konkurencji w okolicy.
P3 Liczba konkurencyjnych stacji w okolicy	n_R [szt.]	Liczba konkurentów	Liczba stacji ładowania innych operatorów w zadanym promieniu (strefa oddziaływania).

Zródło: opracowanie własne.

4.3. OPIS PARAMETRÓW I ICH ATRYBUTÓW W OBSZARZE POPYTU

W obszarze otoczenia konkurencyjnego wskazano pięć istotnych parametrów, tj.:

- P1 interpretowany jako cena sprzedaży,

- P5 interpretowany jako pora dnia,
- P13 interpretowany jako warunki pogodowe i sezonowość,
- P16 interpretowany jako bazowa liczba samochodów EV.

Parametr P1 odzwierciedla wpływ ceny na decyzje zakupowe klientów. Mechanizm ten stanowi barierę dla podnoszenia cen, gdyż próba zwiększenia marży może skutkować spadkiem popytu. Z drugiej strony niższe ceny zwiększają wykorzystanie stacji.

Kluczowym czynnikiem determinującym wpływ tego parametru na ekonomikę stacji jest cenowa elastyczność popytu, która odwzorowuje reakcję użytkowników na wahania cen usług ładowania. Dla stacji ładowania EV oznacza to procentową zmianę wykorzystania stacji wywołaną procentową zmianą ceny za kWh. Badania pokazują, że popyt na ładowanie jest na ogół ujemnie skorelowany z ceną, czyli wzrost ceny zmniejsza wykorzystanie stacji, ponieważ klienci ładują rzadziej lub szukają tańszej alternatywy. Według badań Kuang et al z roku 2024 [84], elastyczność cenowa badana na rynku stacji ładowania Shenzhen wykazuje, że różnica w cenie zaledwie o 0,1-0,2 RMB/kWh jest wystarczającym bodźcem dla kierowców do zmiany wybranej stacji. Ponadto autorzy wskazują na silną zależność elastyczności cenowej od struktury przestrzennej sieci (liczby konkurujących stacji w okolicy). Autorzy wskazują również, że dynamiczna polityka cenowa operatora może przyczynić się do redukcji szczytowego wykorzystania infrastruktury o 10-12%, co również wpływa na wartość wskaźnika wykorzystania stacji. Reakcja klientów na zmianę ceny może też różnić się w zależności od pory dnia, np. w porach nocnych popyt bywa niemal nieelastyczny, podczas gdy w godzinach szczytu reakcja jest silniejsza [84].

Jako atrybuty parametru P1 przyjmuje się cenę i zmianę ceny, które oznaczono odpowiednio: a_1 i a_2 . Oznaczenie atrybutów wraz z interpretacją zapisano poniżej.

a_1	p [PLN/kWh]	Cena	Aktualna cena usługi ładowania.
a_2	Δp [PLN/kWh]	Zmiana ceny	Zmiana ceny operatora.

Parametr P5 odnosi się do pory dnia. Zapotrzebowanie na ładowanie ma charakter dobowo zmienny - w godzinach szczytu popyt jest większy. Operatorzy często stosują rozróżnienie na taryfy szczytowe i pozaszczytowe. W szczycie ceny bywają wyższe co poprawia marżę, kompensując większe wykorzystanie sieci, a poza szczytem niższe, by zachęcić do ładowania w okresie niskiego wykorzystania [68].

Dynamiczne dostosowanie cen do pory dnia pomaga optymalizować wykorzystanie stacji, ponieważ ładowanie takie przesuwają się na tańsze godziny nocne poza szczytem [68]. W efekcie w szczycie cena może wzrosnąć, ale może też ograniczyć poziom wykorzystania

infrastruktury. Odwrotne zjawisko może pojawić się poza szczytem, czyli niższa cena zwiększająca popyt.

Zapotrzebowanie na ładowanie pojazdów elektrycznych wykazuje wyraźne wahania dobowe. W godzinach szczytu w ciągu dnia, gdy ludzie są w pracy, robią zakupy lub podróżują to popyt na publiczne ładowanie jest wyższy. W porach poza szczytem, takich jak np. późna noc, wczesny ranek stacje notują mniejszy ruch [47]. Ten parametr opisuje, jak pora dnia wpływa na wykorzystanie infrastruktury i ewentualnie marżę, jeśli stosowane są taryfy dzienne/nocne.

Jako atrybuty dla parametru P5 przyjmuje się: amplitudę nocną (a_6), godzinę nocną (a_7), rozrzut nocny (a_8), amplitudę poranną (a_9), godzinę poranną (a_{10}), rozrzut poranny (a_{11}). Oznaczenie atrybutów wraz z interpretacją zapisano poniżej.

a_6	H_1	Amplituda nocna	Maksymalna intensywność ładowania wieczorem/nocą.
a_7	μ_1 [h]	Godzina nocna	Godzina, w której zapotrzebowanie nocne jest największe.
a_8	σ_1 [h]	Rozrzut nocny	Odchylenie standardowe szczytu nocnego.
a_9	H_2	Amplituda poranna	Maksymalna intensywność ładowania rano.
a_{10}	μ_2 [h]	Godzina poranna	Godzina, w której poranny szczyt osiąga maksimum.
a_{11}	σ_2 [h]	Rozrzut poranny	Odchylenie standardowe szczytu porannego.

Parametr P13 to warunki pogodowe i sezonowość. Pogoda istotnie modyfikuje zapotrzebowaniem na ładowanie EV. Zimą spada efektywność baterii i rośnie zużycie energii na ogrzewanie, co zwiększa zużycie kWh na km, więc pojazd wymaga częstszego ładowania. Z drugiej strony kierowcy w bardzo mroźne lub bardzo upalne dni ograniczają podróże. Badania wskazują, że nieoptymalne warunki znacząco wpływają na profil wykorzystania stacji [80]. W sezonie wiosennym i jesiennym obserwuje się zazwyczaj najwyższy poziom obłożenia, natomiast zimą ulega ono obniżeniu, a latem wykazuje korelację z okresem wakacyjnym. Pogoda nie ma bezpośredniego wpływu na cenę natomiast wpływa na marżę.

Pogoda oraz pora roku wpływają na zachowania użytkowników EV i sprawność pojazdów, co w efekcie zmienia popyt na ładowanie.

Jako atrybuty dla parametru P13 przyjmuje się: miesiąc/sezon (a_{21}) i temperaturę (a_{22}). Oznaczenie atrybutów wraz z interpretacją zapisano poniżej.

a_{21}	S [1-12]	Miesiąc	Zmienna cykliczna reprezentująca porę roku.
a_{22}	T_{zew} [°C]	Temperatura	Zewnętrzna temperatura powietrza

Parametr P16 odzwierciedla bazową liczbę samochodów EV. Im więcej pojazdów elektrycznych jeździ w danym obszarze, tym większy popyt na usługi ładowania. Wzrost rynku przekłada się na wyższe wykorzystanie stacji, więc operator może sobie pozwolić na stopniowe zwiększanie cen lub mniejszą skłonność do rabatów bez utraty klientów. Z kolei przy niskiej liczbie EV stacje często stoją niewykorzystane i wymagają subsydiowania. Badania ekonomiczne wskazują, że przy wystarczająco wysokim wykorzystaniu i niskich kosztach jednostkowych, stacja może być rentowna nawet bez wsparcia publicznego [74]. Warunkiem jest jednak odpowiednia baza klientów w okolicy, na co wskazują m.in. wyniki pracy Barlaug i Yang [63]. Przedstawiona przez autorów analiza 3 705 stacji, wykazała wyraźne powiązanie poziomu wykorzystania infrastruktury stacji z charakterystyką popytu lokalnego. Liczba pojazdów elektrycznych stanowi zatem bazowe tło popytowe dla stacji. Im więcej EV jeździ po drogach, tym większy jest potencjalny popyt na publiczne ładowanie. Ten parametr jest zewnętrzny, makroekonomiczny - określa stopień penetracji rynku przez EV.

Jako atrybut dla parametru P16 przyjmuje się liczbę aut EV lokalnych (a_{32}). Oznaczenie atrybutu wraz z interpretacją zapisano poniżej.

a_{32}	N_{EV} [szt.]	Liczbę aut EV lokalnych	Bezwzględna liczba samochodów elektrycznych zarejestrowanych w promieniu oddziaływania stacji.
----------	-----------------	-------------------------	--

W Tab. 4.2 zestawiono parametry i ich atrybuty dla obszaru PPO.

Tab. 4.2 Parametry i ich atrybuty w obszarze popytu

Nr i nazwa parametru	Oznaczenie atrybutu	Nazwa atrybutu	Opis atrybutu
P1 Cena sprzedaży	p [PLN/kWh]	Cena sprzedaży	Aktualna cena usługi ładowania.
	Δp [PLN/kWh]	Zmiana ceny	Zmiana ceny operatora.
P5 Pora dnia	H_1 [-]	Amplituda nocna	Maksymalna intensywność ładowania wieczorem.
	μ_1 [h]	Godzina nocna	Godzina, w której zapotrzebowanie nocne jest największe.
	σ_1 [h]	Rozrzut nocny	Odchylenie standardowe szczytu nocnego (jak szeroko rozlany w czasie).
	H_2 [-]	Amplituda poranna	Maksymalna intensywność ładowania rano.
	μ_2 [h]	Godzina poranna	Godzina, w której poranny szczyt osiąga maksimum.

Nr i nazwa parametru	Oznaczenie atrybutu	Nazwa atrybutu	Opis atrybutu
	σ_2 [h]	Rozrzut poranny	Odchylenie standardowe szczytu porannego.
P13 Warunki pogodowe i sezonowość	S [mies]	Miesiąc	Zmienna cykliczna reprezentująca porę roku.
	T_{zew} [°C]	Temperatura	Zewnętrzna temperatura powietrza.
P16 Bazowa liczba samochodów EV	N_{EV} [szt.]	Liczba aut EV lokalnych	Bezwzględna liczba samochodów elektrycznych zarejestrowanych w promieniu oddziaływania stacji.

Źródło: opracowanie własne.

4.4. OPIS PARAMETRÓW I ICH ATRYBUTÓW W OBSZARZE KOSZTÓW

W obszarze kosztów wskazano dwa istotne parametry, tj.:

- P4 interpretowany jako koszt energii elektrycznej,
- P9 interpretowany jako koszty operacyjne stacji.

Parametr P4 odzwierciedla koszt energii elektrycznej. Wzrost kosztu zakupu energii wywiera presję na podniesienie cen ładowania, aby przenieść koszt na klienta [74]. Jeśli ceny nie zostaną podniesione proporcjonalnie, marża operatora spada. Zbyt wysokie ceny ładowania mogą jednak zmniejszyć popyt. Przy umiarkowanym wzroście cen energii możliwy jest kompromis: część kosztów jest przenoszona na klienta, a część absorbowana, co może ograniczyć spadek popytu i zachować akceptowalny poziom marży.

Koszt zakupu energii przez operatora stacji wprost wpływa na marżę jednostkową ze sprzedaży kWh oraz pośrednio na cenę dla klienta. W warunkach wolnorynkowych, gdy rośnie koszt energii w hurcie, operator musi podnieść ceny ładowania lub zaakceptować niższą marżę. Parametr ten uwzględnia zarówno bieżący poziom cen energii, jak i ich zmienność.

Jako atrybut parametru P4 przyjmuje się zmianę kosztu energii (a_5). Oznaczenie atrybutu wraz z interpretacją zapisano poniżej.

a_5	Δc_e [PLN/kWh]	Zmiana kosztu energii	Wzrost lub spadek ceny zakupu prądu u dostawcy względem stanu poprzedniego.
-------	------------------------	-----------------------	---

Natomiast **parametr P9** odzwierciedla koszty operacyjne stacji. Wysokie koszty operacyjne (np. serwis, dzierżawa gruntu, opłaty przesyłowe) wymuszają podniesienie cen dla utrzymania marży. Jednak wyższa cena może ograniczyć wykorzystanie infrastruktury stacji.

Szczególnym składnikiem są opłaty za moc szczytową obowiązujące na niektórych rynkach (tzw. demand charges), które mogą stanowić znaczną część rachunków stacji, sięgając nawet powyżej 5% kosztów energii. Zarządzanie tym kosztem np. poprzez cięcie szczytów mocy przez operatora jest kluczowe dla poprawy rentowności [74].

Oprócz kosztu energii (P4) operator ponosi inne koszty operacyjne: utrzymania i serwisu urządzeń, dzierżawy terenu lub amortyzacji inwestycji, opłat za łączność i systemy płatności, kosztów administracyjnych, podatków od nieruchomości, a także często opłat dystrybucyjnych i mocy (np. Wspomniane wyżej demand charge za pobór szczytowy mocy). Te stałe i zmienne koszty wpływają na opłacalność stacji - im wyższe, tym niższa marża netto, co może wymuszać podniesienie cen lub dodatkowe przychody.

Jako atrybut parametru P9 przyjmuje się zmianę OPEX (a_{16}). Oznaczenie atrybutu wraz z interpretacją zapisano poniżej.

a_{16}	C_{op} [PLN/kWh]	Zmiana OPEX	Współczynnik uśrednionego kosztu operacyjnego stacji ładowania w analizowanym okresie w relacji do ceny sprzedaży energii.
----------	--------------------	-------------	--

W Tab. 4.3 zestawiono parametry i ich atrybuty dla obszaru PKO.

Tab. 4.3 Parametry w obszarze kosztów

Nr i nazwa parametru	Oznaczenie atrybutu	Nazwa atrybutu	Opis atrybutu
P4 Koszt energii elektrycznej	Δc_e [PLN/kWh]	Zmiana kosztu energii	Wzrost lub spadek ceny zakupu energii (giełda/dostawca) względem wartości poprzedniej.
P9 Koszty operacyjne stacji	C_{op} [PLN/kWh]	Zmiana kosztu OPEX	Współczynnik uśrednionego kosztu operacyjnego stacji ładowania w analizowanym okresie w relacji do ceny sprzedaży energii.

Źródło: opracowanie własne.

4.5. OPIS PARAMETRÓW I ICH ATRYBUTÓW W OBSZARZE TECHNICZNYM I INFRASTRUKTURALNYM

W obszarze technicznym i infrastrukturalnym wskazano pięć istotnych parametrów, tj.:

- P8 interpretowany jako awarie i niedostępność,
- P12 interpretowany jako ograniczenia sieci energetycznej,
- P14 interpretowany jako obsługiwane standardy ładowania,

- P18 interpretowany jako moc ładowania (szybkość ładowarek).

Parametr P8 odzwierciedla awarie i niedostępność. Jest to czynnik z zakresu ryzyka operacyjnego - awarie lub inne zdarzenia powodujące niedostępność punktów ładowania negatywnie wpływają na postrzeganie stacji i wykorzystanie infrastruktury. Wielokrotne powtarzanie tego zjawiska może spowodować, że wielu użytkowników będzie omijać daną lokalizację [9]. Natomiast poprawa jakości (niedostępność < 5%) zwiększa zaufanie i częstotliwość ładowań na danej stacji [77]. Dodatkowo niezawodność zmniejsza również koszty napraw, co poprawia marżę.

Parametr P8 odnosi się do nieplanowanych przestojów stacji spowodowanych awariami technicznymi lub innymi problemami (np. prace serwisowe, usterki oprogramowania, uszkodzenia fizyczne urządzeń). Wskaźnikiem jest tu m.in. procent czasu dostępności (tzw. uptime) stacji lub odsetek prób ładowania zakończonych niepowodzeniem. Wysoka niezawodność jest krytyczna dla utrzymania klientów, ponieważ częste awarie skutkują utratą zaufania i odpływem użytkowników do konkurencji.

Jako atrybuty parametru P8 przyjmuje się niedostępność (a_{14}) i liczbę punktów ładowania (a_{15}). Oznaczenie atrybutów wraz z interpretacją zapisano poniżej.

a_{14}	$D [0-1]$	Niedostępność	Udział czasu, w którym stacja jest nieczynna z powodu awarii.
a_{15}	$Z_e [\text{szt.}]$	Liczba punktów ładowania	Liczba punktów ładowania na stacji. Im mniejsza, tym awaria jednego z nich jest bardziej dotkliwa.

Kolejny parametr P12 odzwierciedla ograniczenia sieci energetycznej. Jeśli lokalna sieć energetyczna jest przeciążona np. przez ograniczoną przepustowość transformatora, operator stacji może być zmuszony ograniczać pobór mocy przez wysokie ceny w krytycznych godzinach lub biorąc ten dodatkowy koszt na siebie. Oznacza to, że tzw. lokacyjne ceny krańcowe (DLMP), proponowane w literaturze odzwierciedlają lokalne warunki podaży/popytu, a wyższa cena w węzłach przeciążonych ma skłaniać do ograniczenia poboru energii [68]. Dla operatora oznacza to niższe wolumeny sprzedaży i potencjalnie kosztowne inwestycje w przyłącze.

Parametr P12 dotyczy ograniczeń infrastruktury elektroenergetycznej w miejscu instalacji stacji. Obejmuje problemy takie jak: niewystarczająca moc przyłącza, przeciążenia sieci dystrybucyjnej przy jednoczesnej pracy wielu ładowarek, lokalne limity poboru narzucone przez operatora sieci (DNO/DSO) czy opóźnienia w rozbudowie przyłącza. Jeśli sieć lokalna

jest słaba, stacja może nie być w stanie obsłużyć pełnej mocy bez ryzyka przeciążenia lub wysokich opłat.

Jako atrybuty parametru P12 przyjmuje się redukcję mocy (a_{19}) i czas ograniczenia (a_{20}). Oznaczenie atrybutów wraz z interpretacją zapisano poniżej.

a_{19}	$P_{red} [0-1]$	Redukcja mocy	Współczynnik redukcji mocy z powodu przeciążenia sieci.
a_{20}	$T_{limit} [\text{godz.}]$	Czas ograniczenia	Czas trwania redukcji mocy w ciągu doby.

Parametr P14 odzwierciedla obsługiwane standardy ładowania. Zastosowanie nowoczesnych standardów komunikacji, takich jak wiodący protokół OCPP między stacją a serwerem oraz ISO 15118 między pojazdem a stacją umożliwia wdrożenie zaawansowanych funkcji: np. automatyczne uwierzytelnianie i płatność, ładowanie Plug&Charge. Standard ISO 15118-2 dodatkowo wprowadza m.in. obsługę bieżącej ceny oraz dwukierunkowego przepływu energii [81]. Dzięki temu operator może elastycznie dostosowywać ceny reagując na zmiany kosztu energii lub czerpać dodatkowe przychody z usług sieciowych. Dla kierowcy standaryzacja oznacza jednolitą obsługę i eliminuje konieczność posiadania wielu aplikacji.

Parametr P14 określa, jakie protokoły i złącza techniczne stacja oferuje (np. CCS, CHAdeMO, Type2 AC, Tesla NACS itp.). Im większa różnorodność standardów, tym szersza grupa pojazdów może skorzystać z ładowania. Ograniczenie stacji do najpopularniejszego w Polsce standardu CCS wyklucza wielu posiadaczy aut. W konsekwencji brak udostępnienia szerokiej palety standardów ogranicza zakres obsługiwanego rynku popytu i wówczas parametr ma charakter odcinający i zmniejszający wartość bazową wykorzystania infrastruktury [75].

Jako atrybut parametru P14 przyjmuje się indeks kompatybilności (a_{23}). Oznaczenie atrybutu wraz z interpretacją zapisano poniżej.

a_{23}	$q_{std} [0-1]$	Indeks kompatybilności	Udział standardów ładowania obsługiwanych przez stację (np. CCS, CHAdeMO) w relacji do liczby standardów rynkowych.
----------	-----------------	------------------------	---

Kolejny parametr P18 odzwierciedla moc ładowania (szybkość ładowarek). Badania preferencji pokazują, że krótki czas ładowania znacząco zwiększa atrakcyjność stacji dla użytkowników [1]. Jest to zjawisko korzystne zarówno dla klientów oraz dla stacji. Klient może skrócić czas ładowania, a stacja zwiększyć wykorzystanie infrastruktury.

Parametr P18 to techniczna charakterystyka stacji - maksymalna moc dostarczana pojazdom, od której zależy, jak szybko mogą one uzupełnić energię. Wyższa moc (np. 150 kW, 350 kW) oznacza krótszy czas ładowania, co jest pożądane przez kierowców, zwłaszcza

w podróży. Kierowcy wolą stacje, na których naładują pojazd szybciej, a stacja ładowania może obsłużyć większą liczbę klientów na dobę.

Jako atrybut parametru P18 przyjmuje się moc stacji (a_{29}). Oznaczenie atrybutu wraz z interpretacją zapisano poniżej.

a_{29}	P [kW]	Moc stacji	Efektywna moc ładowania dostępna dla pojazdów.
----------	----------	------------	--

W Tab. 4.4 zestawiono parametry i ich atrybuty dla obszaru PTI

Tab. 4.4. Parametry w obszarze technicznym i infrastrukturalnym

Nr i nazwa parametru	Oznaczenie atrybutu	Nazwa atrybutu	Opis atrybutu
P8 Awarie i niedostępność	D [0-1]	Niedostępność	Udział czasu, w którym stacja jest nieczynna z powodu awarii.
	Z_e [szt.]	Liczba punktów ładowania	Liczba wtyczek/punktów ładowania na stacji
P12 Ograniczenia sieci energetycznej	P_{red} [0-1]	Redukcja mocy	Współczynnik redukcji mocy z powodu przeciążenia/ograniczeń sieci.
	τ_{limit} [godz.]	Czas ograniczenia	Czas trwania redukcji mocy w ciągu doby.
P14 Obsługiwane standardy ładowania	q_{std} [0-1]	Indeks kompatybilności	Udział standardów ładowania obsługiwanych przez stację (np. CCS, CHAdeMO) w relacji do liczby standardów rynkowych.
P18 Moc ładowania	P [kW]	Moc stacji	Efektywna moc ładowania dostępna dla pojazdów.

Źródło: opracowanie własne.

4.6. OPIS PARAMETRÓW I ICH ATRYBUTÓW W OBSZARZE MARKETINGOWYM I PRODUKTOWYM

W obszarze marketingowym i produktowym wskazano pięć istotnych parametrów, tj.:

- P6 interpretowany jako lojalność klientów wobec marki,
- P7 interpretowany jako wartość dodana oferty stacji,
- P11 interpretowany jako widoczność i rzetelna informacja o stacji,
- P17 interpretowany jako UX użytkownika (wygoda),
- P19 interpretowany jako umowy flotowe i abonamenty.

Parametr P6 odzwierciedla lojalność klientów wobec marki. Silna lojalność oznacza, że klienci są mniej wrażliwi na niewielkie zmiany ceny u preferowanego dostawcy. Umożliwia to utrzymanie nieco wyższych cen bez utraty popytu co pozytywnie wpływa na marżę. Część użytkowników wręcz deklaruje, że nie są wrażliwi na cenę i będą korzystać z danej stacji niemal w każdej sytuacji [1]. Tacy lojalni klienci podnoszą bazowy poziom wykorzystania infrastruktury stacji.

Lojalność oznacza stopień przywiązania użytkowników EV do konkretnego operatora sieci ładowania. Wysoka lojalność sprawia, że klienci wracają na tę samą stację lub korzystają z sieci danej marki nawet, gdy konkurencja oferuje podobny produkt. Dla operatora przekłada się to na stabilniejszy popyt i mniejszą wrażliwość na takie czynniki jak cena czy niewielka odległość konkurencyjnej stacji. Obecnie jednak lojalność w sektorze publicznego ładowania jest stosunkowo niska - badania pokazują, że większość kierowców EV nie ma preferowanego dostawcy i kieruje się raczej ceną, lokalizacją i dostępnością [49].

Jako atrybut parametru P6 przyjmuje się indeks lojalności (a_{12}). Oznaczenie atrybutu wraz z interpretacją zapisano poniżej.

a_{12}	$L [0-1]$	Indeks lojalności	Współczynnik lojalności klientów liczony jako współczynnik sumarycznej liczby sesji ładowania do liczby powrotów (np. powracający MAC adres pojazdu).
----------	-----------	-------------------	---

Parametr P7 odzwierciedla wartość dodaną oferty stacji. Jeśli stacja oferuje unikalne udogodnienia jak np. zadaszenie, kawiarnia, WiFi, bliski parking itp., to klienci są skłonni na ponowne skorzystanie z niej, co ma pozytywny wpływ na wykorzystanie infrastruktury stacji [1]. Dodatkowym znaczącym efektem jest wzrost marży operacyjnej, która jest wyższa przy sprzedaży towarów konsumpcyjnych w czasie oczekiwania na naładowanie pojazdu.

Wartość dodana oznacza dodatkowe udogodnienia i usługi oferowane na stacji poza samą energią. Mogą to być zadaszenie stanowisk, dostęp do WiFi, toalety, kawiarnia lub sklep, restauracja w pobliżu, miejsca wypoczynku itp. Te czynniki zwiększają atrakcyjność stacji dla kierowców oczekujących podczas ładowania, co przekłada się na większy ruch oraz potencjalnie umożliwia pobieranie wyższych cen za wyższy standard stacji ładowania.

Jako atrybut parametru P7 przyjmuje się indeks udogodnień (a_{13}). Oznaczenie atrybutu wraz z interpretacją zapisano poniżej.

a_{13}	$V_{add} [0-1]$	Indeks udogodnień	Współczynnik jakości i liczby usług dodatkowych na stacji.
----------	-----------------	-------------------	--

Parametr P11 odzwierciedla widoczność i rzetelność informacji o stacji. Dostępność stacji w popularnych nawigacjach, mapach i aplikacjach (platformy roamingowe, aplikacje producentów, mapy google) oraz dobra widoczność fizyczna (znaki przy drogach) mają istotny wpływ na wykorzystanie infrastruktury stacji [78].

Parametr P11 dotyczy widoczności stacji, zarówno fizycznej (oznaczenia drogowe, lokalizacja przy głównej trasie, oświetlenie, widoczność z drogi), jak i w świecie cyfrowym (obecność w popularnych aplikacjach nawigacyjnych, Google Maps, PlugShare, aktualne informacje o dostępności). Stacja dobrze widoczna i odpowiednio zareklamowana będzie częściej odwiedzana.

Jako atrybut parametru P11 przyjmuje się indeks widoczności (a_{18}). Oznaczenie atrybutu wraz z interpretacją zapisano poniżej.

a_{18}	V_{inf} [0-1]	Indeks widoczności	Ocena jakości oznakowania fizycznego i cyfrowego (SEO, mapy).
----------	-----------------	--------------------	---

Parametr P17 odzwierciedla UX użytkownika (wygoda). Czynniki często pomijane w technicznych analizach, lecz kluczowe z perspektywy klienta: łatwość skorzystania ze stacji. Obejmuje to: prosty system płatności (np. karta zbliżeniowa, Plug&Charge ISO 15118), itp. Jeśli płatność i uruchomienie ładowania jest bezproblemowe, kierowcy chętniej korzystają. Plug&Charge wręcz eliminuje wszelkie czynności po stronie użytkownika - wystarczy podłączyć kabel [82]. Operatorzy inwestują w UX, bo zadowoleni klienci częściej wracają nawet przy nieco wyższej cenie co wpływa również pozytywnie na marżę [82].

UX (User Experience) użytkownika stacji oznacza całość doświadczenia korzystania ze stacji, od łatwości podjechania i podłączenia, przez interfejs płatności, niezawodność działania aplikacji/karty, aż po poczucie pewności niezawodności procesu podczas oczekiwania. Wysokiej jakości UX oznacza, że proces ładowania jest intuicyjny, szybki i bezproblemowy, co zachęca do ponownego skorzystania i polecenia stacji innym klientom.

Jako atrybut parametru P17 przyjmuje się indeks UX (a_{28}). Oznaczenie atrybutu wraz z interpretacją zapisano poniżej.

a_{28}	U_{UX} [0-1]	Indeks UX	Ocena łatwości obsługi aplikacji, płatności, funkcji Plug&Charge, dostępności roamingu usług.
----------	----------------	-----------	---

Parametr P19 odzwierciedla umowy z flotami pojazdów i abonamenty. Stała współpraca z flotami EV (np. taxi, logistyka, carsharing) zapewnia przewidywalny poziom wykorzystania infrastruktury stacji, co zwiększa stabilność przychodów operatora. Jednocześnie takie kontrakty zwykle wymagają rabatów hurtowych, przez co marża

jednostkowa maleje. Badania wskazują, że kontrakty flotowe są jednym z głównych czynników zwiększających bazowe wykorzystanie stacji i przyspieszających zwrot z inwestycji, choć kosztem niższej rentowności per kWh [71], [72]. Podobny efekt obserwuje się przy modelach subskrypcyjnych i abonamentowych, które także zwiększają lojalność i wolumen sprzedaży energii, lecz obniżają marżę jednostkową [74].

Parametr P19 obejmuje kontrakty B2B i oferty subskrypcyjne, które zapewniają stacji stały napływ użytkowników dzięki np. współpracy z korporacją taksówkową, firmą kurierską czy operatorem carsharingu oraz ustabilizowane i regularne przychody abonamentowe od klientów indywidualnych. Z punktu widzenia modelu, umowa flotowa oznacza, że określona liczba pojazdów regularnie korzysta ze stacji na preferencyjnych warunkach płacąc abonament za określony pakiet kWh lub mając zniżki jednostkowe za kWh.

Jako atrybut parametru P19 przyjmuje się udział flotowy (a_{30}). Oznaczenie atrybutu wraz z interpretacją zapisano poniżej.

a_{30}	s_f [0-1]	Udział flotowy	Współczynnik wolumenu sprzedaży generowanego przez kontrakty flotowe oraz abonamenty.
----------	-------------	----------------	---

W Tab. 4.5 zestawiono parametry i atrybuty dla obszaru PMP.

Tab. 4.5. Parametry w obszarze marketingowym i produktowym

Nr i nazwa parametru	Oznaczenie atrybutu	Nazwa atrybutu	Opis atrybutu
P6 Lojalność klientów wobec marki	L [0-1]	Indeks lojalności	Współczynnik lojalności klientów liczony jako współczynnik sumarycznej liczby sesji ładowania do liczby powrotów (np. powracający MAC adres pojazdu).
P7 Wartość dodana oferty stacji	V_{add} [0-1]	Indeks udogodnień	Ocena jakości i liczby usług dodatkowych na stacji (np. zadaszenie, kawiarnia, Wi-Fi itp.).
P11 Widoczność i rzetelna informacja o stacji	V_{inf} [0-1]	Indeks widoczności	Ocena jakości oznakowania fizycznego i cyfrowego (np. oznaczenia, mapy, obecność w aplikacjach/SEO).
P17 UX użytkownika (wygoda)	U_{UX} [0-1]	Indeks UX	Ocena łatwości obsługi: uruchomienie ładowania, płatności, funkcje typu Plug&Charge, roaming usług itp.
P19 Umowy flotowe i abonamenty	s_f [0-1]	Udział flotowy	Część wolumenu sprzedaży generowana przez kontrakty flotowe oraz abonamenty.

Źródło: opracowanie własne.

4.7. OPIS PARAMETRÓW I ICH ATRYBUTÓW W OBSZARZE MAKROEKONOMICZNYM

W obszarze makroekonomicznym wskazano trzy istotne parametry, tj.:

- P10 interpretowany jako subwencje i ulgi podatkowe,
- P15 interpretowany jako udział w programach Demand Response (DSR),
- P20 interpretowany jako wskaźnik inflacji.

Parametr P10 odzwierciedla subwencje i ulgi podatkowe. Dopłaty publiczne do infrastruktury (np. dotacje na stacje, ulgi podatkowe od energii) obniżają efektywne koszty inwestycji i operacji dla operatora. Umożliwia to utrzymanie niższych cen dla klientów co stymuluje popyt i pozytywnie wpływa na wykorzystanie infrastruktury. Jednocześnie dzięki subsydiom poprawia się rentowność biznesu ze względu na to, że część kosztów pokrywa państwo, więc marża operacyjna rośnie. Liczne badania podkreślają kluczową rolę publicznych programów zachęt w rozwoju sieci ładowania i poprawie opłacalności stacji [74]. Bez tych instrumentów stacje częściej wymagają wyższych cen lub mają trudności z rentownością. Chodzi o zewnętrzne formy wsparcia finansowego dla operatorów stacji ładowania - dotacje do inwestycji, dopłaty do każdej kWh, ulgi podatkowe (np. zwolnienie z podatku od nieruchomości dla stacji), preferencyjne kredyty czy granty rozwojowe. Celem subwencji jest przyspieszenie rozbudowy infrastruktury, która początkowo może być nierentowna.

Jako atrybut parametru P10 przyjmuje się wartość subwencji (a_{17}). Oznaczenie atrybutu wraz z interpretacją zapisano poniżej.

a_{17}	d [PLN/kWh]	Wartość subwencji	Wartość dopłaty lub ulgi w przeliczeniu na jednostkę sprzedanej energii.
----------	---------------	-------------------	--

Parametr P15 odzwierciedla udział w tzw. programach Demand Response (DSR). Integracja stacji ładowania z programami DSR (ang. Demand Side Response - programy regulacji popytu na energię elektryczną) sprawia, że w okresach szczytu operator może otrzymać od operatora sygnał do redukcji wykorzystania. Może to odbywać się w ramach standardowej umowy przez dynamiczne ceny, które podczas szczytu są podnoszone, aby skłonić część użytkowników do odłożenia ładowania, a w godzinach niższego obciążenia sieci mogą być obniżane. Drugą strategią poprawy stabilności sieci może być wynagradzanie finansowe największych CPO przez operatora energetycznego za pomocą dodatkowych rabatów lub przychodów zapisanych w umowie DSR co może prowadzić do kompensacji utraconej marży w szczycie.

Jednocześnie przenoszenie części ładowań na godziny pozaszczytowe oznacza nieco niższe średnie wykorzystanie w szczycie, ale wyższe poza szczytem ze względu na efekt spłaszczonego wykorzystania [1]. Sumarycznie udział w DSR optymalizuje profil wykorzystania stacji i może generować dodatkowe przychody, choć wymusza elastyczne kształtowanie cen.

Demand Response to programy zarządzania popytem, w których odbiorcy (tu: stacje ładowania) dostosowują zużycie energii w odpowiedzi na sygnały z sieci energetycznej (np. wysokie zapotrzebowanie, nadmiar OZE). Stacja uczestnicząca w DSR może np. czasowo obniżyć moc ładowania lub opóźnić niektóre sesje na wezwanie operatora sieci, w zamian za wynagrodzenie lub niższe stawki za energię. Parametr ten opisuje, czy i jak stacja jest zintegrowana z takimi mechanizmami.

Jako atrybuty parametru P15 przyjmuje się przychód z DSR (a_{24}) i poziom redukcji dostępności stacji (a_{25}). Oznaczenie atrybutów wraz z interpretacją zapisano poniżej.

a_{24}	R_{DSR} [PLN]	Przychód z DSR	Przychód otrzymywany od operatora systemu za udział w programach redukcji poboru energii.
a_{25}	δ [0-1]	Poziom redukcji dostępności stacji	Stopień ograniczenia dostępności stacji dla kierowców w momentach wezwania DSR.

Parametr P20 to wskaźnik inflacji. Inflacja podnosi OPEX/CAPEX stacji a w tym także koszt energii. Przy niepełnym przeniesieniu kosztów na ceny detaliczne spada marża. Inflacja osłabia realne dochody klientów i może redukować popyt. Inflacja to ogólny wzrost poziomu cen w gospodarce. W rozprawie wpływ inflacji analizowany jest w obszarze zmiany kosztów operacyjnych (energia, pracownicy, serwis) oraz ewentualnie konieczność dostosowania cen usługi.

Wysoka inflacja energetyczna bezpośrednio uderza w koszt prądu (P4), ale też w koszty np. części zamiennych, robocizny, ubezpieczeń itd. Inflacja ogólna zmniejsza siłę nabywczą klientów, którzy mogą ograniczyć podróże i w konsekwencji wolumen ładowania.

Jako atrybut parametru P20 przyjmuje się wskaźnik inflacji (a_{33}). Oznaczenie atrybutu wraz z interpretacją zapisano poniżej.

a_{33}	inf [%]	Wskaźnik inflacji	Wskaźnik wzrostu cen towarów i usług (CPI/PPI).
----------	-----------	-------------------	---

W Tab. 4.6 zestawiono parametry i atrybuty dla obszaru PMR.

Tab. 4.6 Parametry w obszarze makroekonomicznym

Nr i nazwa parametru	Oznaczenie atrybutu	Nazwa atrybutu	Opis atrybutu
P10 Subwencje i ulgi podatkowe	d [PLN/kWh]	Wartość subwencji	Wartość dopłaty lub ulgi w przeliczeniu na jednostkę sprzedanej energii.
P15 Udział w programach Demand Response (DSR)	R_{DSR} [PLN]	Przychód z DSR	Przychody operatora systemu za udział w programach redukcji poboru.
	δ [0-1]	Poziom redukcji dostępności /mocy	Stopień ograniczenia dostępności/mocy ładowania w momentach wezwania DSR.
P20 Wskaźnik inflacji	inf [%]	Wskaźnik Inflacji	Wskaźnik wzrostu cen towarów i usług (np. CPI/PPI).

Źródło: opracowanie własne.

4.8. PODZIAŁ NA PARAMETRY ZEWNĘTRZNE I WEWNĘTRZNE

Zidentyfikowane parametry zostały podzielone na dwie grupy, uwzględniające możliwość sterowania nimi przez operatora stacji (patrz rozdział 1 Rys. 1.1).

Jak wskazano w rozdziale 1 parametry zewnętrzne definiowane są jako czynniki egzogeniczne pozostające poza bezpośrednią kontrolą operatora, na które nie ma on możliwości oddziaływania w sposób bezpośredni. Obejmują one uwarunkowania wpływające na funkcjonowanie stacji ładowania, lecz niezależne od decyzji operacyjnych operatora, takie jak warunki pogodowe, cena energii elektrycznej, liczba pojazdów elektrycznych w danym obszarze, czy poziom inflacji.

Natomiast parametry wewnętrzne oznaczają czynniki o charakterze endogenicznym których źródło znajduje się wewnątrz firmy i którymi operator może sterować oddziałując w ten sposób na poziom marży i wykorzystania infrastruktury stacji. W tej kategorii mieszczą się instrumenty biznesowe, takie jak kampanie promocyjne, programy lojalnościowe, działania prowadzące do redukcji kosztów operacyjnych (OPEX) czy podnoszenie jakości oferowanych usług (Rys. 4.1).

Opisany podział odzwierciedla rozróżnienie pomiędzy determinantami wynikającymi z wpływu otoczenia a tymi, które stanowią bezpośredni przedmiot decyzji zarządczych operatora. Dzięki powyższemu rozróżnieniu model zyskuje sterowalność. Parametry

zewnętrzne opisują otoczenie, w którym funkcjonuje stacja, natomiast parametry wewnętrzne stanowią zestaw instrumentów biznesowych, za pomocą których operator może reagować.


Parametry egzogeniczne	Parametry endogeniczne
P2 – Ceny konkurencji	P1 – Cena sprzedaży
P3 – Liczba konkurencyjnych stacji w okolicy	P6 – Lojalność klientów wobec marki
P4 – Koszt energii elektrycznej	P7 – Wartość dodana oferty stacji
P5 – Pora dnia	P8 – Awarie i niedostępność
P10 – Subwencje i ulgi podatkowe	P9 – Koszty operacyjne stacji
P12 – Ograniczenia sieci energetycznej	P11 – Widoczność i rzetelna informacja o stacji
P13 – Warunki pogodowe i sezonowość	P14 – Obsługiwane standardy ładowania
P16 – Bazowa liczba samochodów EV	P15 – Udział w programach Demand Response (DSR)
P20 – Wskaźnik inflacji	P17 – UX użytkownika (wygoda)
	P18 – Moc ładowania
	P19 – Umowy flotowe i abonamenty

Rys. 4.1 Podział na parametry wewnętrzne i zewnętrzne

Źródło: opracowanie własne.

W ujęciu modelu wektorowego oznacza to, że w każdym kroku obliczeniowym wszystkie parametry (zarówno zewnętrzne, jak i wewnętrzne) wnoszą swój wkład w postaci zmian składowych marży i wykorzystania infrastruktury składając się na stan całego układu.

Wprowadzenie sterowalności do modelu umożliwia nadanie mu charakteru narzędzia decyzyjnego, wspierającego menedżera w podejmowaniu świadomych decyzji biznesowych m.in. poprzez analizy scenariuszowe oparte na symulacji i walidacji skutków planowanych działań, co można zilustrować w postaci odseparowanych warstw pokazanych na Rys. 4.2.




Rys. 4.2 Warstwowa mapa wpływów

Źródło: opracowanie własne.

Należy podkreślić, że sterowalność stanowi tylko jeden z dwóch wymiarów charakteryzujących parametr. Drugim elementem jest czas reakcji na bodziec (tzw. lag), definiowany w literaturze jako czas wpływający na termin pojawienia się efektów zmian lub bodźców w systemie ekonomicznym [32]. Zjawisko to jest zróżnicowane w zależności od czynnika. Przykładowo, parametry makroekonomiczne, takie jak inflacja, cechują się długim czasem reakcji, wpływając na wyniki stacji w dłuższym horyzoncie. Z kolei cena energii posiada krótki czas reakcji, gdyż niemal natychmiast przekłada się na wynik marżowy operatora.

Analogiczna zasada dotyczy parametrów wewnętrznych: zmiana cennika wywołuje błyskawiczną reakcję klientów, natomiast poprawa jakości obsługi czy widoczności stacji przynosi wymierne efekty dopiero w dłuższej perspektywie (Rys. 4.3).



Rys. 4.3 Macierz dynamiki parametrów / lag parametru

Źródło: opracowanie własne.

W rozprawie zjawisko opóźnienia reakcji nie zostało jednak uwzględnione ze względu na zbyt wysoki poziom komplikacji modelu po uwzględnieniu tego czynnika i utrudnioną interpretowalność wyników. Świadomie zrezygnowano z implementacji tego wskaźnika również w symulacji, ponieważ aktualna architektura systemu jest już na tyle zaawansowana, że wprowadzenie dodatkowych zmiennych czasowych na tym etapie rozwoju utrudniłoby weryfikację podstawowych założeń badawczych. Rozszerzenie modelu o dynamikę opóźnień czasowych planowane jest w kolejnych etapach rozwoju modelu wektorowego.

5. MODEL WSKAŹNIKÓW EKONOMICZNYCH STACJI ŁADOWANIA W PRZESTRZENI WEKTOROWEJ 2D

5.1. USTALENIA DLA ELEMENTÓW ARCHITEKTURY MODELU

5.1.1. ZAŁOŻENIA OGÓLNE ARCHITEKTURY MODELU

Mając na uwadze analizy przeprowadzone w rozdziale 3 i 4 jako kluczowe założenia modelu ustalania ceny energii dla danej stacji ładowania przyjmuje się, że:

- ustalono 6 grup parametrów wpływu na marżę i wykorzystanie infrastruktury stacji (PKN, PPO, PKO, PTI, PMP, PMR) na podstawie analizy czynników,
- każdy parametr charakteryzowany jest wektorem atrybutów, które w efekcie stanowią argumenty funkcji modelujących danego parametru,
- model matematyczny, który jest oparty na reprezentacji wektorowej w przestrzeni dwuwymiarowej R^2 , został opracowany na podstawie zidentyfikowanego zbioru parametrów wpływu oraz powiązanego z nimi zbioru atrybutów,
- jako argumenty funkcji modelujących przyjęto atrybuty parametrów oraz wskaźniki korygujące, tym samym wektor atrybutów $\mathcal{A}$ rozszerzono o dodatkowe zmienne kalibrujące,
- przestrzeń wyników R^2 stanowi dziedzinę, w której zdefiniowano wektorowe reprezentacje badanych wskaźników ekonomicznych stacji ładowania, tj. marży jednostkowej $M \in \mathbb{R}$, odwzorowanej na osi odciętych, oraz poziomu wykorzystania infrastruktury $U \in \mathbb{R}$, odwzorowanej na osi rzędnych,
- architektura wewnętrzna opracowanego modelu oparta jest na strukturze trójwarstwowej pokazanej na Rys. 5.1.

Warstwa wejściowa stanowi źródło zasilania modelu danymi. W tej warstwie zdefiniowano zbiór parametrów wejściowych oraz zbiór przypisanych im atrybutów. Warstwa wektorowa jest rdzeniem modelu i silnikiem obliczeniowym symulacji. W tej warstwie następuje przeniesienie parametrów wejściowych do przestrzeni wektorowej przy użyciu funkcji modulujących. Natomiast warstwa wyjściowa prezentuje końcowe wyniki w formie wskaźników marży (M) oraz wskaźnika wykorzystania (U), które mogą podlegać dalszej interpretacji biznesowej i ocenie efektywności ekonomicznej stacji.



Rys. 5.1 Warstwowa architektura modelu

Źródło: opracowanie własne.

5.1.2. ELEMENTY WARSTWY WEJŚCIOWEJ MODELU

Na potrzeby badań zakłada się, że warstwa wejściowa modelu obejmuje następujące elementy składowe:

- zbiór P parametrów modelu**, opisujących zewnętrzne i wewnętrzne czynniki wpływające na ekonomikę stacji ładowania, zapisany w postaci:

$$\mathcal{P} = \{ P_1, P_2, \dots, P_j, \dots, P_N \}$$

Każdy parametr P_j w modelu opisany jest przez wektor, tj.:

$$V_{jp} = \begin{bmatrix} F_{jm} \\ F_{ju} \end{bmatrix} \quad \text{dla każdego } P_j \in \mathcal{P}$$

gdzie:

F_{jm} - wartość funkcji określającej wpływ parametru P_j na marżę,

F_{ju} - wartość funkcji określającej wpływ parametru P_j na wykorzystanie infrastruktury.

- zbiór atrybutów $\mathcal{A}$** , charakteryzujących poszczególne parametry pod względem m.in. kierunku i siły wpływu na marżę i wykorzystanie infrastruktury. Wszystkie atrybuty w modelu można przedstawić w postaci wektora, tj.:

$$\mathcal{A} = [a_1, a_2, \dots, a_i, \dots, a_n],$$

który dla wybranego P_j jest reprezentowany przez wektor atrybutów postaci:

$$\mathcal{A}_j = [a_{j1}, a_{j2}, \dots, a_{ji}, \dots, a_{js}],$$

pełniący w algorytmie obliczeniowym rolę wektora argumentów dla funkcji modulujących parametru P_j

$$F_{ju}(\mathcal{A}_j) \quad \text{ i } \quad F_{jm}(\mathcal{A}_j).$$

5.1.3. ELEMENTY WARSTWY WEKTOROWEJ MODELU

Warstwa wektorowa modelu obejmuje następujące elementy składowe:

- a. **zbiór funkcji modulujących** odwzorowujących nieliniową dynamikę parametrów w funkcji atrybutów (atrybuty $\rightarrow$ argumenty funkcji F),


$$\mathbf{F} = \{F_j(\mathcal{A}_j): j = 1, \dots, N\}; \quad \mathcal{A}_j = [a_{j1}, a_{j2}, \dots, a_{ji}, \dots, a_{js}]$$

$$F_j(\mathcal{A}_j) = \begin{bmatrix} F_{jm}(\mathcal{A}_j) \\ F_{ju}(\mathcal{A}_j) \end{bmatrix}$$

gdzie

i każda z funkcji $F_{jm}, F_{ju} : \mathbb{R}^s \rightarrow \mathbb{R}$

Na Rys. 5.2 przedstawiono przykładowe funkcje modulujące.



Rys 5.2 Przykładowe funkcje modulujące

Źródło: opracowanie własne.

- b. **wektorowe reprezentacje składowych** wpływu parametru P_j na wykorzystanie infrastruktury V_{ju} oraz marżę V_{jm} przenoszą wpływ parametrów do przestrzeni wektorowej.

Wektor V_{ju} odwzorowuje wpływ atrybutów parametru P_j na zmianę wykorzystania infrastruktury stacji (Δu_j):

$$V_{ju} = F_{ju}(\mathcal{A}_j)$$

Natomiast wektor V_{jm} odwzorowuje wpływ atrybutów parametru P_j na zmianę marży (Δm_j):


$$V_{jm} = F_{jm}(\mathcal{A}_j)$$

Daje to w efekcie parę wektorów dla każdego z parametrów P_j .

$$V_{ju} = \begin{bmatrix} 0 \\ \Delta u_j \end{bmatrix}, \quad V_{jm} = \begin{bmatrix} \Delta m_j \\ 0 \end{bmatrix}$$

- c. **wektorowe reprezentacje parametru** V_{jp} dla parametru P_j powstają na bazie struktury pokazanej na Rys. 5.3.

$$V_{jp} = F_j(\mathcal{A}_j), \quad V_{jp} = \begin{bmatrix} \Delta m_j \\ \Delta u_j \end{bmatrix} \in \mathbb{R}^2$$




Rys 5.3 Struktura tworząca wektor V_{jp}

Źródło: opracowanie własne.

- d. **wynikowy wskaźnik decyzyjny (Impact Vector)** reprezentowany przez wektor wyniku końcowego V_u , stanowiący wypadkową oddziaływania wszystkich parametrów uwzględnionych w modelu, co można zapisać formalnie i zaprezentować

$$V_w = \sum_{j=1}^N V_{jp}$$

w postaci graficznej jak pokazano na Rys. 5.4.



Rys 5.4 Reprezentacja graficzna wektora V_w .

Źródło: opracowanie własne.

Tak sformalizowana struktura modelu umożliwia jednoczesną analizę kierunku i skali wpływu poszczególnych parametrów na oba wskaźniki ekonomiczne oraz stanowi fundament dla algorytmu symulacyjnego.

5.1.4. ELEMENTY WARSTWY WYJŚCIOWEJ MODELU - WSKAŹNIKI MARŻY I WYKORZYSTANIA

Warstwę wyjściową modelu tworzą dwa kluczowe wskaźniki ekonomiczne stacji ładowania: marża handlowa brutto (oznaczana symbolem M i nazywana w skrócie “marżą”) oraz wykorzystanie infrastruktury stacji (oznaczana symbolem U). Wielkości te są rezultatem obliczeń algorytmu symulacyjnego i stanowią podstawę do biznesowej oceny efektywności stacji.

A. wskaźnik marży M

W rozprawie marża jest rozumiana jako **marża handlowa brutto** wg definicji Głównego Urzędu Statystycznego, który opisuje ją jako cenę usługi handlowej stanowiącą różnicę między ceną zakupu a ceną sprzedaży towaru lub usługi, przeznaczoną na pokrycie kosztów handlowych i osiągnięcie zysku [57]. Dla stacji ładowania oznacza to różnicę między ceną sprzedaży energii a kosztem jej zakupu, wyrażoną w jednostce PLN/kWh.

$$M = P - C \text{ (PLN/kWh)}$$

W algorytmie obliczeniowym marża jest jednak stosowana w formie procentowej M [%] i definiowana jako stosunek marży do ceny sprzedaży, tj.:

$$M = \frac{P - C}{P} \cdot 100\%$$

gdzie:

P - oznacza cenę sprzedaży [PLN/kWh],

C - oznacza koszt energii w hurcie [PLN/kWh].

Należy podkreślić, że C nie uwzględnia kosztu operacyjnego, ponieważ jego wpływ został uwzględniony w parametrze P_9 - koszty OPEX.

Reprezentacją marży w przestrzeni $\mathbb{R}^2$ M-U jest wymiar odpowiadający punktowi M na osi odciętych i odpowiadający jej wektor wynikowy:

$$V_w = [M, 0]$$

B. wskaźnik wykorzystania infrastruktury U

U [%] reprezentuje procentowy udział sprzedanej mocy U_s [kWh] w stosunku do maksymalnej mocy, którą dysponuje operator stacji ładowania P_{max} [kWh].

$$U = \frac{U_s}{P_{max}} \cdot 100\%$$

Reprezentacją wykorzystania infrastruktury stacji w przestrzeni M-U $\mathbb{R}^2$ jest wymiar odpowiadający punktowi U na osi rzędnej i odpowiadający jej wektor

$$V_w = [0, U]$$

5.2. USTALANIE ZALEŻNOŚCI FUNKCYJNYCH DLA POSZCZEGÓLNYCH PARAMETRÓW WPLYWU

Wprowadzenie do modelu funkcji modulujących jest konieczne w celu odzwierciedlenia nieliniowości w analizowanym systemie. W rzeczywistych warunkach funkcjonowania stacji ładowania wpływ poszczególnych parametrów nie jest stały w czasie ani liniowy w całym zakresie zmienności. Jak wskazano w rozdziałach 1 i 2 rozprawy, ten sam bodziec, może wywoływać odmienną reakcję w zależności od poziomu nasycenia rynku, pory dnia, sezonu czy działań konkurencji. Zastosowanie nieliniowych funkcji modulujących umożliwia uwzględnienie zjawisk cykliczności, progu nasycenia oraz innych efektów asymetrycznych.

Proces ustalania zależności funkcyjnych dla poszczególnych parametrów wpływu był realizowany w sposób iteracyjny z wykorzystaniem narzędzia Jupyter Notebook. Funkcje modulujące były projektowane i testowane przy użyciu języka Python, z wykorzystaniem Matplotlib, co umożliwiało bieżącą analizę przebiegu funkcji oraz ich zachowania przy zmienności atrybutów. Środowiskiem uruchomieniowym było Visual Studio Code, co pozwoliło na powtarzalność eksperymentów obliczeniowych, dokumentowanie kolejnych iteracji oraz kontrolę wersji roboczych poprzez narzędzie Gitlab.

Dobór postaci funkcji oraz ich parametrów oparto na wiedzy zdobytej w trakcie analizy literatury przedmiotu, w szczególności badań dotyczących elastyczności popytu, sezonowości, wpływu ceny, kosztów energii oraz czynników technicznych i rynkowych na ekonomikę infrastruktury ładowania pojazdów elektrycznych. Uzupełnieniem tego podejścia była wiedza ekspercka autora wynikająca z wieloletniego doświadczenia zawodowego w obszarze elektromobilności. Przede wszystkim wiedza z zakresu projektowania i implementacji oprogramowania do obsługi pojazdów FCEV oraz oprogramowania do obsługi sieci stacji ładowania jednego z operatorów, pracy z danymi operacyjnymi z systemów typu backend CPMS (ang. Charge Point Management System - system zarządzania stacjami ładowania EV), informacji dostarczanych przez interfejsy OCPP oraz danych pojazdów EV z magistrali CAN. W procesie doboru funkcji modulujących wykorzystano interaktywne środowisko obliczeniowe Jupyter Notebook, co umożliwiło empiryczną weryfikację przyjętych założeń dotyczących kształtu funkcji, identyfikację obszarów nieliniowości, punktów nasycenia oraz progów reakcji modelu.

Argumentami funkcji modulujących są atrybuty poszczególnych parametrów, które zdefiniowano w pkt 4.4. W celu zapewnienia użyteczności modelu w zastosowaniach

rzeczywistych uwzględniono możliwość jego dostrajania do indywidualnych potrzeb i specyfiki operatora stacji ładowania. Z tego względu zbiór atrybutów

$$\mathcal{A}_j = [a_{j1}, a_{j2}, \dots, a_{ji}, \dots, a_{js}],$$

rozszerzono o dodatkowe zmienne kalibrujące model w postaci wektora $G = [g_{j,1}, g_{j,2}, \dots, g_{j,48}]$.

Dla każdego parametru P_j został przypisany przynależny mu wektor G_j zgodnie z Tab. 5.0.

Tab 5.0 Przypisanie wektorów atrybutów kalibrujących do parametrów

Parametr P_j	Wektor G_j
P_1 - Cena sprzedaży	$G_1 = [g_{1,1}, g_{1,2}, g_{1,3}, g_{1,4}]$
P_2 - Ceny konkurencji	$G_2 = [g_{2,5}, g_{2,6}]$
P_3 - Liczba konkurencyjnych stacji w okolicy	$G_3 = [g_{3,7}, g_{3,8}]$
P_4 - Koszt energii elektrycznej	$G_4 = [g_{4,9}, g_{4,10}, g_{4,11}, g_{4,12}]$
P_5 - Pora dnia	$G_5 = \emptyset$
P_6 - Lojalność klientów wobec marki	$G_6 = [g_{6,13}, g_{6,14}, g_{6,15}]$
P_7 - Wartość dodana oferty stacji	$G_7 = [g_{7,16}, g_{7,17}, g_{7,18}]$
P_8 - Awarie i niedostępność	$G_8 = [g_{8,19}, g_{8,20}]$
P_9 - Koszty operacyjne stacji	$G_9 = [g_{9,21}, g_{9,22}, g_{9,23}, g_{9,24}]$
P_{10} - Subwencje i ulgi podatkowe	$G_{10} = [g_{10,25}, g_{10,26}]$
P_{11} - Widoczność i rzetelna informacja o stacji	$G_{11} = [g_{11,27}, g_{11,28}]$
P_{12} - Ograniczenia sieci energetycznej	$G_{12} = [g_{12,29}]$
P_{13} - Warunki pogodowe i sezonowość	$G_{13} = [g_{13,30}, g_{13,31}]$
P_{14} - Obsługiwane standardy ładowania	$G_{14} = [g_{14,32}, g_{14,33}]$
P_{15} - Udział w programach Demand Response (DSR)	$G_{15} = [g_{15,34}, g_{15,35}]$
P_{16} - Bazowa liczba samochodów EV	$G_{16} = [g_{16,36}, g_{16,37}]$
P_{17} - UX użytkownika (wygoda)	$G_{17} = [g_{17,38}, g_{17,39}, g_{17,40}]$
P_{18} - Moc ładowania	$G_{18} = [g_{18,41}, g_{18,42}, g_{18,43}]$
P_{19} - Umowy flotowe i abonamenty	$G_{19} = [g_{19,44}, g_{19,45}, g_{19,46}]$
P_{20} - Wskaźnik inflacji	$G_{20} = [g_{20,47}, g_{20,48}]$

Źródło: opracowanie własne.

Konkatencja wektorów:

$$A_j = \mathcal{A}_j \parallel G_j$$

tworzy kompletny wektor argumentów funkcji F_j dla parametru P_j w postaci wektora

$$A_j = [a_{j1}, \dots, a_{js}, g_{j1}, \dots, g_{jr}]$$

Atrybuty będące składowymi wektora $\mathcal{A}_j$ oznaczono w zestawieniach tabelarycznych symbolem A, natomiast zmienne kalibrujące będące składowymi wektora G symbolem K. Wartości kolejnych współczynników $G_{j,i}$ zostały określone w ramach procesu doboru funkcji modulujących z wykorzystaniem środowiska obliczeniowego Jupyter Notebook. W rezultacie uzyskano kompletny zbiór argumentów dla funkcji modulujących zapisanych tabelarycznie.

5.3. FUNKCJE MODELUJĄCE DLA PARAMETRÓW MODELU

5.3.1. FUNKCJE MODULUJĄCE DLA PARAMETRÓW OTOCZENIA RYNKOWEGO I KONKURENCYJNEGO

Jak przedstawiono w rozdziale 4 rozprawy parametry obszaru otoczenia rynkowego i konkurencyjnego obejmują dwa parametry: P2 - cenę konkurencji oraz P3 - liczbę konkurencyjnych stacji w okolicy. Poniżej przedstawiono funkcyjne zależności modulujące dla analizowanych parametrów wraz z przykładowymi wykresami ilustrującymi ich przebieg.

A. Parametr P2 - ceny konkurencji

Dla wyznaczenia funkcji modelujących dla parametru P2 jako argumenty funkcji przyjęto zidentyfikowany wcześniej atrybut i zmienne kalibrujące. W Tab. 5.1 zestawiono argumenty funkcji modulujących parametru P2.

Tab 5.1 Tabela atrybutów wpływających na parametr P2 (argumenty funkcji modulujących)

Symbol	Typ	Nazwa	Opis
$\Delta p_{rel} [-]$	A	Różnica względna cen	Stosunek między ceną na badanej stacji a średnią ceną u konkurencji w okolicy.
$\beta_2 [-]$	K	Współczynnik reakcji	Parametr kalibracyjny określający jak silnie klienci reagują na tańszą konkurencję (amplituda odpływu).
$\gamma_2 [-]$	K	Parametr nasycenia	Określa limit krzywej reakcji, jak szybko następuje "ucieczka" klientów przy rosnącej różnicy cen.

Źródło: opracowanie własne.

Zależności funkcyjne modulujące nieliniowość F_{ju} i F_{jm} dla parametru P2 można zapisać za pomocą funkcji tangens hiperboliczny w następujący sposób:


Funkcja modulująca zmianę marży:

$$F_{2m}(A_2) = 0$$

Funkcja modulująca zmianę wykorzystania infrastruktury stacji:

$$F_{2u}(A_2) = -\beta_2 \cdot \tanh(\gamma_2 \cdot \Delta p_{rel})$$

Funkcje modulujące dla parametru P2 można przedstawić w formie graficznej za pomocą przykładowych wykresów pokazanych na Rys. 5.5.



Rys 5.5 Przykładowe wykresy funkcji modulujących dla parametru P2

Źródło: opracowanie własne.

B. Parametr P3 - liczba konkurencyjnych stacji w okolicy

Dla wyznaczenia funkcji modelujących dla parametru P3 jako argumenty funkcji przyjęto zidentyfikowany wcześniej atrybut i zmienne kalibrujące. W Tab. 5.2 zestawiono argumenty funkcji modulujących parametru P2.

Tab 5.2 Tabela atrybutów wpływających na parametr P3 (argumenty funkcji modulujących).

Symbol	Typ	Nazwa	Opis
n_R [szt.]	A	Liczba konkurentów	Liczba stacji ładowania innych operatorów w zadanym promieniu (strefa oddziaływania).
$n_{R,0}$ [szt.]	K	Poziom bazowy	Bazowa liczba stacji, względem której liczona jest zmiana.
β_3 [-]	K	Współczynnik wpływu	Stała określająca siłę spadku wykorzystania infrastruktury w reakcji na pojawienie się nowej stacji.

Źródło: opracowanie własne.

Zależności funkcyjne modulujące nieliniowość F_{ju} i F_{jm} dla parametru P3 można zapisać za pomocą funkcji logarytmicznej w następujący sposób:


Funkcja modulująca zmianę marży:

$$F_{3m}(A_3) = 0$$

Funkcja modulująca zmianę wykorzystania infrastruktury stacji:

$$F_{3u}(A_3) = -\beta_3 \cdot \ln \left(1 + \frac{n_R}{n_{R,0}} \right)$$

Funkcje modulujące dla parametru P3 można przedstawić w formie graficznej za pomocą przykładowych wykresów pokazanych na Rys. 5.6.



Rys 5.6 Przykładowe wykresy funkcji modulujących dla parametru P3.

Źródło: opracowanie własne.

5.3.2. FUNKCJE MODULUJĄCE DLA PARAMETRÓW POPYTU

Zgodnie z opisem w rozdziale 4 rozprawy parametry obszaru popytu obejmują parametry: P1 - cenę sprzedaży, P5 - porę dnia, P13 - warunki pogodowe i sezonowość, P16 - bazowa liczba samochodów EV. Poniżej przedstawiono funkcyjne zależności modulujące dla analizowanych parametrów wraz z przykładowymi wykresami ilustrującymi ich przebieg.

A. Parametr P1 - cena sprzedaży

Dla wyznaczenia funkcji modelujących dla parametru P1 jako argumenty funkcji przyjęto zidentyfikowane wcześniej atrybuty i dodatkowe zmienne kalibrujące. W Tab. 5.3 zestawiono wszystkie argumenty funkcji modulujących parametru P1 wraz z opisem.

Tab 5.3 Tabela atrybutów wpływających na parametr P1 (argumenty funkcji modulujących)

Symbol	Typ	Nazwa	Opis
p [PLN/kWh]	A	Cena	Aktualna cena usługi ładowania.

Symbol	Typ	Nazwa	Opis
Δp [PLN/kWh]	A	Zmiana ceny	Zmiana ceny operatora.
p_0 [PLN/kWh]	K	Cena bazowa	Bazowa cena odniesienia
m_{curr} [PLN/kWh]	K	Marża bieżąca	Marża z poprzedniego kroku.
ϵ_{eff} [-]	K	Elastyczność cenowa popytu	Współczynnik odzorowujący siłę reakcji popytu.
u_{curr} [0-1]	K	Wykorzystanie bieżące	Aktualny poziom wykorzystania infrastruktury stacji.

Źródło: opracowanie własne.


Zależności funkcyjne modulujące nieliniowość F_{ju} i F_{jm} dla parametru P1 zapisano w następujący sposób. Funkcja modulująca zmianę marży:

$$F_{1m}(A_1) = \Delta p \left(1 - \frac{m_{curr}}{100} \right)$$

Funkcja modulująca zmianę wykorzystania infrastruktury:

$$F_{1u}(A_1) = \min \left(1, \max \left(0, u_{curr} \left(\frac{p_0 + \Delta p}{p_0} \right)^{\epsilon_{eff}} \right) \right) - u_{curr}$$

Funkcje modulujące dla parametru P1 można przedstawić w formie graficznej za pomocą przykładowych wykresów pokazanych na Rys. 5.7.



Rys 5.7 Przykładowe wykresy funkcji modulujących dla parametru P1

Źródło: opracowanie własne.

B. Parametr P5 - pora dnia (szczyt/pozaszczyt)

Dla wyznaczenia funkcji modelujących dla parametru P5 jako argumenty funkcji przyjęto zidentyfikowane wcześniej atrybuty (rozdz. 4) i dodatkowe zmienne kalibrujące. W Tab. 5.4 zestawiono wszystkie argumenty funkcji modulujących parametru P5 wraz z opisem.

Tab 5.4 Tabela atrybutów wpływających na parametr P5 (argumenty funkcji modulujących)

Symbol	Typ	Nazwa	Opis
h [h]	A	Godzina doby	Zmienna wejściowa symulacji, dla której obliczamy zapotrzebowanie.
H_1	A	Amplituda nocna	Maksymalna intensywność ładowania wieczorem/nocą.
μ_1 [h]	A	Godzina nocna	Godzina, w której zapotrzebowanie nocne jest największe.
σ_1 [h]	A	Rozrzut nocny	Odchylenie standardowe szczytu nocnego.
H_2	A	Amplituda poranna	Maksymalna intensywność ładowania rano.
μ_2 [h]	A	Godzina poranna	Godzina, w której poranny szczyt osiąga maksimum.
σ_2 [h]	A	Rozrzut poranny	Odchylenie standardowe szczytu porannego.

Źródło: opracowanie własne.

Zależności funkcyjne modulujące nieliniowość F_{ju} i F_{jm} dla parametru P5 zapisano w następujący sposób:


Funkcja modulująca zmianę marży:

$$F_{5m}(A_5) = 0$$

Funkcja modulująca zmianę wykorzystania infrastruktury stacji:

$$F_{5u}(A_5) = H_1 \exp\left(-\frac{(h - \mu_1)^2}{2\sigma_1^2}\right) + H_2 \exp\left(-\frac{(h - \mu_2)^2}{2\sigma_2^2}\right)$$

Funkcje modulujące dla parametru P5 można przedstawić w formie graficznej za pomocą przykładowych wykresów pokazanych na Rys. 5.8.



Rys 5.8 Przykładowe wykresy funkcji modułujących dla parametru P5

Źródło: opracowanie własne.

C. Parametr P13 - warunki pogodowe i sezonowość

Dla wyznaczenia funkcji modelujących dla parametru P13 jako argumenty funkcji przyjęto zidentyfikowane wcześniej atrybuty i dodatkowe zmienne kalibrujące. W Tab. 5.5 zestawiono wszystkie argumenty funkcji modułujących parametru P13 wraz z opisem.

Tab 5.5 Tabela atrybutów wpływających na parametr P13 (argumenty funkcji modułujących)

Symbol	Typ	Nazwa	Opis
S [1-12]	A	Miesiąc	Zmienna cykliczna reprezentująca porę roku.
T_{zew} [°C]	A	Temperatura	Temperatura zewnętrzna powietrza
α_{13} [-]	K	Amplituda sezonowa	Siła wpływu pory roku na wykorzystanie infrastruktury stacji.
β_{13} [-]	K	Wrażliwość temperaturowa	Współczynnik zmiany na skutek temperatury.

Źródło: opracowanie własne.

W celu zapewnienia przejrzystości opisu model pogodowo-sezonowy został rozłożony na dwa submodele: pogodowy i sezonowy. W obu submodelach parametr nie ma wpływu na marżę. Zależności funkcyjne modułujące nieliniowość F_{ju} i F_{jm} dla parametru P13 zapisano w następujący sposób:

Funkcja modułująca zmianę marży:

$$F_{13m}(A_{13}) = 0$$

Funkcje F_{ju} opisujące:


- wpływ sezonowości:

$$F_{13u}(A_{13}) = \alpha_{13} \sin\left(\frac{2 \cdot \pi \cdot S}{12}\right) - \beta_{13}(T_{zew})^2$$

- wpływ temperatury:


$$F_{13u}(A_{13}) = -\beta_{13} \cdot \max(|T_{zew} - 20| - 5)^2 - \beta_{13} \cdot \max(-(T_{zew} - 20) - 10)^2$$

Funkcje modulujące dla parametru P13 można przedstawić w formie graficznej za pomocą pary wykresów pokazanych na Rys. 5.9a i Rys. 5.9b.



Rys 5.9a Przykładowy wykres funkcji modulujących wpływ sezonowości dla parametru P13

Źródło: opracowanie własne.



Rys 5.9b Przykładowe wykresy funkcji modulujących wpływ temperatury dla parametru P13

Źródło: opracowanie własne.

D. Parametr P16 - bazowa liczba samochodów EV

Dla wyznaczenia funkcji modelujących dla parametru P16 jako argumenty funkcji przyjęto zidentyfikowany wcześniej atrybut i dodatkowe zmienne kalibrujące. W tabeli 5.6 zestawiono wszystkie argumenty funkcji modulujących parametru P16 wraz z opisem.

Tab 5.6 Tabela atrybutów wpływających na parametr P16 (argumenty funkcji modulujących)

Symbol	Typ	Nazwa	Opis
N_{EV} [szt.]	A	Liczba aut EV lokalnych	Bezwzględna liczba EV zarejestrowanych w promieniu oddziaływania stacji.
N_{EV0} [szt.]	K	Poziom odniesienia	Współczynnik modelujący nieliniowy rozkład popytu na konkurencyjnym rynku.
α_{21} [-]	K	Współczynnik chłonności	Współczynnik określający, jak silnie lokalna baza aut przekłada się na zajętość stacji.

Źródło: opracowanie własne.

Zależności funkcyjne modulujące nieliniowość F_{ju} i F_{jm} dla parametru P16 zapisano w następujący sposób:


Funkcja modulująca zmianę marży:

$$F_{16m}(A_{16}) = 0$$

Funkcja modulująca zmianę wykorzystania infrastruktury stacji:

$$F_{16u}(A_{16}) = \alpha_{21} \cdot \ln \left(\frac{N_{EV}}{N_{EV0}} \right)$$

Funkcje modulujące dla parametru P16 można przedstawić w formie graficznej za pomocą przykładowych wykresów pokazanych na Rys. 5.10.



Rys 5.10 Przykładowe wykresy funkcji modulujących dla parametru P16

Źródło: opracowanie własne.

5.3.3. FUNKCJE MODULUJĄCE DLA PARAMETRÓW Z GRUPY KOSZTÓW

Zgodnie z opisem w rozdziale 4 rozprawy parametry z obszaru kosztów obejmują: P4 - koszt energii elektrycznej, P9 - koszty operacyjne stacji. Poniżej przedstawiono funkcyjne zależności modulujące dla analizowanych parametrów wraz z przykładowymi wykresami ilustrującymi ich przebieg.

A. Parametr P4 - koszt energii elektrycznej

Dla wyznaczenia funkcji modelujących dla parametru P4 jako argumenty funkcji przyjęto zidentyfikowany wcześniej atrybut i dodatkowe zmienne kalibrujące. W tabeli 5.7 zestawiono wszystkie argumenty funkcji modulujących parametru P4 wraz z opisem.

Tab 5.7 Tabela atrybutów wpływających na parametr P4 (argumenty funkcji modulujących)

Symbol	Typ	Nazwa	Opis
Δc_e [PLN/kWh]	A	Zmiana kosztu energii	Wzrost lub spadek ceny zakupu prądu na giełdzie/u dostawcy względem wartości poprzedniej.
λ_e [0-1]	K	Współczynnik przeniesienia	Część wzrostu kosztów, którą operator decyduje się przerzucić na klienta w wyższej cenie.

Symbol	Typ	Nazwa	Opis
p [PLN/kWh]	K	Cena detaliczna	Aktualna cena dla klienta (używana do obliczenia relatywnego wpływu podwyżki na popyt).
ϵ_{eff} [-]	K	Elastyczność efektywna popytu	Określa, jak bardzo spadnie wykorzystanie infrastruktury stacji, jeśli operator podniesie cenę, by skompensować koszt energii.
u_{curr} [0-1]	K	Wykorzystanie bieżące infrastruktury	Obecne obłożenie stacji, modyfikujące skalę spadku popytu.

Źródło: opracowanie własne.

Zależności funkcyjne modulujące nieliniowość F_{ju} i F_{jm} dla parametru P4 zapisano w następujący sposób:


Funkcja modulująca zmianę marży:

$$F_{4m}(A_4) = -(1 - \lambda_e) \cdot \Delta c_e$$

Funkcja modulująca zmianę wykorzystania infrastruktury stacji:

$$F_{4u}(A_4) = \epsilon_{eff} \cdot \left(\frac{\lambda_e \cdot \Delta c_e}{p} \right) \cdot (1 - u_{curr})$$

Funkcje modulujące dla parametru P4 można przedstawić w formie graficznej za pomocą przykładowych wykresów pokazanych na Rys. 5.11.



Rys 5.11 Przykładowe wykresy funkcji modulujących dla parametru P4.

Źródło: opracowanie własne.

B. Parametr P9 - koszty operacyjne stacji

Dla wyznaczenia funkcji modelujących dla parametru P9 jako argumenty funkcji przyjęto zidentyfikowany wcześniej atrybut i dodatkowe zmienne kalibrujące. W Tab. 5.8 zestawiono wszystkie argumenty funkcji modulujących parametru P9 wraz z opisem.

Tab 5.8 Tabela atrybutów wpływających na parametr P9 (argumenty funkcji modulujących)

Symbol	Typ	Nazwa	Opis
Δc_{op} [PLN/kWh]	A	Zmiana OPEX	Współczynnik uśrednionego kosztu operacyjnego stacji ładowania w relacji do ceny sprzedaży energii.
λ_{op} [0-1]	K	Przeniesienie kosztu	Część wzrostu OPEX przerzucana na cenę końcową dla kierowcy.
p [PLN/kWh]	K	Cena usługi	Aktualna cena, używana do obliczenia elastyczności popytu przy podwyżce.
ϵ_{eff} [-]	K	Elastyczność popytu	Reakcja rynku na ewentualną podwyżkę ceny wynikającą ze wzrostu kosztów.
u_{curr} [0-1]	K	Wkorzystanie bieżąca	Poziom wykorzystania infrastruktury stacji, baza do obliczenia spadku wolumenu.

Źródło: opracowanie własne.

Zależności funkcyjne modulujące nieliniowość F_{ju} i F_{jm} dla parametru P9 zapisano w następujący sposób:


Funkcja modulująca zmianę marży:

$$F_{9m}(A_9) = -(1 - \lambda_{op}) \cdot \Delta c_{op}$$

Funkcja modulująca zmianę wykorzystania infrastruktury stacji:

$$F_{9u}(A_9) = \epsilon_{eff} \cdot \left(\frac{\lambda_{op} \cdot \Delta c_{op}}{p} \right) \cdot (1 - u_{curr})$$

Funkcje modulujące dla parametru P9 można przedstawić w formie graficznej za pomocą przykładowych wykresów pokazanych na Rys. 5.12.



Rys 5.12 Przykładowe wykresy funkcji modulujących dla parametru P9

Źródło: opracowanie własne.

5.3.4. FUNKCJE MODULUJĄCE DLA PARAMETRÓW TECHNICZNYCH I INFRASTRUKTURALNYCH

Zgodnie z opisem w rozdziale 4 rozprawy parametry obszaru technicznego i infrastrukturalnego obejmują: P8 - awarie i niedostępność, P12 - ograniczenia sieci energetycznej, P14 - obsługiwane standardy ładowania, P18 - moc ładowania (szybkość ładowarek). Poniżej przedstawiono funkcyjne zależności modulujące dla analizowanych parametrów wraz z przykładowymi wykresami ilustrującymi ich przebieg.

A. Parametr P8 - awarie i niedostępność

Dla wyznaczenia funkcji modelujących dla parametru P8 jako argumenty funkcji przyjęto zidentyfikowane wcześniej atrybuty i dodatkowe zmienne kalibrujące. W tabeli 5.9 zestawiono wszystkie argumenty funkcji modulujących parametru P8 wraz z opisem.

Tab 5.9 Tabela atrybutów wpływających na parametr P8 (argumenty funkcji modulujących)

Symbol	Typ	Nazwa	Opis
$D [0-1]$	A	Niedostępność	Udział czasu, w którym stacja jest nieczynna z powodu awarii.
$Z_e [\text{szt.}]$	A	Liczba punktów ładowania	Liczba punktów ładowania na stacji.

Symbol	Typ	Nazwa	Opis
$\beta_8 [-]$	K	Kara za awarię	Współczynnik określający jak mocno awarie odstrasza klientów.
$\eta [-]$	K	Czynnik redundancji	Parametr korygujący stratę w zależności od liczby redundantnych punktów ładowania.

Źródło: opracowanie własne.

Zależności funkcyjne modulujące nieliniowość F_{ju} i F_{jm} dla parametru P8 zapisano w następujący sposób:


Funkcja modulująca zmianę marży:

$$F_{8m}(A_8) = 0$$

Funkcja modulująca zmianę wykorzystania infrastruktury stacji:

$$F_{8u}(A_8) = -\beta_8 \cdot D \cdot \left(1 + \frac{\eta}{Z_e}\right)$$

Funkcje modulujące dla parametru P8 można przedstawić w formie graficznej za pomocą przykładowych wykresów pokazanych na Rys. 5.13.



Rys 5.13 Przykładowe wykresy funkcji modulujących dla parametru P8

Źródło: opracowanie własne.

B. Parametr P12 - ograniczenia sieci energetycznej

Dla wyznaczenia funkcji modelujących dla parametru P12 jako argumenty funkcji przyjęto zidentyfikowane wcześniej atrybuty i dodatkową zmienną kalibrującą. W Tab. 5.10 zestawiono wszystkie argumenty funkcji modulujących parametru P12 wraz z opisem.

Tab 5.10 Tabela atrybutów wpływających na parametr P12 (argumenty funkcji modulujących)

Symbol	Typ	Nazwa	Opis
P_{red} [0-1]	A	Redukcja mocy	Współczynnik redukcji mocy z powodu przeciążenia/ograniczeń sieci.
τ_{limit} [godz.]	A	Czas ograniczenia	Czas trwania redukcji mocy w ciągu doby.
β_{12} [-]	K	Współczynnik straty	Przelicznik utraconej mocy i czasu na spadek wykorzystania infrastruktury stacji (utracona sprzedaż).

Źródło: opracowanie własne.

Zależności funkcyjne modulujące nieliniowość F_{ju} i F_{jm} dla parametru P12 zapisano w następujący sposób:


Funkcja modulująca zmianę marży:

$$F_{12m}(A_{12}) = 0$$

Funkcja modulująca zmianę wykorzystania infrastruktury stacji:

$$F_{12u}(A_{12}) = -\beta_{12} \cdot P_{red} \cdot \tau_{limit}$$

Funkcje modulujące dla parametru P12 można przedstawić w formie graficznej za pomocą przykładowych wykresów pokazanych na Rys. 5.14.



Rys 5.14 Przykładowe wykresy funkcji modulujących dla parametru P12

Źródło: opracowanie własne.

C. Parametr P14 - obsługiwane standardy ładowania

Dla wyznaczenia funkcji modelujących dla parametru P14 jako argumenty funkcji przyjęto zidentyfikowany wcześniej atrybut i dodatkowe zmienne kalibrujące. W tabeli 5.11 zestawiono wszystkie argumenty funkcji modulujących parametru P14 wraz z opisem.

Tab. 5.11 Tabela atrybutów wpływających na parametr P14 (argumenty funkcji modulujących)

Symbol	Typ	Nazwa	Opis
q_{std} [0-1]	A	Indeks kompatybilności	Udział obsługiwanych standardów ładowania w relacji do liczby standardów rynkowych.
α_{14} [-]	K	Pokrycie rynku	Współczynnik przekładający kompatybilność na dostępną bazę klientów.
ϕ_{14} [-]	K	Premia	Premia za wysoką kompatybilność.

Źródło: opracowanie własne.

Zależności funkcyjne modulujące nieliniowość F_{ju} i F_{jm} dla parametru P14 zapisano w następujący sposób:


Funkcja modulująca zmianę marży:

$$F_{14m}(A_{14}) = \phi_{14} \cdot q_{std}$$

Funkcja modulująca zmianę wykorzystania infrastruktury stacji:

$$F_{14u}(A_{14}) = \alpha_{14} \cdot q_{std}$$

Funkcje modulujące dla parametru P14 można przedstawić w formie graficznej za pomocą przykładowych wykresów pokazanych na Rys. 5.15.



Rys 5.15 Przykładowe wykresy funkcji modulujących dla parametru P14

Źródło: opracowanie własne.

D. Parametr P18 - Moc ładowania (szybkość ładowarek)

Dla wyznaczenia funkcji modelujących dla parametru P18 jako argumenty funkcji przyjęto zidentyfikowany wcześniej atrybut i dodatkowe zmienne kalibrujące. W Tab. 5.12 zestawiono wszystkie argumenty funkcji modulujących parametru P18 wraz z opisem.

Tab. 5.12 Tabela atrybutów wpływających na parametr P18 (argumenty funkcji modulujących)

Symbol	Typ	Nazwa	Opis
P [kW]	A	Moc stacji	Efektywna moc ładowania dostępna dla pojazdu.
P_0 [kW]	K	Moc odniesienia	Standard rynkowy (np. 50 kW), do którego porównywana jest oferta stacji.
ϕ_{18} [PLN]	K	Premia za szybkość	Dodatkowa marża możliwa do uzyskania za oferowanie szybkiego ładowania.
α_{18} [-]	K	Przyciąganie mocą	Siła wpływu wysokiej mocy na wybór stacji przez klientów.

Źródło: opracowanie własne.

Zależności funkcyjne modulujące nieliniowość F_{ju} i F_{jm} dla parametru P18 zapisano w następujący sposób:


Funkcja modulująca zmianę marży:

$$F_{18m}(A_{18}) = \phi_{18} \cdot \ln \left(1 + \frac{P}{P_0} \right)$$

Funkcja modulująca zmianę wykorzystania infrastruktury stacji:

$$F_{18u}(A_{18}) = \alpha_{18} \cdot \ln \left(1 + \frac{P}{P_0} \right)$$

Funkcje modulujące dla parametru P18 można przedstawić w formie graficznej za pomocą przykładowych wykresów pokazanych na Rys. 5.16.



Rys 5.16 Przykładowe wykresy funkcji modulujących dla parametru P18

Źródło: opracowanie własne.

5.3.5. FUNKCJE MODULUJĄCE DLA PARAMETRÓW MARKETINGOWYCH I PRODUKTOWYCH

Zgodnie z opisem w rozdziale 4 rozprawy parametry z grupy marketingowej i produktowej obejmują: P6 - lojalność klientów wobec marki, P7 - wartość dodaną oferty stacji, P11 - widoczność i rzetelność informacji o stacji, P17 - UX użytkownika (wygoda), P19 - umowy flotowe i abonamenty. Poniżej przedstawiono funkcyjne zależności modulujące dla analizowanych parametrów wraz z przykładowymi wykresami ilustrującymi ich przebieg.

A. Parametr P6 - lojalność klientów wobec marki

Dla wyznaczenia funkcji modelujących dla parametru P6 jako argumenty funkcji przyjęto zidentyfikowany wcześniej atrybut i dodatkowe zmienne kalibrujące. W tabeli 5.13 zestawiono wszystkie argumenty funkcji modulujących parametru P6 wraz z opisem.

Tab. 5.13 Tabela atrybutów wpływających na parametr P6 (argumenty funkcji modulujących)

Symbol	Typ	Nazwa	Opis
L [0-1]	A	Indeks lojalności	Współczynnik lojalności klientów liczony jako współczynnik sumarycznej liczby sesji ładowania do liczby powrotów (np. powracający MAC adres pojazdu).
ϕ_6 [PLN/kW]	K	Premia za markę	Kwota, jaką lojalni klienci są skłonni dopłacić za markę.
α_6 [-]	K	Wpływ na wolumen	Współczynnik przekładający wzrost lojalności na wzrost częstotliwości odwiedzin.
γ_6 [-]	K	Nasycenie marży	Parametr kształtu funkcji nasycenia dla premii marżowej.

Źródło: opracowanie własne.

Zależności funkcyjne modulujące nieliniowość F_{ju} i F_{jm} dla parametru P6 zapisano w następujący sposób:


Funkcja modulująca zmianę marży:

$$F_{6m}(A_6) = \phi_6 \cdot \tanh(\gamma_6 \cdot L)$$

Funkcja modulująca zmianę wykorzystania infrastruktury stacji:

$$F_{6u}(A_6) = \alpha_6 \cdot L$$

Funkcje modulujące dla parametru P6 można przedstawić w formie graficznej za pomocą przykładowych wykresów pokazanych na Rys. 5.17.



Rys 5.17 Przykładowe wykresy funkcji modulujących dla parametru P6

Źródło: opracowanie własne.

B. Parametr P7 - wartość dodana oferty stacji

Dla wyznaczenia funkcji modelujących dla parametru P7 jako argumenty funkcji przyjęto zidentyfikowany wcześniej atrybut i dodatkowe zmienne kalibrujące. W Tab. 5.14 zestawiono wszystkie argumenty funkcji modulujących parametru P7 wraz z opisem.

Tab 5.14 Tabela atrybutów wpływających na parametr P7 (argumenty funkcji modulujących)

Symbol	Typ	Nazwa	Opis
$V_{add} [0-1]$	A	Indeks udogodnień	Współczynnik jakości i liczby usług dodatkowych na stacji.
$\phi_7 [PLN]$	K	Premia za usługi	Wzrost akceptowalnej ceny dzięki wyższemu standardowi stacji.
$\alpha_7 [-]$	K	Przyciąganie klienta	Siła wpływu udogodnień na decyzję o wyborze stacji.
$\gamma_7 [-]$	K	Nasylenie użyteczności	Określa poziom, powyżej którego kolejne udogodnienia nie zwiększają już istotnie ruchu.

Źródło: opracowanie własne.

Zależności funkcyjne modulujące nieliniowość F_{ju} i F_{jm} dla parametru P7 zapisano w następujący sposób:


Funkcja modulująca zmianę marży:

$$F_{7m}(A_7) = \phi_7 \cdot V_{add}$$

Funkcja modulująca zmianę wykorzystania infrastruktury stacji:

$$F_{7u}(A_7) = \alpha_7 \cdot \tanh(\gamma_7 \cdot V_{add})$$

Funkcje modulujące dla parametru P7 można przedstawić w formie graficznej za pomocą przykładowych wykresów pokazanych na Rys. 5.18.



Rys 5.18 Przykładowe wykresy funkcji modulujących dla parametru P7

Źródło: opracowanie własne.

C. Parametr P11 - widoczność i rzetelność informacji o stacji

Dla wyznaczenia funkcji modelujących dla parametru P11 jako argumenty funkcji przyjęto zidentyfikowany wcześniej atrybut i dodatkowe zmienne kalibrujące. W Tab. 5.15 zestawiono wszystkie argumenty funkcji modulujących parametru P11 wraz z opisem.

Tab 5.15 Tabela atrybutów wpływających na parametr P11 (argumenty funkcji modulujących)

Symbol	Typ	Nazwa	Opis
V_{inf} [0-1]	A	Indeks widoczności	Ocena jakości oznakowania fizycznego i cyfrowego (SEO, mapy).

Symbol	Typ	Nazwa	Opis
α_{11} [-]	K	Konwersja na ruch	Współczynnik określający, jak widoczność przekłada się na liczbę odwiedzin.
ϕ_{11} [PLN]	K	Premia informacyjna	Wzrost marży wynikający z łatwości znalezienia stacji i pewności informacji.

Źródło: opracowanie własne.

Zależności funkcyjne modulujące nieliniowość F_{ju} i F_{jm} dla parametru P11 zapisano w następujący sposób:


Funkcja modulująca zmianę marży:

$$F_{11m}(A_{11}) = \phi_{11} \cdot V_{inf}$$

Funkcja modulująca zmianę wykorzystania infrastruktury stacji:

$$F_{11u}(A_{11}) = \alpha_{11} \cdot V_{inf}$$

Funkcje modulujące dla parametru P11 można przedstawić w formie graficznej za pomocą przykładowych wykresów pokazanych na Rys. 5.19.



Rys 5.19 Przykładowe wykresy funkcji modulujących dla parametru P11

Źródło: opracowanie własne.

D. Parametr P17 - UX użytkownika (wygoda)

Dla wyznaczenia funkcji modelujących dla parametru P17 jako argumenty funkcji przyjęto zidentyfikowany wcześniej atrybut i dodatkowe zmienne kalibrujące. W Tab. 5.16 zestawiono wszystkie argumenty funkcji modulujących parametru P17 wraz z opisem.

Tab 5.16 Tabela atrybutów wpływających na parametr P17 (argumenty funkcji modulujących)

Symbol	Typ	Nazwa	Opis
U_{UX} [0-1]	A	Indeks UX	Wskaźnik wygody obsługi
ϕ_{17} [PLN/kWh]	K	Premia za wygodę	Wartość, jaką klienci są skłonni zapłacić za bezproblemową obsługę.
α_{17} [-]	K	Powroty	Wpływ UX na retencję klientów.
γ_{17} [-]	K	Nasycenie	Parametr określający granicę nasycenia.

Źródło: opracowanie własne.


Zależności funkcyjne modulujące nieliniowość F_{ju} i F_{jm} dla parametru P17 zapisano w następujący sposób: Funkcja modulująca zmianę marży:

$$F_{17m}(A_{17}) = \phi_{17} \cdot U_{UX}$$

Funkcja modulująca zmianę wykorzystania infrastruktury stacji:

$$F_{17u}(A_{17}) = \alpha_{17} \cdot \tanh(\gamma_{17} \cdot U_{UX})$$

Funkcje modulujące dla parametru P17 można przedstawić w formie graficznej za pomocą przykładowych wykresów pokazanych na Rys. 5.20.



Rys 5.20 Przykładowe wykresy funkcji modulujących dla parametru P17

Źródło: opracowanie własne.

E. Parametr P19 - Umowy flotowe i abonamenty

Dla wyznaczenia funkcji modelujących dla parametru P19 jako argumenty funkcji przyjęto zidentyfikowany wcześniej atrybut i dodatkowe zmienne kalibrujące. W Tab. 5.17 zestawiono wszystkie argumenty funkcji modulujących parametru P19 wraz z opisem.

Tab 5.17 Tabela atrybutów wpływających na parametr P19 (argumenty funkcji modulujących)

Symbol	Typ	Nazwa	Opis
s_f [0-1]	A	Udział flotowy	Część wolumenu sprzedaży generowana przez kontrakty flotowe oraz abonamenty.
R_{abon} [PLN/kWh]	K	Stawka w kontrakcie	Średnia cena netto uzyskana z kontraktów.
m_{baz} [PLN/kWh]	K	Marża bazowa	Bazowa marża detaliczna
α_{19} [-]	K	Stabilizacja popytu	Współczynnik dodatniego wpływu kontraktów na poziom wykorzystania infrastruktury.

Źródło: opracowanie własne.

Zależności funkcyjne modulujące nieliniowość F_{ju} i F_{jm} dla parametru P19 zapisano w następujący sposób:


Funkcja modulująca zmianę marży:

$$F_{19m}(A_{19}) = s_f \cdot (R_{abon} - m_{baz})$$

Funkcja modulująca zmianę wykorzystania infrastruktury stacji:

$$F_{19u}(A_{19}) = \alpha_{19} \cdot s_f$$

Funkcje modulujące dla parametru P19 można przedstawić w formie graficznej za pomocą przykładowych wykresów pokazanych na Rys. 5.21.



Rys 5.21 Przykładowe wykresy funkcji modulujących dla parametru P19

Źródło: opracowanie własne.

5.3.6. FUNKCJE MODULUJĄCE DLA PARAMETRÓW MAKROEKONOMICZNYCH I REGULACJI

Zgodnie z opisem w rozdziale 4 rozprawy parametry obszaru makroekonomicznego i regulacji obejmują: P10 - subwencje i ulgi podatkowe, P15 - udział w programach DSR, P20 - wskaźnik inflacji. Poniżej przedstawiono funkcyjne zależności modulujące dla analizowanych parametrów wraz z przykładowymi wykresami ilustrującymi ich przebieg.

A. Parametr P10 - subwencje i ulgi podatkowe

Dla wyznaczenia funkcji modelujących dla parametru P10 jako argumenty funkcji przyjęto zidentyfikowany wcześniej atrybut i dodatkowe zmienne kalibrujące. W tabeli 5.18 zestawiono wszystkie argumenty funkcji modulujących parametru P10 wraz z opisem.

Tab 5.18 Tabela atrybutów wpływających na parametr P10 (argumenty funkcji modulujących)

Symbol	Typ	Nazwa	Opis
d [PLN/kWh]	A	Wartość subwencji	Wartość dopłaty lub ulgi w przeliczeniu na jednostkę sprzedanej energii.
λ_s [0-1]	K	Przekazanie korzyści klientowi	Wartość przekazania subwencji klientowi w postaci niższej ceny.

Symbol	Typ	Nazwa	Opis
ϵ_{eff} [-]	K	Elastyczność popytu	Określa zmianę elastyczności popytu, jeśli subwencja zostanie użyta do obniżki ceny.
p [PLN/kWh]	A	Cena	Cena sprzedaży energii.
u_{curr} [%]	A	Wykorzystanie bieżące infrastruktury	Bazowy współczynnik wykorzystania infrastruktury.

Źródło: opracowanie własne.

Zależności funkcyjne modulujące nieliniowość F_{ju} i F_{jm} dla parametru P10 zapisano w następujący sposób:


Funkcja modulująca zmianę marży:

$$F_{10m}(A_{10}) = (1 - \lambda_s) \cdot d$$

Funkcja modulująca zmianę wykorzystania infrastruktury stacji:

$$F_{10u}(A_{10}) = -\epsilon_{eff} \cdot \left(\frac{\lambda_s \cdot d}{p} \right) \cdot (1 - u_{curr})$$

Funkcje modulujące dla parametru P10 można przedstawić w formie graficznej za pomocą przykładowych wykresów pokazanych na Rys. 5.22.



Rys 5.22 Przykładowe wykresy funkcji modulujących dla parametru P10

Źródło: opracowanie własne.

B. Parametr P15 - udział w programach DSR

Dla wyznaczenia funkcji modelujących dla parametru P15 jako argumenty funkcji przyjęto zidentyfikowane wcześniej atrybuty i dodatkowe zmienne kalibrujące. W tabeli 5.19 zestawiono wszystkie argumenty funkcji modulujących parametru P15 wraz z opisem.

Tab 5.19 Tabela atrybutów wpływających na parametr P15 (argumenty funkcji modulujących)

Symbol	Typ	Nazwa	Opis
R_{DSR} [PLN]	A	Przychód z DSR	Wynagrodzenie otrzymywane od operatora systemu za gotowość do redukcji poboru.
δ [0-1]	A	Poziom redukcji dostępności stacji	Stopień ograniczenia dostępności stacji dla kierowców w momentach wezwania DSR.
τ_{DSR} [-]	K	Konwersja przychodu	Przelicznik przychodu z DSR na ekwiwalent marży jednostkowej.
α_{15} [-]	K	Spadek wykorzystania infrastruktury	Współczynnik określający, ile normalnych sesji ładowania stacja traci przez udział w DSR.

Źródło: opracowanie własne.

Zależności funkcyjne modulujące nieliniowość F_{ju} i F_{jm} dla parametru P15 zapisano w następujący sposób:


Funkcja modulująca zmianę marży:

$$F_{15m}(A_{15}) = \tau_{DSR} \cdot R_{DSR}$$

Funkcja modulująca zmianę wykorzystania infrastruktury stacji:

$$F_{15u}(A_{15}) = -\alpha_{15} \cdot \delta \cdot u_{curr}$$

Funkcje modulujące dla parametru P15 można przedstawić w formie graficznej za pomocą przykładowych wykresów pokazanych na Rys. 5.23.



Rys 5.23 Przykładowe wykresy funkcji modulujących dla parametru P15

Źródło: opracowanie własne.

C. Parametr P20 - wskaźnik inflacji

Dla wyznaczenia funkcji modelujących dla parametru P20 jako argumenty funkcji przyjęto zidentyfikowane wcześniej atrybuty i dodatkowe zmienne kalibrujące. W Tab. 5.20 zestawiono wszystkie argumenty funkcji modulujących parametru P20 wraz z opisem.

Tab 5.20 Tabela atrybutów wpływających na parametr P20 (argumenty funkcji modulujących)

Symbol	Typ	Nazwa	Opis
inf [%]	A	Wskaźnik inflacji	Wskaźnik wzrostu cen towarów i usług (CPI/PPI).
λ_{π} [0-1]	K	Indeksacja ceny	Współczynnik podniesienia ceny w odpowiedzi na inflację.
ϕ_{π} [0-1]	K	Ekspozycja	Udział kosztów operatora wrażliwych na inflację.
p	A	Cena	Cena bieżąca
u_{curr}	A	Ociążenie aktualne	Ociążenie aktualne

Źródło: opracowanie własne.

Zależności funkcyjne modulujące nieliniowość F_{ju} i F_{jm} dla parametru P20 zapisano w następujący sposób:


Funkcja modulująca zmianę marży:

$$F_{20m}(A_{20}) = -(1 - \lambda_{inf}) \cdot \phi_{inf} \cdot inf$$

Funkcja modulująca zmianę wykorzystania infrastruktury stacji:

$$F_{20u}(A_{20}) = \epsilon_{eff} \cdot \left(\frac{\lambda_{inf} \cdot \phi_{inf} \cdot inf}{p} \right) \cdot (1 - u_{curr})$$

Funkcje modulujące dla parametru P20 można przedstawić w formie graficznej za pomocą przykładowych wykresów pokazanych na Rys. 5.24.



Rys 5.24 Przykładowe wykresy funkcji modulujących dla parametru P20

Źródło: opracowanie własne.

6. ALGORYTM SYMULACYJNY

6.1. ZAŁOŻENIA OGÓLNE ORAZ SŁOWNIK PRZYJĘTYCH SYMBOLI I OZNACZEŃ

6.1.1. SŁOWNIK PRZYJĘTYCH SYMBOLI I OZNACZEŃ

Algorytm symulacyjny służy do realizacji symulacji stanowiącej jedną z możliwych form wykorzystania opracowanego modelu. Celem symulacji jest oszacowanie przewidywanego wyniku ekonomicznego stacji ładowania w zadanym czasie. Algorytm uwzględnia dynamiczną zmienność impulsów ekonomicznych (parametrów modelu) w czasie poprzez implementację mechanizmu próbkowania danych wejściowych, polegającego na cyklicznej aktualizacji wartości atrybutów parametrów z dostępnych źródeł danych z ustaloną, stałą częstotliwością f_s . Takie podejście umożliwia odwzorowanie bieżącego stanu układu oraz obliczenie wpływu zmian na wynik ekonomiczny stacji w kolejnych krokach symulacji.

W celu zapewnienia jednoznaczności i czytelności algorytmu przyjęto założenia co do zapisu poszczególnych symboli:

A. Indeksy i symbole wykorzystywane w symulacji:

- j - indeks (numer) parametru,
- i - indeks (numer) atrybutu,
- k - indeks kroku symulacji,
- t_0 - moment rozpoczęcia symulacji (znacznik czasu),
- T_s - okres próbkowania [h],
- f_s - częstotliwość próbkowania [Hz],
- T_{sim} - całkowity czas trwania symulacji [h],
- K - liczba kroków symulacji.

B. Symbole opisujące parametry modelu:

- N - liczba parametrów modelu,
- P_j - j -ty parametr modelu,
- $\mathcal{P} = \{P_1, P_2, \dots, P_j, \dots, P_N\}$ - zbiór parametrów modelu.

C. Symbole opisujące atrybuty modelu i argumenty funkcji:

- n - sumaryczna liczba atrybutów modelu,
- $\mathcal{A} = \{a_1, a_2, \dots, a_i, \dots, a_n\}$ - zbiór atrybutów modelu,

- a_{ji} - argument numer i funkcji modulującej dla parametru P_j ,
- js - sumaryczna liczba argumentów funkcji modulującej dla parametru P_j ,
- $\mathcal{A}_j = [a_{j1}, a_{j2}, \dots, a_{ji}, \dots, a_{js}]$ - wektor argumentów funkcji modulującej dla parametru P_j .
- $G_j = G = [g_{j,1}, g_{j,2}, \dots, g_{j,i}, \dots, g_{j,48}]$ - wektor argumentów kalibracyjnych parametru P_j

D. Symbole opisujące funkcje matematyczne:

- $\mathcal{F} = \{F_1, F_2, \dots, F_N\}$ - zbiór funkcji modulujących,
- F_{jm} - funkcja modulująca zmianę (deltę) marży dla parametru P_j ,
- F_{ju} - funkcja modulująca zmianę (deltę) wykorzystania infrastruktury stacji dla parametru P_j ,
- f_{jm} - funkcja normalizująca dla składowej marży parametru P_j ,
- f_{ju} - funkcja normalizująca dla składowej wykorzystania infrastruktury stacji parametru P_j ,
- κ_{jm} - współczynnik normalizujący składowej marży dla parametru P_j . Jest to współczynnik kalibracyjny,
- κ_{ju} - współczynnik normalizujący składowej wykorzystania infrastruktury stacji dla parametru P_j . Jest to współczynnik kalibracyjny.

E. Symbole do opisu marży i wykorzystania infrastruktury stacji:

- $m_j(t_k)$ - wartość marży dla parametru P_j w kroku symulacji k ,
- $u_j(t_k)$ - wartość wykorzystania infrastruktury stacji dla parametru P_j w kroku symulacji k ,
- m_0 - marża początkowa na początku symulacji,
- u_0 - początkowe wykorzystanie infrastruktury na początku symulacji,
- M_s - skumulowana wartość marży [PLN/kWh],
- U_s - skumulowana wartość wykorzystania infrastruktury [kWh],
- ΔM - szacowana zmiana marży w okresie symulacji [%],
- ΔU - szacowana zmiana wykorzystania infrastruktury w okresie symulacji [%].

F. Symbole opisujące zapis wektorowy wykorzystywany w modelu:

- V_{mj} - składowa marży wektora V_{jp} dla parametru P_j ,
- V_{uj} - składowa wykorzystania infrastruktury wektora V_{jp} dla parametru P_j ,
- V_{jp} - wektor parametru P_j ,
- V_w - wektor wyniku końcowego (ImpactVector),

- V_{wm} - składowa marży wyniku końcowego,
- V_{wu} - składowa wykorzystania infrastruktury wyniku końcowego.

G. Symbole opisujące ograniczenia systemowe i infrastrukturalne stacji ładowania:


- z_e - liczba złączy ładowania EVSE,
- u_z - współczynnik zajętości stanowisk ładowania
- $Z_{max} = [Z_1, Z_2, \dots, Z_{z_e}]$ - wektor EVSE maksymalnych mocy poszczególnych złączy,
- P_{max} - maksymalna moc jaką stacja może sprzedać w jednostce czasu,
- P_{grid} - ograniczenie mocy przyłączeniowej,
- P_{peak} - maksymalna dopuszczalna moc szczytowa,
- P_{uk} - moc stacji sprzedana w kroku k symulacji.

6.1.2. ZAŁOŻENIA OGÓLNE DO ALGORYTMU

Na potrzeby badań przyjęto następujące założenia:

- 1) Wartości początkowe u_0 i m_0 definiują stan układu w chwili rozpoczęcia symulacji t_0 i mają charakter wartości skumulowanych. Wartości te są wyznaczone przez operatora na podstawie danych historycznych. Przyjmuje się, że okres, na podstawie którego wyznaczone są wartości u_0 i m_0 , nie jest krótszy niż przyjęty czas symulacji T_{sim} . Założenie to zapewnia porównywalność pomiędzy wskaźnikami startowymi a wynikami uzyskanymi w badanym okresie. Reprezentatywność wyników wzrasta, gdy okres symulacji T_{sim} obejmuje co najmniej jeden pełny rok rozrachunkowy. Umożliwia to uwzględnienie efektów sezonowości oraz zjawisk charakteryzujących się wydłużonym lagiem, czyli opóźnieniem pomiędzy wystąpieniem bodźca a obserwowanym efektem rynkowym.
- 2) Źródła danych wejściowych oraz wyniki każdego z kroków symulacji mają charakter chwilowy. Oznacza to, że stan modelu zmienia się w momencie zakończenia procesu próbkowania danych wejściowych t_k i odwzorowuje stabilny stan parametrów modelu do czasu pobrania kolejnej próbki t_{k+1} .
- 3) Wszystkie funkcje modulujące oraz wektory wykorzystywane w modelu służą do wyznaczania zmian wartości analizowanych wskaźników, tj. przyrostów lub spadków (Δ), a nie ich wartości absolutnych. Oznacza to, że algorytm opisuje dynamikę przejścia układu pomiędzy kolejnymi stanami t , a nie bezwzględne poziomy wskaźników w danej chwili czasu.
- 4) Po rozpoczęciu symulacji dane wejściowe podlegają próbkowaniu z zadaną, stałą częstotliwością. W każdym kroku symulacyjnym próbkowane są jednocześnie wszystkie

atrybuty modelu, co stanowi podstawę do wyznaczenia odpowiadających im wektorów przesunięć V_{mj} i V_{uj} . Przyjmuje się, że częstotliwość próbkowania f_s jest jednakowa dla wszystkich źródeł danych wykorzystywanych w modelu i należy ją dobrać tak, aby odpowiadała najszybciej zmieniającemu się atrybutowi modelu. Zbyt niska częstotliwość próbkowania spowoduje utratę informacji o części bodźców (parametrów V_p), które wystąpią pomiędzy próbkami, co może prowadzić do zafałszowania wyniku symulacji (patrz Rys. 6.1).



Rys 6.1 Utrata próbki przy zbyt niskiej częstotliwości próbkowania f_s

Źródło: opracowanie własne.

- 5) Zakłada się z góry ustaloną liczbę kroków symulacji K przy zadanej częstotliwości próbkowania f_s . Na tej podstawie wyznaczany jest czas symulacji T_{sim} zgodnie z zapisem:

$$T_{sim} = \frac{K}{f_s}$$

czyli okres predykcji odpowiada iloczynowi liczby kroków i okresu próbkowania. Dopuszczalne jest też podejście odwrotne, w którym najpierw określa się okres predykcji T_{sim} , a następnie oblicza wymaganą liczbę kroków symulacji, tj.:

$$K = f_s \cdot T_{sim}$$

6.2. SCHEMAT BLOKOWY ALGORYTMU ORAZ OPIS REALIZACJI OBLICZEŃ

Celem algorytmu jest obliczenie wyniku ekonomicznego stacji w postaci wskaźników marży i wykorzystania infrastruktury stacji poprzez przeprowadzenie wielokrokowej symulacji

uwzględniającej zmienność oraz nieliniowość parametrów wpływających na ten wynik. Algorytm oparty jest na modelu wektorowym opisanym we wcześniejszych punktach.

Wynikiem algorytmu jest skumulowana wartość marży operacyjnej i wykorzystania infrastruktury w symulowanym okresie. Obie wartości są wyrażone w jednostkach procentowych i pokazują zmianę tych wartości w stosunku do stanu inicjalnego. Innymi słowy, pokazują, jak zmienność parametrów zewnętrznych oraz łańcuch decyzyjny parametrów wewnętrznych może wpłynąć na długookresowe wyniki stacji ładowania. Schemat blokowy algorytmu przedstawiono na Rys. 6.2. Ilustruje on najważniejsze kroki algorytmu, które poniżej opisano.

KROK 1 - Inicjacja algorytmu

Proces symulacji realizowany jest w dyskretnym czasie, z krokiem próbkowania określonym przez okres T_s .


Oś czasu symulacji (Rys. 6.3) definiuje się jako: $t_k = t_0 + k \cdot T_s$, $k = 0, 1, 2, \dots, K$ gdzie:

- t_0 - czas rozpoczęcia symulacji [data],
- T_s - okres próbkowania [h],
- $K = \frac{T_{sim}}{T_s}$ - liczba kroków symulacji,
- T_{sim} - całkowity czas trwania symulacji [h].

Częstotliwość próbkowania danych wejściowych wynosi:


$$f_s = \frac{1}{T_s}$$

i jest oznaczona jednostką [Hz] przy czym minimalny dopuszczalny okres próbkowania odpowiada $T_s = 1h$.



Rys 6.2 Relacja między czasem symulacji T_{sim} i okresem próbkowania T_s

Źródło: opracowanie własne.



Rys 6.3 Algorytm symulacyjny

Źródło: opracowanie własne.

Stan początkowy wskaźników ekonomicznych stacji w chwili t_0 definiowany jest jako:

$$m(t_0) = m_0, \quad u(t_0) = u_0$$

gdzie:

- $m(t_0)$ - marża handlowa brutto liczona od ceny sprzedaży energii w chwili t_0 ,
- $u(t_0)$ - wartość wskaźnika wykorzystania infrastruktury w chwili t_0 ,
- m_0, u_0 - wartości początkowe wskaźników.

Konfiguracja techniczna symulowanej stacji ładowania opisywana jest przez zbiór parametrów:

- Z_c - liczba złączy ładowania,
- $Z_{\max} = [Z_1, Z_2, \dots, Z_{n_c}]$ - wektor opisujący maksymalną moc każdego ze złącz,
- P_{grid} - ograniczenie mocy przyłączeniowej,
- P_{peak} - maksymalna dopuszczalna moc szczytowa.

Zakończenie etapu inicjacji algorytmu skutkuje utworzeniem kompletnego stanu początkowego symulacji, który stanowi punkt odniesienia dla dalszych kroków obliczeniowych realizowanych w pętli symulacyjnej. Od tego momentu algorytm przechodzi do iteracyjnego przetwarzania danych wejściowych i wyznaczania trajektorii zmian wskaźników ekonomicznych stacji ładowania w czasie.

KROK 2 - Próbkowanie wartości atrybutów (dane wejściowe)

Próbkowanie wartości atrybutów stanowi pierwszy etap obliczeniowy realizowany w ramach kroku symulacji algorytmu i odpowiada za odwzorowanie chwilowego stanu parametrów modelu w dyskretnych momentach czasu. Etap ten zapewnia powiązanie modelu wektorowego z rzeczywistą lub scenariuszową zmiennością warunków otoczenia.

Proces próbkowania będzie realizowany w dyskretnych krokach czasowych, tj.:

$$t_k = t_0 + k \cdot T_s, \quad k = 0, 1, 2, \dots, K$$


gdzie:

- t_0 - moment rozpoczęcia symulacji,
- T_s - okres próbkowania,
- K - liczba kroków symulacji wynikająca z całkowitego czasu symulacji.

Algorytm w kroku próbkowania przyjmuje jako dane wejściowe:

- identyfikator parametru $j = 1, \dots, N$, gdzie N to liczba parametrów modelu,

- zbiór aktualnych wartości atrybutów każdego parametru P_j , $A_j(t_k)$, pobierany jest ze źródeł danych.



Rys 6.4 Próbkowanie atrybutów ze źródeł danych

Źródło: opracowanie własne.

Istotnym założeniem etapu próbkowania jest neutralność obliczeniowa algorytmu względem danych wejściowych. Algorytm nie dokonuje na tym etapie żadnych transformacji, filtracji ani reinterpretacji próbkowanych wartości. Zbiory wartości atrybutów $A_j(t_k)$ wraz z jednostkami są przekazywane w niezmienionej postaci do kolejnego etapu obliczeń, gdzie pełnią rolę argumentów funkcji modulujących wpływ parametru na wskaźniki ekonomiczne.

Etap próbkowania można zdefiniować jako operacja przypisania dla każdego parametru P_j zbioru $A_j(t_k)$ aktualnych wartości atrybutów w danym kroku symulacji, tj.:

$$\forall P_j \in \mathcal{P}, \quad A_j(t_k) = \{a_{j,1}(t_k), a_{j,2}(t_k), \dots, a_{j,M_j}(t_k)\}$$

KROK 3 - Wyznaczenie wartości funkcji modulujących

W etapie tym następuje przejście od surowych, próbkowanych danych wejściowych do ilościowego opisu wpływu parametru na wskaźniki ekonomiczne stacji ładowania. Celem jest odwzorowanie zależności pomiędzy aktualnym stanem atrybutów parametru a kierunkiem oraz intensywnością jego oddziaływania na marżę oraz wykorzystanie infrastruktury.

Dla każdego parametru wpływu $P_j \in \mathcal{P}$ oraz dla każdego kroku symulacji t_k , algorytm wyznacza wartości dwóch funkcji modulujących:

$Fju(A_j)$ - funkcja opisująca wpływ parametru P_j na składową marży,

$Fjm(A_j)$ - funkcja opisująca wpływ parametru P_j na składową wykorzystania infrastruktury

Argumentami obu funkcji jest zbiór wartości A_j , który w implementacji komputerowej będzie reprezentowany w postaci wektora próbkowanych atrybutów:

$$A_j(t_k) = [a_{j,1}(t_k), a_{j,2}(t_k), \dots, a_{j,n}(t_k)]$$

Zastosowanie odrębnych funkcji modulujących dla marży i wykorzystania infrastruktury, umożliwia uchwycenie ich antagonistycznego charakteru oraz odmiennego przebiegu nieliniowości. Ten sam parametr może bowiem oddziaływać pozytywnie na jeden wskaźnik i jednocześnie negatywnie na drugi w odmienny nieliniowy sposób. W kolejnym etapie algorytmu funkcje modulujące podlegają normalizacji do wspólnej, bezwymiarowej przestrzeni modelu.

KROK 4 - Normalizacja wyników funkcji modulujących do wspólnej przestrzeni bezwymiarowej

Ze względu na zróżnicowaną naturę parametrów P_j , $j = 1, \dots, N$, gdzie atrybuty wyrażone są w jednostkach niejednorodnych (np. PLN/kWh, %, szt., min), bezpośrednia superpozycja wektorowa jest niemożliwa bez standaryzacji. W związku z tym, algorytm obliczeniowy wprowadza warstwę normalizacji jednostek i zakresów funkcji F_{ju} , F_{jm} których wartości są po wyznaczeniu zdefiniowane w przestrzeni jednostek “ekonomiczno-fizycznych”. W efekcie działania warstwy normalizacji wartości te są przenoszone do przestrzeni bezwymiarowej. Celem jest zarówno homogenizacja jednostek oraz normalizacja do ustandaryzowanej przestrzeni, która jest w kolejnych krokach algorytmu wspólną przestrzenią $\mathbb{R}^2$, dla docelowych wektorów składowych

$$V_{ju}, V_{jm}, V_{jp}, j = 1, \dots, N.$$

Przeniesienie wartości funkcji modulujących do wspólnej, bezwymiarowej przestrzeni realizowane jest przez funkcje normalizujące f_{jm} (dla marży) oraz f_{ju} (dla wykorzystania infrastruktury).

Zadaniem tych funkcji jest:

- homogenizacja jednostek, czyli eliminacja jednostek fizycznych poprzez zastosowanie współczynników o mianie odwrotnym κ_{jm} i κ_{ju} ,
- skalowanie wartości do zakresu $(-1,1)$, które zapewnia, że wpływ pojedynczego czynnika mieści się w znormalizowanym przedziale.

Jako funkcję bazową dla normalizacji przyjęto sigmoidalną funkcję tangensa hiperbolicznego ($\tanh$) ponieważ zapewnia kontrolę zakresu sterowania dodając efekt łagodnej saturacji wyników. Jednak problem stanowi fakt, iż wyniki funkcji $\mathcal{F}$ cechują się dużym rozrzutem wartości w niesymetrycznych przedziałach.


Jako przykład można przytoczyć zmienność cen energii która waha się w granicach $[-100,2000]$ PLN/MWh z medianą w punkcie ~ 400 PLN/MWh. Aby zapewnić możliwość

modelowania tej asymetryczności przyjęto, że funkcja saturacji $\tanh$ musi być również asymetryczna.

$$f_{jm}(F_{jm}) = \tanh(\kappa(F_{jm} - o))$$

Przykładowo dla ceny energii funkcja ta ma postać pokazaną na Rys. 6.5, gdzie:

- F_m jest argumentem funkcji reprezentującym zmienną cenę energii,
- $\kappa=0.00636$ stała nachylenia dobrana tak, aby saturacja następowała w zakresie $[-100,1000]$,
- $o = 400$ mediana ceny.



Rys 6.5 Normalizacja wyników funkcji modulujących

Źródło: opracowanie własne.

Uogólniona postać funkcji normalizujących dla całego modelu jest zdefiniowana jako $\tanh(\cdot)$ odwzorowująca zbiór liczb rzeczywistych $\mathbb{R}$ na przedział $(-1,1)$ i przyjmuje postać:

$$f_{jm}(F_{jm}) = \tanh(\kappa_{jm}(F_{jm} - o)) \text{ - dla czynników wpływających na marżę,}$$

$$f_{ju}(F_{ju}) = \tanh(\kappa_{ju}(F_{ju} - o)) \text{ - dla czynników wpływających na wykorzystanie infrastruktury stacji,}$$

gdzie:

F_{jm} - wartość funkcji modulującej (argument funkcji normalizującej)

κ_{jm} - stała kappa sterująca czułością funkcji i oczekiwanym poziomem saturacji w zakresie wartości funkcji modulującej (regulacja wrażliwości modelu na bodziec P_j)

o - stała offsetu saturacji, reprezentującą medianę wartości funkcji modulującej (wprowadza asymetrię do funkcji tanh)

Powyższy zbiór parametrów kalibracyjnych modelu powinien być unikalny dla każdego P_j , jednak na potrzeby aplikacji symulacyjnej dokonano uproszczenia i przyjęto, że zbiór jest taki sam dla wszystkich P_j . Współczynnik κ_{jm} posiada jednostkę odwrotną do jednostki F_{jm} zapewniając bezwymiarowość znormalizowanego wyniku. Zastosowana metoda normalizacji zabezpiecza również algorytm przed niestabilnością w przypadku wystąpienia danych wejściowych odstających od normy (np. błędnych wartości).

KROK 5 - Przeniesienie wyniku do przestrzeni wektorowej i wyznaczenie wektorów V_u i V_m

Znormalizowane wartości f_{jm} i f_{ju} są przenoszone do przestrzeni bezwymiarowej $\mathbb{R}^2$ poprzez wektory V_{jm} i V_{ju} . Efektem tego kroku jest zatem para wektorów unikalna dla każdego parametru.

$$V_{ju} = \begin{bmatrix} 0 \\ f_{ju} \end{bmatrix} \quad V_{jm} = \begin{bmatrix} f_{jm} \\ 0 \end{bmatrix}$$

Wektory te są wyznaczane dla każdego z parametrów P_j modelu $j=1, \dots, N$.

KROK 6 - Wyznaczenie wektora V_{jp}

Na podstawie ustandaryzowanych składowych V_{jm} i V_{ju} , dla każdego parametru P_j konstruowany jest bezwymiarowy wektor V_{jp} :

$$V_{jp} = \begin{bmatrix} V_{jm} \\ V_{ju} \end{bmatrix}$$

Dzięki zastosowaniu funkcji normalizujących f_{jm} i f_{ju} dla wszystkich $j = 1 \dots N$, wektory V_{jp} należą do tej samej przestrzeni metrycznej, a ich moduły są ograniczone przez maksymalną normę uwzględniającą własności funkcji tanh:

$$\tanh(x) \in (-1, 1),$$

$$|V_{jm}| \leq 1, \quad |V_{ju}| \leq 1$$

W celu ilościowego porównywania wpływu poszczególnych parametrów oraz zapewnienia poprawności operacji składania wektorów, jako miarę modułu wektora wpływu przyjęto normę euklidesową L^2 . Wybór ten zapewnia równoważne traktowanie skumulowanego oddziaływania wszystkich parametrów na oba analizowane wskaźniki, tj. marżę i wykorzystanie infrastruktury stacji.

Dla przyjętej normy euklidesowej (L^2)

$$\|V_{jp}\| = \sqrt{V_{jm}^2 + V_{ju}^2}$$

zatem maksymalny moduł wektora wynikowego to

$$\|V_{jm}\|_{max} = \sqrt{1^2 + 1^2} = \sqrt{2}$$

KROK 7 - Przeniesienie wektorów V_{jp} do przestrzeni M-U (mapowanie)

W tym kroku symulacji nadawana jest interpretacja ekonomiczna otrzymanemu zbiorowi wektorów V_{jp} , opisujących wpływ poszczególnych parametrów modelu stacji ładowania na marżę oraz poziom wykorzystania infrastruktury. Wektory te są w poprzedzających krokach algorytmu definiowane w przestrzeni bezwymiarowej $\mathbb{R}^2$, natomiast w bieżącym kroku przypisywane są im konkretne znaczenia ekonomiczne oraz odpowiadające im jednostki miary:

- marży - zmiana marży operacyjnej z 1 kWh sprzedanej energii [PLN/1kWh],
- wykorzystania infrastruktury - zmiana ilości sprzedanej energii [kWh].

W konsekwencji zbiór bezwymiarowych wektorów V_{jp} jest mapowany na przestrzeń $\mathbb{R}^2$ wskaźników ekonomicznych M-U infrastruktury. Przeniesienie wektorów do interpretowalnej przestrzeni jest niezbędne, aby wynik symulacji posiadał znaczenie użytkowe i mógł być analizowany w kategoriach ekonomicznych, zrozumiałych dla użytkowników końcowych systemu symulacyjnego.

KROK 8 - Wyznaczenie wskaźnika Impact Vector reprezentowanego przez wektor V_w w przestrzeni M-U


Wektor wypadkowy, stanowiący wynik końcowy kroku symulacji, wyznaczany jest poprzez sumowanie wektorów. V_{jp} .

$$V_w(t_k) = \sum_{j=1}^N V_{jp}$$

Wynikowy wektor V_w reprezentuje zatem sumę impulsów rynkowych wpływających w bieżącym kroku t_k na badaną stację ładowania i w takiej postaci może być interpretowany w przestrzeni $\mathbb{R}^2$ wskaźników ekonomicznych M-U infrastruktury. Efektem jest wektor V_w opisujący sumaryczny wpływ wszystkich parametrów na wynik w przestrzeni M-U w bieżącym kroku symulacji t_k .

KROK 9 - Wyznaczenie wyniku skumulowanego V_ω

Następnie wyznaczana jest wartość skumulowana V_ω jako suma wszystkich V_ω w przestrzeni M-U infrastruktury $\mathbb{R}^2$. Łańcuch tych wektorów można interpretować jako trajektorię rozwoju stacji w symulowanym okresie (Rys. 6.6).



Rys 6.6 Reprezentacja graficzna trajektorii stacji w symulowanym okresie $t_0 - t_6$.

Źródło: opracowanie własne.

Z punktu widzenia operatora stacji kluczowym celem symulacji jest jednak określenie wartości zmiany wartości marży oraz zmiany poziomu wykorzystania infrastruktury stacji w całym okresie symulacji T_{sim} względem poziomu przyjętego w kroku początkowym t_0 . Wektor wynikowy V_ω może być zapisany w postaci macierzy dla każdego kroku symulacji t_k . Elementy macierzy odpowiadają składowym w obu wymiarach przestrzeni M-U.

$$V_w(t_k) = \begin{bmatrix} V_{W_m}(t_k) \\ V_{W_u}(t_k) \end{bmatrix} \in \mathbb{R}^2$$

gdzie:

$V_{W_m}(t_k) \in \mathbb{R}^1$ to składowa marży w kroku t_k (nazywana dalej węzłem marży)

$V_{W_u}(t_k) \in \mathbb{R}^1$ to składowa wykorzystania infrastruktury w kroku t_k (nazywana dalej węzłem wykorzystania infrastruktury)

Dla zadanej liczby K kroków symulacji otrzymujemy zatem zbiór węzłów marży

$$V_{W_m} = \{V_{W_m}(t_0), V_{W_m}(t_1), V_{W_m}(t_2), \dots, V_{W_m}(t_K)\}$$


i analogiczny zbiór węzłów wykorzystania infrastruktury

$$V_{W_u} = \{V_{W_u}(t_0), V_{W_u}(t_1), V_{W_u}(t_2), \dots, V_{W_u}(t_K)\}$$

Krok 9a - Wyznaczanie skumulowanego wykorzystania infrastruktury U_s [kWh]

Przykładowy zbiór węzłów wykorzystania infrastruktury został przedstawiony na rysunku 6.7 za pomocą wykresu V_{W_u} w funkcji kroku symulacji t_k .

$$V_{W_u} = \{V_{W_u}(t_k) \mid t_k \in \{t_0, t_1, \dots, t_K\}\}$$



Rys 6.7 Reprezentacja graficzna składowych wykorzystania infrastruktury w okresie $t_0 - t_7$


Źródło: opracowanie własne.

Należy podkreślić, że model uwzględnia szczególnie przypadek, kiedy następuje zmiana znaku (niebieskie pole $t_2 - t_5$ na rys 6.7. w takim przypadku pole pod krzywą należy interpretować jako ujemną wartość ΔU wykorzystanie infrastruktury chwilowej względem wykorzystania infrastruktury bazowej i jest to scenariusz realny i zgodny z rzeczywistością biznesową. Nie jest to błąd.

Dysponując zbiorem węzłów można wyznaczyć wartość skumulowaną wykorzystania infrastruktury U_s [kWh] dla składowej V_{Wu} poprzez obliczenie powierzchni pod krzywą wyznaczoną przez węzły. Wartość 0 na osi odciętych wyznacza wartość u_0 wykorzystania infrastruktury stacji (wartość bazowa wykorzystania infrastruktury). Jest to stała ustalana w kroku inicjacji algorytmu i oznacza poziom startowy stacji ładowania EV w chwili rozpoczęcia symulacji t_0 . Należy zatem uwzględnić fakt, że $u_0 > 0$ i wówczas wartość każdego z węzłów $V_{Wu}(t)$ musi być powiększona o wartość bazowa u_0 . Zatem ostateczny kształt krzywej uwzględniający u_0 wyznacza zbiór węzłów.

$$V_{Wu} = \{V_{Wu}(t_k) + u_0 \mid t_k \in \{t_0, t_1, \dots, t_K\}\}$$

Pole powierzchni pod krzywą wyznaczoną przez węzły wykorzystania infrastruktury stacji można interpretować jako wartość skumulowaną U_s [kWh] pokazaną w formie graficznej na Rys. 6.8.



Rys 6.8 Reprezentacja graficzna wykorzystania infrastruktury skumulowanej w okresie $t_0 - t_7$.

Źródło: opracowanie własne.

Wartości między węzłami są w algorytmie interpolowane, zatem powierzchnia może być obliczona za pomocą sumy pól trapezów prostokątnych P_i między węzłami wykorzystania infrastruktury. Zakreskowane pole na rys 6.8 reprezentuje skumulowaną wartość wykorzystania infrastruktury stacji U_s [kWh] w zadanym czasie symulacji T_{sim} . Czas $t_k - t_{k+1}$ to okres próbkowania T_s [h], który jest odwrotnością częstotliwości próbkowania danych f_s [Hz] przyjmowanej jako parametr symulacji na etapie inicjalizacji algorytmu.

Dla pojedynczego okresu próbkowania $t_k - t_{k+1}$ wartość wykorzystania infrastruktury jest równa polu trapezu P_i [kWh] skorygowanemu o współczynnik zajętości stanowisk

ładowania u_z [0-1], który modeluje przeciętną zajętość stanowisk ładowania. Wartość $u_z = 0$ oznacza, że przeciętnie wszystkie stanowiska ładowania są wolne, zaś wartość $u_z = 1$ oznacza, że wszystkie stanowiska ładowania są zajęte. Uwzględniając współczynnik zajętości $P_t(t_k)$ [kWh] wynosi


$$P_t(t_k) = \left(\frac{u_z}{2}\right) \cdot (V_{W_u}(t_k) + V_{W_u}(t_k + 1)) \cdot T_s$$

natomiast wartość skumulowana wykorzystania infrastruktury stacji U_s [kWh] wynosi:

$$U_s = \sum_{t=t_0}^{t_K} \left(\frac{u_z}{2}\right) (V_{W_u}(t_k) + V_{W_u}(t_k + 1)) T_s$$

KROK 9b - Wyznaczanie skumulowanej marży M_s [PLN/kWh]

Przykładowy zbiór węzłów marży $V_{W_m} = V_{W_m}(t_k) \mid t_k \in t_0, t_1, \dots, t_K$ został przedstawiony na Rys. 6.9 za pomocą wykresu V_{W_m} w funkcji kroku symulacji t_k .



Rys 6.9 Reprezentacja graficzna zbioru składowych marży w okresie symulacji $t_0 - t_7$

Źródło: opracowanie własne.

Model uwzględnia przypadek zilustrowany w kroku t_3 , kiedy marża chwilowa spada w okresie T_s poniżej 0 (obszar zaznaczony czerwonym kolorem na Rys. 6.9) Jest to scenariusz niekorzystny dla operatora stacji ładowania, ale dopuszczalny ekonomicznie i zgodny z rzeczywistością biznesową. Nie jest to błąd.

Metoda sumowania powierzchni zastosowana w przypadku wykorzystania infrastruktury skumulowanej nie ma zastosowania dla marży skumulowanej ze względu na inną naturę tej miary. Wartość skumulowana marży M_s jest wyznaczana jako **marża handlowa brutto** wg definicji Głównego Urzędu Statystycznego jako “Cena usługi handlowej stanowiąca różnicę

między ceną zakupu a ceną sprzedaży towarów, przeznaczona na pokrycie kosztów handlowych i osiągnięcie zysku” [57]. Dla stacji ładowania oznacza to różnicę między ceną sprzedaży energii, a kosztem jej zakupu, wyrażoną w PLN. Zatem skumulowana marża handlowa brutto M_s [PLN] ze sprzedaży energii wynosi:

$$M_s = \sum_{t=t_0}^{t_{K-1}} \left| P_t(t_k) \frac{V_{W_m}(t_k + 1) - V_{W_m}(t)}{2} \right|$$

Efektom tego kroku jest para wskaźników ekonomicznych:

- U_s - skumulowana ilość sprzedanej energii [kWh] w okresie symulacji T_{sim} ,
- M_s - skumulowana wartość przychodu z tytułu marży handlowej brutto [PLN] w okresie symulacji T_{sim} .

KROK 10 - Prezentacja wyniku końcowego

Następnie wyznaczany jest wynik końcowy, który oznacza zmianę kluczowych wskaźników marży i wykorzystania infrastruktury na skutek działania czynników opisanych parametrami modelu P1-P20. Wartość należy interpretować jako procentowy współczynnik skumulowanej zmiany wykorzystania infrastruktury i marży w badanym okresie T_{sim} .

Produktem końcowym jest para wskaźników:

- ΔU [%] - szacowana zmiana skumulowanej wykorzystania infrastruktury,
- ΔM [%] - szacowana zmiana skumulowanej marży.

ΔU jest wyznaczana jako stosunek skumulowanej wykorzystania infrastruktury stacji (sprzedanej mocy) do maksymalnej mocy, którą może sprzedać stacja ładowania. Maksymalna moc jest ograniczana przez:

- P_{grid} [kW] fizyczne ograniczeń przyłącza sieciowego,
- P_{peak} [kW] ograniczenia mocy szczytowej wynikające z umowy z dostawcą energii,
- Z_{max} [kW] ograniczenia posiadanej infrastruktury ładowania EVSE.

P_{grid} i P_{peak} są podane jawnie na etapie inicjalizacji algorytmu jako wartości wyrażone w kW, natomiast Z_{max} jest wyznaczane na podstawie wektora EVSE (mocy poszczególnych złączy stacji ładowania) jako:

$$Z_{max} = \sum_{c=1}^{z_e} Z_c$$

Wówczas wskaźnik maksymalnego wykorzystania infrastruktury wynosi:

$$P_{max} = \min \{P_{grid}, P_{peak}, Z_{max}\} \cdot T_{sim} \cdot u_z$$

więc wskaźnik wykorzystania infrastruktury stacji ładowania

$$U = \frac{U_s}{P_{\max}} \cdot 100\%$$

i wynik końcowy oznaczający procentową zmianę poziomu wykorzystania infrastruktury stacji w stosunku do poziomu startowego symulacji wynosi za okres T_{sim}

$$\Delta U = \frac{u_0}{U_s} \cdot 100\%$$

Ponieważ marża początkowa m_0 jest wskaźnikiem tożsamym w zakresie jednostki i sensu ekonomicznego do M_s to zmiana procentowa ΔM [%] wymaga tylko zastosowania iloczynu obu składowych i wynosi w symulowanym okresie:

$$\Delta M = \frac{m_0}{M_s} \cdot 100\%$$

7. IMPLEMENTACJA KOMPUTEROWA, SYMULACJA I OCENA MODELU

7.1. APLIKACJA SYMULACYJNA SIMVEC

7.1.1. INTERFEJS APLIKACJI

Na podstawie algorytmu obliczeniowego przedstawionego w rozdziale 6 opracowano autorską aplikację, która stanowi praktyczne ogniwo łączące część formalno-matematyczną rozprawy z częścią eksperymentalną umożliwiając uruchamianie obliczeń symulacyjnych, analizę wkładu parametrów P1-P20, obserwację trajektorii stanu ekonomicznego stacji oraz porównywanie wyników między różnymi scenariuszami strumieni danych wejściowych (Rys. 7.1).



Rys 7.1 Interfejs aplikacji SIMVEC

Źródło: opracowanie własne.

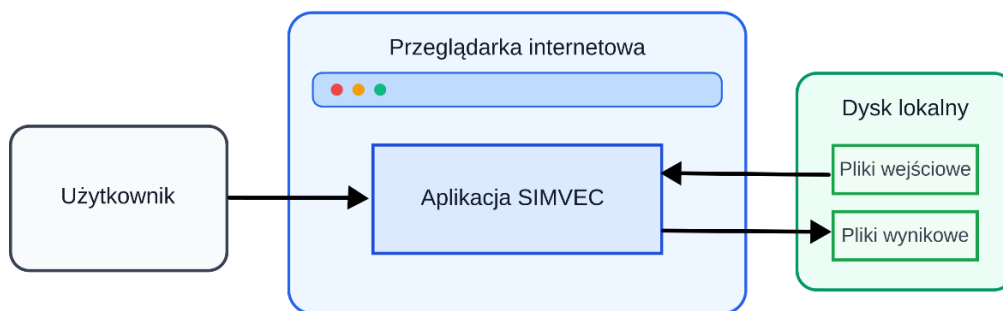
W kontekście celów rozprawy SIMVEC pełni 3 zasadnicze funkcje:

- weryfikacyjną - pozwala sprawdzić, czy model zachowuje się zgodnie z intuicją ekonomiczną i założeniami,
- analityczną - umożliwia dekompozycję wyniku na wkłady poszczególnych parametrów i składowych oraz ich ocenę. Udostępnia funkcjonalność rejestracji danych symulacyjnych do pliku json co umożliwia dalsze analizy numeryczne,

- utylitarną - jest praktyczną implementacją modelu i algorytmu obliczeniowego, co daje możliwość wdrożenia modelu do pracy w rzeczywistych warunkach, dostosowania do potrzeb operatora infrastruktury ładowania EV, testowania rzeczywistych scenariuszy i wdrożenia do użytku po skalibrowaniu i przetestowaniu poprawności działania.

7.1.2. ARCHITEKTURA APLIKACJI

Architektura SIMVEC została zaprojektowana w modelu aplikacji typu *client-side* (Rys. 7.2), opierając się na klasycznym, trójwarstwowym wzorcu projektowym (Rys. 7.3).



Rys 7.2 Założenie projektowe aplikacji - model aplikacji

Źródło: opracowanie własne.

Struktura ta obejmuje warstwę kontrolera logiki aplikacyjnej i orkiestracji procesu symulacyjnego (zarządzaną przez skrypt `simvec.js`). Warstwę obliczeniową, pełniącą funkcję dedykowanego silnika modelu (zawartą w pliku `engine.js`). Warstwę prezentacji interfejsu UI (implementowaną za pomocą plików `simvec.html` oraz `simvec.css`).

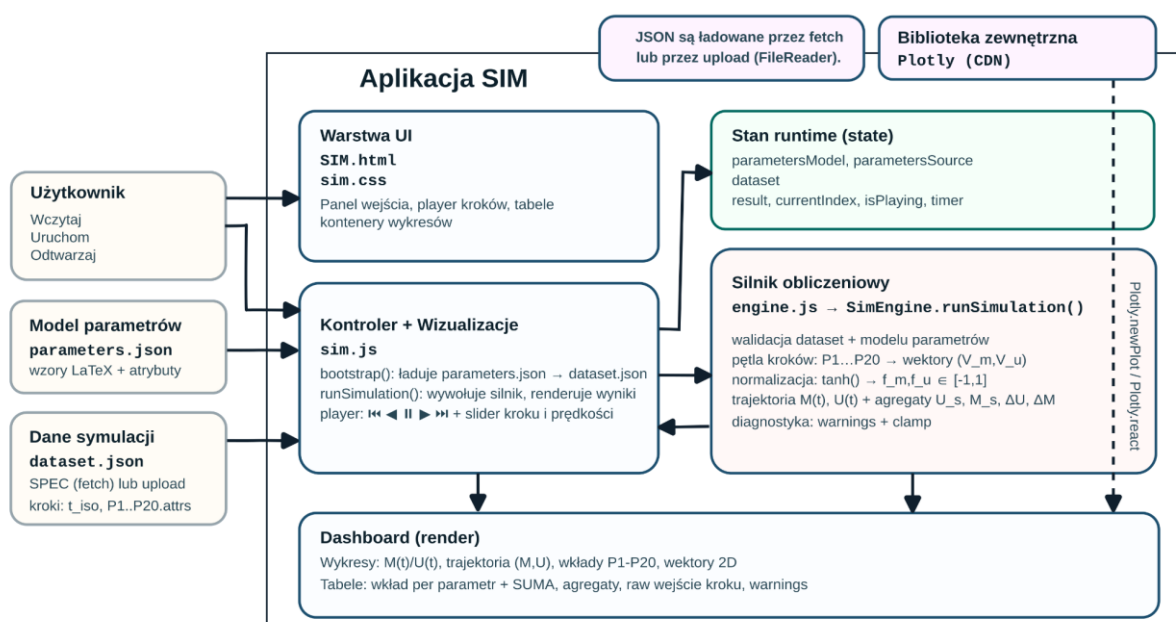


Rys 7.3 Architektura warstwowa aplikacji SIMVEC

Źródło: opracowanie własne.

W ramach warstwy prezentacji zdefiniowano graficzny interfejs użytkownika (Rys.7.1), który podzielono na trzy główne przestrzenie robocze. Pierwszą z nich stanowi panel wejścia i sterowania, odpowiedzialny za inicjowanie danych wsadowych, uruchamianie symulacji, kontrolę nad przetwarzaniem krokowym i prędkością odtwarzania, a także za selektywną aktywację lub dezaktywację poszczególnych parametrów. Drugi obszar to panel wizualizacji, prezentujący wyniki modelowania w postaci wykresów czasowych i przestrzennych. Trzeci komponent, panel szczegółów, dostarcza surowych danych dla pojedynczego kroku obliczeniowego, kart stanu, zagregowanych statystyk, tabelarycznego zestawienia wkładu parametrów oraz alertów diagnostycznych. Generowanie interaktywnych wizualizacji zrealizowano przy użyciu biblioteki Plotly, co ułatwia analitykowi płynną nawigację pomiędzy globalnym ujęciem wyników a szczegółowym rzutem na konkretny krok symulacji.

Za warstwę logiki aplikacyjnej odpowiada moduł `simvec.js`, którego kluczowym zadaniem jest kompleksowa orkiestracja przepływu informacji (Rys. 7.4). Obejmuje to pobieranie struktury parametrów z pliku `parameters.json` oraz inicjalizację zbioru danych wejściowych (zarówno z domyślnej ścieżki sieciowej, jak i z zasobów lokalnych).



Rys 7.4 Architektura aplikacji SIMVEC

Źródło: opracowanie własne.


Ponadto moduł ten zarządza wstępną walidacją, delegowaną do warstwy obliczeniowej, inicjuje symulację, kontroluje stany odtwarzania oraz odpowiada za renderowanie wyników. Istotnym mechanizmem w tej warstwie jest obsługa dynamicznego przełączania stanu aktywności parametrów, co wiąże się z jawną sygnalizacją konieczności ponownego

przeliczenia modelu (stan RUN). Rozwiązanie to stanowi istotne zabezpieczenie, uniemożliwiające interpretację zdezaktualizowanych wyników badawczych.

Warstwa obliczeniowa engine.js stanowi rdzeń obliczeniowy, w którym zakodowano model uwzględniający wszystkie parametry P1-P20. Interfejs programistyczny silnika realizuje metody walidacji danych oraz wykonania pętli symulacyjnej. Integralność wymiany danych w modelu zapewniają wewnętrzne stałe konfiguracyjne, określające całkowitą pulę badanych parametrów oraz wektor ich identyfikatorów.

7.2. WYMIENNY SILNIK OBLICZENIOWY

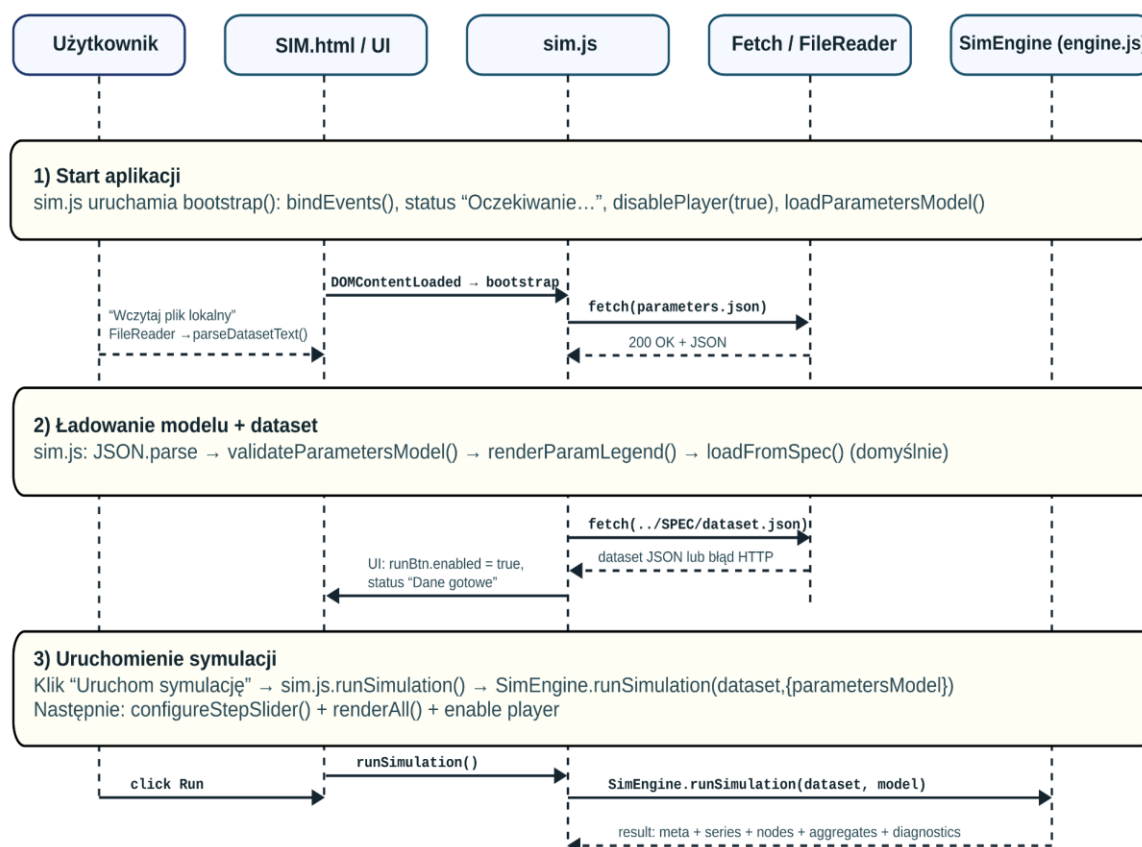
Zaprojektowana architektura oprogramowania opiera się na paradygmacie pełnej separacji warstwy logicznej od silnika obliczeniowego, co gwarantuje wysoką elastyczność i wymiennność modelu matematycznego. Centralnym elementem sterującym tą konfiguracją jest plik `parameters.json`. Jego modyfikacja umożliwia swobodne zarządzanie zbiorem parametrów oraz ich definicjami. Pozwala także na wprowadzanie nowych atrybutów kalibracyjnych. Ponadto struktura ta dopuszcza całkowitą redefinicję funkcji modulujących, których analityczna postać implementowana jest z wykorzystaniem standardu LaTeX. W konsekwencji docelowy model matematyczny nie jest na stałe zintegrowany z kodem źródłowym aplikacji, lecz pozostaje w pełni wymienny przez zewnętrzną warstwę konfiguracyjną (patrz Rys. 7.5).



Rys 7.5 Wymienny silnik obliczeniowy w aplikacji SIMVEC

Źródło: opracowanie własne.

Możliwość wymiany silnika obliczeniowego czyni system elastycznym, skalowalnym i podatnym na dalsze badania oraz ułatwia kalibrację modelu w warunkach rzeczywistego wdrożenia. Na Rys. 7.6 zaprezentowano diagram sekwencji UML pokazujący mechanizm ładowania silnika oraz danych scenariuszowych podczas uruchamiania aplikacji, walidacji i wykorzystania tych danych w kodzie silnika statycznego engine.js.



Rys 7.6 Diagram sekwencji aplikacji SIMVEC

Źródło: opracowanie własne.

7.3. ARCHITEKTURA I ŹRÓDŁA DANYCH

7.3.1. ZAŁOŻENIA OGÓLNE DLA POZYSKANIA DANYCH

Dane wykorzystane w symulacji mają charakter mieszany. Część informacji pochodzi ze źródeł publicznych, natomiast część została wygenerowana syntetycznie. Przyjęcie takiego podejścia było konieczne ze względu na fakt, iż rzeczywiste dane operacyjne stanowią istotny element przewagi konkurencyjnej operatorów i są ochronie jako know-how przedsiębiorstwa. Dane syntetyczne zostały opracowane tak, aby odzwierciedlały realistyczne scenariusze biznesowe, lecz nie pozwalały na identyfikację konkretnego podmiotu ani odtworzenie jego rzeczywistych wyników operacyjnych.

Z punktu widzenia modelu matematycznego wszystkie dane odnoszą się do zbioru parametrów oznaczonych jako:

$$\mathcal{P} = \{P_j : j = 1, \dots, 20\}$$

gdzie każdy parametr opisuje odrębny czynnik wpływu na ekonomikę stacji ładowania, przy czym jego znaczenie jest doprecyzowane poprzez zestaw atrybutów. Atrybuty stanowią ilościowy opis danego parametru i w silniku symulacyjnym są wykorzystywane jako argumenty funkcji modulujących. Zapisane są w kodzie aplikacji jako wektor:

$$A_j = [a_{j1}, a_{j2}, \dots, a_{ji}, \dots, a_{jn}]$$

gdzie każdy element a_{ji} określa konkretną wielkość liczbową wpływającą na marżę lub wykorzystanie infrastruktury stacji.

Dane wykorzystywane w symulacji zostały zakodowane w sposób zgodny z przyjętą strukturą czasową modelu. Symulacja prowadzona jest w czasie dyskretnym z okresem próbkowania T_s , który może przyjmować wartości od jednej godziny do 50 lat, w zależności od celu analizy. Liczba kroków symulacyjnych zgodnie z założeniami algorytmu wynosi:

$$K = \frac{T_{sim}}{T_s}$$

co oznacza, że zbiór danych zawsze zawiera dokładnie tyle próbek, ile wynika z przyjętego horyzontu czasowego i częstotliwości próbkowania. Zapewnia to pełną zgodność danych wejściowych z algorytmem obliczeniowym.

Każdy zbiór danych rozpoczyna się nagłówkiem zawierającym informacje identyfikujące scenariusz symulacyjny. W nagłówku zapisywany jest identyfikator stacji, region geograficzny, czas rozpoczęcia i zakończenia symulacji w standardzie ISO 8601, okres próbkowania, wersja modelu, wersja silnika obliczeniowego, wersja zbioru danych, autor scenariusza oraz data jego utworzenia. Taka struktura pozwala jednoznacznie odtworzyć warunki, w jakich przeprowadzono daną symulację oraz zapewnia powtarzalność eksperymentów. Część właściwa zbioru danych składa się z kolejnych kroków symulacyjnych. Każdy krok oznaczony jest indeksem k oraz znacznikiem czasu t_{iso} . W obrębie kroku znajdują się kompletne dane wszystkich parametrów P1-P20 wraz z ich atrybutami. Przyjęcie zasady pełnej kompletności parametrów w każdym kroku eliminuje niejednoznaczności i umożliwia jednoznaczną rekonstrukcję trajektorii systemu w przestrzeni wynikowej.

Formatem danych wejściowych jest JSON. Wybór tego formatu wynika z jego strukturalności, czytelności oraz powszechnej obsługi przez środowiska programistyczne

i analityczne. JSON umożliwia hierarchiczne uporządkowanie danych, jednoznaczne definiowanie kluczy oraz łatwą walidację składniową. Dane numeryczne zapisywane są w precyzji typu float64, z dokładnością do sześciu miejsc po przecinku, co zapewnia wystarczającą dokładność obliczeń ekonomicznych przy zachowaniu efektywności przetwarzania. Znaczniki czasu zapisywane są w standardzie ISO 8601, co gwarantuje jednoznaczną interpretację strefy czasowej i chronologii zdarzeń.

System symulacyjny umożliwia ładowanie wielu scenariuszy danych, wizualizację wyników na panelu analitycznym, generowanie raportów w formacie CSV oraz eksport danych do zewnętrznych narzędzi analitycznych, takich jak Python, R, MATLAB czy arkusze kalkulacyjne. Dzięki temu środowisko symulacyjne nie jest zamkniętym systemem, lecz stanowi element szerszego systemu analizy danych.

Kluczową cechą architektury systemu jest wymiennność silnika obliczeniowego. Przy każdym uruchomieniu aplikacja ładuje plik konfiguracyjny `parameters.json`, który zawiera definicję parametrów modelu, zestaw ich atrybutów, wzory funkcji modulujących zapisane w formacie LaTeX oraz współczynniki kalibracyjne i normalizacyjne. Zmiana struktury modelu nie wymaga modyfikacji kodu aplikacji. Wystarczy zmodyfikować treść pliku konfiguracyjnego, aby zmienić zależności matematyczne, liczbę parametrów lub sposób ich oddziaływania. Oznacza to, że warstwa programistyczna została oddzielona od warstwy matematycznej, co zwiększa elastyczność i skalowalność rozwiązania.

Ogólna struktura pliku `parameters.json` obejmuje część opisową, sekcję parametrów, sekcję normalizacji oraz konfigurację silnika. Każdy parametr posiada własną nazwę, zestaw atrybutów z określeniem jednostek i typu (A - scenariuszowe, K - kalibracyjne) oraz funkcje modulujące. Wzory są interpretowane dynamicznie przez silnik obliczeniowy, który przekształca zapis LaTeX do postaci wykonywalnej i wylicza wektory wpływu w przestrzeni M-U infrastruktury.

Podsumowując, przyjęta architektura danych opiera się na rozdzieleniu trzech warstw: semantycznej, scenariuszowej i obliczeniowej. Rozdzielenie to zwiększa przejrzystość systemu, umożliwia niezależne modyfikowanie poszczególnych komponentów, poprawia walidowalność oraz zapewnia odporność na błędy wynikające z niejednoznaczności interpretacyjnych. W efekcie powstało narzędzie spójne, skalowalne i metodologicznie uzasadnione, umożliwiające symulację ekonomiki stacji ładowania w sposób formalnie ścisły i powtarzalny.


7.3.2. DANE SYMULACYJNE

Z uwagi na fakt, iż rzeczywiste dane operacyjne operatorów stacji ładowania są informacjami zastrzeżonymi jako know-how biznesowe i podlegają ochronie handlowej w rozprawie część danych wejściowych została wygenerowana syntetycznie. Dane syntetyczne zostały przygotowane w taki sposób, aby odwzorowywać realistyczne scenariusze biznesowe, jednak bez możliwości identyfikacji konkretnego operatora, lokalizacji ani rzeczywistych wolumenów sprzedaży. Dane jawne obejmują natomiast informacje publiczne lub pochodzące ze źródeł ogólnodostępnych, takich jak raporty branżowe, dane statystyczne, publikacje regulatorów rynku energii oraz oficjalne rejestry pojazdów elektrycznych.

7.3.3. STRUKTURA I FORMAT DANYCH

Dane symulacyjne zostały zakodowane w formacie czasowym kompatybilnym z modelem, tj. z określoną częstotliwością próbkowania T_s oraz liczbą kroków K odpowiadającą okresowi symulacji T_{sim} . Zbiór danych zawiera dokładnie K próbek. Każda próbka odpowiada jednemu krokowi symulacji i reprezentuje kompletny chwilowy “stan świata” (zbiór parametrów P1-P20 wraz z atrybutami). Zakres symulacji może obejmować dowolny okres od minimalnego kroku $T_s = 1h$ do maksymalnego horyzontu równego 50 lat, przy czym ograniczenie to wynika wyłącznie z racjonalnych potrzeb biznesowych oraz wartości analitycznej symulacji. Precyzja danych liczbowych w modelu przyjęta została na poziomie podwójnej precyzji zmiennoprzecinkowej (IEEE 754, 64-bit), natomiast prezentacja wyników do 4-6 miejsc po przecinku w zależności od wielkości.

Dane zostały zakodowane w standardzie JSON, który charakteryzuje się zdolnością do hierarchicznej reprezentacji struktur danych i zapewnia wysoką interoperacyjność. Wybór ten został podyktowany również efektywnością standardu JSON w obsłudze dużych zbiorów danych, a także standaryzacją gwarantującą poprawność odczytu tak zakodowanych danych przez szeroką paletę aplikacji. W proponowanym rozwiązaniu format JSON służy do kodowania danych wejściowych dataset.json oraz do strukturyzacji zbioru parametrów atrybutów oraz powiązanych z nimi funkcji modulujących parameters.json (patrz Rys. 7.7). Definicje funkcji zakodowano zgodnie ze standardem LaTeX, co pozwala na precyzyjną reprezentację wyrażeń matematycznych.



Rys 7.7 Ładowanie danych wejściowych oraz definicji parametrów modelu z plików JSON

Źródło: opracowanie własne.

7.3.4. STRUKTURA NAGŁÓWKA DATASET.JSON

Struktura dataset.json charakteryzuje się budową modułową i składa się z sześciu głównych sekcji. Pierwszą z nich jest deklaracja wersji specyfikacji symulacyjnej, zapewniająca kompatybilność z odpowiednim silnikiem obliczeniowym. Kolejny blok stanowi metryka scenariusza, zawierająca jego nazwę, opis analityczny oraz zdefiniowaną strefę czasową. Trzecim elementem jest sekcja parametrów czasowych, która określa punkt początkowy symulacji, długość pojedynczego kroku całkowania oraz całkowity horyzont badawczy. Następnie definiowany jest stan początkowy układu, opisujący inicjalne wartości kluczowych zmiennych operacyjnych. Piąty moduł odpowiada za konfigurację techniczną stacji ładowania, w tym parametry punktów dystrybucji energii oraz charakterystykę przyłącza sieciowego. Struktura zamyka zbiór globalnych stałych wejściowych, wykorzystywanych

w modelu ekonomicznym. Przykładowo dla scenariusza symulującego 1 rok stacji z dwoma punktami ładowania DC 150kW, przy startowej wykorzystania infrastruktury stacji na poziomie 12%, cenie 3,19 PLN/kWh i marży na poziomie 65%:

```
{
  "simspec": "v1",
  "scenario": {
    "name": "Scenariusz referencyjny - aglomeracja miejska",
    "description": "Symulacja stacji DC 150 kW w regionie o średnim udziale pojazdami EV",
    "timezone": "Europe/Warsaw"
  },
  "time": {
    "t0_iso": "2025-01-01T00:00:00+01:00",
    "Ts_h": 1,
    "K": 8760
  },
  "initial_state": {
    "M0_pct": 65.0,
    "U0_pct": 12.0
  },
  "station": {
    "evse_count": 2,
    "evse_kw": [150, 150],
    "P_grid_kw": 320,
    "P_peak_kw": 300,
    "u_z": 0.5
  },
  "constants": {
    "p": 3.19
  }
}
```

7.3.5. DANE WEJŚCIOWE DLA KROKU SYMULACJI DATASET.JSON

Przyjęta struktura danych zakłada, że dla każdego kroku symulacji opisany jest stan wszystkich parametrów modelu. W strukturze JSON każdy z parametrów definiowany jest przez indeks P_j , opis wyjaśniający jego przeznaczenie i zbiór wartości przypisanych mu atrybutów. Opis pojedynczego zdarzenia symulacyjnego składa się z identyfikatora k kroku oraz przypisanego mu punktu na osi czasu znacznika w formacie ISO-8601. Zasadniczą część struktury stanowi definicja zdarzenia dla parametru P_j , opis tekstowy wprowadzanej zmiany, zbiór atrybutów numerycznych *attrs* dla parametru P_j , który determinuje stan danych wejściowych w kroku k . Poniżej pokazano przykładową strukturę kroku symulacji dla parametru P_1 w kroku $k = 1$ dla zdarzenia z dnia 2025-01-01T00:00:00+01:00.

```

{
  "k": 1,
  "t_iso": "2025-01-01T00:00:00+01:00",
  "P1": {
    "note": "Podwyżka ceny o 0.10 PLN/kWh",
    "attrs": {
      "delta_p": 0.10,
      "p": 3.19,
      "p_0": 3.19,
      "epsilon_eff": -0.45,
      "u_curr": 0.42
    }
  }
}

```

7.3.6. DEFINICJA PARAMETRU W PLIKU PARAMETERS.JSON

Drugim zbiorem JSON niezbędnym do przeprowadzenia symulacji jest plik `parameters.json`, który zawiera definicje wszystkich parametrów. W pliku tym każdy parametr modelu jest zdefiniowany poprzez unikalny indeks P_j , nazwę *name* oraz zbiór funkcji modulujących V_u i V_m opisanych w sekcji *latex*. Równania tych funkcji implementowane są bezpośrednio w strukturze danych z wykorzystaniem notacji LaTeX. Należy tu zauważyć, że przyjęta konwencja tagów otwierających i zamykających (backslash “\”) została dostosowana do potrzeb aplikacji i wychodzi poza standard. Przykładowo, dla parametru P1, oznaczającego cenę sprzedaży, struktura tej definicji przyjmuje następującą postać:

```

"P1": {
  "name": "Cena sprzedaży",
  "latex": {
    "P1_Vm": "\\( V_m = delta_p \\cdot (1 + epsilon_eff \\cdot (p_0 / p)) \\)",
    "P1_Vu": "\\( V_u = epsilon_eff \\cdot (delta_p / p_0) \\cdot (1 - u_curr) \\)"
  }
}

```

7.4. APLIKACJA KONTROLI DANYCH WEJŚCIOWYCH SIMDATA

7.4.1. INTERFEJS APLIKACJI

W toku prac badawczych związanych z testowaniem modelu zaistniała potrzeba kontroli danych wejściowych. W tym celu została zaprojektowana i zaimplementowana autorska aplikacja dedykowana analizie tych danych w formacie przyjętym w rozprawie. Głównym celem jest umożliwienie badaczowi wielowymiarowej oceny danych do scenariusza

symulacyjnego w zadanym przedziale czasu. Narzędzie pozwala na precyzyjną weryfikację przebiegów funkcji poszczególnych atrybutów, stanowiących elementarne sygnały wejściowe. Daje to możliwość wizualnej kontroli sygnałów odzwierciedlanych poprzez atrybuty z podziałem na egzogeniczne czynniki otoczenia rynkowego oraz endogeniczne decyzje biznesowe podejmowane przez operatora stacji ładowania w ramach symulowanego scenariusza. Implementacja mechanizmów elastycznego skalowania widoku ułatwia użytkownikowi walidację poprawności danych zarówno w perspektywie globalnej dla całego horyzontu badawczego, jak i w znacznym przybliżeniu, pozwalającym na analizę wybranych mikro okresów. Przykładowy ekran aplikacji do badanie przebiegu sygnału wejściowego pokazano na Rys. 7.8.



Rys 7.8 Interfejs graficzny aplikacji SIMDATA

Źródło: opracowanie własne.

7.4.2. ARCHITEKTURA APLIKACJI

Architektura oprogramowania SIMDATA została zaprojektowana w oparciu o 4 warstwowy model, zapewniający separację poszczególnych zadań analitycznych i prezentacyjnych (Rys. 7.9). Pierwszą warstwę stanowi interfejs użytkownika (simdata.html, simdata.css), podzielony na czytelne panele informacyjne, sterujące i obszar wykresów (Rys. 7.8), co ułatwia analizę wielowymiarowych zbiorów danych. Z interfejsem tym bezpośrednio integruje się druga warstwa logiki aplikacyjnej (simdata.js). Jej działanie opiera

się na obiekcie stanu (state), zarządzającym danymi i metadanymi niezbędnymi do działania aplikacji.



Rys 7.9 Architektura warstwowa aplikacji SIMDATA

Źródło: opracowanie własne.


Trzecia warstwa dedykowana jest przetwarzaniu danych i realizuje zadania związane z walidacją wejścia, rekonstrukcją osi czasu oraz wyznaczaniem statystyk szeregów czasowych. Wydajność tego modułu została znacząco zoptymalizowana poprzez wdrożenie mechanizmu buforowania statystyk pełnozakresowych (statsCacheFull), minimalizującego wykorzystanie obliczeniowe. Ostatnim elementem jest warstwa wizualizacji i interakcji, zrealizowana przy użyciu biblioteki plotly. Wspiera ona zaawansowane mechanizmy wyświetlania sygnałów dzięki implementacji interaktywnego interfejsu krokowego. Zastosowana metoda jest odporna na wartości odstające i skutecznie łączy cechy analitycznego dashboardu z precyzyjnym narzędziem do diagnostyki danych wejściowych.

7.4.3. FUNKCJE UŻYTKOWE

Zakres funkcjonalny SIMDATA został dobrany pod kątem pracy badawczej, w której niezbędne jest jednocześnie porównywanie wielu sygnałów, kontrola jakości danych i szybka inspekcja anomalii (Rys. 7.10). Podstawową funkcją aplikacji jest wczytywanie danych z pliku JSON. Po załadowaniu danych aplikacja aktywuje ich walidację. Mechanizm ten minimalizuje ryzyko analizy niekompletnego lub niezgodnego zbioru danych.

Równie ważnym mechanizmem funkcjonalnym jest selekcja sygnałów. Użytkownik wybiera parametr P1-P20 i jeden lub wiele atrybutów, które następnie są dodawane do legendy

aktywnych przebiegów. Rozwiązanie to jest szczególnie istotne dla danych o dużej liczbie zmiennych, gdzie tradycyjna płaska legenda przestaje być użyteczna.



Rys 7.10 Funkcje użytkowe aplikacji SIMDATA wykorzystane w rozprawie

Źródło: opracowanie własne.

Kolejną funkcją jest sterowanie perspektywą czasową. Oprócz predefiniowanych zakresów (7, 30, 90 dni, całość) użytkownik może narzucić własny zakres kroków. Funkcja ta wspiera zarówno analizę makro trendów, jak i analizę epizodów krótkookresowych, np. lokalnych zaburzeń popytu lub zmian kosztowych.

Istotny mechanizm stanowi skalowanie danych osi Y, dostępne w czterech wariantach: auto, pełny zakres atrybutu (dla całego zbioru), robust oraz normalizacja do zakresu $<0,1>$. Umożliwia to porównanie sygnałów o różnych rzędach wielkości bez utraty informacji o dynamice. W praktyce badawczej szczególnie użyteczny jest tryb robust, ograniczający wpływ obserwacji odstających na percepcję trendu.

SIMDATA oferuje również moduł inspektora kroków, który prezentuje pełną tabelę wartości dla wybranego kroku k , wraz z klasyfikacją kluczy (np. A dla ścieżek atrybutowych). Dla badacza jest to mechanizm kluczowy: pozwala przejść z poziomu syntetycznej wizualizacji do poziomu surowych danych i zweryfikować źródło konkretnej zmiany na wykresie.

Do funkcji wspierających pracę analityczną należą ponadto: eksport wykresu do PNG, statystyki zakresowe dla aktywnych sygnałów oraz interaktywne sprzężenie wykres-inspektor (kliknięcie punktu ustawia krok analizy). Z perspektywy użyteczności badawczej szczególnie istotna jest ta ostatnia funkcja, ponieważ skraca czas lokalizacji przyczyn odchyleń i ułatwia

iteracyjne testowanie scenariuszy. W ujęciu końcowym SIMDATA należy traktować nie jako odrębny produkt, lecz jako integralny komponent metody badawczej. Aplikacja zwiększa wiarygodność interpretacji wyników modelu, skraca cykl analityczny i umożliwia systematyczne przejście od danych surowych do wniosków o charakterze naukowym i wdrożeniowym.

7.5. ZASADY PRZYGOTOWANIE DANYCH DLA REALIZACJI SCENARIUSZY SYMULACYJNYCH

7.5.1. KONTROLA JAKOŚCI DANYCH WEJŚCIOWYCH W SIMDATA DLA SCENARIUSZY

Wejściowy scenariusz jest zapisywany jako pojedynczy plik JSON (dataset.json), który zawiera metadane scenariusza, definicję osi czasu (t_0 , krok T_s , liczba kroków K), stan początkowy modelu oraz wszystkie atrybuty parametrów zdefiniowane w modelu, co pozwala w sposób pełny opisać wartości danych wejściowych modelu w każdym kroku symulacji. Zbiór ten można interpretować jako “stan świata” w danym kroku symulacji.

Zakodowany plik JSON jest poddawany kontroli w aplikacji SIMDATA. Duża liczba szczegółowych danych zawartych w każdym scenariuszu wymusza konieczność analizy z dwóch perspektyw: ciągłej (szeregi czasowe) i dyskretniej (inspekcja poszczególnych kroków). Aplikacja SIMDATA umożliwia kontrolę spójności danych wejściowych poprzez analizę kompatybilności ze standardem aplikacji SIMVEC, walidację kompletności danych, ponowne sprawdzenie ciągłości linii czasu, spójności zakresów atrybutów oraz analizę wizualną ich przebiegów co ogranicza ryzyko błędów w trakcie samej symulacji. Pełna procedura przetwarzania jest pokazana na Rys. 7.11.

Badania prowadzone są, na ogół, na wielu scenariuszach, ponieważ porównywalność eksperymentów zależy od poprawności wejściowej struktury danych. SIMDATA wspiera ocenę scenariuszową umożliwiając szybkie porównanie przebiegów w różnych zakresach czasu. Funkcja stack pozwala oddzielić sygnały i ograniczyć ryzyko błędów zgrubnych, natomiast tryb overlay sprzyja ocenie korelacji.



Rys 7.11 Procedura opracowania danych wejściowych przy użyciu aplikacji SIMDATA

Źródło: opracowanie własne.

7.5.2. WŁAŚCIWE URUCHOMIENIE SYMULACJI W SIMVEC

Po zatwierdzeniu danych uruchamiana jest symulacja w SIMVEC. Silnik obliczeniowy realizuje kolejne kroki symulacji $k = 1 \dots K$, i dla każdego kroku oblicza wartości wektorów wpływu w oparciu o algorytm opisany w rozdziale 6. Wyniki są rejestrowane i wizualizowane, co umożliwia zarówno szybką ocenę, jak i pogłębioną analizę wyników oraz porównanie wyników między scenariuszami. Precyzja obliczeń zastosowana w JavaScript jest na poziomie liczb typu double (IEEE-754, 64-bit), co odpowiada ok. 15-16 cyfom znaczącym. W praktyce pozwala to pominąć błędy zaokrągleń.

7.5.3. KRZYŻOWA WERYFIKACJA OBLICZEŃ (JUPYTER NOTEBOOK/PYTHON)

Na etapie walidacji silnika obliczeniowego SIMVEC została wprowadzona procedura krzyżowego potwierdzania poprawności obliczeń aplikacji SIMVEC. W tym celu zostało przygotowane “wirtualne laboratorium” Simstep.ipynb w środowisku Jupyter Notebook, którego celem było odtworzenie obliczeń dla pojedynczego kroku na podstawie tych samych danych wejściowych jak w aplikacji SIMVEC.

Porównywane były wartości końcowe wektorów V_p i V_W uzyskane z aplikacji SIMVEC i laboratorium Simstep.ipynb. Uzyskane wyniki generowały rozbieżności, które posłużyły do poprawy implementacji algorytmu. Błędy najczęściej obejmowały nieprawidłowe kolejności działań po konwersji funkcji modulujących z formatu latex, zaokrągleń, obsługi wartości

brzegowych. W obecnej wersji aplikacji SIMVEC, która posłużyła do przeprowadzenia symulacji wyniki są identyczne zarówno w Simstep.ipynb, jak i aplikacji SIMVEC.

8. WERYFIKACJA MODELU Z ZASTOSOWANIEM APLIKACJI KOMPUTEROWYCH DLA USTALONYCH SCENARIUSZY SYMULACYJNYCH

8.1. ZAŁOŻENIA METODOLOGICZNE

Symulacje są wykonywane z wykorzystaniem dwóch aplikacji: SIMDATA (kontrola i inspekcja danych wejściowych) oraz SIMVEC (właściwy silnik symulacyjny). Algorytm obliczeń kroku symulacyjnego został zdefiniowany w rozdziale 6. W metodyce badań zostały przygotowane scenariusze symulacyjne obejmujące dwa typy. Typ A oznaczający scenariusz całkowicie syntetyczny. Typ B oznaczający scenariusz hybrydowy, wygenerowany częściowo na danych z rzeczywistych źródeł, które zostały ekstrapolowane na szczegółowe kroki symulacyjne, częściowo na założeniach scenariuszowych.

A. Dane całkowicie syntetyczne wygenerowane bez dostępu do źródeł, na podstawie założeń scenariusza zostały wygenerowane poprzez wykorzystanie:

- Modelowania zmienności funkcjami deterministycznymi: trend liniowy, wzrost logarytmiczny, cykliczność sinusoidalna.
- Do sygnałów syntetycznych został dodany szum, aby zasymulować niepewność lub niekontrolowaną zmienność.
- Zdarzenia scenariuszowe zostały uzupełnione manualnie, tak aby odpowiadały tematyce scenariusza i obejmowały: skoki poziomu, krótkie epizody awarii stacji, kampanii promocyjnej, gwałtownego skoku kosztu energii, wejścia na rynek konkurencyjnej stacji ładowania.

B. Dane hybrydowe, w których baza danych i trend pochodzą ze źródła, a szczegóły są syntetyzowane na drodze ekstrapolacji z dodaniem szumu.

Źródła, które były podstawą do przygotowania danych hybrydowych zostały przypisane do następujących parametrów:

- Koszt energii P4, P12, P15: TGE (dane statystyczne/średnie ceny RDN),
- Inflacja P20: GUS (CPI),
- Nasycenie rynku pojazdami EV i rynek pojazdów P16: IEA Global EV Data Explorer,
- Infrastruktura ładowania i konkurencja lokalna P3, P2: EAFO i Open Charge Map,
- Warunki klimatyczne P13: IMGW i Copernicus/ERA5,
- Regulacje i programy wsparcia P10: akty prawne (AFIR) i programy NFOŚiGW.

8.2. PRZEPROWADZENIE SYMULACJI DLA SCENARIUSZY I ANALIZA WYNIKÓW

8.2.1. ZDEFINIOWANIE SCENARIUSZY SYMULACYJNYCH

W celu przeprowadzenia kompleksowej weryfikacji poprawności działania modelu oraz oceny jego stabilności numerycznej zaprojektowano zestaw zróżnicowanych scenariuszy badawczych. Przygotowywanych zostało 6 scenariuszy symulacyjnych. Scenariusze obejmują m.in. wariant bazowy bez zaburzeń, warianty z zaburzeniami kosztowymi (np. wzrost ceny energii), warianty konkurencyjne (wejście nowych stacji w okolicy) oraz warianty operacyjne (np. spadek dostępności mocy lub awarie). Kluczowa jest ich różnorodność, której celem jest identyfikacja słabych punktów modelu oraz sprawdzenie czy wnioski pozostają stabilne w różnych warunkach.

Szczegółowe opisy parametrów oraz dane źródłowe wykorzystane w poszczególnych wariantach zostały zamieszczone w załącznikach do rozprawy. Badania podzielono na dwie główne kategorie: scenariusze typu A (w pełni syntetyczne, ukierunkowane na izolowane testy parametrów) oraz scenariusze typu B (oparte na danych hybrydowych, symulujące warunki zbliżone do rzeczywistych).

Symulacje typu A

- SC1 - test sygnału piłokształtnego

Scenariusz służący do badania pojedynczych parametrów w izolacji. W każdym cyklu aktywowany jest wyłącznie jeden parametr, podczas gdy pozostałe pozostają wyzerowane. Celem symulacji jest weryfikacja kierunku oddziaływania parametrów oraz symetrii odpowiedzi modelu na zboczu narastającym i opadającym sygnału.

- SC2 - test sygnału liniowego narastającego

Scenariusz syntetyczny oparty na wolno narastającym sygnale liniowym. Jego celem jest analiza współliniowości parametrów oraz ocena poziomu ich wzajemnej korelacji w warunkach identycznego sygnału wejściowego.

- SC6 - test losowy (szum biały)

Scenariusz wykorzystujący sygnały całkowicie losowe. Celem symulacji jest wykrycie ewentualnych tendencji modelu do asymetrii odpowiedzi (biasu) oraz identyfikacja potencjalnej podatności modelu na zjawisko saturacji lub niestabilności w warunkach losowych fluktuacji parametrów.

Symulacje typu B

- SC3 - scenariusz rynkowy

Scenariusz oparty na danych hybrydowych symulujący realistyczne warunki funkcjonowania stacji ładowania. W modelu uwzględniono m.in. zmienność cen energii elektrycznej, dynamikę liczby pojazdów elektrycznych, czynniki makroekonomiczne oraz zdarzenia operacyjne wpływające na funkcjonowanie infrastruktury.

- SC4 - scenariusz dysrupcyjny

Scenariusz symulujący serię negatywnych zdarzeń o charakterze ekonomicznym i operacyjnym, takich jak długotrwała awaria stacji, wzrost kosztów energii elektrycznej oraz pojawienie się konkurencyjnej infrastruktury ładowania w bezpośrednim otoczeniu analizowanej stacji.

- SC5 - scenariusz operacyjny

Scenariusz przedstawiający sytuację, w której wzrost ceny usługi prowadzi do spadku wykorzystania infrastruktury stacji. W dalszej części symulacji operator podejmuje działania korygujące, takie jak kampanie promocyjne, poprawa jakości obsługi oraz wprowadzenie ofert flotowych, których celem jest odbudowa poziomu wykorzystania infrastruktury.


8.2.2. PRZEPROWADZENIE SYMULACJI I ANALIZA WYNIKÓW DLA SCENARIUSZA SC1

Scenariusz SC1 (typ A) to test w pełni syntetyczny, wykorzystujący sygnał piłokształtny (narastający i opadający). Celem scenariusza jest badanie poszczególnych parametrów w izolacji: w trakcie testu aktywowany jest wyłącznie jeden parametr, podczas gdy pozostałe 19 parametrów jest wyzerowanych. Ocenie podlega zgodność trendu z przewidywaniami teoretycznymi na obu zboczach sygnału (wznoszącym i opadającym).

Na Rys. 8.1 przedstawiono pełny sygnał wejściowy symulacji, dla którego $T_s = 1\text{ h}$ oraz liczba kroków $K = 200$, co wynika z faktu, że dynamika zmiany wartości parametru obejmuje 5 kroków na parametr.

W oparciu o scenariusz SC1 przeprowadzono symulację SC1.sim, której celem było sprawdzenie kierunku oraz wartości wpływu poszczególnych parametrów na zmianę stanu modelu. Było to możliwe dzięki funkcji symulowania izolowanych sygnałów zaimplementowanej w aplikacji SIMVEC. Obserwacja izolowanego sygnału zarówno na zboczu narastającym, jak i opadającym umożliwiła weryfikację poprawności wyniku w kroku

poprzedzającym wystąpienie impulsu oraz po jego wygaśnięciu. Nie zaobserwowano wartości resztkowych po całym cyklu działania impulsu - wartości początkowe i końcowe były identyczne. W trakcie działania impulsu zachowanie obserwowanego wektora V_p było zgodne z oczekiwaniami; wartość, moduł i zwrot wektora odpowiadały spodziewanej sumie wektorowej.




Rys. 8.1 Wykres SC1 znormalizowany do wartości [0...1] z aplikacji SIMDATA

Źródło: opracowanie własne.

Na Rys. 8.2 przedstawiono przykładowy przebieg pojedynczego sygnału w wartościach bezwzględnych.


Scenariusz SC1 wykorzystano również do krzyżowej weryfikacji z obliczeniami realizowanymi w „wirtualnym laboratorium” Jupyter Notebook SimStep.ipynb opisanym w punkcie 7.6.4. Uzyskane wyniki potwierdziły poprawność odpowiedzi silnika obliczeniowego SIMVEC na wprowadzane impulsy wejściowe, a tym samym zgodność implementacji z algorytmem.

Przebieg symulacji w poszczególnych krokach przedstawiono na Rys. 8.3.



Rys 8.2 Wykres wartości bezwzględnej dla przykładowej wartości parametru P6 z aplikacji SIMDATA

Źródło: opracowanie własne.



Rys 8.3. Wynik symulacji SC1 z aplikacji SIMVEC


Źródło: opracowanie własne.

Należy podkreślić, że SC1 nie niesie bezpośredniej logiki ekonomicznej, ponieważ stanowi w pełni syntetyczny test walidacji obliczeń. Jednocześnie zaobserwowano zjawisko dryftu wyniku końcowego: M o 13 pp (punktów procentowych) oraz U o -13 pp. Zjawisko to nie było planowane i wymaga dalszych badań na pełnych danych rzeczywistych operatora.

8.2.3. PRZEPROWADZENIE SYMULACJI I ANALIZA WYNIKÓW DLA SCENARIUSZA SC2

Scenariusz SC2 (typ A) to test syntetyczny oparty na wolno narastającym sygnale liniowym. Scenariusz ten służy do weryfikacji współliniowości parametrów oraz oceny poziomu ich wzajemnej korelacji przy identycznym sygnale wejściowym.


Na Rys. 8.4 zaprezentowano wykres wszystkich sygnałów wejściowych scenariusza SC2. Pozornie nieintuicyjny charakter wykresu jest bezpośrednim rezultatem normalizacji, w wyniku której wszystkie badane sygnały uległy idealnemu nałożeniu. W konsekwencji zlewają się one ze sobą, tworząc obraz pojedynczego przebiegu i ukrywając wielość nałożonych serii danych.



Rys. 8.4 Wykres SC2 znormalizowany do wartości [0...1] z aplikacji SIMDATA

Źródło: opracowanie własne.

Na Rys. 8.5 przedstawiono przykładowy, wyizolowany impuls dla parametru P3. Sygnał główny parametru oznaczono kolorem zielonym, natomiast wykresy różowy i czerwony reprezentują atrybuty kalibracyjne parametru.




Rys 8.5 Przykładowy wykres sygnału w symulacji SC2 dla parametru P3 w wartościach nominalnych

Źródło: opracowanie własne.

W oparciu o scenariusz SC2 przeprowadzono symulację SC2.sim, której przebieg przedstawiono na Rys. 8.6. W ramach symulacji wykonano obserwację wizualną wyników z wykorzystaniem funkcjonalności izolacji sygnałów w aplikacji SIMVEC, a następnie przeprowadzono badanie wrażliwości modelu oraz korelacji parametrów na danych rejestrowanych do pliku przez aplikację. Dokładny opis metodologii i wnioski przedstawiono w rozdziale 7.4. W wyniku obserwacji nie stwierdzono anomalii: odpowiedź modelu na znormalizowane impulsy była zgodna z oczekiwanym wpływem co do modułu, kierunku i zwrotu wektorów V_p i V_w .

Na Rys. 8.6 przedstawiono przebieg symulacji przy aktywnych wszystkich impulsach jednocześnie. Scenariusz ten nie posiada sensu ekonomicznego dla operatora stacji ładowania, natomiast z perspektywy badań umożliwia analizę wzajemnego wpływu różnych kombinacji parametrów oraz wyznaczenie efektu ich superpozycji, który w warunkach rzeczywistych może występować rzadko lub wcale. Aplikacja SIMVEC umożliwia w tym trybie badanie efektu końcowego przy jednoczesnym zbiegu impulsów o jednakowym natężeniu oraz ocenę kierunku, w którym dana kombinacja zjawisk „prowadzi” stację (np. oszacowanie skali działań

marketingowych wymaganej do przeciwdziałania negatywnym skutkom pojawienia się konkurencyjnej stacji).



Rys 8.6 Wynik symulacji SC2 z aplikacji SIMVEC

Źródło: opracowanie własne.

Na Rys. 8.6 widoczna jest również szybka saturacja modelu - już w kroku $k = 50$. Z tego względu dalszą część wyników ($k > 50$) odrzucono jako niemiarodajną. Tak szybka saturacja wynika z charakteru modelu, który jest modelem addytywnym, a więc szczególnie wrażliwym na wiele jednoczesnych impulsów o charakterze rosnącym.

8.2.4. PRZEPROWADZENIE SYMULACJI I ANALIZA WYNIKÓW DLA SCENARIUSZA SC3


Scenariusz SC3 (typ B) to scenariusz oparty na danych hybrydowych, symulujący realistyczne funkcjonowanie stacji ładowania. Celem scenariusza było zbadanie zgodności odpowiedzi modelu z logiką ekonomiczną w typowych warunkach rynkowych. Sygnały opracowano na bazie danych rzeczywistych. Hurtowe ceny energii przyjęto na poziomie 420-460 PLN/MWh dla drugiego i trzeciego kwartału 2025 roku, w oparciu o publikacje Urzędu Regulacji Energetyki (URE) oraz Towarowej Giełdy Energii (TGE).

Punkt odniesienia dla cen detalicznych skalibrowano w przedziale 2,0-3,2 PLN/kWh, bazując na publicznych cennikach operatorów stacji HPC w Polsce: ORLEN Charge i TAURON eMobility. Wzrost bazy potencjalnych klientów zamodelowano na podstawie „Licznik Elektromobilności” Polskiego Związku Przemysłu Motoryzacyjnego (PZPM), uwzględniając, że w 2025 roku liczba pojazdów BEV i PHEV przekroczyła 200 tys., a roczna dynamika wzrostu wynosi 25-35%.

Tło makroekonomiczne stanowiła inflacja na poziomie 3-5% r/r, zaczerpnięta z danych Głównego Urzędu Statystycznego (GUS) oraz Narodowego Banku Polskiego (NBP).

Generację danych uzupełniono o epizodyczne zakłócenia, takie jak kilkuprocentowe przestoje awaryjne, ograniczenia mocy przyłączeniowej w upalne dni oraz mechanizm niepełnego przenoszenia kosztów (inflacji i cen energii) na klienta końcowego.


Na Rys. 8.7 przedstawiony jest pełny sygnał wejściowy symulacji, $T_s = 1h$ liczba kroków $K = 4392$ co odpowiada symulacji okresu $T_{sim} = 1$ roku



Rys 8.7 Kompletny znormalizowany sygnał wejściowy symulacji SC3

Źródło: opracowanie własne.

Na Rys. 8.8 przedstawiono wyizolowane impulsy cenowo-kosztowe, które miały istotny wpływ na przebieg scenariusza, tj. parametry ceny sprzedaży (wykres czerwony) oraz kosztu energii (wykres niebieski)..




Rys 8.8 Przykładowy sygnał szczegółowy symulacji SC3 dla cen energii P4 i ceny P1

Źródło: opracowanie własne.


W oparciu o scenariusz SC3 przeprowadzono symulację SC3.sim; jej przebieg przedstawiono na Rys. 8.9. Dominującym zjawiskiem jest znaczny spadek wykorzystania infrastruktury stacji do poziomu 2,38% w perigeum (Rys. 8.10). Zjawisko to wynika z wpływu zbyt wysokiej ceny oraz stopniowego odbicia po obniżeniu ceny (w praktyce: zmniejszeniu różnicy pomiędzy ceną sprzedaży a średnią ceną konkurencji). Intensywny odpływ klientów

wynika z niskiej elastyczności popytu w sektorze elektromobilności oraz wysokiej wrażliwości na różnice cen pomiędzy konkurującymi stacjami, co zostało uwzględnione w modelu poprzez atrybut ϵ_{eff} . Zjawisko to jest zgodne z wnioskami z badań literatury dziedzinowej zaprezentowanymi w rozdziale 3.



Rys 8.9 Wynik symulacji SC3 z aplikacji SIMVEC

Źródło: opracowanie własne.




Rys 8.10 Perigeum wykorzystania infrastruktury w scenariuszu SC3 z aplikacji SIMVEC

Źródło: opracowanie własne.

Kolejne zjawisko zaobserwowano w kroku $k = 2531$, co odpowiada w symulacji dniowi 22.07.2025, gdzie scenariusz wprowadza impuls symulujący poważną awarię stacji (Rys. 8.11). Odpowiedź modelu jest prawidłowa i wywołuje znaczący, długotrwały spadek wykorzystania infrastruktury stacji z poziomu 33,93% do 29,56% w okresie awarii trwającej od $k = 2531$ do


$k = 2660$, co odpowiada 5 dniom i 9 godzinom. Następnie stacja powraca na wcześniejszą, stabilną trajektorię wzrostu wykorzystania infrastruktury stacji.



Rys 8.11 Epizod awarii w scenariuszu SC3 z aplikacji SIMVEC

Źródło: opracowanie własne.

Problemy ujawnione w ramach SC3 dotyczą głównie nadmiernego wpływu parametru P5, który modeluje wzrosty wykorzystania infrastruktury stacji w szczytach cyklu dziennego. W ramach badania przeprowadzono symulację scenariusza SC3 dla wyizolowanego parametru P5 (jedyń aktywny), aby zbadać jego wpływ skumulowany. Wynik wykazał, że parametr ten w opracowanym modelu powoduje nadmierny wzrost wykorzystania stacji. Wykres na Rys. 8.12 wyraźnie pokazuje, że wykorzystanie infrastruktury sterowane wyłącznie cyklami dziennymi wzrasta w horyzoncie $T_{sim} = 1$ rok z 25,13% do 65,59%, co daje wzrost o 40,46 pp i jest ekonomicznie nierealne. Podobny, nadmierny wpływ na model wykazuje parametr P13.



Rys 8.12 Przebieg scenariusza SC3 dla wyizolowanego parametru P5 z aplikacji SIMVEC

Źródło: opracowanie własne.

Podsumowując, SC3 potwierdził prawidłowość trendów i kierunków odpowiedzi modelu, natomiast wskazał na zbyt duże amplitudy zmian. Oznacza to, że model jest nadmiernie dynamiczny, co uzasadnia tezę, iż w ramach kalibracji opartej o dane rzeczywiste operatora należy odpowiednio stłumić siłę odpowiedzi modelu, aby ograniczyć przeszacowanie reakcji na impulsy wejściowe.

8.2.5. PRZEPROWADZENIE SYMULACJI I ANALIZA WYNIKÓW DLA SCENARIUSZA SC4

Scenariusz SC4 (typ B) stanowi scenariusz „dysrupcyjny”, symulujący serię następujących po sobie zaburzeń ekonomicznych i operacyjnych: długotrwałą awarię stacji, drastyczny wzrost cen energii połączony z impulsem inflacyjnym oraz pojawienie się stacji konkurencyjnych w bezpośrednim sąsiedztwie. Celem scenariusza jest obserwacja zachowania modelu i identyfikacja potencjalnych anomalii w odwzorowaniu kondycji ekonomicznej stacji poddanej ekstremalnym obciążeniom.

Na Rys. 8.13 przedstawiono pełny sygnał wejściowy symulacji SC4: $T_s = 24h$ oraz liczba kroków $K = 365$, co odpowiada okresowi symulacji $T_{sim} = 1rok$.




Rys. 8.13 Kompletny znormalizowany sygnał wejściowy symulacji SC4

Źródło: opracowanie własne.

Wykres na Rys. 8.14 przedstawia kolejne symulowane zjawiska kryzysowe:

- P8: awaria w dniu 10.03.2025 (wykres czerwony), $k = 66$,
- P3: pojawienie się konkurencyjnej stacji w okolicy w dniu 11.06.2025 (wykres zielony), $k = 160$,

- P4: impuls cenowy, drastyczny wzrost kosztu energii (TGE) w dniu 03.10.2025 (wykres niebieski), $k = 243$.




Rys 8.14 Impulsy kryzysowe w scenariuszu SC4, wartości znormalizowane

Źródło: opracowanie własne.

W oparciu o SC4 przeprowadzono symulację, która wykazała prawidłową odpowiedź modelu na każde z zaburzeń. Dla impulsu P8 odnotowano spadek wykorzystania infrastruktury stacji o 8,98 pp: z poziomu 21,02% do 12,04% (Rys. 8.15). Analogiczny spadek wykorzystania infrastruktury stacji zaobserwowano po pojawieniu się konkurencji (impuls P3), przy czym w tym przypadku wystąpiło opóźnienie reakcji na impuls: spadek odnotowano dopiero w kroku $k = 166$ i wyniósł on 33,9%-29,7%. Przyczynę opóźnienia reakcji modelu o 6 kroków należy zbadać, ponieważ autor nie implementował tzw. лагу (opóźnienia pomiędzy zadziałaniem czynnika a obserwacją skutku), co wykazano w punkcie 4.8 rozprawy.

M(t) i U(t)




Rys 8.15 Wynik symulacji SC4 z aplikacji SIMVEC

Źródło: opracowanie własne.

Trzeci impuls dotyczył drastycznego wzrostu kosztu energii. Odpowiedź modelu przedstawiono na Rys. 8.16, gdzie obserwuje się znaczny spadek marży w kroku $k = 251$, co jest zachowaniem spodziewanym. Należy zwrócić uwagę, że trend spadku marży jest skorelowany ze wzrostem wykorzystania infrastruktury stacji, co wynika z faktu, że współczynnik przeniesienia kosztu na klienta został ustawiony na bardzo niskim poziomie, tj. $\lambda_c = 0,25$, co odpowiada przyjęciu przez operatora 75% kosztu podwyżki energii w hurcie. Jest to założenie scenariuszowe; w praktyce operatorzy częściej stosują strategię przerzucania pełnego kosztu na klienta, a przy dużych zwyżkach, korzystając z trendu, podnoszą ceny o wartości większe niż sam wzrost kosztu. Niezależnie od tego, model reagował na impulsy w sposób zgodny z wiedzą pozyskaną z literatury opisanej w rozdziale 3.

M(t) i U(t)




Rys 8.16 Odpowiedź modelu na impuls P8 w scenariuszu SC4 z aplikacji SIMVEC

Źródło: opracowanie własne.

8.2.6. PRZEPROWADZENIE SYMULACJI I ANALIZA WYNIKÓW DLA SCENARIUSZA SC5

Scenariusz SC5 (typ B) to scenariusz cenowy, w którym operator staje się relatywnie drogi, co prowadzi do spadku wykorzystania infrastruktury stacji. Następnie, w reakcji na trend spadkowy, operator uruchamia pakiet decyzji biznesowych mających odbudować wykorzystanie infrastruktury stacji.

Na Rys. 8.17 przedstawiono pełny sygnał wejściowy symulacji SC5: $T_s = 24h$ oraz liczba kroków $K = 365$, co odpowiada symulacji okresu $T_{sim} = 6mies.$




Rys 8.17 Kompletny znormalizowany sygnał wejściowy symulacji SC5

Źródło: opracowanie własne.

Na Rys. 8.18 zaprezentowano przebiegi czasowe sygnałów odzwierciedlających działania korygujące podjęte przez operatora w celu przeciwdziałania spadkowi wykorzystania infrastruktury stacji. Przedstawione wykresy ilustrują dynamikę zmiennych endogenicznych, które stanowią bezpośrednią odpowiedź symulowanego operatora systemu na niekorzystne ekonomicznie zjawisko:

- P7: kampania promocyjna (wykres turkusowy),
- P17: poprawiona jakość obsługi stacji (wykres różowy),
- P19: oferowanie abonamentów flotowych (wykres czerwony),
- P11: działania poprawiające widoczność stacji w wyszukiwarkach oraz w aplikacjach (wykres żółty).




Rys 8.18 Działania operatora w scenariuszu SC5 - wartości znormalizowane

Źródło: opracowanie własne.

W pierwszej fazie symulacji SC5 układ M-U porusza się po stabilnej trajektorii wzrostu wykorzystania infrastruktury stacji, osiągając lokalne maksimum $U = 23,95\%$ w kroku $k = 40$

(2025-02-10), przy jednoczesnym wzroście marży do poziomu $M = 62,42\%$. Scenariusz odwzorowuje następnie zjawisko zbyt wysokiej ceny. Relatywna różnica ceny sprzedaży względem konkurencji narasta do poziomu 25%, co w modelu skutkuje pojawieniem się wyraźnie ujemnej składowej wypadkowego wektora V_w w osi wykorzystania infrastruktury stacji. Innymi słowy, suma wkładów cząstkowych parametrów zaczyna generować ujemną zmianę ΔU . Zjawisko to jest dobrze widoczne w kroku $k = 52$ (2025-02-22), gdzie mimo dalszego wzrostu marży do $M = 63,42\%$ wykorzystanie infrastruktury stacji spada do $U = 21,29\%$, a dzienny jej przyrost wynosi $\Delta U = -0,3281$ pp. Oznacza to, że w tym okresie ujemny wpływ presji cenowej dominuje nad łącznym dodatnim oddziaływaniem pozostałych parametrów korzystnych dla ekonomiki symulowanej stacji.

W ramach scenariusza zasymulowano następnie podjęcie przez operatora działań promocyjnych i marketingowych mających na celu odbudowę poziomu wykorzystania infrastruktury stacji (krok $k = 66$, 2025-03-08) (Rys.8.19). Odpowiedź modelu nadal wykazuje jednak spadki wykorzystania infrastruktury stacji, co można interpretować jako sytuację, w której bilans wkładów pozostaje ujemny: czynnik dominujący (zbyt wysoka cena) wciąż jest aktywny, a efekty kompensacyjne narastają stopniowo i początkowo nie są w stanie zmienić znaku wypadkowej w osi U . Perigeum wykorzystania infrastruktury stacji występuje dopiero w kroku $k = 94$ (2025-04-05) na poziomie $U = 9,96\%$, podczas gdy marża osiąga $M = 68,67\%$. W tym punkcie zmiana dzienna jest już bliska zera (około $\Delta U = -0,030$ pp), co oznacza, że suma dodatnich i ujemnych wkładów parametrów niemal się równoważy. Faktyczne odbicie rozpoczyna się w kroku $k = 95$ (2025-04-06), kiedy pojawia się pierwszy dodatni przyrost $\Delta U = +0,0038$ pp.




Rys 8.19 Wynik symulacji SC5 z aplikacji SIMVEC

Źródło: opracowanie własne.

Ocena końcowa scenariusza SC5 wskazuje, że model w sposób poprawny odwzorowuje logikę ekonomiczną: wykorzystanie infrastruktury stacji zaczyna rosnąć dopiero w momencie, gdy presja cenowa ulega osłabieniu, a łączny efekt działań kompensacyjnych osiąga poziom wystarczający do zmiany znaku wypadkowego wektora V_w w osi wykorzystania infrastruktury stacji. W ramach symulacji SC5 nie zaobserwowano anomalii w działaniu modelu; trajektorie M i U są spójne z logiką scenariusza oraz z ekonomiczną interpretacją analizowanego zjawiska.

8.2.7. PRZEPROWADZENIE SYMULACJI I ANALIZA WYNIKÓW DLA SCENARIUSZA SC6


Scenariusz SC6 (Typ A - wariant uzupełniający) stanowi test oparty na sygnałach całkowicie losowych. Został zaprojektowany w celu wykrycia ewentualnych tendencji modelu do asymetrii którejś składowej (nazywanej dalej biasem). Na Rys. 8.20 przedstawiono pełny sygnał wejściowy symulacji SC6.



Rys 8.20 Kompletny znormalizowany sygnał wejściowy symulacji SC6

Źródło: opracowanie własne.


Na Rys. 8.21 przedstawiono przykładowy przebieg sygnału znormalizowanego dla 7 dni. Należy podkreślić, że wynik symulacji SC6 nie był interpretowany w kategoriach ekonomicznych, ponieważ stanowi w pełni syntetyczny test walidacji obliczeń. W wyniku obserwacji wartości wynikowych (Rys. 8.22) stwierdzono znaczny bias składowej marży M o +11pp (punktów procentowych). Zatem wartość względna biasu zbadanego szumem białym odbiega od wartości marży inicjalnej ustalonej na poziomie $M_0 = 60\%$ o $\Delta M = 18,33\%$.



Rys 8.21 Kompletny znormalizowany sygnał wejściowy symulacji SC6 w perspektywie 7 dni

Źródło: opracowanie własne.

Zjawiska tego nie zaobserwowano dla składowej wykorzystania infrastruktury stacji, której bias utrzymywał się na poziomie +1pp i został w analizie potraktowany jako stabilny. Zjawisko zaobserwowane dla składowej marży nie było planowane i wymaga dalszych badań na pełnych danych rzeczywistych operatora.



Rys. 8.22 Wynik symulacji SC6 z aplikacji SIMVEC

Źródło: opracowanie własne.

8.3. ANALIZA WRAŻLIWOŚCI MODELU METODĄ OAT

8.3.1. ZAŁOŻENIA OGÓLNE I WYNIKI ANALIZY WRAŻLIWOŚCI PARAMETRÓW MODELU

Analiza wyników obliczeń uzyskanych z wykorzystaniem silnika obliczeniowego SIMVEC, oparta na definicjach parametrów zawartych w pliku parameters.json oraz danych wejściowych zapisanych w pliku dataset_sensitivity.json,.

W celu zbadania wrażliwości parametrów modelu zastosowano lokalną analizę OAT (One-At-a-Time) ze zmiennością (perturbacją) atrybutów wejściowych +5% dla każdego parametru P1-P20 i liczby kroków K=100. Dla każdego parametru P_j wykonano symulację bazową oraz symulację z perturbacją dla funkcji celu F_j :

$$F_j = \frac{mean(F_{ju}) + mean(F_{jm})}{2}$$

gdzie operator mean jest definiowany jako średnia arytmetyczna

$$mean(F_{ju}) = \frac{1}{2} \sum_{k=1}^K F_{ju}(t_k)$$

$$mean(F_{jm}) = \frac{1}{2} \sum_{k=1}^K F_{jm}(t_k)$$

wyznaczana w K krokach.

Współczynniki wynikowe:

$$S_{abs} = \frac{F_+ - F_0}{\delta}, \quad S_{rel} = \frac{S_{abs}}{F_0}$$

zostały wyznaczone dla założonego $\delta = 0.05$.

Dla każdego parametru P_j :

1. uruchomiono symulację bazową i zapisano F_{base} ,
2. zwiększono atrybuty parametru o +5%,
3. uruchomiono symulację ponownie i zapisano F_{plus} ,
4. obliczono S_{abs} oraz S_{rel} .

W wyniku uzyskano przybliżoną lokalną wrażliwość, która jest interpretowana jako czułość znormalizowana modelu względem parametru P_j w następujący sposób:

dla $S_j > 0$ parametr zwiększa wynik,

dla $S_j < 0$ parametr zmniejsza wynikowi.


Parametry dominujące zostały pokazane w postaci tabelarycznej Tab. 8.1 i na Rys. 8.23. Dodatkowo zaprezentowano uzyskane wyniki w formie wykresu „tornado” na Rys. 8.24. Wykres ten wizualizuje wpływ pojedynczych zmian każdego z badanych parametrów, przy symulowanych odchyleniach rzędu -5% oraz +5% od ich wartości bazowych na wynik

końcowy modelu. Na osi odciętych odłożono zmienną ΔF_{plus} , obrazującą skalę i kierunek zmiany wyniku, co pozwala na czytelne uszeregowanie czynników od najbardziej do najmniej determinujących badany model.

Tab 8.1 Tabela parametrów P1-P20 uporządkowana według siły wpływu na model


Lp	P _j	Nazwa parametru	F_{plus}	dF_{plus}	S_{abs}	S_{rel}
1	P5	Pora dnia	26.805624	0.157829	3.156586	0.118456
2	P3	Liczba konkurencyjnych stacji w okolicy	26.511266	-0.136528	-2.730568	-0.102469
3	P1	Cena sprzedaży	26.778817	0.131022	2.620445	0.098336
4	P2	Ceny konkurencji	26.525955	-0.121839	-2.436783	-0.091444
5	P16	Bazowa ilość samochodów EV	26.750889	0.103095	2.061891	0.077376
6	P4	Koszt energii elektrycznej	26.548766	-0.099028	-1.980557	-0.074323
7	P8	Awarie i niedostępność	26.552920	-0.094874	-1.897487	-0.071206
8	P11	Widoczność i informacja o stacji	26.736443	0.088649	1.772975	0.066534
9	P6	Lojalność klientów do marki	26.731017	0.083223	1.664461	0.062461
10	P15	Udział w programach DSR	26.712915	0.065121	1.302424	0.048875
11	P14	Obsługiwane standardy ładowania	26.711932	0.064138	1.282757	0.048137
12	P7	Wartość dodana oferty stacji	26.683993	0.036199	0.723980	0.027168
13	P9	Koszty operacyjne stacji	26.616973	-0.030821	-0.616417	-0.023132
14	P20	Wskaźnik inflacji	26.622448	-0.025346	-0.506923	-0.019023
15	P19	Umowy flotowe i abonamenty	26.622630	-0.025165	-0.503293	-0.018887
16	P17	UX użytkownika (wygoda dostępu)	26.670121	0.022327	0.446537	0.016757
17	P13	Warunki pogodowe i sezonowość	26.667866	0.020072	0.401430	0.015064
18	P12	Kongestia sieci energetycznej / ograniczenia lokalne	26.641195	-0.006599	-0.131977	-0.004953
19	P10	Subwencje i ulgi podatkowe	26.651473	0.003679	0.073582	0.002761
20	P18	Moc ładowania (szybkość)	26.647794	0.000000	0.000000	0.000000

Źródło: opracowanie własne.



Rys 8.23 Ranking wpływu parametrów na model

Źródło: opracowanie własne.



Rys. 8.24 Wykres tornado wpływu parametrów na model

Źródło: opracowanie własne.

8.3.2. ANALIZA KORELACJI PARAMETRÓW

Zakres przeprowadzonego badania obejmował wszystkie parametry modelu oznaczone jako P_1 – P_{20} . Każdy parametr P_j został zdekomponowany na parę funkcji modulujących: F_{mj} , odpowiadającą składowej marży, oraz F_{uj} , odpowiadającą składowej obciążenia (wykorzystania infrastruktury). Celem przeprowadzonej analizy było zbadanie struktury funkcji modulujących w warunkach kontrolowanej zmienności danych wejściowych, randomizowanych metodą Monte Carlo. Należy podkreślić, że badanie nie stanowi walidacji empirycznej opartej na rzeczywistych danych operacyjnych, lecz ma charakter analizy symulacyjnej, ukierunkowanej na identyfikację korelacji wewnątrz modelu.

Założenia metodologiczne

Podstawową miarą zastosowaną w analizie był współczynnik korelacji rang Spearmana, właściwy dla identyfikacji zależności monotonicznych, w tym o charakterze nieliniowym. Zastosowanie metody współczynników Pearsona, zostało odrzucone ze względu na nieadekwatność w odniesieniu do nieliniowego charakteru funkcji modulujących.

W ramach przeprowadzonego badania przyjęto niezmiennosć wartości dla atrybutów typu K (stałe kalibracyjne), natomiast zmienność danych wejściowych została odwzorowana poprzez randomizację atrybutów typu A z wykorzystaniem metody Monte Carlo, co miało na celu randomizowane odwzorowanie zbioru czynników zewnętrznych oddziałujących na funkcje modulujące poszczególnych parametrów modelu.

W przypadkach, w których dana składowa funkcji modulującej przyjmowała wartość stałą równą zero, współczynnik korelacji rang Spearmana pozostawał nieokreślony, co w modelu odwzorowuje brak wpływu danego parametru na analizowaną składową (marży lub wykorzystania infrastruktury). W tabelach przypadki te oznaczono symbolem „-”, a przy wyznaczaniu wartości maksymalnych w macierzy S_{hj} uwzględniano wyłącznie składniki określone (tj. różne od zera).

Procedura badawcza

Dla każdej pary parametrów wyznaczono macierz korelacji obejmującą wszystkie kombinacje składowych marży i obciążenia.

$$R_{hj} = \begin{bmatrix} [\rho(V_{\{mh\}}, V_{\{mj\}}), \rho(V_{\{mh\}}, V_{\{uj\}})] \\ [\rho(V_{\{uh\}}, V_{\{mj\}}), \rho(V_{\{uh\}}, V_{\{uj\}})] \end{bmatrix}$$

Następnie zastosowano zagregowaną miarę siły zależności S_{hj} , definiowaną jako maksimum wartości bezwzględnej spośród czterech współczynników cząstkowych.

$$S_{hj} = \max(|\rho(V_{\{mh\}}, V_{\{mj\}})|, |\rho(V_{\{mh\}}, V_{\{uj\}})|, |\rho(V_{\{uh\}}, V_{\{mj\}})|, |\rho(V_{\{uh\}}, V_{\{uj\}})|)$$

Symbolem ρ_s oznaczono współczynnik korelacji rang Spearmana, gdzie d_i jest różnicą pomiędzy rangami obserwacji. W ramach badania zastosowano procedurę rangowania i wyznaczania korelacji dla każdej pary wektorów wyjściowych funkcji modulujących.

$$\rho_s = 1 - \frac{(6 \sum_{i=1}^n d_i^2)}{(n(n^2 - 1))}$$


Po randomizacji zbioru danych wejściowych wyznaczono 4 macierze mające na celu zbadanie korelacji między:

- $\rho(F_{mh}, F_{mj})$ - składowymi marży badanej pary (Rys. 8.26),
- $\rho(F_{uh}, F_{uj})$ - składowymi wskaźnika wykorzystania badanej pary (Rys. 8.29),
- $\rho(F_{mh}, F_{uj})$ - składowymi marży i wskaźnika wykorzystania badanej pary (Rys. 8.27),
- $\rho(F_{ui}, F_{mj})$ - między składowymi wykorzystania i marży badanej pary (Rys. 8.28).

Interpretację wyników przeprowadzono według czterostopniowej skali oznaczającej:

- $S_{hj} < 0.3$ brak istotnej korelacji funkcjonalnej,
- $0.3 \leq S_{hj} < 0.5$ korelację słabą,
- $0.5 \leq S_{hj} < 0.7$ korelację umiarkowaną,
- $S_{hj} \geq 0.7$ korelację silną.

Macierz S_{hj} (Rys. 8.25) ilustruje zagregowane wagi współzależności pomiędzy parametrami modelu. Obserwowana dominacja wag niskiego poziomu korelacji wskazuje na rozproszony charakter lokalnych zaburzeń oraz brak klastrów korelacyjnych. Jedyny obszar względnie wyższej intensywności zależności obserwowany jest dla par parametrów powiązanych z mechanizmami cenowo-regulacyjnymi oraz udziałem programów DSR.



Rys 8.25 . Macierz zagregowanego natężenia współzależności S_{ij}


Źródło: opracowanie własne

Macierze pomocnicze (Rys. 8.26 - Rys. 8.29) umożliwiają pogłębioną analizę wartości zdekomponowanych na poszczególne składowe funkcji modulujących. W wyniku analizy wyników pokazanych na macierzy $\rho(F_{mh}, F_{mj})$ (Rys. 8.26) zaobserwowano zjawisko dominacji składowych stałych lub o niskiej zmienności dla wielu parametrów, co wynika wprost z konstrukcji modelu zawierającego liczne wartości nieokreślone dla paramatrów nie wpływających na składową marży. Z kolei macierz $\rho(F_{uh}, F_{uj})$ (Rys. 8.28) ujawnia wyraźniejsze relacje pomiędzy parametrami, których wpływ na wykorzystanie infrastruktury został zdefiniowany przy użyciu wspólnych sygnałów wejściowych lub analogicznej logiki reakcji.




Rys 8.26 Macierz powiązań między składowymi współczynników marzy

Źródło: opracowanie własne




Rys 8.27 Macierz powiązań krzyżowych między składowymi marzy i współczynnika wykorzystania

Źródło: opracowanie własne



Rys 8.28 Macierz powiązań krzyżowych między składowymi współczynnika wykorzystania i marży


Źródło: opracowanie własne



Rys 8.29 Macierz powiązań między składowymi współczynników wykorzystania

Źródło: opracowanie własne

Najsilniejsza zidentyfikowana zależność dotyczy pary parametrów $P_{15} - P_{20}$, dla której wartość $S_{hj} = 0,3077$ przy $h=15$, $j=20$. W analizowanym przypadku dominującym składnikiem zależności jest relacja pomiędzy składowymi wykorzystania, co wskazuje na wspólny charakter oddziaływania tych parametrów na poziom wykorzystania infrastruktury. Kolejne pozycje w rankingu, tj. pary $P_{10}-P_{20}$ ($S_{hj} = 0,2749$, $h = 10$, $j = 20$), $P_{10}-P_{15}$ ($S_{hj} = 0,2058$, $h = 10$, $j = 15$) oraz P_1-P_{10} ($S_{hj} = 0,1784$, $h = 1$, $j = 10$), nie przekraczają wartości progowej 0,3, a tym samym klasyfikowane są w obszarze braku istotnej korelacji. Ranking najsilniejszych powiązań między parametrami pokazano na Rys. 8.30.



Rys 8.30 Ranking najsilniejszych powiązań między parametrami.

Źródło: opracowanie własne

Analiza wyników przedstawionych na Rys. 83 wskazuje, że obserwowane zależności powstają przede wszystkim tam, gdzie parametry wykorzystują wspólne sygnały stanu lub podobne konstrukcje analityczne. Dotyczy to zwłaszcza parametrów cenowo-regulacyjnych, dla których składowe obciążenia zawierają zbliżone ilorazy z udziałem ceny detalicznej, utylizacji bieżącej oraz elastyczności efektywnej. Jednocześnie brak silnych korelacji w większości pozostałych par świadczy o tym, że przyjęty zbiór parametrów nie ulega nadmiernemu skorelowaniu na poziomie funkcji modulujących. Należy jednak podkreślić, że uzyskane wyniki nie powinny być interpretowane jako bezpośrednie odzwierciedlenie

rzeczywistych warunków rynkowych. Stanowią one analizę wzajemnych zależności pomiędzy parametrami modelu, wynikających ze współdzielenia części sygnałów wejściowych oraz przyjętej struktury funkcji modulujących.

W tabeli Tab. 8.2 zostały dodatkowo zaprezentowane statystyki wyników uzyskanych przez funkcje modulujące poszczególnych parametrów w trakcie badania.

Tab. 8.2 Statystyki funkcji modulujących F_{mj} i F_{uj}

P_j	Nazwa parametru	Średnia F_{mj}	Odchylenie standardowe F_{mj}	Średnia F_{uj}	Odchylenie standardowe F_{uj}
P1	Cena sprzedaży	-0.0047	0.1607	0.0013	0.0152
P2	Ceny konkurencji	0.0	0.0	-0.004	0.1185
P3	Ilość konkurencyjnych stacji w okolicy	0.0	0.0	-0.1389	0.0333
P4	Koszt energii elektrycznej	0.0012	0.0539	0.0001	0.0057
P5	Pora dnia (szczyt/pozaszczyt)	0.0	0.0	0.1054	0.1174
P6	Lojalność klientów do marki	0.2275	0.0159	0.2179	0.047
P7	Wartość dodana oferty stacji	0.4844	0.1221	0.1666	0.0138
P8	Awarie i niedostępność	0.0	0.0	-0.0626	0.0378
P9	Koszty operacyjne stacji	-0.0021	0.0362	-0.0002	0.0038
P10	Subwencje i ulgi podatkowe	0.0492	0.0199	0.0062	0.0028
P11	Widoczność i informacja o stacji	0.1509	0.039	0.1811	0.0468
P12	Kongestia sieci energetycznej	0.0	0.0	-0.0577	0.0479
P13	Warunki pogodowe i sezonowość	0.0	0.0	-0.0935	0.0701
P14	Obsługiwane standardy ładowania	0.091	0.0167	0.2654	0.0488
P15	Udział w programach DSR	0.303	0.0807	-0.0562	0.0303
P16	Bazowa ilość samochodów EV	0.0	0.0	0.0924	0.0405
P17	UX użytkownika (wygoda dostępu)	0.4556	0.0909	0.2133	0.0071
P18	Moc ładowania (szybkość)	0.1475	0.0282	0.2655	0.0507
P19	Umowy flotowe i abonamenty	-0.056	0.0205	0.0783	0.0287
P20	Wskaźnik inflacji	-0.0096	0.0032	-0.001	0.0004

Źródło: opracowanie własne

Przeprowadzona analiza wykazała, że na poziomie wyjść funkcji modulujących zdecydowana większość parametrów charakteryzuje się niskim stopniem współzależności, co pozwala uznać ich wkład do modelu za relatywnie odrębny funkcjonalnie. Najwyższą wartość zagregowanej miary współzależności odnotowano dla pary P_{15} – P_{20} , dla której $S_{hj} = 0,3077$, co odpowiada jedynie słabej korelacji. Brak zależności umiarkowanych i silnych wskazuje, że obecna struktura modelu nie generuje istotnych redundancji pomiędzy parametrami. Z punktu widzenia konstrukcji modelu stanowi to wynik korzystny, gdyż zwiększa interpretowalność poszczególnych składowych oraz umożliwia ich niezależną analizę. Najwyraźniejsze

powiązania koncentrują się w obrębie parametrów związanych z mechanizmami cenowymi, obciążeniem infrastruktury oraz uwarunkowaniami regulacyjnymi, co wskazuje, że ewentualne dalsze prace kalibracyjne powinny w pierwszej kolejności obejmować ten obszar współdzielonych sygnałów wejściowych.

Należy dodać że ograniczeniem przeprowadzonego był syntetyczny charakter danych wejściowych. Oznacza to, że uzyskane wyniki odzwierciedlają strukturę funkcji modulujących, nie uwzględniając rzeczywistych współzależności rynkowych, sezonowych, kosztowych ani behawioralnych. W kolejnym etapie badań zasadne jest zatem przeprowadzenie analogicznej analizy z wykorzystaniem danych rzeczywistych.

8.3.3. ANALIZA WYNIKÓW BADAŃ SCENARIUSZOWYCH

Przeprowadzona analiza miała charakter dwutorowy tj. dokonano:

- weryfikacji poprawności formalnej implementacji i stabilności numerycznej algorytmu symulacyjnego,
- oceny trafności behawioralnej odpowiedzi modelu w scenariuszach zbliżonych do realiów rynku infrastruktury ładowania pojazdów elektrycznych.

Wynik symulacji jest interpretowany jako trajektoria stanu stacji w przestrzeni M-U. W każdym kroku t_k wektor wyniku $V_w(t_k)$ jest wypadkową oddziaływania wektorów parametrów $V_{pj}(t_k)$, co w ujęciu formalnym zapisuje zależność:

$$V_w(t_k) = \sum_{j=1}^K V_{pj}(t_k)$$

Z punktu widzenia interpretacji ekonomicznej kluczowe są składowe odpowiadające marży M oraz wykorzystania infrastruktury stacji U . Wartości M i U prezentowane na wykresach SIMVEC mają charakter skumulowanych zmian w horyzoncie T_{sim} , wyznaczanych na podstawie przyrostów generowanych w kolejnych krokach algorytmu. Z tego względu interpretacja wyników powinna rozróżniać: (a) poprawność kierunku i kształtu odpowiedzi chwilowej (przyrosty), oraz (b) wiarygodność wartości skumulowanych (sumaryczny efekt w całym horyzoncie). To rozróżnienie jest istotne, ponieważ część obserwowanych artefaktów ujawnia się dopiero po kumulacji.

8.3.4. WALIDACJA OBLICZEŃ I STABILNOŚĆ NUMERYCZNA

Scenariusze typu A (SC1 i SC2) zostały zaprojektowane jako testy kontrolowane, w których możliwe jest odizolowanie wpływu pojedynczego parametru oraz obserwacja

zachowania agregatu wektorowego w warunkach skrajnych. W scenariuszu SC1, opartym na sygnale piłokształtnym, weryfikowano przede wszystkim symetrię odpowiedzi modelu na zboczu narastającym i opadającym oraz brak wartości resztkowych po wygaśnięciu impulsu. Zaobserwowana zgodność wartości stanu przed i po cyklu oddziaływania impulsu wskazuje, że implementacja nie generuje nieuzasadnionej pamięci modelu w sytuacji, gdy sygnał wejściowy wraca do poziomu bazowego.

Dodatkowym argumentem na rzecz poprawności formalnej jest krzyżowa weryfikacja obliczeń z niezależnym środowiskiem obliczeniowym (wirtualne laboratorium Jupyter Notebook SimStep.ipynb, opisane w rozdz. 7.6.4). Procedura ta redukuje ryzyko błędów implementacyjnych o charakterze systematycznym (np. niepoprawnych indeksowań, błędów znaku, różnic w kolejności operacji lub niezamierzonych uproszczeń numerycznych).

Jednocześnie w SC1 zidentyfikowano zjawisko dryftu wyniku końcowego: przesunięcie marży o około +13 pp oraz wykorzystania infrastruktury o około -13 pp mimo cyklicznego charakteru pobudzenia. Obserwacja ta sugeruje asymetrię w którymś z elementów toru obliczeniowego (najczęściej: nieliniową normalizację, funkcję saturacji lub mechanizm kumulacji niewielkiego błędu). Zjawisko dryftu nie podważa wprost poprawności odpowiedzi chwilowej na impuls, ale wskazuje na konieczność dodatkowych badań. Dla sygnałów o średniej równej zero powinno zachodzić przybliżenie

$$\sum_{k=1}^K \Delta M(t_k) \approx 0$$

oraz

$$\sum_{k=1}^K \Delta U(t_k) \approx 0$$

W praktyce oznacza to potrzebę dopracowania elementów odpowiedzialnych za symetryczność transformacji wejść/wyjść, zanim model zostanie wykorzystany do długich horyzontów predykcyjnych.

W scenariuszu SC2, w którym wszystkie parametry pobudzono jednocześnie sygnałem rosnącym, zaobserwowano bardzo szybkie wejście modelu w stan saturacji (już w około kroku $k = 50$), co wprost wynika z addytywnej natury agregacji wektorów. Zjawisko to należy interpretować jako test odporności: model ujawnia ograniczenia konstrukcji addytywnej, natomiast z punktu widzenia zastosowań wymusza wprowadzenie mechanizmów stabilizujących (normalizacja, tłumienie amplitud, ograniczenia na maksymalne przyrosty

w kroku, bądź jawne modelowanie sprzężeń zwrotnych). Warto podkreślić, że odrzucono część wyników po osiągnięciu saturacji jako niemiarodajną.

8.4. TRAFNOŚĆ BEHAWIORALNA W SCENARIUSZACH HYBRYDOWYCH

O zasadniczej przydatności opracowanego podejścia decydują scenariusze typu B, w których sygnały wejściowe odzwierciedlają typowe mechanizmy rynkowe i operacyjne. W scenariuszu SC3, zbudowanym na danych hybrydowych (m.in. ceny hurtowe energii, ceny detaliczne, dynamika liczby EV oraz tło inflacyjne), model wygenerował jakościowo spójne reakcje: wzrost relatywnej ceny operatora prowadził do istotnego spadku wykorzystania infrastruktury stacji, a korekta ceny umożliwiała stopniową odbudowę trajektorii. Zależność ta jest spójna z mechanizmem elastyczności popytu na usługę ładowania, uwzględnionym w modelu poprzez atrybut ε_{eff} .

Wynik SC3 ujawnił także poprawną reakcję na zdarzenia awaryjne. W kroku $k = 2531$ (22.07.2025) zasymulowano poważną awarię stacji; odpowiedź modelu w postaci spadku wykorzystania infrastruktury stacji z 33,93% do 29,56% utrzymującego się w okresie $k = 2531 \dots 2660$ (5 dni i 9 godzin) potwierdza, że parametr P8 (awarie i niedostępność) został odwzorowany w sposób zgodny z intuicją i praktyką eksploatacyjną. Test zdarzeń awaryjnych ma wysoką wartość diagnostyczną, ponieważ prawidłowa reakcja na awarię jest warunkiem koniecznym, aby model mógł być wykorzystywany do oceny ryzyk operacyjnych i planowania poziomów redundancji infrastruktury.

Jednocześnie SC3 ujawnił problem nadmiernej amplitudy zmian generowanych przez parametry cykliczne. W symulacji izolowanej dla P5 (pora dnia) wykorzystanie infrastruktury stacji wzrosło w horyzoncie rocznym z 25,13% do 65,59% (o 40,46 pp), co zostało uznane za ekonomicznie nierealistyczne. Analogiczny charakter błędu przypisano parametrowi P13 (warunki pogodowe i sezonowość). Jest to sygnał, że funkcje modulujące i/lub atrybuty kalibracyjne parametrów cyklicznych wymagają dodatkowego tłumienia oraz ograniczeń wynikających z fizycznej pojemności rynku i ograniczeń stacji. Model poprawnie odwzorowuje kierunek i strukturę odpowiedzi (trend), natomiast wymaga dopracowania w warstwie skali (amplitudy).

Scenariusz SC4 (dysrupcja ekonomiczna i operacyjna) dostarczył dodatkowych wniosków o spójności modelu. Dla impulsu P8 (awaria) zaobserwowano spadek wykorzystania infrastruktury stacji o 8,98 pp: z 21,02% do 12,04% co potwierdza prawidłowość

zaobserwowaną w SC3. Dla impulsu P3 (pojawienie się konkurencji) zidentyfikowano spadek wykorzystania infrastruktury stacji z 33,9% do 29,7%, jednak z opóźnieniem: efekt wystąpił dopiero w kroku $k = 166$ przy zadaniu impulsu w $k = 160$. Ponieważ w modelu nie implementowano jawnego mechanizmu laga, opóźnienie o 6 kroków należy traktować jako potencjalny błąd implementacyjny lub efekt uboczny interakcji z innymi sygnałami.

Trzeci impuls w SC4 dotyczył gwałtownego wzrostu kosztu energii (P4) i wygenerował spodziewany spadek marży (obserwowany w okolicy $k = 251$). Jednocześnie odnotowano wzrost wykorzystania infrastruktury stacji skorelowany z obniżeniem marży, co jest konsekwencją przyjętego założenia o bardzo niskim przeniesieniu kosztu na klienta $\lambda_c = 0,25$ (operator absorbuje 75% wzrostu kosztu). Zjawisko to jest spójne z konstrukcją scenariusza, gdzie łagodniejszy wzrost ceny detalicznej ogranicza spadek popytu, ale pogarsza marżę. Wynik ten podkreśla, że parametr λ_c jest dźwignią strategiczną i wymaga kalibracji na podstawie rzeczywistych polityk cenowych operatora.

Scenariusz SC5 został zdefiniowany jako studium reakcji operatora na utratę konkurencyjności cenowej: najpierw pojawia się spadek wykorzystania infrastruktury stacji wynikający z relatywnie wysokiej ceny, a następnie uruchamiany jest pakiet decyzji biznesowych (m.in. działania promocyjne, poprawa jakości obsługi, oferty abonamentowe, zwiększenie widoczności). Wyniki symulacji wskazują na spójność logiczną odpowiedzi modelu na sygnały stymulujące działania operatora i powodują zmianę znaku wektora V_w , dopiero po pewnym czasie, gdy superpozycja sygnałów P7, P17, P9, P11 zaczyna przeważać nad wpływem nadmiernej różnicy między ceną operatora a średnią ceną konkurencji modelowanej parametrem P2.

8.5. ZNACZENIE WYNIKÓW DLA ZASTOSOWANIA MODELU I OGRANICZENIA INTERPRETACYJNE

Z punktu widzenia zastosowań decyzyjnych najistotniejszy wniosek z badań jest następujący: model w obecnej postaci spełnia rolę narzędzia do analizy scenariuszowej oraz testowania kierunku wpływu działań i zdarzeń (np. awarie, zmiany cen, działania marketingowe, zmiany otoczenia konkurencyjnego) na trajektorię $M(k)$, $U(k)$. Rezultaty scenariuszy SC3-SC4 wskazują, że odpowiedzi kierunkowe są spójne z intuicją ekonomiczną, a zatem model może wspierać porównywanie strategii (np. agresywne korygowanie ceny vs. utrzymanie ceny i akceptacja spadku wykorzystania infrastruktury stacji).

Jednak należy podkreślić, że badania przedstawione w rozdziale 7 mają przede wszystkim charakter weryfikacji formalnej oraz walidacji behawioralnej na danych hybrydowych. Nie jest to pełna walidacja empiryczna na danych rzeczywistych operatora, ponieważ dane takie nie mogły zostać wykorzystane w publicznym opracowaniu ze względu na ochronę know-how partnera biznesowego. W konsekwencji wyniki nie powinny być traktowane jako prognoza konkretnej stacji, lecz jako analiza mechanizmów i zależności w ujęciu zgeneralizowanym.

Zidentyfikowane artefakty (dryft w SC1, przedwczesna saturacja w SC2, nadmierna amplituda parametrów cyklicznych w SC3 oraz nieoczekiwane opóźnienie odpowiedzi w SC4) wskazują konkretne ograniczenia konstrukcyjne oraz miejsca, w których konieczna jest dalsza kalibracja i/lub modyfikacja algorytmu (np. wprowadzenie jawnych opóźnień, ograniczeń na kumulację, korekt funkcji normalizacji, a także procedur dekompozycji sygnałów cyklicznych w celu redukcji nakładania się parametrów częściowo skorelowanych).

Podsumowując, przeprowadzone symulacje potwierdzają poprawność konstrukcji kierunkowej modelu wektorowego oraz jego zdolność do odtwarzania kluczowych mechanizmów ekonomicznych (cena-popyt, awaryjność-wykorzystanie infrastruktury stacji, koszt energii-marża). Jednocześnie wykazane ograniczenia ilościowe (amplitudy, saturacja, dryft, opóźnienia) wyznaczają naturalny zakres dalszych prac: kalibrację na danych operatorskich, wzmocnienie stabilizacji numerycznej oraz uzupełnienie modelu o elementy dynamiki (lagi, sprzężenia zwrotne) w miejscach, w których są one uzasadnione empirycznie.

9. PODSUMOWANIE ROZPRAWY

9.1. WNIOSKI

Zasadniczym celem rozprawy było opracowanie metody wspomagania decyzji operacyjnych i biznesowych operatorów infrastruktury ładowania EV, umożliwiającej ocenę wpływu wybranych parametrów na marżę jednostkową oraz wykorzystanie infrastruktury stacji w odpowiedzi na zmienność warunków otoczenia i łańcuch decyzji podejmowanych przez operatora. Realizacja celu została oparta na założeniu, że marża oraz wykorzystanie infrastruktury mają w praktyce charakter antagonistyczny. Działania poprawiające jednostkową rentowność (np. podniesienie ceny) mogą jednocześnie osłabiać popyt, a działania zwiększające obłożenie infrastruktury często wymagają kompromisu po stronie marży. W tym kontekście zaproponowano ujęcie geometryczne problemu w przestrzeni M-U stacji, w której wpływ czynników zewnętrznych lub instrumentów biznesowych opisano wektorem wynikowym Impact Vector odzwierciedlającym zagregowany wpływ obu składowych na współczynnik marży i współczynnik wykorzystania infrastruktury stacji.

W części teoretycznej rozprawy przeprowadzono krytyczną analizę stanu wiedzy oraz zidentyfikowano lukę badawczą w zakresie narzędzi integrujących jednoczesny nieliniowy wpływ wielu dynamicznych czynników na oba wskaźniki. W wyniku tej analizy wyodrębniono i usystematyzowano bazę parametrów wpływu oraz ich atrybutów ilościowych, co pozwoliło na formalizację narzędzia wsparcia decyzyjnego w postaci modelu obliczeniowego.

W części metodycznej opracowano dwuwymiarowy model wektorowy oraz algorytm symulacyjny obejmujący: próbkowanie danych wejściowych, wyznaczanie funkcji modulujących, normalizację do wspólnej przestrzeni decyzyjnej, konstrukcję wektorów wpływu i ich superpozycję, a następnie wyznaczanie trajektorii ekonomicznej stacji w czasie. Zaproponowane podejście umożliwia nie tylko ocenę pojedynczej decyzji (np. zmiany ceny), ale również analizę pakietu działań operacyjno-biznesowych w ujęciu skumulowanym.

Weryfikację tezy pracy zrealizowano poprzez symulacje scenariuszowe, w tym testy syntetyczne służące walidacji obliczeń w izolacji oraz scenariusze hybrydowe odzwierciedlające warunki zbliżone do rzeczywistych. Wyniki wykazały poprawność kierunków oddziaływania kluczowych czynników na marżę i wykorzystanie infrastruktury (m.in. spadek wykorzystania przy wzroście ceny, spadek wykorzystania w przypadku awarii, wzrost wykorzystania wraz ze wzrostem widoczności i wartości dodanej oferty, wpływ kosztu energii na marżę i efekt współczynnika przeniesienia kosztów), a także odwzorowanie

cykliczności dobowej popytu w wykorzystania. Jednocześnie badania symulacyjne ujawniły ograniczenia wynikające z addytywnego charakteru agregacji wektorów, w szczególności ryzyko wejścia w stan saturacji (nasycenia) oraz zjawisko nadmiernego wzmocnienia sygnałów częściowo skorelowanych (np. cykli dobowych i sezonowych). Wskazuje to na konieczność dalszej kalibracji modelu i dopracowania sposobu kumulacji wyników, tak aby wartości skumulowane były w pełni zgodne z logiką ekonomiczną i ograniczeniami fizycznymi systemu.

Podsumowując, rozprawa dostarczyła spójnej metody analitycznej łączącej formalizację czynników wpływu, modelowanie geometryczne kompromisu między marżą a wykorzystaniem oraz implementację symulacyjną umożliwiającą testowanie scenariuszy decyzyjnych. Opracowane rozwiązanie tworzy fundament pod budowę narzędzi decyzyjnych dla operatorów stacji ładowania oraz dalszy rozwój modelu w kierunku większej wiarygodności predykcyjnej i zastosowań wdrożeniowych. Jednocześnie cel naukowy jak i cele dodatkowe rozprawy zostały osiągnięte.

9.2. EFEKTY ROZPRAWY

W pracy przeprowadzono rozważania w ujęciu teoretycznym jak i prace o charakterze użytkowym z zakresu ekonomiki infrastruktury ładowania pojazdów elektrycznych, modelowania decyzji operacyjnych oraz wytworzenia narzędzi symulacyjnych wspierających optymalizację wskaźników ekonomicznych operatorów stacji ładowania. Uzyskane efekty można przedstawić w następujących punktach:

A. Efekty poznawcze (metodyczne i teoretyczne)

W rozprawie przeprowadzono usystematyzowaną oraz krytyczną analizę uwarunkowań ekonomicznych funkcjonowania infrastruktury ładowania pojazdów elektrycznych (EV), ze szczególnym uwzględnieniem wysokiej zmienności czynników kosztowych, rynkowych i regulacyjnych. Wykazano, że dynamika cen energii, zmiany modeli taryfowych, ewolucja regulacji publicznych oraz niestabilność popytu mają wpływ na poziomy wskaźników marży oraz stopnia wykorzystania infrastruktury, wpływając bezpośrednio na stabilność finansową operatorów i przewidywalność zwrotu z inwestycji.

W toku analizy zidentyfikowano lukę badawczą w zakresie zintegrowanego narzędzia analitycznego umożliwiającego jednoczesne uwzględnienie wielu dynamicznych czynników oddziałujących nieliniowo na wskaźniki marży i wykorzystania infrastruktury. Dotychczasowe

podejścia koncentrują się najczęściej na analizie pojedynczych determinant w izolacji, co ogranicza możliwość uchwycenia efektów synergicznych, kompensacyjnych oraz antagonistycznych pomiędzy badanymi zmiennymi.

W odpowiedzi na zidentyfikowaną lukę zaproponowano formalizację czynników wpływu w postaci parametrów modelu wyposażonych w atrybuty ilościowe, umożliwiające ich jednoznaczną operacjonalizację i implementację w środowisku symulacyjnym. Parametry te zostały uporządkowane według kryterium sprawczości, z wyróżnieniem parametrów zewnętrznych, opisujących warunki otoczenia rynkowego i regulacyjnego, oraz parametrów wewnętrznych, stanowiących instrumenty decyzyjne pozostające w gestii operatora infrastruktury.

Integralnym elementem koncepcji modelowej jest wprowadzenie dwuwymiarowej przestrzeni analitycznej M-U oraz interpretacji wektorowej wpływów poszczególnych parametrów. Umożliwia to geometryczną analizę kompromisu pomiędzy wskaźnikami o charakterze częściowo antagonistycznym oraz pozwala na ścisłą ocenę kierunku i siły oddziaływania zmian parametrów na wynik ekonomiczny. Takie ujęcie tworzy podstawę do systemowego wsparcia decyzyjności i oceny wyników strategii operatora infrastruktury ładowania EV w warunkach zmiennego otoczenia.

B. Efekty w postaci środowiska badawczego do dalszego rozwoju modelu

Na bazie opracowanego modelu zaprojektowano algorytm symulacyjny obejmujący pełny cykl obliczeniowy, od przetwarzania danych wejściowych i wyznaczania funkcji wpływu, poprzez konstrukcję wektorów cząstkowych i ich superpozycję, aż do wyznaczania przebiegów marży $M(t_k)$ oraz wykorzystania infrastruktury $U(t_k)$ w zadanym horyzoncie czasowym. Struktura algorytmu umożliwia analizę zarówno efektów krótkookresowych, jak i długoterminowych, z zachowaniem spójności formalnej pomiędzy kolejnymi krokami obliczeń.

Integralnym elementem pracy była również implementacja prototypowego środowiska symulacyjnego SIMVEC, które pozwala na uruchamianie zdefiniowanych scenariuszy, wizualizację trajektorii w przestrzeni M-U oraz analizę wkładu poszczególnych parametrów w kolejnych iteracjach symulacji. Środowisko to stanowi praktyczną demonstrację użyteczności modelu i umożliwia eksperymentowanie z różnymi konfiguracjami czynników wpływu.

Opracowano również spójną strukturę oraz format danych wejściowych w postaci scenariuszy, a także jednoznaczny sposób definiowania parametrów modelu. Takie

rozwiązanie ułatwia rozwój koncepcji, jej kalibrację do rzeczywistych danych empirycznych oraz potencjalne przenoszenie modelu do innych zastosowań analitycznych o zbliżonej strukturze problemowej.

W celu potwierdzenia poprawności działania modelu przeprowadzono proces walidacji obliczeń, obejmujący weryfikację krzyżową oraz analizę zachowania systemu w scenariuszach syntetycznych i hybrydowych. Dodatkowo wykonano analizę wrażliwości oraz badanie korelacji parametrów, co pozwoliło ocenić stabilność modelu oraz zidentyfikować czynniki o kluczowym znaczeniu dla dynamiki marży i poziomu wykorzystania infrastruktury.

C. Efekty w wytycznych wdrożeniowych

W toku badań zidentyfikowano krytyczne ograniczenia podejścia opartego na agregacji addytywnej wpływów, wskazując na ryzyko występowania efektu saturacji oraz błędu kumulacji. Wykazano, że w warunkach jednoczesnego oddziaływania wielu parametrów o zbliżonym kierunku wpływu może dochodzić do nieliniowego przeszacowania wyników, prowadzącego do deformacji rzeczywistej dynamiki systemu. Szczególną uwagę zwrócono na zjawisko nadmiernego wzmacniania sygnałów cyklicznych o częściowej korelacji, które w modelu sumarycznym mogą generować amplitudy nieadekwatne do rzeczywistych mechanizmów ekonomicznych.

Na tej podstawie sformułowano przesłanki dla dalszej kalibracji i rozwoju modelu. Wskazano konieczność doprecyzowania doboru funkcji normalizujących, tak aby zapewnić właściwe odwzorowanie relatywnej siły parametrów przy zachowaniu stabilności obliczeń. Zasygnalizowano również potrzebę wprowadzenia mechanizmów tłumienia amplitud oraz dodatkowych rozwiązań stabilizujących dynamikę symulacji, co pozwoli ograniczyć efekt nadmiernej akumulacji wpływów i zwiększyć odporność modelu na zakłócenia o charakterze losowym lub quasi-cyklicznym.

9.3. KIERUNKI DALSZYCH BADAŃ

Zrealizowane w rozprawie prace stanowią punkt wyjścia do dalszych badań oraz rozwoju zaproponowanej metody modelowania ekonomiki infrastruktury ładowania EV. W pierwszej kolejności zasadne jest przeprowadzenie pogłębionej kalibracji i walidacji modelu na danych rzeczywistych operatorów, obejmujących dane transakcyjne, telemetryczne (np. z protokołu OCPP) oraz dane opisujące otoczenie rynkowe, takie jak ceny energii, warunki pogodowe czy natężenie ruchu. Estymacja współczynników funkcji modulujących i normalizujących na

podstawie empirycznych obserwacji pozwoli zwiększyć trafność predykcijną modelu oraz jego przydatność decyzyjną.

Istotnym kierunkiem rozwoju jest również udoskonalenie mechanizmu kumulacji wpływów oraz stabilizacji dynamiki symulacji. Wymaga to ograniczenia efektów saturacji, wprowadzenia sprzężeń zwrotnych, np. pomiędzy popytem, ceną i poziomem obłożenia, a także mechanizmów opóźnień reakcji (tzw. lag) i filtracji sygnałów cyklicznych. Takie rozwiązania pozwolą redukować zjawiska rezonansu i zdudnienia, zwiększając realizm odwzorowania procesów ekonomicznych.

Naturalnym rozszerzeniem koncepcji jest rozwinięcie przestrzeni decyzyjnej do przestrzeni $\mathbb{R}^3$ lub nawet $\mathbb{R}^4$ poprzez włączenie dodatkowych celów optymalizacyjnych. Oprócz marży i wykorzystania infrastruktury można uwzględnić koszty operacyjne (OPEX), koszty mocy zamówionej i opłat typu demand charges, intensywność emisyjną energii (śląd węglowy CO₂) czy wskaźniki inwestycyjne, takie jak CAPEX lub NPV, przy zachowaniu geometrycznej interpretacji zależności między wskaźnikami.

Kolejnym kierunkiem jest integracja modelu z metodami optymalizacji wielokryterialnej np. Pareto, lub wykorzystaniem technik sztucznej inteligencji do automatycznego wyznaczania cen i umożliwiającym automatyczne wyszukiwanie łańcuchów decyzji prowadzących do osiągnięcia zadanego obszaru w przestrzeni kluczowych wskaźników efektywności, przy uwzględnieniu ograniczeń infrastrukturalnych i regulacyjnych. Rozwój w kierunku automatyzacji decyzji, opartej na rzetelnych i wiarygodnych danych, stanowi zatem pożądany kierunek zmian. Znajduje on uzasadnienie zarówno w literaturze przedmiotu, jak i w wynikach badań, co potwierdzają m.in. analizy prowadzone przez prof. D. Mazurkiewicza [5].

Rozwoju wymaga także model popytu oraz segmentacja użytkowników. Wskazane jest uwzględnienie odrębnych profili dla różnych typów lokalizacji (np. trasy tranzytowe versus obszary miejskie), różnych grup klientów (floty, użytkownicy indywidualni) oraz wprowadzenie heterogenicznej elastyczności cenowej i czynników behawioralnych, co zwiększy realizm symulacji.

Istotne znaczenie ma również przejście od modelowania pojedynczej lokalizacji do ujęcia sieci stacji ładowania, z uwzględnieniem efektów substytucji pomiędzy stacjami, redystrybucji popytu, ograniczeń sieci elektroenergetycznej oraz wspólnej polityki cenowej w portfolio operatora (CPO). Umożliwi to analizę efektów skali i optymalizacji na poziomie całej sieci.

Perspektywiczny kierunek stanowi też włączenie do modelu zasobów energetycznych, takich jak magazyny energii, instalacje OZE czy mechanizmy DSR. Pozwoli to analizować

strategie arbitrażu cenowego, zarządzania mocą szczytową oraz świadczenia usług elastyczności, a także ich wpływ na marżę i poziom wykorzystania infrastruktury.

Równolegle celowe jest udoskonalenie warstwy implementacyjnej poprzez rozwój narzędzia symulacyjnego do postaci rozwiązania gotowego do integracji z systemami operatorów (ERP, CRM, systemy billingowe), wraz z automatyzacją poboru danych i cykliczną aktualizacją parametrów modelu.

Wreszcie, ważnym obszarem dalszych badań jest analiza zgodności regulacyjnej oraz scenariuszy interwencji regulatora. Badanie wpływu ograniczeń cenowych, wymogów przejrzystości oraz standardów interoperacyjności na strategię operatorów i efektywność ekonomiczną infrastruktury pozwoli osadzić model w szerszym kontekście polityki publicznej i transformacji energetycznej.

BIBLIOGRAFIA

1. S. Limmer, "Dynamic pricing for electric vehicle charging - A literature review," *Energies*, vol. 12, no. 18, p. 3574, 2019, doi: 10.3390/en12183574.
2. D. Anggraini, M. Amelin, and L. Söder, "Business models for electric vehicle charging considering grid limitations: An extended review from the European electricity market perspective," *Applied Energy*, vol. 399, Dec. 2025, doi: 10.1016/j.apenergy.2025.126493
3. A. K. Kalakanti i S. Rao "Dynamic Pricing for Electric Vehicle Charging" Symp. (SAC '25), Catania, Italy, Mar. 31-Apr. 4, 2025, doi: 10.1145/3672608.3707745
4. W. Wang, S. Bi, Y.-J. A. Zhang oraz J. Huang, „Electrical Vehicle Charging Station Profit Maximization: Admission, Pricing, and Online Scheduling”, *IEEE Trans. Sustain. Energy*, vol. 9, no. 4, pp. 1722-1731, Oct. 2018, doi: 10.1109/TSTE.2018.2810274
5. D. Mazurkiewicz, "Computer-aided maintenance and reliability management systems for conveyor belts," *Eksploracja i Niezawodność - Maintenance and Reliability*, vol. 16, no. 3, pp. 377-382, 2014.
6. S. Luo and Y. Wang, "The impacts of rate surge on electric vehicle charging behaviors: Evidence from California," *Journal of Economic Behavior & Organization*, vol. 236, p. 107048, Aug. 2025, doi: 10.1016/j.jebo.2025.107048.
7. S. Tani and R. Millard, "Negative European energy prices hit record level," *Financial Times*, Sep. 14, 2024. [Online]. Available: <https://www.ft.com/content/1f94d0b4-c839-40a2-9c8d-782c00384154>
8. T. Rodemann i S. Limmer, "Peak load reduction through dynamic pricing for electric vehicle charging," *Int. J. Electr. Power Energy Syst.*, vol. 113, s. 117-128, gru. 2019. DOI: 10.1016/j.ijepes.2019.05.031.
9. M. Izdebski, M. Jacyna, & J. Bogdański (2024). Minimisation of the energy expenditure of electric vehicles in municipal service companies, taking into account the uncertainty of charging point operation. *Energies*, vol. 17, no. 9, p. 2179, 2024, doi: 10.3390/en17092179.
10. McKinsey & Company, "Exploring consumer sentiment on electric-vehicle charging," McKinsey Center for Future Mobility, luty 2024.
11. NREL, "Impact of Electric Vehicle Charging Station Reliability, Resilience, and Availability on EV Adoption", Report NREL/TP, 2024.
12. H. Mosalli, S. Sanami, Y. Yang, H. Yeh i A. G. Aghdam, "Dynamic Load Balancing for EV Charging Stations Using Reinforcement Learning and Demand Prediction," Conf. (SysCon) Montreal, Canada , Apr. 2025
13. NREL, "Assessment of Economic Viability of Direct Current Fast Charging Stations," *Sustainability*, vol. 16, nr 15, s. 5-6, 2024.
14. Dyrektywa 2014/94/UE Parlamentu Europejskiego i Rady z dnia 22 października 2014 r. w sprawie rozwoju infrastruktury dla alternatywnych paliw (Dz.U. L 307/17, art. 4).

15. S. R. Kirchner, "OCPP Interoperability: A Unified Future of Charging," *World Electric Vehicle Journal*, vol. 15, no. 5, art. no. 191, Apr. 2024, doi:10.3390/wevj15050191.
E. Sendek-Matysiak, D. Pyza, Z. Łosiewicz, and W. Lewicki, "Total cost of ownership of light commercial electrical vehicles in city logistics," *Energies*, vol. 15, no. 22, p. 8392, 2022, doi: 10.3390/en15228392.
16. K. Tomczuk, P. Tomczuk, and M. Chrzanowicz, "Lighting systems for pedestrian crossings in off-grid areas," *Applied Sciences*, vol. 14, no. 7, p. 3054, 2024, doi: 10.3390/app14073054
17. C. Will, F. Zimmermann, A. Ensslen, C. Fraunholz, P. Jochem i D. Keles, "Can electric vehicle charging be carbon neutral? Uniting smart charging and renewables," *Applied Energy*, vol. 371, p. 116792, 2024.
18. Z. Pietrzykowski, P. Wołęjsza, and P. Borkowski, "Decision Support in Collision Situations at Sea," *The Journal of Navigation*, vol. 70, no. 3, 2017 (published online Nov. 2016), doi: 10.1017/S0373463316000746.
19. International Energy Agency (IEA), „Electric vehicle charging,” w: *Global EV Outlook 2025*. Paris, France: IEA, 2025. Available: <https://www.iea.org/reports/global-ev-outlook-2025/electric-vehicle-charging> (IEA)
20. International Energy Agency (IEA), „Outlook for electric mobility,” w: *Global EV Outlook 2024*. Paris, France: IEA, 2024. Available: <https://www.iea.org/reports/global-ev-outlook-2024/outlook-for-electric-mobility> (IEA)
21. M. Lasota, A. Zabielska, M. Jacyna, P. Gołębiowski, R. Żochowska, and M. Wasiak, "Method for delivery planning in urban areas with environmental aspects," *Sustainability*, vol. 16, no. 4, p. 1571, 2024, doi: 10.3390/su16041571
22. P. Fröde, M. Lee, and S. Sahdev, „Can public EV fast-charging stations be profitable in the United States?,” *McKinsey & Company*, artykuł, 5 października 2023 r. Available: <https://www.mckinsey.com/features/mckinsey-center-for-future-mobility/our-insights/can-public-ev-fast-charging-stations-be-profitable-in-the-united-states> (McKinsey & Company)
23. E. Szczepański, R. Żochowska, M. Izdebski, and M. Jacyna, "Decision-making problems in urban transport decarbonization strategies: Challenges, tools, and methods," *Energies*, vol. 18, no. 15, p. 3970, 2025, doi: 10.3390/en18153970
24. B. Borlaug, V. Caristo, F. Ouren, F. Yang, E. Wood and L. Roberson, "Economics of electric vehicle corridor fast charging in the United States," *Advances in Applied Energy*, vol. 12, 2025, Art. no. 100257, doi: 10.1016/j.adapen.2025.100257.
25. eMobility Excellence Report 2025. Stuttgart & München, DE: eMobility Excellence, 2025. [Online]. Available: <https://emobilityexcellence.com/en/reports-en>
26. C. Hecht, J. Figgenger, and D. U. Sauer, "Analysis of electric vehicle charging station usage and profitability in Germany based on empirical data," *iScience*, vol. 25, no. 12, p. 105634, 2022, doi: 10.1016/j.isci.2022.105634.
27. P. Chiradeja, S. Yoomak, C. Sottiyaphai, A. Ngaopitakkul, J. Klomjit, and S. Ananwattanaporn, "Analysis of Investment Feasibility for EV Charging Stations in

- Residential Buildings,” *Applied Sciences*, vol. 15, no. 17, 2025, doi: 10.3390/app15179716
28. Energa SA, “ORLEN Charge.” Available: <https://www.energa.pl/dom/obsługa/ORLENCharge>.
 29. IONITY, “Introducing our annual subscription plans,” 2024. Available: <https://www.ionity.eu/stories/introducing-our-annual-subscription-plans>.
 30. European Alternative Fuels Observatory, *Electric Vehicle Recharging Prices*, Brussels, Belgium: European Commission, 2024. [Online]. Available: <https://alternative-fuels-observatory.ec.europa.eu/consumer-portal/electric-vehicle-recharging-prices>
 31. B. H. Baltagi, *Econometrics*. New York, NY, USA: Springer-Verlag, 1998, ISBN: 978-3-540-64434-8.
 32. K. Turoń, P. Czech, and J. Tóth, “Safety and security aspects in shared mobility systems,” *Scientific Journal of Silesian University of Technology. Series Transport*, vol. 104, pp. 169-175, 2019, doi: 10.20858/sjsutst.2019.104.15.
 33. J. Zethmayr and D. Kolata, *Charge for Less: An Analysis of Hourly Electricity Pricing for Electric Vehicles*, MDPI. Available: <https://www.mdpi.com/2032-6653/10/1/6>. (MDPI) (Citizens Utility Board)
 34. S. Noble, N. Smith, and J. Hamilton, *2024 Global Automotive Consumer Study: EMEA Focus Countries*, Deloitte, 2024. Available: <https://www.deloitte.com/nl/en/Industries/automotive/analysis/global-automotive-consumer-study-emea-focus-countries.html>. (Deloitte) (Deloitte Brazil)
 35. European Commission, Directorate-General for Mobility and Transport „Alternative Fuels Infrastructure,” *Mobility and Transport (strona tematyczna o Alternative Fuels Infrastructure Regulation)*, 2024. Available: https://transport.ec.europa.eu/transport-themes/clean-transport/alternative-fuels-sustainable-mobility-europe/alternative-fuels-infrastructure_en (Mobility and Transport)
 36. J. Andruszkiewicz, J. Lorenc i A. Weychan, „Price-Based Demand Side Response Programs and Their Effectiveness on the Example of TOU Electricity Tariff for Residential Consumers”, *Energies*, vol. 14, no. 2, art. 287, 2021, doi: 10.3390/en14020287
 37. C. Hatch, Idaho National Laboratory, *Electric Vehicles - Integrated Energy Research*, INL. Available: <https://inl.gov/integrated-energy/electric-vehicles/#:~:text=The%20researchers%20found%20that%20charging,%20the%20same%20amount%20of%20time>. (Idaho National Laboratory)
 38. European Commission, *Energy Prices and Costs in Europe, 6th report*, 2025. Available: https://energy.ec.europa.eu/data-and-analysis/energy-prices-and-costs-europe_en. (Energy)
 39. K. G. Miller and H. Richardson, „Electric Vehicle Supply Equipment and Considerations for a Reasonable Rate of Return,” *DriveElectric.gov*, white paper, Aug. 2024. Available: <https://driveelectric.gov/files/evse-rate-of-return.pdf>. (driveelectric.gov)
 40. D. Tucker and M. Snyder, „Demand Charges and Electric Vehicle Fast-Charging,” *National Association of State Energy Officials (NASEO)*, report, Oct. 2021. Available: <https://www.naseo.org/data/sites/1/documents/publications/Demand%20Charges%20and%20EV%20Charging%20-%20Final.pdf>

41. Tauron Dystrybucja, „E-mobility - Przyłączenie do sieci.” Available: <https://www.tauron-dystrybucja.pl/przylaczenie-do-sieci/e-mobility>.
42. Driivz, „From Reactive Repairs to Predictive Performance: How Proactive Maintenance Is Revolutionizing EV Charging Reliability.” Available: <https://driivz.com/blog/proactive-maintenance-boosts-ev-charging-reliability/>.
43. International Energy Agency, „Energy and AI - Executive Summary,” IEA, 2025. Available: <https://www.iea.org/reports/energy-and-ai/executive-summary>.
44. C. Brickenstein, H. Rennert, M. Bartosek, P. Stergiopoulos, J. Jin, and B. C. Chen, „EV Charging Market Outlook,” Strategy& (PwC), report, Apr. 2024. Available: <https://www.strategyand.pwc.com/jp/ja/publications/report/asset/pdf/ev-charging-market-outlook-en.pdf>. (PwC)
45. A. Gąsiorek-Kowalewicz, W. Wasilewski, K. Worach, and M. Nattke, “Electric Vehicle Charging Infrastructure in Poland and the European Union,” Scientific Papers of Silesian University of Technology - Organization and Management Series, vol. 229, pp. 121-146, 2025, doi:10.29119/1641-3466.2025.229.7.
46. N. Hübner, „Tesla Revised Supercharger Price Structure for the Subscription Model,” Shop4Tesla, Apr. 19, 2024. Available: <https://www.shop4tesla.com/en/blogs/news/tesla-aendert-supercharger-preisstruktur-beim-abo-modell>.
47. National Electric Vehicle Infrastructure Formula Program Annual Report: Plan Year 2023-2024, Joint Office of Energy and Transportation, NEVI Program, 2024. Available: <https://driveelectric.gov/files/nevi-annual-report-2023-2024.pdf>. (driveelectric.gov)
48. S. R. Kirchner and H. Ruiz, “OCPP Interoperability: Democratized Future of Charging,” World Electric Vehicle Journal, vol. 15, May 2024, doi:10.3390/wevj15050191. [Online]. Available: <https://www.mdpi.com/2032-6653/15/5/191/pdf>
49. N. Chamier-Gliszczyński, W. Musiał, P. Kotylak, J. Dyczkowska, A. Panek „Energy Transformation of Road Transport Infrastructure—Concept and Assessment of the Electric Vehicle Recharging Systems”, Energies, 2025, vol. 18, s.1-34, Numer artykułu:4241. DOI:10.3390/en18164241
50. NKL Nederland, Price Transparency Benchmark. Utrecht, The Netherlands: Nationale Agenda Laadinfrastructuur (NKL), 2021. [Online]. Available: https://nkl nederland.nl/wp-content/uploads/2021/12/Price-transparency_EN.pdf
51. European Commission, Questions and Answers on the Regulation on the Deployment of Alternative Fuels Infrastructure (EU 2023/1804), DG MOVE, 2023. Available: https://transport.ec.europa.eu/transport-themes/clean-transport/alternative-fuels-sustainable-mobility-europe/alternative-fuels-infrastructure/questions-and-answers-regulation-deployment-alternative-fuels-infrastructure-eu-20231804_en.
52. Wielki słownik języka polskiego PAN, P. Źmigrodzki, Red. Kraków: Instytut Języka Polskiego PAN. [Online]. Dostępny: <https://wsjp.pl/haslo/podglad/32282/parametr> . [Dostęp: 13.02.2026].

53. D. Malarkey, R. Singh, and D. MacKenzie, Customer Experience at Public Charging Stations and Its Effects on the Purchase and Use of Electric Vehicles, Idaho National Laboratory, 2023. Available: https://inl.gov/content/uploads/2023/07/Customer-Experience-at-Public-Charging-Stations_INLRPT-23-74951_12-12-23_Optimized-1.pdf.
54. European Alternative Fuels Observatory, Electric Vehicle Recharging Prices. Brussels, Belgium: European Commission, 2024. [Online]. Available: <https://alternative-fuels-observatory.ec.europa.eu/consumer-portal/electric-vehicle-recharging-prices>
55. European Automobile Manufacturers' Association (ACEA), „European EV Charging Infrastructure Masterplan,” research white paper, 2022. Available: <https://www.acea.auto/files/Research-Whitepaper-A-European-EV-Charging-Infrastructure-Masterplan.pdf>.
56. Główny Urząd Statystyczny, „Marża handlowa”, w: Słownik pojęć stosowanych w statystyce publicznej, Warszawa, Polska. [Online]. Dostęp: <https://stat.gov.pl/metainformacje/slownik-pojec/pojecia-stosowane-w-statystyce-publicznej/3788,pojecie.html>
57. Blink Charging Co., “EV Demand Response Strategies and Management,” Blink Charging - Blog, Feb. 21, 2024. Available: <https://blinkcharging.com/blog/demand-response-management-for-evs>.
58. Nuvve, “V2G Revenue in Denmark,” background information for VGI Working Group meeting, 28 Nov. 2017. Available: <https://www.cpuc.ca.gov/-/media/cpuc-website/files/legacyfiles/v/6442455489-value-of-v2g-denmark-nuvve-11-28-17.pdf>.
59. European Alternative Fuels Observatory, “Poland Launches Major Funding Programs for Zero-Emission Transport Infrastructure,” EAFO News, 2024. Available: <https://alternative-fuels-observatory.ec.europa.eu/general-information/news/poland-launches-major-funding-programs-zero-emission-transport>.
60. European Alternative Fuels Observatory (EAFO), “June 2024 Polish Electric Vehicle Market Overview,” European Alternative Fuels Observatory, Aug. 1, 2024. [Online]. Available: <https://alternative-fuels-observatory.ec.europa.eu/general-information/news/june-2024-polish-electric-vehicle-market-overview>. Accessed: Jan. 31, 2026
61. M. Rajon Bernard, J. Dornoff, U. Tietge, K. Morrison, M. Negri, G. Bieker, J. Benoit, S. Díaz, A. Plummer, S. Wappelhorst, and P. Mock, EV Transition Check 2025. Brussels, Belgium: International Council on Clean Transportation (ICCT), Sep. 22, 2025. [Online]. Available: <https://theicct.org/wp-content/uploads/2025/09/ID-432-%E2%80%93-Transition-check-Report-final-v2.pdf>
62. B. Borlaug, F. Yang, E. Pritchard, E. Wood, and J. Gonder, “Public Electric Vehicle Charging Station Utilization in the United States,” Transportation Research Part D, vol. 114, art. no. 103564, 2023, doi: 10.1016/j.trd.2022.103564.
63. A. Kazemtarghi, A. Mallik, and Y. Chen, “Dynamic pricing strategy for electric vehicle charging stations to distribute the congestion and maximize the revenue,” Int. J. Electrical Power & Energy Systems, vol. 158, p. 109946, 2024.

64. Y. Zhang et al., "China's urban EV ultra-fast charging distorts regulated price signals and elevates risk to grid stability," *Nature Communications*, vol. 14, art. 63199, 2025.
65. J. Wang et al., "Comprehensive DEA-Based Evaluation of Charging Station Operational Efficiency," *World Electric Vehicle Journal*, vol. 16, no. 11, p. 613, 2025.
66. E. Bagherzadeh, A. Ghiasian, and A. Rabiee, "Long-term profit for electric vehicle charging stations: a stochastic optimization approach," *Sustainable Energy Grids and Networks*, vol. 24, p. 100391, 2020.
67. G. Motlagh, J. Oladigbolu, and L. Li, "A review on electric vehicle charging station operation considering market dynamics and grid interaction," *Applied Energy*, vol. 392, art. no. 126058, 2025, doi: 10.1016/j.apenergy.2025.126058.
68. H. R. Sayarshad, "Optimization of electric charging infrastructure: integrated model for routing and charging coordination with power-aware operations," *npj Sustainable Mobility and Transport*, vol. 1, art. no. 4, 2024.
69. E. Pritchard, B. Borlaug, F. Yang, and J. Gonder, "Evaluating Electric Vehicle Public Charging Utilization in the United States using the EV WATTS Dataset," Sacramento, CA, USA, Oct. 2023, Report No. NREL/CP-5400-85902, National Renewable Energy Laboratory. [Online]. Available: <https://docs.nrel.gov/docs/fy24osti/85902.pdf>
70. L. Bernard, A. Hackett, R. Metcalfe, L. Panzone, and A. Schein, "The Impact of Dynamic Prices on Electric Vehicle Public Charging Demand: Evidence from a Nationwide Natural Field Experiment," *Centre for Net Zero*, May 2025. [Online].
71. Y. Ding, F. Chen, J. Feng, and H. Cheng, "Competition and Pricing Strategy of Electric Vehicle Charging Services Considering Mobile Charging," *IEEE Access*, vol. 12, pp. 88739-88755, 2024, doi: 10.1109/ACCESS.2024.3418996.
72. S. Weekx, "How Many More Public Charging Stations Do We Need? A Data-Driven Approach Considering Charging Station Overflow Dynamics," *Transportation Research Record: Journal of the Transportation Research Board*, vol. 2678, no. 9, Apr. 2024, doi: 10.1177/03611981241242081.
73. D. Bernal, A. A. Raheem, S. Inti, and H. Wang, "Assessment of Economic Viability of Direct Current Fast Charging Infrastructure Investments for Electric Vehicles in the United States," *Sustainability*, vol. 16, art. no. 6701, Aug. 2024, doi: 10.3390/su16156701.
74. A. Mentani et al., "A Comprehensive Review of Developments in EV Fast Charging Technology," *Applied Sciences*, 2024, doi: 10.3390/app14114728.
75. A. Zabielska, M. Jacyna, M. Lasota, and K. Nehring, "Evaluation of the efficiency of the delivery process in the technical object of transport infrastructure with the application of a simulation model," *Eksploracja i Niezawodność - Maintenance and Reliability*, vol. 25, no. 1, 2023, doi: 10.17531/ein.2023.1.5

76. Q. Yu et al., "Equity and reliability of public electric vehicle charging stations in the United States," *Nature Communications*, vol. 16, art. no. 5291, Jun. 2025, doi: 10.1038/s41467-025-60091-y.
77. Z. Du, L. Zheng, and B. Lin, "Influence of charging stations accessibility on charging stations utilization," *Energy*, vol. 298, art. no. 131374, 2024, doi: 10.1016/j.energy.2024.131374.
78. AleaSoft, "Prices rise in European electricity markets due to gas and CO₂ while renewable records PV," AleaSoft, maj 2024.
79. W. Wang, A. Tang, F. Wei, H. Yang, L. Xinran, and J. Peng, "Electric vehicle charging load forecasting considering weather impact," *Applied Energy*, vol. 383, art. no. 125337, Apr. 2025, doi: 10.1016/j.apenergy.2025.125337.
80. ABB E-mobility, *The Digital Side of Charging: The Future of OCPP and ISO 15118*, Dec. 18, 2024. [Online]. Available: https://e-mobility.abb.com/sites/default/files/2024-12/241218_ABB_White-Paper.pdf
81. S. Kirchner and H. Ruiz, "OCPP Interoperability: Democratized Future of Charging," in *Proc. 36th Int. Electric Vehicle Symposium and Exhibition (EVS36)*, Sacramento, CA, USA, Jun. 11-14, 2023. [Online]. Available: https://evs36.com/wp-content/uploads/finalpapers/FinalPaper_Kirchner_Silke.pdf
82. K. Sheng, M. Dibaj, and M. Akrami, "Analysing the Cost-Effectiveness of Charging Stations for Electric Vehicles in the U.K.'s Rural Areas," *World Electric Vehicle Journal*, vol. 12, no. 4, p. 232, 2021, doi: 10.3390/wevj12040232.
83. H. Kuang, X. Zhang, H. Qu, L. You, R. Zhu, and J. Li, "Unraveling the effect of electricity price on electric vehicle charging behavior: A case study in Shenzhen, China," *Sustainable Cities and Society*, vol. 115, art. no. 105836, Dec. 2024, doi: 10.1016/j.scs.2024.105836.
84. McKinsey & Company, "Can public EV fast-charging stations be profitable in the United States", McKinsey Center for Future Mobility, 5 października 2023.
85. M. Jacyna, P. Kotylak, „Decision-Making Problems of Collective Transport Development in Terms of Sustainable Urban Mobility”, *Journal of KONBiN*, 2020, vol. 50, nr 2, s.359-375
86. Nationale Leitstelle Ladeinfrastruktur, "Charging infrastructure in the EU context." Available: <https://nationale-leitstelle.de/en/charging-infrastructure-in-the-eu-context/>. (nationale-leitstelle.de)

SPIS RYSUNKÓW

RYS. 0.1. SYMULACJE - OBSZARY DECYZYJNE I PUNKT DOCELOWY WYNIKU EKONOMICZNEGO STACJI	11
RYS. 0.2 SYMULACJA ZMIANY CEN W RÓŻNYCH SCENARIUSZACH	12
RYS. 0.4 KATEGORIE CZYNNIKÓW WPŁYWAJĄCYCH NA MARŻĘ I WYKORZYSTANIE INFRASTRUKTURY STACJI	14
RYS.1.1 MOŻLIWOŚĆ AUTOMATYZACJI DYNAMICZNYCH CEN (POTENCJAŁ ROZWOJOWY MODELU)	18
RYS. 1.2 ANTAGONISTYCZNY CHARAKTER MARŻY I WYKORZYSTANIA INFRASTRUKTURY	20
RYS. 1.3 WYNIK KOŃCOWY JAKO SUMA CZYNNIKÓW SKŁADOWYCH	20
RYS. 1.4 RELACJE MIĘDZY GŁÓWNYMI ELEMENTAMI MODELU	21
RYS.1.5 POŻĄDANA TRAJEKTORIA ROZWOJU WSKAŹNIKÓW EKONOMICZNYCH STACJI	23
RYS. 2.1. ZŁOŻONOŚĆ CZYNNIKÓW WPŁYWAJĄCYCH NA DECYZJE BIZNESOWE OPERATORA STACJI ŁADOWANIA	31
RYS. 2.2 DWIE GRUPY CZYNNIKÓW WPŁYWAJĄCYCH NA WYNIK EKONOMICZNY STACJI ŁADOWANIA	32
RYS. 2.3 MODEL WEKTOROWY W PRZESTRZENI M-U	34
RYS. 2.4 CELE CZĄSTKOWE REALIZACJI ROZPRAWY	35
RYS. 2.5 ZALEŻNOŚCI MIĘDZY GŁÓWNYMI ELEMENTAMI MODELU: PARAMETREM, ATRYBUTEM, FUNKCJĄ MODULUJĄCĄ	36
RYS. 2.6. ZAKRES ROZPRAWY I JEJ GŁÓWNE WYMIARY	37
RYS. 3.1 WZROST FLOTY POJAZDÓW ELEKTRYCZNYCH, 2023-2035 WG IEA	47
RYS. 3.2 PRZYKŁAD PODZIAŁU KOSZTÓW ŁADOWANIA W USA (\$/kWh)	49
RYS. 3.3 PROCENT AUTOSTRAD WYPOSAŻONYCH W SZYBKĄ LUB ULTRASZYBKĄ ŁADOWARKĄ W USA I EUROPIE, 2024	52
RYS. 3.4 WSPÓLDZIELENIE MOCY MIĘDZY POJAZDAMI ELEKTRYCZNYMI ZA POŚREDNICTWEM FUNKCJI V2G	56
RYS. 4.1 PODZIAŁ NA PARAMETRY WEWNĘTRZNE I ZEWNĘTRZNE	77
RYS. 4.2 WARSTWOWA MAPA WPŁYWÓW	77
RYS. 4.3 MACIERZ DYNAMIKI PARAMETRÓW / LAG PARAMETRU	78
RYS. 5.1 WARSTWOWA ARCHITEKTURA MODELU	80
RYS 5.2 PRZYKŁADOWE FUNKCJE MODULUJĄCE	81
RYS 5.3 STRUKTURA TWORZĄCA WEKTOR V_P	82
RYS 5.4 REPREZENTACJA GRAFICZNA WEKTORA V_W	83
RYS 5.5 PRZYKŁADOWE WYKRESY FUNKCJI MODULUJĄCYCH DLA PARAMETRU P2	88
RYS 5.6 PRZYKŁADOWE WYKRESY FUNKCJI MODULUJĄCYCH DLA PARAMETRU P3.	89
RYS 5.7 PRZYKŁADOWE WYKRESY FUNKCJI MODULUJĄCYCH DLA PARAMETRU P1	90
RYS 5.8 PRZYKŁADOWE WYKRESY FUNKCJI MODULUJĄCYCH DLA PARAMETRU P5	92
RYS 5.9A PRZYKŁADOWY WYKRES FUNKCJI MODULUJĄCYCH WPŁYW SEZONOWOŚCI DLA PARAMETRU P13	93
RYS 5.9B PRZYKŁADOWE WYKRESY FUNKCJI MODULUJĄCYCH WPŁYW TEMPERATURY DLA PARAMETRU P13	93
RYS 5.10 PRZYKŁADOWE WYKRESY FUNKCJI MODULUJĄCYCH DLA PARAMETRU P16	95
RYS 5.11 PRZYKŁADOWE WYKRESY FUNKCJI MODULUJĄCYCH DLA PARAMETRU P4	96
RYS 5.12 PRZYKŁADOWE WYKRESY FUNKCJI MODULUJĄCYCH DLA PARAMETRU P9	98
RYS 5.13 PRZYKŁADOWE WYKRESY FUNKCJI MODULUJĄCYCH DLA PARAMETRU P8	99
RYS 5.14 PRZYKŁADOWE WYKRESY FUNKCJI MODULUJĄCYCH DLA PARAMETRU P12	101
RYS 5.15 PRZYKŁADOWE WYKRESY FUNKCJI MODULUJĄCYCH DLA PARAMETRU P14	102
RYS 5.16 PRZYKŁADOWE WYKRESY FUNKCJI MODULUJĄCYCH DLA PARAMETRU P18	103

RYS 5.17 PRZYKŁADOWE WYKRESY FUNKCJI MODULUJĄCYCH DLA PARAMETRU P6.....	105
RYS 5.18 PRZYKŁADOWE WYKRESY FUNKCJI MODULUJĄCYCH DLA PARAMETRU P7.....	106
RYS 5.19 PRZYKŁADOWE WYKRESY FUNKCJI MODULUJĄCYCH DLA PARAMETRU P11.....	107
RYS 5.20 PRZYKŁADOWE WYKRESY FUNKCJI MODULUJĄCYCH DLA PARAMETRU P17.....	108
RYS 5.21 PRZYKŁADOWE WYKRESY FUNKCJI MODULUJĄCYCH DLA PARAMETRU P19.....	110
RYS 5.22 PRZYKŁADOWE WYKRESY FUNKCJI MODULUJĄCYCH DLA PARAMETRU P10.....	111
RYS 5.23 PRZYKŁADOWE WYKRESY FUNKCJI MODULUJĄCYCH DLA PARAMETRU P15.....	113
RYS 5.24 PRZYKŁADOWE WYKRESY FUNKCJI MODULUJĄCYCH DLA PARAMETRU P20.....	114
RYS 6.1 UTRATA PRÓBKII PRZY ZBYT NISKIEJ CZĘSTOTLIWOŚCI PRÓBKOWANIA f_s	118
RYS 6.2 RELACJA MIĘDZY CZASEM SYMULACJI T_{sim} I OKRESEM PRÓBKOWANIA T_s	119
RYS 6.3 ALGORYTM SYMULACYJNY	120
RYS 6.4 PRÓBKOWANIE ATRYBUTÓW ZE ŹRÓDEŁ DANYCH	122
RYS 6.5 NORMALIZACJA WYNIKÓW FUNKCJI MODULUJĄCYCH.....	124
RYS 6.6 REPREZENTACJA GRAFICZNA TRAJEKTORII STACJI W SYMULOWANYM OKRESIE $T_0 - T_6$	127
RYS 6.7 REPREZENTACJA GRAFICZNA SKŁADOWYCH WYKORZYSTANIA INFRASTRUKTURY W OKRESIE $T_0 - T_7$	128
RYS 6.8 REPREZENTACJA GRAFICZNA WYKORZYSTANIA INFRASTRUKTURY SKUMULOWANEJ W OKRESIE $T_0 - T_7$	129
RYS 6.9 REPREZENTACJA GRAFICZNA ZBIORU SKŁADOWYCH MARŻY W OKRESIE SYMULACJI $T_0 - T_7$	130
RYS 7.1 INTERFEJS APLIKACJI SIMVEC.....	133
RYS 7.2 ZAŁOŻENIE PROJEKTOWE APLIKACJI - MODEL APLIKACJI	134
RYS 7.3 ARCHITEKTURA WARSTWOWA APLIKACJI SIMVEC	134
RYS 7.4 ARCHITEKTURA APLIKACJI SIMVEC	135
RYS 7.5 WYMIENNY SILNIK OBLICZENIOWY W APLIKACJI SIMVEC	136
RYS 7.6 DIAGRAM SEKWENCJI APLIKACJI SIMVEC	137
RYS 7.7 ŁADOWANIE DANYCH WEJŚCIOWYCH ORAZ DEFINICJI PARAMETRÓW MODELU Z PLIKÓW JSON.....	141
RYS 7.8 INTERFEJS GRAFICZNY APLIKACJI SIMDATA	144
RYS 7.10 FUNKCJE UŻYTKOWE APLIKACJI SIMDATA WYKORZYSTANE W ROZPRAWIE.....	146
RYS 7.11 PROCEDURA OPRACOWANIA DANYCH WEJŚCIOWYCH PRZY UŻYCIU APLIKACJI SIMDATA.....	148
RYS. 8.1 WYKRES SC1 ZNORMALIZOWANY DO WARTOŚCI [0...1] Z APLIKACJI SIMDATA.....	153
RYS 8.2 WYKRES WARTOŚCI BEZWZGLĘDNEJ DLA PRZYKŁADOWEJ WARTOŚCI PARAMETRU P6 Z APLIKACJI SIMDATA....	154
RYS 8.3. WYNIK SYMULACJI SC1 Z APLIKACJI SIMVEC	154
RYS. 8.4 WYKRES SC2 ZNORMALIZOWANY DO WARTOŚCI [0...1] Z APLIKACJI SIMDATA.....	155
RYS 8.5 PRZYKŁADOWY WYKRES SYGNAŁU W SYMULACJI SC2 DLA PARAMETRU P3 W WARTOŚCIACH NOMINALNYCH	156
RYS 8.6 WYNIK SYMULACJI SC2 Z APLIKACJI SIMVEC	157
RYS 8.7 KOMPLETNY ZNORMALIZOWANY SYGNAŁ WEJŚCIOWY SYMULACJI SC3	158
RYS 8.8 PRZYKŁADOWY SYGNAŁ SZCZEGÓŁOWY SYMULACJI SC3 DLA CEN ENERGII P4 I CENY P1.....	158
RYS 8.9 WYNIK SYMULACJI SC3 Z APLIKACJI SIMVEC	159
RYS 8.10 PERIGEUM WYKORZYSTANIA INFRASTRUKTURY W SCENARIUSZU SC3 Z APLIKACJI SIMVEC	159
RYS 8.11 EPIZOD AWARII W SCENARIUSZU SC3 Z APLIKACJI SIMVEC	160
RYS 8.12 PRZEBIEG SCENARIUSZA SC3 DLA WYIZOLOWANEGO PARAMETRU P5 Z APLIKACJI SIMVEC	160
RYS. 8.13 KOMPLETNY ZNORMALIZOWANY SYGNAŁ WEJŚCIOWY SYMULACJI SC4.....	161

RYS 8.14 IMPULSY KRYZYSOWE W SCENARIUSZU SC4, WARTOŚCI ZNORMALIZOWANE	162
RYS 8.15 WYNIK SYMULACJI SC4 Z APLIKACJI SIMVEC.....	162
RYS 8.16 ODPOWIEDZ MODELU NA IMPULS P8 W SCENARIUSZU SC4 Z APLIKACJI SIMVEC.....	163
RYS 8.17 KOMPLETNY ZNORMALIZOWANY SYGNAŁ WEJŚCIOWY SYMULACJI SC5.....	164
RYS 8.18 DZIAŁANIA OPERATORA W SCENARIUSZU SC5 - WARTOŚCI ZNORMALIZOWANE.....	164
RYS 8.19 WYNIK SYMULACJI SC5 Z APLIKACJI SIMVEC.....	165
RYS 8.20 KOMPLETNY ZNORMALIZOWANY SYGNAŁ WEJŚCIOWY SYMULACJI SC6.....	166
RYS 8.21 KOMPLETNY ZNORMALIZOWANY SYGNAŁ WEJŚCIOWY SYMULACJI SC6 W PERSPEKTYWIE 7 DNI	167
RYS. 8.22 WYNIK SYMULACJI SC6 Z APLIKACJI SIMVEC.....	167
RYS 8.23 RANKING WPŁYWU PARAMETRÓW NA MODEL	170
RYS. 8.24 WYKRES TORNADO WPŁYWU PARAMETRÓW NA MODEL.....	170
RYS 8.25 . MACIERZ ZAGREGOWANEGO NATĘŻENIA WSPÓŁZALEŻNOŚCI S_{ij}	173
RYS 8.26 MACIERZ POWIĄZAŃ MIĘDZY SKŁADOWYMI WSPÓŁCZYNNIKÓW MARŻY.....	174
RYS 8.27 MACIERZ POWIĄZAŃ KRZYŻOWYCH MIĘDZY SKŁADOWYMI MARŻY I WSPÓŁCZYNNIKA WYKORZYSTANIA	174
RYS 8.28 MACIERZ POWIĄZAŃ KRZYŻOWYCH MIĘDZY SKŁADOWYMI WSPÓŁCZYNNIKA WYKORZYSTANIA I MARŻY	175
RYS 8.29 MACIERZ POWIĄZAŃ MIĘDZY SKŁADOWYMI WSPÓŁCZYNNIKÓW WYKORZYSTANIA	175
RYS 8.30 RANKING NAJSILNIEJSZYCH POWIĄZAŃ MIĘDZY PARAMETRAMI.	176

SPIS TABEL

TAB. 3.1. PRZYKŁADOWE STAWKI ZA ŁADOWANIE W POLSCE (2025)	43
TAB. 3.2. PORÓWNANIE CZYNNIKÓW POPYTU STACJI PALIW VS. STACJI ŁADOWANIA EV	44
TAB. 3.3 STRUKTURA KOSZTÓW OPEX PRZYKŁADOWEJ STACJI ŁADOWANIA.....	50
TAB. 3.4 MIARY UX / ZADOWOLENIA KLIENTA STACJI ŁADOWANIA	55
TAB. 4.1 PARAMETRY I ATRYBUTY OTOCZENIA RYNKOWEGO I KONKURENCYJNEGO	62
TAB. 4.2 PARAMETRY I ICH ATRYBUTY W OBSZARZE POPYTU	65
TAB. 4.3 PARAMETRY W OBSZARZE KOSZTÓW	67
TAB. 4.4. PARAMETRY W OBSZARZE TECHNICZNYM I INFRASTRUKTURALNYM	70
TAB. 4.5. PARAMETRY W OBSZARZE MARKETINGOWYM I PRODUKTOWYM.....	73
TAB. 4.6 PARAMETRY W OBSZARZE MAKROEKONOMICZNYM	76
TAB 5.0 PRZYPISANIE WEKTORÓW ATRYBUTÓW KALIBRUJĄCYCH DO PARAMETRÓW.....	86
TAB 5.1 TABELA ATRYBUTÓW WPLYWAJĄCYCH NA PARAMETR P2 (ARGUMENTY FUNKCJI MODULUJĄCYCH).....	87
TAB 5.2 TABELA ATRYBUTÓW WPLYWAJĄCYCH NA PARAMETR P3 (ARGUMENTY FUNKCJI MODULUJĄCYCH).....	88
TAB 5.3 TABELA ATRYBUTÓW WPLYWAJĄCYCH NA PARAMETR P1 (ARGUMENTY FUNKCJI MODULUJĄCYCH).....	89
TAB 5.4 TABELA ATRYBUTÓW WPLYWAJĄCYCH NA PARAMETR P5 (ARGUMENTY FUNKCJI MODULUJĄCYCH).....	91
TAB 5.5 TABELA ATRYBUTÓW WPLYWAJĄCYCH NA PARAMETR P13 (ARGUMENTY FUNKCJI MODULUJĄCYCH).....	92
TAB 5.6 TABELA ATRYBUTÓW WPLYWAJĄCYCH NA PARAMETR P16 (ARGUMENTY FUNKCJI MODULUJĄCYCH).....	94
TAB 5.7 TABELA ATRYBUTÓW WPLYWAJĄCYCH NA PARAMETR P4 (ARGUMENTY FUNKCJI MODULUJĄCYCH).....	95
TAB 5.8 TABELA ATRYBUTÓW WPLYWAJĄCYCH NA PARAMETR P9 (ARGUMENTY FUNKCJI MODULUJĄCYCH).....	97
TAB 5.9 TABELA ATRYBUTÓW WPLYWAJĄCYCH NA PARAMETR P8 (ARGUMENTY FUNKCJI MODULUJĄCYCH).....	98
TAB 5.10 TABELA ATRYBUTÓW WPLYWAJĄCYCH NA PARAMETR P12 (ARGUMENTY FUNKCJI MODULUJĄCYCH)	100
TAB. 5.11 TABELA ATRYBUTÓW WPLYWAJĄCYCH NA PARAMETR P14 (ARGUMENTY FUNKCJI MODULUJĄCYCH)	101
TAB. 5.12 TABELA ATRYBUTÓW WPLYWAJĄCYCH NA PARAMETR P18 (ARGUMENTY FUNKCJI MODULUJĄCYCH)	102
TAB. 5.13 TABELA ATRYBUTÓW WPLYWAJĄCYCH NA PARAMETR P6 (ARGUMENTY FUNKCJI MODULUJĄCYCH)	104
TAB 5.14 TABELA ATRYBUTÓW WPLYWAJĄCYCH NA PARAMETR P7 (ARGUMENTY FUNKCJI MODULUJĄCYCH).....	105
TAB 5.15 TABELA ATRYBUTÓW WPLYWAJĄCYCH NA PARAMETR P11 (ARGUMENTY FUNKCJI MODULUJĄCYCH)	106
TAB 5.16 TABELA ATRBUTÓW WPLYWAJĄCYCH NA PARAMETR P17 (ARGUMENTY FUNKCJI MODULUJĄCYCH)	108
TAB 5.17 TABELA ATRYBUTÓW WPLYWAJĄCYCH NA PARAMETR P19 (ARGUMENTY FUNKCJI MODULUJĄCYCH)	109
TAB 5.18 TABELA ATRYBUTÓW WPLYWAJĄCYCH NA PARAMETR P10 (ARGUMENTY FUNKCJI MODULUJĄCYCH)	110
TAB 5.19 TABELA ATRYBUTÓW WPLYWAJĄCYCH NA PARAMETR P15 (ARGUMENTY FUNKCJI MODULUJĄCYCH)	112
TAB 5.20 TABELA ATRYBUTÓW WPLYWAJĄCYCH NA PARAMETR P20 (ARGUMENTY FUNKCJI MODULUJĄCYCH)	113
TAB 8.1 TABELA PARAMETRÓW P1-P20 UPORZĄDKOWANA WEDŁUG SIŁY WPLYWU NA MODEL.....	169
TAB. 8.2 STATYSTYKI FUNKCJI MODULUJĄCYCH F_{mj} I F_{uj}	177