

POLITECHNIKA WARSZAWSKA

INŻYNIERIA MECHANICZNA
NAUKI INŻYNIERYJNO-TECHNICZNE

Rozprawa doktorska

mgr inż. Łukasz Marcin Markiewicz

**Metoda pomiaru ciała człowieka z wykorzystaniem chmury
punktów na potrzeby przemysłu odzieżowego**

Promotor
prof. dr hab. inż. Robert Sitnik

WARSZAWA 2024

Streszczenie

Przedmiotem niniejszej rozprawy jest opracowana na potrzeby przemysłu odzieżowego metoda pomiaru ludzkiego ciała zarejestrowanego cyfrowo w postaci chmury punktów. Praca zawiera przegląd istniejących technik i wyzwań związanych z cyfrową antropometrią. Zebrana wiedza pozwoliła na przygotowanie i udokumentowanie w pełni automatycznego procesu kompleksowego wymiarowania ludzi. Jego opis obejmuje kolejne etapy przetwarzania chmury punktów, takie jak filtracja, segmentacja, detekcja punktów antropometrycznych na powierzchni i właściwe algorytmy wymiarowania w podziale na pomiary obwodowe, łukowe oraz liniowe. Proponowane podejście zostało przeanalizowane zarówno w odniesieniu do manualnych pomiarów antropometrycznych dokonanych przez ekspertów, jak i do wyników pozyskanych za pomocą jednego z wiodących systemów komercyjnych. Z kolei użyteczność opracowanej metody została potwierdzona nie tylko w serii testów dokładnościowych oraz jakościowych, ale i w praktyce. W toku prac wykazano, że pomimo swoich ograniczeń i nieuniknionej rozbieżności w stosunku do pomiarów manualnych uznawanych nadal za złoty standard, metoda ta może być z powodzeniem stosowana do szeroko zakrojonych badań antropometrycznych. Wyniki algorytmów pomiarowych posłużyły do opracowania nowych tabel rozmiarów dla wybranych służb mundurowych w ramach projektu „Formfit – Badania antropometryczne funkcjonariuszy służb podległych Ministrowi Spraw Wewnętrznych”. Podsumowując, zaproponowana metodologia wpisuje się w trend nowoczesnej antropometrii 3D, która dzięki wysokiej precyzji i powtarzalności może być stosowana na dużą skalę, bez względu na różnorodność rozmiarów i kształtów ciała człowieka.

Słowa kluczowe: skanowanie 3D, antropometria, automatyczne pomiary ciała człowieka, odzieżownictwo

Abstract

The subject of this dissertation is a method developed for the apparel industry for measuring the human body, digitally registered as a point cloud. The work includes a review of existing techniques and challenges related to digital anthropometry. The gathered knowledge allowed for the preparation and documentation of a fully automated process for comprehensive human measurement. Its description covers successive stages of point cloud processing, such as filtration, segmentation, detection of anthropometric points on the surface, and the relevant measurement algorithms divided into girth, arc, and linear ones. The proposed approach has been analyzed with reference to manual anthropometric measurements conducted by experts and to results obtained using one of the leading commercial systems. Furthermore, the usefulness of the developed method has been confirmed not only through a series of accuracy and quality tests, but also in practice. In the course of the work, it was shown that despite its limitations and inevitable discrepancy with manual measurements still considered the gold standard, this method can be successfully applied to extensive anthropometric studies. The results obtained from the measurement algorithms were used to develop new size tables for selected uniformed services as part of project “Formfit – Anthropometric studies of officers employed by the Ministry of the Interior”. In summary, the proposed methodology aligns with the trend of modern 3D anthropometry, which, thanks to its high precision and repeatability, can be used on a large scale regardless of the diversity of human body sizes and shapes.

Keywords: 3D scanning, anthropometry, automated human body measurements, apparel industry

Spis treści

1. Wprowadzenie.....	11
1.1. Motywacja	11
1.2. Cel i założenia pracy	13
1.3. Zarys pracy	17
2. Przegląd metod pomiaru ciała człowieka	18
2.1. Standardy.....	18
2.2. Metody tradycyjne	20
2.3. Metody cyfrowe.....	22
2.3.1. Zarys procesu.....	22
2.3.2. Rekonstrukcja 3D ciała człowieka.....	23
2.3.3. Przygotowanie danych	29
2.3.4. Detekcja punktów antropometrycznych.....	36
2.3.5. Wymiarowanie.....	42
2.4. Nowoczesne systemy antropometryczne dostępne na rynku	47
2.4.1. Systemy 3D.....	47
2.4.2. Systemy 4D.....	50
2.4.3. Aplikacje mobilne	53
2.4.4. Bazy danych antropometrycznych i narzędzia do ich analizy.....	54
2.5. Podsumowanie.....	57
3. Materiały	61

4. Metoda pomiaru ciała z wykorzystaniem chmury punktów	65
4.1. Przetwarzanie wstępne chmury punktów	66
4.1.1. Przygotowanie danych	66
4.1.2. Segmentacja.....	67
4.1.3. Krzywizna Gaussa.....	70
4.2. Detekcja punktów antropometrycznych.....	72
4.3. Wymiarowanie.....	74
4.3.1. Pomiary obwodowe.....	75
4.3.2. Pomiary łukowe	77
4.3.3. Pomiary liniowe	79
5. Walidacja algorytmów wymiarowania	81
5.1. Pozyskanie danych testowych	81
5.2. Analiza dokładności pomiarów	83
5.3. Ocena spójności oraz zgodności absolutnej pomiędzy metodami.....	87
5.4. Ocena powtarzalności wymiarowania	91
5.5. Porównywalność pomiarów manualnych i automatycznych	92
5.6. Rozbieżności między wynikami automatycznych i manualnych pomiarów	95
6. Praktyczne zastosowanie metody w przemyśle odzieżowym.....	101
6.1. Opracowane aplikacje	101
6.1.1. Skanowanie 3D.....	102
6.1.2. Algorytmy wymiarowania.....	103

6.1.3. Eksport danych.....	104
6.2. Pomiary w ramach projektu Formfit.....	107
7. Podsumowanie.....	109
7.1. Realizacja celów badawczych	109
7.2. Wnioski wynikające z badań	114
7.2.1. Korzyści z zastosowania metody	114
7.2.2. Ograniczenia	115
7.3. Perspektywy dalszych badań i rozwoju metody	117
8. Bibliografia	119

Wykaz pojęć i skrótów

Skrót lub pojęcie	Rozwinięcie skrótu	Tłumaczenie lub opis
2D	two-dimensional	przestrzeń dwuwymiarowa obejmująca współrzędne kartezjańskie X, Y
3D	three-dimensional	przestrzeń trójwymiarowa obejmująca współrzędne kartezjańskie X, Y, Z
4D	four-dimensional	przestrzeń czterowymiarowa obejmująca współrzędne kartezjańskie X, Y, Z oraz t (czas)
AdaBoost	Adaptive Boosting	metoda uczenia maszynowego, która łączy wiele słabych modeli w jeden silny poprzez nadawanie większej wagi błędnie sklasyfikowanym próbkom
Adam	nie dotyczy	parametryczny model statystyczny ciała człowieka
ANSUR	Anthropometric Survey of U.S. Army Personnel	badanie antropometryczne personelu armii amerykańskiej
ASTM International	American Society for Testing and Materials	Amerykańskie Stowarzyszenie Badań i Materiałów
BfSNet	Body from Silhouette Network	sieć neuronowa do rekonstrukcji 3D ciała człowieka
BMI	Body Mass Index	wskaźnik masy ciała
CAESAR	Civilian American and European Surface Anthropometry Resource	pierwsze istotne cyfrowe badanie antropometryczne 3D, dla którego zostały udostępnione dane
CCD	Charge Coupled Device	technologia wytwarzania matryc elementów światłoczułych
CEN	European Committee for Standardization	Europejski Komitet Normalizacyjny
CNN	Convolutional Neural Network	konwolucyjna sieć neuronowa
DLP	Digital Light Processing	cyfrowa technologia projekcji światła
DCN	Directionally Convolutional Network	kierunkowa sieć konwolucyjna
DNN	Deep Neural Network	głęboka sieć neuronowa
FRAMES	Framework and Robust Algorithms for Models of Extreme Size	środowisko do wizualizacji oraz przetwarzania dużych i skomplikowanych obliczeniowo danych 3D opracowane przez zespół OGX OPTOGRAPHX Wydziału Mechatroniki Politechniki Warszawskiej
GHUM	Generative 3D Human	parametryczny model statystyczny ciała człowieka
GT	Ground Truth	wartość referencyjna uznawana za prawdziwą
HKS	Heat Kernel Signature	typ deskryptora kształtu oparty o własności dyfuzji ciepła na powierzchniach 3D
HS	Human Solutions	komercyjny system antropometryczny 3D firmy Human Solutions

Skrót lub pojęcie	Rozwinięcie skrótu	Tłumaczenie lub opis
ICON	Implicit Clothed Humans Obtained from Normals	metoda rekonstrukcji 3D ciała człowieka z wykorzystaniem funkcji uwikłanych
ICC	Intraclass Correlation	metoda korelacji wewnątrzklasowej
ICP	Iterative Closest Point	metoda orientacji wzajemnej chmur punktów
IEEE	Institute of Electrical and Electronics Engineers	Instytut Inżynierów Elektryków i Elektroników
IF	Impact Factor	wskaźnik cytowań
IPC	Interprocess Communication	komunikacja międzyprocesowa
IP-Net	Implicit Part Network	multimodalna metoda rekonstrukcji niepełnej chmury punktów ciała człowieka
IQR	Interquartile Range	rozstęp ćwiartkowy
ISAK	International Society for the Advancement of Kinanthropometry	Międzynarodowe Stowarzyszenie na Rzecz Rozwoju Kinantropometrii
ISO	International Organization for Standardization	Międzynarodowa Organizacja Normalizacyjna
JPEG	Joint Photographic Experts Group	format kompresji obrazów
LiDAR	Light Detection And Ranging	metoda wykorzystująca pomiar odbicia światła laserowego do generowania map 3D otoczenia
LT	Laser Triangulation	triangulacja laserowa
MAD	Mean Absolute Difference	maksymalny dopuszczalny błąd pomiaru
MRF	Markov Random Fields	losowe pola Markowa
MoCap	Motion Capture	technika przechwytywania ruchu 3D
MSP	Mobilny System Pomiarowy	system antropometryczny 3D, którego częścią są opracowane w ramach pracy algorytmy
MVS	Multi-View Stereo	metoda gęstej rekonstrukcji 3D z wykorzystaniem wielu obrazów z różnych perspektyw i informacji o parametrach kamer
NeRF	Neural Radiance Fields	głęboka sieć neuronowa pozwalająca na generowanie nowych widoków sceny 3D na podstawie częściowego zbioru obrazów
NHANES	National Health and Nutrition Examination Survey	amerykańskie badanie dotyczące zdrowia i żywienia
PaMIR	Parametric Model-conditioned Implicit Representation	metoda rekonstrukcji 3D ciała człowieka z wykorzystaniem funkcji uwikłanych
PCA	Principal Components Analysis	analiza głównych składowych

Skrót lub pojęcie	Rozwinięcie skrótu	Tłumaczenie lub opis
PHDS	Part Heat Diffusion Signature	deskryptor kształtu oparty o własności dyfuzji ciepła na powierzchniach 3D pozwalający na rozróżnienie symetrycznych części ciała
PIFu	Pixel-aligned Implicit Function	metoda rekonstrukcji 3D ciała człowieka z wykorzystaniem funkcji uwikłanych
PIFuHD	Pixel-aligned Implicit Function for High-Resolution 3D Human Digitization	metoda rekonstrukcji 3D ciała człowieka z wykorzystaniem funkcji uwikłanych
PLY	Polygon File Format	format zapisu plików 3D
punkt orientacyjny	nie dotyczy	unikalne i jednoznacznie określone miejsce na powierzchni ciała człowieka lub względem niej, inaczej punkt antropometryczny
RF	Random Forests	losowe lasy
rejestracja chmury punktów	nie dotyczy	synonim orientacji wzajemnej chmur punktów
SCAPE	Shape Completion and Animation of People	parametryczny model statystyczny ciała człowieka
SfM	Structure from Motion	metoda rzadkiej rekonstrukcji 3D z wykorzystaniem wielu obrazów z różnych perspektyw
SfS	Shape from Silhouette	metoda rekonstrukcji 3D na podstawie zarysów obiektów z różnych perspektyw
SI	Spin Image	deskryptor kształtu 3D oparty o analizę zorientowanego wierzchołka we współrzędnych cylindrycznych
SIF	Skeleton-aware Implicit Function	metoda rekonstrukcji 3D ciała człowieka z wykorzystaniem funkcji uwikłanych
SL	Structured Light	światło strukturalne
SMPL	Skinned Multi-Person Linear	parametryczny model statystyczny ciała człowieka
STAR	Sparse Trained Articulated Regressor	parametryczny model statystyczny ciała człowieka
ToF	Time of Flight	analiza czasu przelotu wiązki
VDI/VDE	Verein Deutscher Ingenieure/Verband Deutscher Elektrotechniker	Związek Niemieckich Inżynierów/Zrzeszenie Niemieckich Elektrotechników
VOI	Volume of Interest	objętość zainteresowania w analizie danych 3D
WEAR	World Engineering Anthropometry Resource	konsorcjum udostępniające liczne zestawy danych antropometrycznych
WHO	World Health Organization	Światowa Organizacja Zdrowia
WKS	Wave Kernel Signature	deskryptor kształtu 3D oparty o funkcję falową

1. Wprowadzenie

1.1. Motywacja

Od czasów starożytnych budowa ludzkiego ciała, jego wymiary oraz proporcje stanowiły obiekt zainteresowań człowieka. Antropometria (z gr. *ánthrōpos* – człowiek, *metréō* – mierzę) jest dziedziną nauki, która ewoluowała z fascynacji ludzkim ciałem i zajmuje się pomiarami rozmiaru, kształtu, siły oraz innych mierzalnych cech ciała człowieka [1]. Początkowo antropometria obejmowała głównie pomiary liniowe, powierzchniowe, objętościowe i kątowe – zarówno ciała (somatometria), jak i szkieletu (osteometria) ze szczególnym uwzględnieniem czaszki (kranimetria) [2]. Jej korzenie sięgają antycznego Egiptu, gdzie ok. 3500 – 2200 lat p.n.e. odkryto, że ciało może być podzielone na 19 części [3]. Z kolei już w IV – I wieku p.n.e. w dokładny i naukowy sposób antropometria została opisana w najstarszym chińskim traktacie medycznym znanym jako „Kanon medycyny chińskiej Żółtego Cesarza” (z chiń. *Huángdì Nèijīng*) [4], a za początek rozwoju nowoczesnej, systematycznej antropometrii uważa się XVIII wiek [5], [6]. Współcześnie, stanowi ona ważną gałąź nie tylko przemysłu odzieżowego, ale i ergonomii, medycyny, kryminalistyki, wirtualnej rzeczywistości czy morfologii porównawczej [4], [7], [8].

Przemysł odzieżowy jest jednym z najważniejszych sektorów gospodarki na świecie, a jego przychody miały przekroczyć 1,7 biliona dolarów amerykańskich w 2023 roku [9]. Obejmuje on nie tylko projektowanie i produkcję odzieży, ale także dystrybucję i sprzedaż na rynkach krajowych i międzynarodowych. Niewątpliwie niesie to za sobą istotne konsekwencje dla środowiska, gdyż przemysł ten jest odpowiedzialny za 8-10% globalnej emisji dwutlenku węgla [10]. W związku z tym wiele firm odzieżowych intensyfikuje swoje działania w kierunku zrównoważonego rozwoju, aby przeciwdziałać negatywnym skutkom produkcji odzieży. Istotnym wyzwaniem dla tej branży jest zrozumienie i adaptacja do złożoności oraz różnorodności kształtów ciała ludzkiego zależnych od wieku, płci czy przynależności do danej grupy etnicznej. Pomiary ciała stanowią kluczowy element tego procesu, będąc zarazem źródłem trudności dla konsumentów, dla których zakup odpowiednio dopasowanego ubioru stanowi częstokroć duże wyzwanie. W przypadku elektronicznego handlu odzieżą ok. 25% zamówień jest zwracanych [11], z czego aż 70% zwrotów ubrań wynika ze złego ich dopasowania [12]. Tylko w Stanach Zjednoczonych ich wartość szacuje się na 38 miliardów dolarów [13]. Precyzyjne, regularnie aktualizowane pomiary ciała są niezbędne nie tylko w przypadku produkcji odzieży na miarę, ale również w produkcji masowej. Ta druga

wymaga stałej optymalizacji typoszeregów ubrań, aby minimalizować straty z tytułu obsługi niepasującej odzieży, jak również zwiększać komfort użytkownika.

Fizjonomia człowieka ewoluuje z czasem zarówno w sposób indywidualny z powodu wieku, diety i poziomu sprawności fizycznej, jak i globalny poprzez zmiany środowiskowe. Przykładowo w Polsce, tak jak i w większości krajów europejskich, wysokość ciała wzrastała o 1 do 3 cm na dekadę na przestrzeni ostatnich 150 lat [14]. Co więcej, średnie BMI (z ang. *Body Mass Index* – wskaźnik masy ciała) na świecie stale rośnie [15]. Przełożenie pomiarów antropometrycznych na tabele rozmiarów odzieży, tak aby zapewniony był możliwie najlepszy poziom dopasowania i komfort odbiorców końcowych, nie jest łatwym procesem i wymaga ciągłego monitorowania grupy docelowej [16]. Pociąga to za sobą konieczność cyklicznego przeprowadzania obszernych badań antropometrycznych populacji, których przykładami są m.in. ANSUR I i II (z ang. *Anthropometric Survey of U.S. Army Personnel*) [17], [18] czy NHANES (z ang. *National Health and Nutrition Examination Survey*) [19]. Problem ten nie dotyczy tylko przemysłu odzieżowego, ale też m.in. ergonomii. O tym, że nie istnieje „średni” człowiek, przekonało się wojsko amerykańskie już w latach 50. XX w., próbując zaprojektować uniwersalny kokpit dla przeciętnego pilota. Okazało się, że spośród ponad 4 tysięcy zmierzonych lotników żaden nie wpasowywał się w widełki 10 podstawowych wymiarów, a biorąc pod uwagę tylko 3 z nich – mniej niż 3,5% osób [20]. Stało się to przyczynkiem do wdrożenia regulowanych foteli i oprzyrządowania.

W tradycyjny sposób metryki ciała są mierzone ręcznie przez wyszkolonego specjalistę, który bada powierzchnię ciała lub szkieletu przy użyciu sprzętu, takiego jak taśmy miernicze, wzrostomierze, antropometry czy suwmiarki [21]. Jednak od czasu, gdy skanery 3D stały się przedmiotem szeroko zakrojonych badań w późnych latach 80. XX w., znaczenie półautomatycznej i w pełni automatycznej antropometrii cyfrowej odpowiednio wzrosło [22], [23]. Dynamiczny rozwój technologii obrazowania 3D przyniósł narzędzia pozwalające na zautomatyzowanie i przyspieszenie wykonywanych dotychczas manualnie czasochłonnych pomiarów antropometrycznych. Wykorzystanie skanerów 3D pozwala zebrać dane dotyczące geometrii powierzchni ciała w czasie od kilku do ułamków sekund w przypadku technik 4D [24]. Ponadto dzięki technologii 3D projektanci i producenci odzieży mogą lepiej zrozumieć kształt i proporcje ciała swoich klientów, co pozwala im tworzyć odzież, która lepiej dopasowuje się do różnych typów sylwetek.

Od nowoczesnej antropometrii 3D oczekuje się wysokiej precyzji, powtarzalności i łatwości w stosowaniu na dużą skalę bez względu na różnorodność kształtów i rozmiarów ciała ludzkiego. Na rynku istnieje wiele rozwiązań komercyjnych wykorzystujących technologię 3D [25], ale są one zamknięte i działają na zasadzie tzw. „czarnej skrzynki” [26], [27]. Opracowanie nowej, w pełni udokumentowanej metody pomiaru ciała z wykorzystaniem chmury punktów może wpłynąć pozytywnie na proces projektowania i produkcji ubrań, umożliwiając szybsze i dokładniejsze dostosowanie wymiarów odzieży do indywidualnych potrzeb klientów.

1.2. Cel i założenia pracy

Celem głównym pracy jest opracowanie oraz weryfikacja metody automatycznego pomiaru ciała człowieka, która zostanie dostosowana do potrzeb przemysłu odzieżowego. Metoda ta opierać się ma na analizie danych uzyskanych za pomocą skanera 3D, który generuje chmurę punktów we współrzędnych kartezjańskich (x , y , z) [28] pełnej sylwetki człowieka. Wynikiem przetwarzania powinien być kompleksowy zestaw wymiarów oparty o punkty antropometryczne (patrz Tabele 1.1 i 1.2), który będzie mógł być bez przeszkód wykorzystywany do projektowania odzieży czy przeprowadzania badań antropometrycznych populacji.

Szczegółowe efekty zaplanowane do osiągnięcia w niniejszej pracy obejmują cele naukowe, takie jak:

- opracowanie w pełni udokumentowanej metodyki wyznaczania wymiarów antropometrycznych na podstawie chmury punktów ciała człowieka o następujących parametrach:
 - błąd procentowy względem manualnych pomiarów $< 10\%$,
 - powtarzalność o odchyleniu standardowym < 15 mm,
 - współczynniki spójności i zgodności absolutnej ICC (z ang. *Intraclass Correlation Coefficient* – współczynnik korelacji wewnątrzklasowej) [29] w stosunku do pomiarów manualnych na poziomie doskonałym > 0.75 [30],
- bezobsługowość poszczególnych etapów procesu przetwarzania danych obejmujących filtrację i segmentację skanu, detekcję punktów antropometrycznych oraz właściwe wyznaczenie przebiegu linii pomiarowej, która powinna odpowiadać zachowaniu

taśmy mierniczej dla krzywych i obwodów lub cyrkla antropometrycznego dla długości liniowych,

- zobiektywizowanie i usprawnienie obecnie stosowanej metodyki przeprowadzania badań antropometrycznych

oraz cele aplikacyjne:

- zapewnienie kompleksowego zestawu wymiarów obejmującego obwody, wysokości czy krzywe, który może mieć zastosowanie do różnych typów odzieży,
- weryfikację konkurencyjności rozwiązania na podstawie analizy jakości wyznaczanych danych antropometrycznych poprzez zestawienie ich z wynikami pozyskanymi manualnie przez ekspertów, a także przy użyciu jednego z wiodących, acz zamkniętych systemów komercyjnych Human Solutions Vitronic Vitus Smart XXL [31], który deklaruje zgodność z normą ISO 20685 [32] (szczegółowy opis norm znajduje się w podrozdziale 2.1 niżej),
- określenie stosowalności metody w praktyce przemysłowej z uwzględnieniem różnic między nią a tradycyjnymi metodami i normami, które nie były tworzone z myślą o pomiarze 3D,
- aktualizację tabel rozmiarów dla funkcjonariuszy służb mundurowych w ramach projektu „Formfit – Badania antropometryczne funkcjonariuszy służb podległych Ministrowi Spraw Wewnętrznych” na podstawie danych uzyskanych proponowaną metodą,
- opracowanie narzędzi do pozyskiwania danych antropometrycznych i ich integracja z zewnętrznym oprogramowaniem ewidencyjno-analitycznym oraz aplikacją do obsługi systemu skanującego.

Opracowanie powyższej metody powinno wspomóc w przyszłości pozyskiwanie danych antropometrycznych w szybki, wiarygodny i powtarzalny sposób. Ponadto holistyczny opis procesu wyznaczania wymiarów przyczyni się do usystematyzowania wiedzy o technikach antropometrii 3D w przemyśle odzieżowym, co pozwoli na usprawnienie procesu projektowania i produkcji ubrań.

Podstawę do przeprowadzania badań stanowiły wymagania określone w ramach projektu „Formfit – Badania antropometryczne funkcjonariuszy służb podległych Ministrowi Spraw Wewnętrznych”, który został wsparty przez Narodowe Centrum Badań i Rozwoju (konkurs nr


6/2014 na rzecz bezpieczeństwa i obronności państwa, umowa nr DOB-BIO6/20/74/2014). Jednym z jego głównych celów była aktualizacja tabel rozmiarowych odzieży służb mundurowych na podstawie wyników pozyskanych automatycznie za pomocą technik 3D. Omawiana w niniejszej rozprawie metoda miała umożliwić przeprowadzanie antropometrycznych pomiarów krawieckich, których definicje zostały opracowane przez ekspertów z Instytutu Włókiennictwa w Łodzi. Ich selekcji dokonano na podstawie wybranych typów pomiarów z dokumentu [33] oraz norm ISO 7250 [34], ISO 8559 [35] i PN-EN 13402 [36]. Spis wymaganych 34 pomiarów wraz z odpowiadającymi im punktami antropometrycznymi zaprezentowany jest w Tabelach 1.1 i 1.2, a ich wizualizacja na modelu ciała człowieka znajduje się na Rysunku 1.1.

Tabela 1.1 Spis pomiarów antropometrycznych wraz z podziałem na kategorię (l./p. – lewy/prawy).

Pomiary obwodowe	Pomiary łukowe	Pomiary liniowe	
		Szerokości	Wysokości
<i>opx</i> przez piersi	<i>RvRv</i> barków tyłu	<i>PcPl</i> pachy l./p.	<i>Zwo</i> wzrost
<i>opp</i> pod piersiami	<i>RvSxRv</i> barków przodu	<i>XcXc</i> barków tyłu	<i>ZSy</i> 7 kręgu szyi
<i>os</i> szyi	<i>XlXl</i> przodu przez piersi	<i>XpXp</i> międzypiersiowa	<i>ZTv</i> talii
<i>on</i> nadgarstka l./p.	<i>SySvXp</i> długości przodu do piersi l./p.		<i>ZUo</i> krocza
<i>oh</i> podudzia l./p.	<i>SySvXpTp</i> długości przodu przez pierś l./p.		<i>ZKo</i> kolana l./p.
<i>ot</i> talii	<i>SyTy</i> długości pleców		<i>ZHo</i> kostki l./p.
<i>ou</i> uda l./p.	<i>SvRv</i> długości barku l./p.		<i>ZPc</i> pachy l./p.
<i>ok</i> kolana l./p.	<i>RvNv</i> długości kończyny górnej l./p.		<i>ZRv</i> barku l./p.
<i>ol</i> łydki l./p.	<i>PcRvPl</i> pachy l./p.		<i>ZSv</i> nasady szyi l./p.
<i>orl</i> przedramienia l./p.			
<i>or</i> ramienia l./p.			
<i>ob</i> bioder			
<i>ob</i> wg największego obwodu pośladków			
<i>ob</i> bioder			
<i>obt</i> z uwzględnieniem wypukłości brzucha			

Tabela 1.2 Spis punktów antropometrycznych (l./p. – lewy/prawy).

Akronim	Opis antropometryczny	Akronim	Opis antropometryczny
Rv	wyrostek barkowy l./p.	Tp	talia pod piersią l./p.
Sv	ramiona-szyja l./p.	Ty	talia pod kręgiem C7
Sy	kręg C7	El	łokieć l./p.
Sx	dół szyjny pomiędzy obojczykami	Nv	nadgarstek l./p.
Pl	przód pachy l./p.	Tv	talia
Pc	tył pachy l./p.	Uo	krocze
Xp	brodawki sutkowe l./p.	Ko	kolano l./p.
Xl	przód pachy na wysokości brodawek sutkowych l./p.	Ho	kostka l./p.
Xc	tył pachy na wysokości sutków l./p.		



Rysunek 1.1 Wizualizacja pomiarów antropometrycznych i odpowiadających im punktów antropometrycznych na potrzeby konstrukcji odzieży.

1.3. Zarys pracy

Niniejsza rozprawa doktorska składa się z 8 rozdziałów. W rozdziale 1 jest zaprezentowana tematyka i zarys pracy, a także motywacja do jej realizacji oraz szczegółowe cele i założenia. Rozdział 2 zawiera przegląd istniejących metod pomiaru ciała w przemyśle odzieżowym. Omówiono w nim standardy pomiarów ciała człowieka oraz różne sposoby ich przeprowadzania, w tym tradycyjne, manualne metody pomiarowe, oraz nowoczesne, wykorzystujące skanowanie 3D czy uczenie maszynowe. Obejmuje on również przegląd dostępnych na rynku systemów antropometrycznych 3D, 4D oraz aplikacji mobilnych. Ponadto w ramach podsumowania zostały omówione zalety i wady istniejących technik. W rozdziale 3 zawarte są założenia i opis przebiegu procesu pozyskania danych antropometrycznych na potrzeby weryfikacji metody pomiarowej będącej przedmiotem pracy. Zaprezentowano w nim wykorzystaną technologię skanowania ciała 3D i zastosowane rozwiązania sprzętowe, które porównano z referencyjnym systemem komercyjnym. Z kolei rozdział 4 przedstawia autorską metodę pomiaru ciała na podstawie chmury punktów. Kluczowe etapy przetwarzania danych, takie jak filtracja, segmentacja, detekcja punktów antropometrycznych oraz właściwe algorytmy wymiarowania są szczegółowo opisane w jego kolejnych podrozdziałach. Rozdział 5 otwiera opis procesu pozyskania danych testowych, które posłużyły do weryfikacji zaproponowanych algorytmów wymiarowania. Uzyskane wyniki porównano z innymi metodami pomiaru ciała człowieka, zarówno tradycyjnymi, jak i dostępnym komercyjnie konkurencyjnym rozwiązaniem 3D. W następnych podrozdziałach zaprezentowana jest szczegółowa analiza dokładności, powtarzalności pomiarów czy możliwości wykorzystania ich do bezpośredniego zastąpienia klasycznych metod. W rozdziale 6 przedstawione jest praktyczne zastosowanie opisanej metody w przemyśle odzieżowym. Omówiono w nim opracowane w toku prac oprogramowanie oraz przeprowadzono ewaluację metody na przykładzie projektu Formfit. Rozdział 7 zawiera podsumowanie pracy i realizacji celów badawczych oraz wnioski wynikające z badań, w tym korzyści z zastosowania metody oraz jej ograniczenia. W jego ramach zaprezentowane są także perspektywy dalszych badań i rozwoju metody. Pracę wieńczy rozdział 8, w którym znajduje się spis źródeł bibliograficznych wykorzystanych przy jej tworzeniu.

2. Przegląd metod pomiaru ciała człowieka

Przemysł odzieżowy nieustannie dąży do optymalizacji procesów produkcyjnych, poprawy jakości produktów i zwiększenia satysfakcji klientów. Jednym z kluczowych aspektów, który decyduje o tych czynnikach, jest precyzyjny pomiar ciała ludzkiego [21], [37]. Właściwe pomiary umożliwiają nie tylko tworzenie odzieży, która odpowiednio pasuje do kształtów konsumentów, ale także zwiększają wydajność procesów produkcyjnych i redukują marnotrawstwo materiałów [38]. W ostatnich latach rozwój technologii widzenia i uczenia maszynowego doprowadził do powstania nowych podejść do antropometrii [4]. Tradycyjne manualne pomiary antropometryczne coraz częściej zastępowane są nowoczesnymi, automatycznymi metodami, których przegląd został zaprezentowany poniżej. Niezależnie jednak od metody podstawę dla wszelkich technik wymiarowania stosowanych w praktyce przemysłowej stanowią standardy pomiarów ciała człowieka.

2.1. Standardy

Standaryzacja pomiarów ciała człowieka jest niezbędna, aby zapewnić spójność, dokładność, wiarygodność i przewidywalność wyników. Niemniej jednak nie istnieje uniwersalny zestaw międzynarodowych norm dla wszystkich aspektów antropometrii. Najważniejszymi organizacjami standaryzacyjnymi, które podejmują wysiłki w celu rozwiązania tego problemu, są:

- ISO (z ang. *International Organization for Standardization* – Międzynarodowa Organizacja Normalizacyjna) – niezależna, międzynarodowa organizacja, która opracowuje standardy mające na celu zapewnienie jakości, bezpieczeństwa i efektywności produktów, usług i systemów [39],
- CEN (z ang. *European Committee for Standardization* – Europejski Komitet Normalizacyjny) – stowarzyszenie łączące organizacje normalizacyjne z 34 krajów europejskich, w tym PKN (Polski Komitet Normalizacyjny) [40], [41],
- ASTM International (z ang. *American Society for Testing and Materials* – Amerykańskie Stowarzyszenie Badań i Materiałów) – organizacja wywodząca się z rynku amerykańskiego, która opracowuje międzynarodowe standardy dla różnych dziedzin, w tym antropometrii [42],
- IEEE (z ang. *Institute of Electrical and Electronics Engineers* – Instytut Inżynierów Elektryków i Elektroników) – stowarzyszenie które, choć głównie skupia się na

standardach technologicznych, odgrywa ważną rolę w kontekście antropometrii, zwłaszcza w przypadku jej styku z nowoczesnymi technologiami 3D [43],

- ISAK (z ang. *International Society for the Advancement of Kinanthropometry* – Międzynarodowe Stowarzyszenie na Rzecz Rozwoju Kinantropometrii) – organizacja, która opracowuje standardy międzynarodowe dla kinantropometrycznej (łącej anatomię z ruchem i funkcjonalnością) oceny ciała, a także szkoli i certyfikuje antropometrów na całym świecie [44],
- WHO (z ang. *World Health Organization* – Światowa Organizacja Zdrowia) – organizacja skupiająca się m.in. na wytycznych i standardach dla pomiarów zdrowotnych, w tym antropometrii. Przykładem jest WHO Child Growth Standards (z ang. standardy WHO rozwoju fizycznego dzieci), czyli zestaw wytycznych dotyczących oceny wzrostu, wagi i rozwoju dzieci [45].

Z kolei za najistotniejsze normy w kontekście przeprowadzania pomiarów antropometrycznych na potrzeby przemysłu odzieżowego zarówno w tradycyjny, jak i nowoczesny sposób uznaje się m.in. [46]:

- ISO 7250-1:2017 – standard określający podstawowe wymiary ciała ludzkiego, punkty pomiarowe oraz wytyczne dla projektowania technicznego [34],
- ISO 8559-1:2017 – standard dotyczący terminologii i metodyki wykorzystywanej w kontekście odzieży i innych artykułów tekstylnych [35],
- ISO 15535:2012 – standard odpowiadający za kontrolę jakości pomiarów i spójności baz danych antropometrycznych oraz określający wymagania co do ich tworzenia i zarządzania nimi [47],
- ISO 20685-1:2018 – standard mający na celu stworzenie pomostu pomiędzy tradycyjnym podejściem antropometrycznym a techniką wykorzystującą skanowanie 3D. Dokument ten określa poziomy akceptowalnych błędów dla różnych typów pomiarów w przestrzeni 3D w przypadku porównywania ich z tradycyjnymi pomiarami [32],
- PN-EN 13402-3:2017-11 – standard opisujący europejski system oznaczania rozmiarów odzieży wraz z wykazem najważniejszych pomiarów potrzebnych do określenia rozmiaru ubrań [36],
- ASTM D5219-15 – standard definiujący terminologię związaną z pomiarami ciała w celu określania odpowiednich rozmiarów odzieży [48],

- IEEE P3141 – standard określający ramy, metody i narzędzia oceny jakości przetwarzania ciała w 3D, zapewniające interoperacyjność, bezpieczeństwo i niezawodność technologii pomiarowych. Dokument ten nie jest jeszcze ukończony w całości [49].

Przegląd metod pomiaru, które umożliwiają uzyskanie precyzyjnych danych antropometrycznych w odniesieniu do powyższych norm został zaprezentowany poniżej.


2.2. Metody tradycyjne

Postęp w dziedzinie technologii widzenia maszynowego zaowocował powstaniem szeregu metod pozyskiwania kształtu obiektów 3D, które odgrywają istotną rolę w procesie analizy danych o geometrii ciała człowieka. Technologia antropometryczna przeszła ewolucję od metod 1D i 2D do metod 3D i 4D, od pomiarów kontaktowych do bezkontaktowych oraz od manualnego do automatycznego wyznaczania wymiarów przy wykorzystaniu komputerów [7]. Pomimo tego nadal najczęściej za złoty standard uznaje się klasyczny pomiar manualny oparty na fundamentalnych cechach anatomii człowieka [25], [26], [50]. Proces ten zakłada stosowanie standaryzowanych postaw osoby mierzonej i wyznaczenie odległości między umownymi punktami antropometrycznymi obejmującymi m.in. wyrostek barkowy, łokciowy, pępek czy rzepkę [27], [34]. Pomiary bezpośrednich i proporcjonalnych długości, szerokości, kątów, obwodów i krzywych na powierzchni ciała człowieka dokonywane są za pomocą gamy specjalistycznego sprzętu, takiego jak [4], [51]:

- taśma miernicza – elastyczna, ale nierozciągliwa taśma najczęściej z podziałką milimetrową dedykowana do mierzenia obwodów różnych części ciała np. talii, klatki piersiowej czy bicepsów i odcinków krzywizn jego powierzchni,
- antropometr – regulowany przymiar używany do bezpośrednich lub pośrednich pomiarów wysokości i długości pomiędzy konkretnymi punktami antropometrycznymi a podłożem,
- cyrkiel liniowy (suwmiarka) – narzędzie używane do pomiarów średnicy, długości, wysokości, a także do pomiarów głębokości i wewnętrznych wymiarów ciała,
- cyrkiel kabłąkowy – narzędzie używane zamiast cyrkla liniowego w sytuacji gdy jego przesuwające się końce miałyby napotkać przeszkodę lub nie sięgałyby punktów pomiarowych np. dla głębokości klatki piersiowej w płaszczyźnie pośrodkowej czy długości głowy,

- stadiometr (wzrostomierz) – przyrząd do mierzenia wysokości osoby zarówno w pozycji stojącej, jak i siedzącej, który zwykle składa się z pionowej ścianki i ruchomej poprzeczki,
- goniometr – instrument służący do mierzenia zakresu ruchów w stawach.

Przykłady wybranych narzędzi pomiarowych zaprezentowano na Rysunku 2.1. Należy nadmienić, że metryki antropometryczne nie ograniczają się jedynie do pomiarów długości, ale też obejmują cechy, takie jak poziom tkanki tłuszczowej, masa ciała czy gęstość mineralna kości. Nie są one jednak przedmiotem zainteresowania niniejszej dysertacji.



Rysunek 2.1 Przykłady tradycyjnych narzędzi antropometrycznych: a) antropometr, b) cyrkiel liniowy duży, c) cyrkiel liniowy mały, d) cyrkiel kabłąkowy, e) taśma miernicza (źródło rysunku: [21]).


Narzędzia wykorzystywane w tradycyjnej antropometrii są zazwyczaj ekonomiczne i intuicyjne w użyciu. Jednakże sam proces pomiaru jest czasochłonny i żmudny, a często również niewystarczająco precyzyjny, zwłaszcza w przypadku bardziej skomplikowanych

kształtów ciała. Jednym z możliwych rozwiązań tych problemów jest wykorzystanie technologii skanowania 3D. Dzięki niej możliwe są szybkie i precyzyjne pomiary ciała, bez konieczności fizycznego kontaktu z osobą mierzoną. Skanery 3D mogą wykonać setki pomiarów w ciągu kilku sekund tworząc dokładny model ciała [24], który może być następnie poddany automatycznej analizie antropometrycznej oraz wykorzystany do projektowania i produkcji odzieży.

2.3. Metody cyfrowe

2.3.1. Zarys procesu


Podstawą nowoczesnych metod antropometrycznych jest technologia skanowania 3D, która pozwala na precyzyjny pomiar skomplikowanej geometrii, morfologii oraz wyglądu ciała człowieka. Integruje m.in. zaawansowaną optykę, optoelektronikę, mechanikę, widzenie oraz coraz częściej uczenie maszynowe, a jej bezpośrednim wynikiem jest z reguły chmura punktów lub mapy głębi [25] (patrz Rysunek 2.2). Przegląd ciągle ewoluujących technik skanowania 3D w kontekście pomiarów ciała został szeroko opisany w literaturze [25], [37], [52]–[61].



*Rysunek 2.2 Przykłady reprezentacji danych 3D na przykładzie królika Stanforda [62]:
a) chmura punktów, b) woksele, c) drzewo ósemkowe, d) siatka trójkątów, (e) mapa głębi
(źródło rysunku: [63]).*

Typowa procedura postępowania w antropometrii 3D obejmuje następujące kroki: przygotowanie do pomiaru, akwizycję danych i na końcu ich przetwarzanie, którego wynikiem jest zestaw wymiarów ciała ludzkiego [4], [25]. Pierwszy etap jest opcjonalny i może dotyczyć zarówno aspektów sprzętowych, takich jak konfiguracja czy kalibracja systemu [4], jak i przybrania odpowiedniej pozycji do skanowania czy oznaczenie ciała osoby mierzonej znacznikami zgodnie z normami [25]. W następnym kroku przeprowadzany jest proces skanowania wybraną techniką, a jego wynik poddawany jest dalszej analizie.

Właściwe wyznaczanie wymiarów człowieka poprzedzone jest wstępnym przetwarzaniem obejmującym filtrację czy łączenie danych z wielu sensorów, wykryciem cech charakterystycznych na ciele i/lub dopasowaniem do zebranych danych modelu statystycznego, albo wstępnie przygotowanej siatki trójkątów. Dodatkowo skan ciała ludzkiego często bywa uprzednio dzielony na kilka części (głowa, tors, obie ręce i obie nogi), aby zredukować przestrzeń poszukiwania cech [64], [65]. Poglądowy schemat pomiaru antropometrycznego 3D, uwzględniający najnowsze techniki pozyskiwania danych wykorzystujące uczenie maszynowe, został zaprezentowany na Rysunku 2.3 [25].



Rysunek 2.3 Schemat pomiaru antropometrycznego 3D: 1) przygotowanie do skanowania zgodnie z zaleceniami norm, 2) właściwe skanowanie, 3) detekcja cech charakterystycznych (z reguły punktów antropometrycznych czy sylwetek), 4) dopasowanie istniejącej siatki trójkątów lub statystycznego modelu do skanu, 5) wyznaczenie wymiarów. Etapy opcjonalne 1, 3, 4 zostały oznaczone kolorem szarym (źródło rysunku: [25]).

2.3.2. Rekonstrukcja 3D ciała człowieka

Metody skanowania 3D

Wspólną cechą łączącą różne technologie skanowania 3D ciała dla potrzeb antropometrii jest wykorzystanie urządzeń optycznych do bezkontaktowego pozyskania danych. Metody te różnią się jednak sposobem akwizycji współrzędnych powierzchni. Można je podzielić na dwie główne grupy – pasywne (korzystające z naturalnego oświetlenia, zazwyczaj

słonecznego) i aktywne (wspierane dodatkowym źródłem sygnału) [66]. Do najczęściej używanych zalicza się [25], [46], [59], [67], [68]:


- triangulację laserową (z ang. *Laser Triangulation*, LT) – technika analizy deformacji kształtu i kąta odbicia emitowanej wiązki laserowej [69],
- analizę czasu przelotu wiązki (z ang. *Time of Flight*, ToF) – technika pomiaru odległości polegająca na pomiarze czasu jaki wiązka świetlna potrzebuje na podróż do celu i z powrotem [70], sensory wykorzystujące impulsowe lub ciągłe modulowane światło lasera znane są też pod nazwą LiDAR (z ang. *Light Detection And Ranging*) [71],
- projekcję światła strukturalnego (z ang. *Structured Light*, SL) – proces rekonstrukcji opierający się na podstawie deformacji projektowanego wzoru np. prążków sinusoidalnych [72],
- fotogrametrię – odtworzenie kształtu na podstawie zestawu zdjęć wykonanych z różnych perspektyw i geometrycznych różnic pomiędzy nimi z zastosowaniem technik, takich jak MVS (z ang. *Multi-View Stereo*) [73], SfM (z ang. *Structure from Motion*) [74] czy SfS (z ang. *Shape from Silhouette*) [68].

W Tabeli 2.1 przedstawione zostało uproszczone porównanie wybranych parametrów powyższych metod akwizycji: dokładności, rozdzielczości, czasu akwizycji, wymaganej do rekonstrukcji minimalnej liczby kierunków obserwacji oraz stopnia skomplikowania systemu wpływającego na koszt [67].

Tabela 2.1 Porównanie metod skanowania 3D ciała (źródło tabeli: [67]).

Metoda akwizycji	Dokładność	Rozdzielczość	Czas	Kierunki obserwacji	Koszt
SL	< 1 mm	> 1 punkt na mm ²	< 8 ms	2	zestaw kamer i projektor lub źródło laserowe
ToF	< 4 mm	> 0,25 punktu na mm ²	< 8 ms	1	zestaw kamer i aktywne oświetlenie
fotogrametria	< 2 mm	> 0,25 punktu na mm ²	< 8 ms	> 5	tylko zestaw kamer
LT	< 1 mm	> 1 punkt na mm ²	> 66 ms	2	zestaw kamer i projektor lub źródło laserowe

W ostatnich latach, wraz z popularyzacją urządzeń do akwizycji na poziomie konsumenckim, nasiliły się badania nad rekonstrukcją 3D geometrii ciała ludzkiego na podstawie prostych danych, takich jak zdjęcia [61], nagrania wideo [75]–[77], zestawy podstawowych wymiarów ciała [78]–[83] a nawet same opisy oczekiwanej sylwetki [78], [84]. Dynamiczny rozwój metod wykorzystujących uczenie maszynowe był możliwy dzięki wzrostowi dostępności obszernych zestawów danych 2D i 3D z adnotacjami [85]–[103] (przykłady na Rysunku 2.4). Na szczególną uwagę w tym kontekście zasługuje projekt CAESAR (z ang. *Civilian American and European Surface Anthropometry Resource*) [104], czyli jedno z pierwszych cyfrowych badań antropometrycznych dokonanych na szeroką skalę, którego dane 3D zostały udostępnione, co miało istotny wpływ na rozwój technik modelowania 3D ciała. Przegląd nowoczesnych technik rekonstrukcji z wykorzystaniem danych uczących przedstawiono poniżej.




Rysunek 2.4 Przykłady dostępnych typów danych 2D i 3D do uczenia maszynowego (od lewej): binarne i szaroodcieniowe sylwetki 2D, siatka trójkątów modeli parametrycznych 3D, szkielet, skan 3D w postaci chmury punktów, wymiary ciała (źródło rysunku: [105]).

Modele parametryczne


Dopasowanie do obrazu modelu parametrycznego 3D w postaci siatki trójkątów jest obecnie jedną z podstawowych metod przybliżonej rekonstrukcji ciała człowieka. Polega ona na optymalizacji parametrów pozy i kształtu modelu (tzw. fenotypu [106]), tak aby najlepiej pasowały do danych wejściowych obejmujących obrazy 2D, kontury sylwetki, szkielet,

punkty orientacyjne czy bezpośrednio, zaszumione dane ze skanera 3D [25], [61]. Docelowa geometria może być pozyskana zarówno w typowym dla dziedziny animacji komputerowej procesie deformowania siatki [107], jak i za pomocą regresji z wykorzystaniem modeli statystycznych [25]. Do statystycznego badania zmian fenotypu w zestawie dopasowywanych szablonów siatek stosowana jest analiza głównych składowych (z ang. *Principal Components Analysis*, PCA), która pozwala zredukować liczbę parametrów do opisu zbioru danych przy zachowaniu ich maksymalnej wariancji [25]. Najbardziej znanymi przykładami wytrenowanych modeli statystycznych są SCAPE (z ang. *Shape Completion and Animation of People*) [108], SMPL (z ang. *Skinned Multi-Person Linear*) [109], STAR (z ang. *Sparse Trained Articulated Regressor*) [110], GHUM (z ang. *Generative 3D Human Shape and Articulated Pose Model*) [111] oraz Adam [112]. Ilustracje statystycznych modeli SCAPE dla najbardziej znaczących komponentów PCA zostały zaprezentowane na Rysunku 2.5.



Rysunek 2.5 Przykłady wygenerowanych modeli SCAPE dla pierwszych czterech składowych PCA w przestrzeni deformacji kształtu ciała (źródło rysunku: [108]).


W ostatnich latach metody wykorzystujące głębokie sieci neuronowe (z ang. *Deep Neural Network*, DNN), a w szczególności ich konwolucyjny podtyp (z ang. *Convolutional Neural Network*, CNN) pozwoliły na zwiększenie dokładności dopasowania estymowanego modelu parametrycznego zwłaszcza w przypadku niepełnych czy mało licznych danych wejściowych [113]–[123]. Przykładowa konwolucyjna sieć neuronowa BfSNet (z ang. *Body from Silhouette Network*), wykorzystująca do rekonstrukcji 3D obrazy sylwetek ciała i podstawowe dane takie jak wzrost, została zaprezentowana na Rysunku 2.6 [121]. Techniki te szczególnie dobrze sprawdzają się w przypadku rekonstrukcji człowieka w ubraniu, gdzie podstawowe dopasowanie szablonu siatki może być niewystarczające [61].



Rysunek 2.6 Architektura sieci CNN BfSNet do rekonstrukcji 3D ciała na podstawie zaszumionych obrazów sylwetek. Dane wejściowe sieci obejmują maski segmentacyjne, a także znane cechy, takie jak wzrost, waga czy płeć. Z kolei na dane wyjściowe składa się położenie środków stawów, objętość siatki trójkątów, pozycja szkieletu i parametry kształtu modelu SMPL (źródło rysunku: [121]).

Modele nieparametryczne

Zamiast skupiać się tylko na optymalizacji parametrów siatki i pozy szkieletu względem obrazów, najnowsze badania obejmują wykorzystanie wytrenowanych DNN na danych 3D w różnej formie. Najczęściej do ich uczenia stosowana jest reprezentacja w postaci chmur punktów [124]–[129], wolumetrycznej [130]–[134] i funkcji uwikłanych [135]–[144]. Zastosowanie funkcji uwikłanych i ich neuronowych kombinacji to nowy trend, który dynamicznie się rozwija oraz zasługuje na szczególną uwagę. Dzięki nim możliwy jest wydajny sposób reprezentowania modeli 3D, ponieważ nie muszą przechowywać w pamięci wszystkich wokseli czy punktów chmury [61]. Postęp w dziedzinie rekonstrukcji ciała na podstawie jednego obrazu z wykorzystaniem funkcji uwikłanych został przedstawiony na Rysunku 2.7.



Rysunek 2.7 Rozwój metod rekonstrukcji ciała z wykorzystaniem funkcji uwikłanych na przełomie lat 2019-2023: PIFu (z ang. *Pixel-aligned Implicit Function*, 2019) [136], PIFuHD (z ang. *Pixel-aligned Implicit Function for High-Resolution 3D Human Digitization*, 2020) [137], PaMIR (z ang. *Parametric Model-conditioned Implicit Representation*, 2021) [145], ICON (z ang. *Implicit Clothed humans Obtained from Normals*, 2022) [144], SIF (z ang. *Skeleton-aware Implicit Function*, 2023) [141], GT (z ang. *Ground Truth*) – referencyjny model SMPL (źródło rysunku: [141]).

W ostatnim czasie w literaturze naukowej pojawiły się również metody NeRF (z ang. *Neural Radiance Fields*) [95], [146]–[149]. Ich działanie polega na uczeniu się reprezentacji scen 3D na podstawie częściowych obserwacji z rzadkiego zestawu obrazów 2D. Zarówno funkcje uwikłane, jak i NeRF mogą zostać wykorzystane do rekonstrukcji skomplikowanej geometrii i wyglądu człowieka. Jednakże metody NeRF dostarczają wyniki w bardziej kompaktowej formie, a ich kluczową zaletą jest to, że są w stanie zredukować koszty przechowywania zdyskretyzowanych siatek wokselowych podczas odtwarzania złożonych scen w wysokiej rozdzielczości [61]. Choć nie były jeszcze stosowane bezpośrednio do badań antropometrycznych, to jest to zapewne tylko kwestią czasu i dojrzałości tych technik.


2.3.3. Przygotowanie danych

Niezależnie od zastosowanej metody skanowania 3D dane pozyskane bezpośrednio z sensorów nie są wolne od nieprawidłowości, ubytków i niepożądanych obiektów tła. Ze względu na czynniki, takie jak przesłonięcia, odbicia światła od powierzchni czy kąt skanowania, pojawienie się szumu jest nieuchronne i prowadzi do powstawania błędnych punktów odstających [150]. W kontekście precyzyjnej antropometrii 3D kluczowe znaczenie ma jakość analizowanej chmury punktów, od której zależy pomyślny przebieg kolejnych etapów procesu przetwarzania. W związku z tym konieczne jest przeprowadzenie wstępnej obróbki danych w celu poprawy odwzorowania geometrii powierzchni, a co za tym idzie dokładności w kontekście wymiarowania ciała. Ponadto dane wyjściowe z poszczególnych urządzeń skanujących reprezentują często jedynie wycinek przestrzeni i wymagają łączenia w całość z uwzględnieniem wzajemnego położenia. Celem ułatwienia dalszego przetwarzania możliwe jest również przeprowadzanie semantycznej segmentacji skanu w kolejnym kroku. Główne etapy wstępnego przetwarzania danych obejmują zatem [4]:

- filtrację szumu,
- uzupełnienie braków,
- orientację wzajemną chmur punktów z poszczególnych sensorów,
- segmentację.

Filtracja szumu

Punkty odstające można podzielić na następujące kategorie ze względu na ich położenie w przestrzeni: grupy pojedynczych punktów o niskiej gęstości; odizolowane klastry, które charakteryzują się wysoką gęstością i są istotnie oddalone od skanowanego obiektu oraz punkty wmieszane, które są blisko zeskanowanej powierzchni, co utrudnia ich rozróżnienie [151]. Powyższe typy rozkładów szumu zaprezentowano na Rysunku 2.8.



Rysunek 2.8 Przykłady rozkładów szumu: ramka niebieska – odizolowane grupy punktów o dużej gęstości, ramka czerwona – pojedyncze, rzadkie grupy punktów, ramka zielona – błędne punkty wymieszane z właściwymi na powierzchni (źródło rysunku: [151]).

Metody usuwania punktów odstających można podzielić na dwie główne grupy stosujące [151]:

- analizę ciągłości powierzchni [152]–[164] – przykładem może być analiza statystyczna zagęszczenia punktów w otoczeniu [153] czy ich klasteryzacja [162],
- dopasowanie powierzchni [165]–[169] – np. anizotropowe wygładzanie na podstawie krzywizny średniej Gaussa [165] czy dopasowanie płaszczyzny ważoną metodą najmniejszych kwadratów [169].


Punkty odstające można też usunąć stosując np. filtrację spektralną [170].

Filtracja na podstawie analizy ciągłości zazwyczaj koncentruje się na konkretnym rodzaju szumu i nie ma zastosowania do innych typów wartości odstających. Sprawdza się w wykrywaniu pojedynczych punktów i usuwaniu odizolowanych klastrow. Niestety ma też tendencję do błędnej detekcji punktów na krawędziach, których gęstość otoczenia lokalnie spada. Ponadto nieprawidłowe punkty na powierzchni są zwykle ignorowane. Dopiero

zastosowanie metod opartych o dopasowanie powierzchni pozwala je usunąć lub zredukować ich wpływ poprzez wygładzenie geometrii. Jednakże algorytmy te wymagają ciągłości danych by były skuteczne [151].

Uzupełnianie ubytków


Problem generowania zwartych, czyli pozbawionych dziur i nieciągłości powierzchni modeli 3D, jest zazwyczaj rozwiązywany za pomocą algorytmów dopasowania siatki trójkątów [68]. Do najpopularniejszych metod tego typu można zaliczyć: rekonstrukcję Poissona na rzadkiej chmurze punktów [171], wypełnianie otworów w siatce trójkątów przy użyciu metody najmniejszych kwadratów [172] oraz dyfuzję wolumetryczną [173]. Modelowanie nieznannej geometrii dziur jest również możliwe za pomocą powierzchni algebraicznych [174] lub dopasowania płatów Béziera do punktów sąsiadujących z krawędzią ubytku powierzchni (patrz Rysunek 2.9) [175].



Rysunek 2.9 Przykład rekonstrukcji brakującej geometrii na chmurze punktów za pomocą płatów Béziera w obszarze pachy: a) widok od frontu, b) widok od góry z wnętrza skanu (źródło rysunku: [175]).

Zaprezentowane powyżej metody mają charakter uniwersalny i mogą zostać zastosowane do dowolnej chmury punktów. Natomiast w przypadku uzupełniania dziur w skanach ciała człowieka możliwe jest posiłkowanie się wiedzą o typie obiektu i dopasowanie modeli parametrycznych opisanych szerzej w poprzednim podrozdziale 2.3.2. Wynikiem tego procesu jest czysta i spójna topologicznie siatka trójkątów, która wypełnia dziury

w oryginalnym, zaszumionym skanie 3D [25]. Przykład rekonstrukcji niepełnej chmury punktów ręki z wykorzystaniem metody IP-Net (z ang. *Implicit Part Network*) [140] łączącej sieci neuronowe, funkcje uwikłane i modele parametryczne został zaprezentowany na Rysunku 2.10.



Rysunek 2.10 Przykład rekonstrukcji brakującej geometrii na chmurze punktów z wykorzystaniem sieci IP-Net: a) chmura punktów, b) dopasowany model parametryczny (źródło rysunku: [140]).

Orientacja wzajemna chmur punktów

Uzyskanie pełnej geometrii powierzchni ciała człowieka wymaga przeprowadzania skanowania z wielu pozycji dookoła niego. W celu osiągnięcia jednolitej chmury punktów z różnych źródeł, wszystkie częściowe skany powinny zostać połączone w jednym układzie odniesienia za pomocą procesu znanego jako orientacja wzajemna lub rejestracja (z ang. *registration*) [176]. Dopasowywane do siebie skany powinny się przynajmniej częściowo pokrywać, aby było to możliwe [177], [178]. Rysunek 2.11 poniżej przedstawia wizualizację tego problemu.

W ogólności dopasowanie powierzchni może odbywać się za pomocą wyznaczenia macierzy transformacji afinicznej (z ang. *rigid registration* – rejestracja ciała sztywnego) lub deformacji elastycznej (z ang. *non-rigid registration* – rejestracja ciała deformującego się) [180]. W przypadku rejestracji ciała sztywnego wszystkie punkty ulegają jednorodnej rotacji i translacji, co wykorzystywane jest do orientacji wzajemnej kształtów statycznych. Rejestracja ciała deformującego się z kolei uwzględnia zniekształcenia powierzchni wynikające np. ze zmiany położenia kończyn pomiędzy skanami wykonanymi w różnych pozycjach [179].



Rysunek 2.11 Przykład orientacji wzajemnej dwóch częściowych chmur punktów (źródło rysunku: [179]).

W przypadku wielosensorowej akwizycji w statycznej pozie wykorzystuje się algorytmy do rejestracji ciała sztywnego, zakładając niewielkie ruchy osoby skanowanej w trakcie trwania pomiaru. Proces orientacji wzajemnej często bywa dzielony na dwa etapy: zgrubny i dokładny [176], [181]. Do dokładnej rejestracji najczęściej używany jest optymalizacyjny algorytm ICP (z ang. *Iterative Closest Point*) [182] i jego warianty [183]–[187]. ICP wymaga dobrego początkowego przybliżenia transformacji by móc zbiec do globalnego minimum. Jednakże nawet w przypadku znacznego pokrycia się wzajemnego skanów zbieżność ta nie zawsze jest zagwarantowana [188]. Dlatego na ogół dwie chmury punktów są najpierw orientowane wzajemnie w przybliżony sposób za pomocą zgrubnej, ale mniej dokładnej metody. Do kategorii tych metod zalicza się te oparte o wykrywanie cech charakterystycznych (z ang. *feature-based*) [176]. Na podstawie wykrytych na ich podstawie korespondujących ze sobą par punktów pomiędzy skanami wyznaczana jest transformacja, najczęściej metodą RANSAC (z ang. *Random Sample Consensus*) [178], [189].


Techniki dopasowania ciała sztywnego można również podzielić na tradycyjne i wykorzystujące głębokie uczenie [178], [190]. Do tradycyjnych zaliczają się nie tylko wcześniej opisane techniki optymalizacyjne i wykrywania cech, ale też i algorytmy korelacji

wzajemnej czy operujące w dziedzinie częstotliwościowej [190]. Sieci DNN nie tylko wspierają wyszukiwanie cech charakterystycznych, ale też i usuwanie wartości odstających z zestawu orientowanych wzajemnie punktów, co pozwala zwiększyć dokładność dopasowania [190].

Segmentacja


Typowy proces pozyskania danych antropometrycznych bezpośrednio z chmury punktów ciała człowieka obejmuje jej podział względem podstawowych części ciała, co pozwala uprościć dalsze przetwarzanie [64], [65]. Można wyróżnić trzy główne kategorie metod segmentacji, które wykorzystują [67]:

- analizę przecięć i przekrojów 2D [191]–[197] – algorytmy tej grupy wykorzystują wiedzę a priori o geometrii kształtu człowieka w zadanej statycznej pozie [197], a do wyznaczania granic pomiędzy konturami segmentów definiowanych z reguły w miejscu krocza, pach i szyi [192]–[194] stosują m.in. logikę rozmytą [192], analizę krzywych [191], [195], [196] i dopasowanie kształtu do przekrojów [191], [196], [197] (patrz Rysunek 2.12),



Rysunek 2.12 Segmentacja za pomocą przecięć i analizy ich przekrojów dla: a) głowy, b) rąk, c) nóg oraz d) wynik segmentacji (źródło rysunku: [197]).

- topologię i szkieletyzację [198]–[210] – metody te polegają na przekształceniu reprezentacji chmury punktów w strukturę topologiczną w procesie tzw. szkieletyzacji. Obejmują m.in. algorytmy wyznaczania grafu Reeba [198] (patrz Rysunek 2.13), klasteryzacji spektralnej [209] czy mapowania cech izometrycznych [206]. Techniki topologiczne w porównaniu do metod analizy przekrojów są bardziej uniwersalne, gdyż nie są ograniczone do jednej pozy [67],




Rysunek 2.13 Segmentacja topologiczna z wykorzystaniem grafu Reeba: a) zbiór poziomic kształtu ciała, b) graf Reeba, c) dyskretny graf Reeba, d) wizualizacja poziomic na podstawie odległości geodezyjnej [211] na rzeczywistych danych, e) wyniki (opracowanie własne na podstawie źródła: [201]).

- uczenie maszynowe [212]–[229] – różnorodna grupa metod obejmująca techniki, takie jak losowe pola Markowa (z ang. *Markov Random Fields*, MRF) [213], losowe lasy (z ang. *Random Forests*, RF) [218] czy warianty sieci CNN wykorzystujące m.in. globalną, bezszwową parametryzację dla kształtów sferycznych [221], opis sparametryzowanego płatu otoczenia za pomocą deskryptorów kształtu [227] (patrz Rysunek 2.14) lub kierunkową sieć konwolucyjną (z ang. *Directionally Convolutional Network*, DCN).

Techniki topologiczne w porównaniu do analizy przekrojów są bardziej uniwersalne, gdyż nie są ograniczone do jednej pozy [67]. Z kolei sieci neuronowe do procesu uczenia wykorzystują duże zbiory danych zarówno rzeczywistych, jak i syntetycznych, co pozwala im osiągnąć wysoką dokładność i wydajność w różnorodnych zastosowaniach segmentacji chmury punktów [67].

Następnym krokiem przetwarzania jest znalezienie punktów antropometrycznych na ciele człowieka będących podstawą do określenia jego rozmiarów i kształtów. Należy jednakże nadmienić, iż podejścia antropometrii 3D wykorzystujące modele parametryczne do rekonstrukcji geometrii 3D ciała nie wymagają przeprowadzenia ani tego, ani kolejnego etapu, ponieważ dla każdego z wierzchołków dopasowanej siatki trójkątów znana jest jego semantyka [109].



Rysunek 2.14 Segmentacja za pomocą sieci CNN, gdzie dla każdego wierzchołka wyznaczany jest lokalny płat na powierzchni, który następnie parametryzuje się i rzutuje na siatkę 2D. Przypisane do siatki globalne i lokalne deskryptory, takie jak krzywizny średnie czy Gaussa [230], średnia odległość geodezyjna [211] i WKS (z ang. Wave Kernel Signature) [231] stanowią wejście do sieci VGG16 [232], która dokonuje regresji etykiety semantycznej (źródło rysunku: [227]).

2.3.4. Detekcja punktów antropometrycznych

Punkty antropometryczne są jednym z najważniejszych obszarów zainteresowania w dziedzinie pomiaru człowieka ze względu na bezpośredni i istotny wpływ na jakość oraz wynik mierzenia [233]. W literaturze znane są też pod nazwą punktów orientacyjnych (z ang. *landmark*) lub bardziej ogólnie charakterystycznych czy kluczowych, a przypisane jest do nich położenie i nazwa [234]. W antropometrii 3D definiowane są jako unikalne i jednoznacznie określone miejsca na powierzchni skóry człowieka lub względem niej [27], [235], których używa się do definiowania wymiarów ciała i anatomicznej zgodności pomiędzy dwoma różnymi skanami ciała oraz charakteryzowania zarówno wielkości, jak

i kształtu populacji ludzkich [233], [236]. W przypadku zastosowań w przemyśle odzieżowym można je podzielić na następujące kategorie [27] w zależności od przeznaczenia:


- środki stawów – miejsca połączeń i stawów kończyn oraz obszary, w których ruch powoduje zmianę pomiaru np. kolana i łokcie,
- segmentacyjne – punkty podziału ciała na regiony np. lewy łokieć dzielący rękę na ramię i przedramię,
- referencyjne – punkty podziału obwodów (część lewa/prawa czy przednia/tylna), co pomaga przenieść wymiary ciała na projekt odzieży i umożliwia lepsze zrozumienie wymagań jej kształtowania

lub ze względu na ich typologię:

- szkieletowe – główne punkty określające pozycję na ciele w odniesieniu do znajdującej się pod spodem struktury szkieletowej np. kostka, siódmy kręg szyjny (C7) czy łokieć,
- tkanki miękkiej (mięśnie) – punkty na powierzchni ciała definiowane względem tkanki mięśniowej, takiej jak biceps, łydka i udo,
- tkanki miękkiej (tkanka tłuszczowa) – punkty na powierzchni ciała definiowane względem tkanki tłuszczowej np. fałdy talii czy bruzdy pośladkowej,
- tkanki miękkiej (cecha powierzchni skóry) – punkty wyróżniające się na powierzchni, takie jak sutek, pępek i oczy,
- pochodne – punkty odniesienia względem innych punktów np. tył kolana na wysokości środka rzepki z przodu,
- największego/najmniejszego obwodu – punkty definiowane na podstawie skrajnego pomiaru w danym obszarze np. biodro jako największy obwód dolnej części tułowia czy nadgarstek jako najmniejszy obwód przedramienia,
- najwęższe/najszerze – punkty reprezentujące najwęższy/najszerzy punkt w danej płaszczyźnie, używane jako punkt pośredni dla określenia pozycji talii czy bioder,
- największej wypukłości – punkty orientacyjne zdefiniowane jako największa wypukłość ciała lub środek obszaru o największej wypukłości, takie jak biust i pośladki, maksymalny obwód brzucha i wystające łopatki,
- najwyższe/najniższe – skrajne punkty płaszczyźnie poprzecznej np. podeszwa stopy czy wierzchołek głowy,

- zdefiniowane przez produkt – punkty dedykowane dla danego projektu odzieży np. paska do spodni, ramiączek czy kształtów miseczek stanika.

Dokładne wyznaczenie punktów antropometrycznych tylko na podstawie powierzchni bywa niemożliwe bez palpacyjnego badania podskórnych struktur kostnych [233]. Ponadto ich położenie w przestrzeni ulega znaczącej zmianie nawet przy niewielkim ruchu ciała, co wymaga utrzymania statycznej sylwetki podczas pomiarów [27]. Typowe pozycje dla skanowania 3D zostały zdefiniowane w normie ISO 20685 [32]. Najczęściej rekomendowana jest postawa A, w której ramiona są odwodzone od tułowia pod kątem 20°, a odległość między osiami obu stóp wynosi 20 cm, gdyż jest relatywnie bliska postury anatomicznej, która może być traktowana jako podstawowa postawa do analizy anatomii i ruchu [27], [32]. Pozycja ta zapewnia lepszą widoczność dla sensorów pomiarowych, a co za tym idzie bardziej kompletny skan 3D niż tradycyjna, w pełni wyprostowana sylwetka [21]. Przykłady punktów orientacyjnych w pozycji A zaprezentowano na Rysunku 2.15.




Rysunek 2.15 Zestawienie antropometrycznych punktów orientacyjnych 3D do zastosowań w branży tekstylnej wraz z przykładowymi wykrojami odzieży (źródło rysunku: [27]).

Punkty antropometryczne na podstawie danych 3D można wyznaczać ręcznie, półautomatycznie za pomocą znaczników lub w pełni automatycznie [25]. Podobnie jak w przypadku tradycyjnego określania położenia za pomocą dotyku, manualne wybieranie punktów na skanie jest żmudnym zadaniem i podatnym na subiektywność operatora oraz błędy związane z czynnikiem ludzkim [237], [238]. Częściowa automatyzacja procesu może obejmować wybór lokalizacji do przymocowania znaczników, ich wykrycie na skanie czy przyporządkowanie etykiety [21]. Znaczniki mogą być zarówno pasywne (najczęściej retrorefleksyjne), jak i aktywne, czyli emitujące światło, co ułatwia ich wykrywanie [239]. Ich detekcja bywa też upraszczana za pomocą wykorzystania kodowania kolorem [65].

Algorytmy automatycznej detekcji punktów orientacyjnych na chmurze punktów ciała zwykle opierają się na trzech rodzajach informacji: wiedzy a priori, informacji o geometrii i cechach powierzchni oraz dopasowaniu szablonów [4]. W pierwszym z tych podejść ogólne cechy charakterystyczne ciała człowieka ujęte są w postaci zasad, które określają relacje pomiędzy punktami. Przykładem może być reguła „różnica w osi Z pomiędzy lewym i prawym wyrostkiem barkowym nie powinna przekroczyć 38 mm”, która pozwala na odróżnienie tego punktu od pachy [236]. Do predefiniowanych relacji pomiędzy kształtami powierzchni części ciała możliwe jest również zastosowanie logiki rozmytej [192]. Kolejna grupa metod wykorzystuje informacje o właściwościach wyróżniających dany punkt na ciele. Kategoria ta obejmuje m.in.: analizę cech powierzchni (np. krzywiznę gaussowską, indeks kształtu) [240], [241], analizę konturów sylwetki, wyznaczanie minimalnego obwodu, detekcję w skali szarości czy wykresów konturowych ciała człowieka [64], [238]. Powyższe dwie grupy metod można też zbiorczo określić jako systemy eksperckie [242]. Niestety ich heurystyki bywają zawodne i są w dużym stopniu zależne od jakości danych [243]. Ostatnia kategoria obejmuje bardziej uniwersalne [4] dopasowanie modeli opisanych za pomocą szablonów [244], [245] czy parametrycznych funkcji kształtu [8] na podstawie stopnia ich podobieństwa. Porównanie sześciu automatycznych metod do nauki i przewidywania lokalizacji punktów antropometrycznych na podstawie deskryptorów kształtu, takich jak SI (z ang. *Spin Image*) [246] czy HKS (z ang. *Heat Kernel Signature*) [247] oraz dopasowania zdeformowanych powierzchni zostało przedstawione w artykule [248]. Przykład algorytmu tego typu wykorzystujący deskryptor SI i graf wzajemnego ułożenia punktów w przestrzeni został przedstawiony na Rysunku 2.16. W przypadku grupy tych metod dokładność wyznaczenia punktów orientacyjnych zależy bezpośrednio od dokładności dopasowania szablonu. W celu zniwelowania nieizometrycznej różnicy z zestawu danych treningowych wybierany jest


model najbardziej zbliżony do docelowego [224]. Postęp w dziedzinie dopasowania kształtów w ostatnich latach [249]–[251] może się przyczynić do dalszego zwiększenia dokładności wyznaczania punktów orientacyjnych tymi metodami.



Rysunek 2.16 Metoda automatycznej detekcji punktów antropometrycznych na podstawie ich charakterystyki oraz wzajemnego ułożenia w przestrzeni z wykorzystaniem losowych pól Markowa: a) obraz deskryptora SI ((a) wklęsłość pomiędzy kością czołową i nosową, (b) środek brodawki piersiowej, (c) nadkłykieć boczny kości udowej), b) model grafowy sieci Markowa, c) porównanie wyników metody z referencyjnymi markerami wyznaczonymi w badaniu CAESAR (czerwony – referencja, zielony – prezentowana metoda) (opracowanie własne na podstawie źródła: [252]).


Nowoczesne metody wykrywania punktów antropometrycznych za pomocą uczenia maszynowego wykorzystują ponadto m.in. regresję za pomocą losowych lasów [253] czy algorytmu AdaBoost (z ang. *Adaptive Boosting*) [234], a także techniki głębokiego uczenia

[254]–[259]. Przykładem ich zastosowania jest użycie potrójnej sieci CNN do wytrenowania deskryptorów potrafiących rozróżnić punkty orientacyjne, co pozwoliło poprawić dokładność ich identyfikacji, ale nie lokalizacji [254]. Detekcja punktów za pomocą konwolucyjnych sieci neuronowych jest też możliwa w przestrzeni 2D na podstawie map głębi i rzutów map krzywizny oraz oświetlenia modelu ciała 3D na płaszczyznę [255], [256]. Pozwala to na zredukowanie wpływu niedoskonałości modeli 3D, takich jak szum czy ubytki. Niemniej jednak na skuteczność tych metod nadal wpływ ma poza przyjęta przez osobę skanowaną, od której zależy wygląd wygenerowanych rzutów. Uniezależnienie od postawy możliwe jest np. poprzez wstępne wyrównanie segmentów modelu ciała, co zostało zastosowane m.in. w metodzie z regresją AdaBoost [234]. Schemat działania tej techniki zaprezentowany został na Rysunku 2.17.



Rysunek 2.17 Schemat metody automatycznej detekcji punktów antropometrycznych za pomocą regresji AdaBoost z wykorzystaniem zestawu deskryptorów kształtów, takich jak PHDS (z ang. Part Heat Diffusion Signature) [234], WKS czy wektory normalne (źródło rysunku: [234]).

Oszacowanie wymiarów ciała możliwe jest nie tylko na podstawie punktów antropometrycznych 3D, ale i 2D (patrz podrozdział 2.3.5 niżej). W tym celu można je wyznaczać np. za pomocą analizy konturów sylwetek w przestrzeni 2D [260]–[264]. Ponadto warto zaznaczyć, że uogólniona detekcja punktów orientacyjnych jest istotna nie tylko w kontekście definicji miejsc pomiarowych na ciele człowieka, ale również w przypadku wcześniej omawianej orientacji wzajemnej chmur punktów [4] (patrz podrozdział 2.3.3 wyżej), a także w procesie estymacji pozy. Wynikiem tej ostatniej jest szkielet stworzony na podstawie punktów odpowiadających środkom stawów [265]–[270]. Przykłady detekcji punktów w przestrzeni 2D zaprezentowano na Rysunku 2.18.



Rysunek 2.18 Przykłady wykorzystania danych 2D do detekcji: a) punktów orientacyjnych na podstawie analizy krzywej konturu sylwetki, b) środków stawów – u góry bezpośrednio w przestrzeni 2D za pomocą sieci CNN, u dołu pośrednio w 3D na podstawie przecięć promieni kamer z wielu widoków przechodzących przez wyznaczone przez sieć punkty (źródła rysunków: a) [260], b) [265]).

2.3.5. Wymiarowanie


Pomiar ciała obejmuje wyznaczanie nie tylko bezpośrednich i proporcjonalnych długości, szerokości, głębokości i wysokości, ale także obwodów i łuków krzywych [25], [271]. W odróżnieniu od tradycyjnych metod wykorzystanie skanów 3D pozwala dodatkowo na pomiar powierzchni i objętości ciała wprost [272], co z kolei umożliwia np. pośrednią estymację masy [78]. Nowoczesne techniki antropometryczne operują głównie na danych 3D w postaci chmur punktów lub siatek trójkątów i obrazach 2D z wykrytymi na nich punktami

orientacyjnymi oraz sylwetkami. Poza nimi istnieją również metody statystyczne, które na podstawie ograniczonego zestawu podstawowych danych 1D, takich jak wzrost, waga czy płeć, umożliwiają predykcję pozostałych parametrów ciała [83], [105].

Wymiary człowieka można wyznaczyć bezpośrednio na podstawie geometrii skanów 3D lub pośrednio za pomocą metod uczenia maszynowego obejmujących statystyczne modele parametryczne czy głębokie uczenie. Dopasowywana siatka trójkątów może być zarówno sparametryzowana, co ułatwia proces, gdyż topologia wierzchołków zostaje zachowana, jak i deformowana swobodnie, co pozwala osiągnąć lepszą dokładność odwzorowania powierzchni, ale tracąca jest semantyka jej wierzchołków.

Pomiary bezpośrednie na danych 3D

Pomiary tego typu oparte są o wcześniej wyznaczone punkty antropometryczne. Zazwyczaj dokonywane są bezpośrednio na chmurach punktów lub siatce trójkątów zrekonstruowanej na ich podstawie na etapie przygotowania danych (patrz podrozdział 2.3.3 wyżej, sekcja uzupełnianie ubytków). Wymiary ciała pomiędzy punktami antropometrycznymi wyznaczone są w postaci linii prostej lub wzdłuż konturów ciała [27]. Pomiary odległości mogą być jednego z trzech typów: euklidesowe, geodezyjne i obwodowe. Odległość euklidesową lub geodezyjną można łatwo wyznaczyć na podstawie dwóch punktów chmury lub wierzchołków siatki modelu [81]. Z kolei obwody i ich fragmenty można obliczyć za pomocą metody wykorzystującej otoczkę wypukłą, która przybliża zachowanie taśmy mierniczej [65], [238], [271]. Dane do analizy obwodu uzyskuje się poprzez przecięcie chmury punktów prostopadłą do mierzonej części ciała płaszczyzną w miejscu danego punktu antropometrycznego [25]. Wartość obwodu aproksymowana jest z reguły jako suma długości boków wielokąta otoczki punktów, które znajdują się wokół określonej odległości od płaszczyzny i są na nią rzutowane. W przypadku rzadkiej i zaszumionej chmury możliwe jest też zastosowanie dodatkowej aproksymacji np. krzywymi B-sklejanymi [271]. Schemat procesu wyznaczania otoczki wypukłej zarówno jako obwodu, jak i łuku krzywej pomiarowej został przedstawiony na Rysunku 2.19.




Rysunek 2.19 Schemat aproksymacji wymiarów wirtualną taśmą mierniczą w formie otoczki wypukłej dla: a) obwodu, b) łuku krzywej wzdłuż konturu ciała (źródła rysunków: a) [25], b) [271]).

Pomiary na podstawie modeli parametrycznych

W dziedzinie antropometrii cyfrowej szczególnym zainteresowaniem cieszą się techniki dopasowania modeli parametrycznych do skanów 3D [273]–[275], zdjęć sylwetek 2D [121], [122], [276] oraz wymiarów czy opisów 1D [78], [79], [84] (patrz podrozdział 2.3.2 wyżej, sekcja modele parametryczne). O ile dane 3D pozyskiwane są z reguły ze skalibrowanych skanerów 3D, o tyle w przypadku innych podejść występuje problem braku skali. W przypadku gdy nie jest dostępna informacja o parametrach wewnętrznych i zewnętrznych kamer, kalibrację metryczną najczęściej opiera się o dodatkowe informacje wejściowe, takie jak np. wzrost. Tak jak wcześniej wspomniano, w przypadku zastosowania modeli parametrycznych wyznaczenie linii wymiarowania jest ułatwione dzięki znanej topologii dopasowywanej siatki. Jednakże o ile położenie niezależnych punktów orientacyjnych po deformacji można uznać za poprawne, o tyle przebieg referencyjnej ścieżki pomiarowej w przypadku obwodów często odbiega od oczekiwanego [277].

Do obliczenia wyniku pomiaru wykorzystuje się z reguły jedno z trzech podejść: predefiniowane ścieżki składające się z zestawu kolejnych wierzchołków [273], odległości geodezyjne przechodzące przez ustalone punkty orientacyjne [115], [122], [278] oraz

dopasowanie płaszczyzny do zdeformowanych wierzchołków ścieżki [82], [277], [279]. W pierwszej metodzie sumowane są długości krawędzi pomiędzy referencyjnymi wierzchołkami. Jednakże, ze względu na elastyczny sposób dopasowywania modelu, pozycje wierzchołków mogą być na tyle silnie zdeformowane, że zawczasu zdefiniowana linia pomiarowa nie odpowiada już najkrótszej ścieżce, naturalnej dla tradycyjnej antropometrii. Drugie podejście opiera się o szereg punktów orientacyjnych wzdłuż obwodu, pomiędzy którymi wyznaczane są najkrótsze odległości. Niemniej jednak same punkty orientacyjne są nadal narażone na zbyt duże deformacje, analogicznie do poprzedniego podejścia [82]. Ostatnia grupa technik umożliwia dokładniejszy transfer linii pomiarowej poprzez zastosowanie dodatkowego etapu przetwarzania, obejmującego dopasowanie płaszczyzny do zdeformowanych wierzchołków obwodu. W tym wypadku punkty nowej ścieżki pomiarowej pozyskiwane są w wyniku przecięcia płaszczyzny z siatką trójkątów [82], [279] lub chmurą punktów skanu, na podstawie której model był aproksymowany [277]. Ostateczny wymiar antropometryczny może być przybliżany nie tylko jako suma długości krawędzi siatki trójkątów przynależnych do obwodu, ale również za pomocą otoczki wypukłej [279], analogicznie do wyżej opisanych pomiarów bezpośrednich. Ilustracja problemu zdeformowanego szablonu ścieżki pomiarowej i propozycja jego rozwiązania przedstawiona jest na Rysunku 2.20.




*Rysunek 2.20 Przenoszenie pomiaru talii z referencyjnego szablonu do zdeformowanego:
a) predefiniowana linia pomiarowa na szablonie, b) zniekształcona linia pomiarowa po deformacji modelu, c) dopasowanie płaszczyzny pomiaru do zdeformowanych punktów linii i wyznaczenie nowej ścieżki wymiarowania na podstawie jej przecięcia z modelem (źródło rysunków: a, b, c) [279]).*

Konkretny wymiar antropometryczny na podstawie modelu parametrycznego można wyznaczyć nie tylko na podstawie analizy jednej predefiniowanej ścieżki pomiarowej jak opisano wyżej, ale także poprzez regresję zbioru jej okolicznych alternatywnych wariantów

przebiegu [273]. Określenie wymiarów, z pominięciem etapu optymalizacji i transferu linii pomiarowej, jest także osiągalne za pomocą technik głębokiego uczenia maszynowego [275].

Pomiary bezpośrednie na podstawie cech obrazów 2D


W ostatnich latach dane antropometryczne na podstawie zdjęć sylwetki człowieka pozyskiwane są najczęściej w sposób pośredni na podstawie dopasowanego modelu parametrycznego. Niemniej jednak wymiary ciała człowieka mogą być również określone tylko na podstawie cech obrazu 2D, z pominięciem rekonstrukcji 3D [261]–[264], [280]. Proste długości liniowe można wyznaczyć bezpośrednio jako odległości między punktami antropometrycznymi na konturze sylwetki w widoku od frontu czy boku. W kolejnym etapie mogą być wykorzystywane do uzyskania dwóch rodzajów wymiarów wtórnych, tj. proporcji i obwodów. Nieliniowe obwody przybliżane są z reguły za pomocą okręgów lub elips, których osie określone są na podstawie odcinków pomiędzy punktami konturów. Rysunek 2.21 przedstawia przykład liczenia wybranych długości liniowych oraz obwodu talii jako sumy dwóch połówek elips na podstawie analizy obrysów ciała [263].



Rysunek 2.21 Wymiary antropometryczne na podstawie punktów konturu sylwetki:
a) bezpośrednie liniowe na podstawie widoku od frontu, b) pomocnicze liniowe na podstawie widoku od boku jako część procesu szacowania wartości obwodu, c) pochodny obwodowy na podstawie przybliżenia dwóch połówek elipsy (opracowanie własne na podstawie źródła: [263]).

Estymacja wymiarów za pomocą uczenia maszynowego

Stosunkowo nowym podejściem, które dotychczas zaskakująco rzadko było podejmowane przez badaczy, jest zastosowanie uczenia maszynowego do szacowania wymiarów bezpośrednio z danych wejściowych 2D [82], [103] i 3D [105] z pominięciem etapu dopasowania modelu. Eliminacja tej części procesu pozwala ograniczyć wpływ dodatkowych błędów związanych z pomiarem na dopasowanej siatce trójkątów. Przykładowy schemat procesu wyznaczania wymiarów antropometrycznych na podstawie zdjęć sylwetek z pominięciem pośredniej rekonstrukcji modelu 3D przedstawiony jest na Rysunku 2.22.



Rysunek 2.22 Kolejne etapy procesu wyznaczania wymiarów antropometrycznych na podstawie zdjęć sylwetek z pominięciem pośredniej rekonstrukcji modelu 3D: a) ekstrakcja cech obrazu 2D z wykorzystaniem sieci CNN, b) wielowarstwowa sieć neuronowa mająca na wejściu wektor cech obrazów, a na wyjściu szacowane wymiary, c) opcjonalna rekonstrukcja geometrii na podstawie estymowanych wymiarów z wykorzystaniem PCA (źródło rysunku: [82]).


2.4. Nowoczesne systemy antropometryczne dostępne na rynku

2.4.1. Systemy 3D

Rynek obrazowania 3D rozwija się bardzo dynamicznie i ma wzrosnąć z 3,7 miliarda w 2020 roku do ok. 16,7 miliardów dolarów amerykańskich w 2030 roku [112]. Jego wycinek obejmuje skanery 3D ciała człowieka, których ceny wahają się średnio od ok. 1,4 tysiąca, w przypadku najtańszego rozwiązania do użytku domowego Naked [281], do 250 tysięcy dolarów amerykańskich za studio wolumetryczne Mantis Vision 3iosk [282], [283]. Do najpopularniejszych skanerów antropometrycznych na rynku można zaliczyć produkty, takie

jak Fit3D Proscanner [284], Size Stream SS20 [285], Styku S100 [286], Vitronic Vitus Bodyscan [31], [TC]² TC2-19M [287], Texel Portal BX [288], Twindom Twinstant Mobile v3 [289], Botspot Botscan Neo [290], TG3D Studio Scanatic [291] czy Artec Leo [292]. Oprócz zastosowania, skanery te różnią się między sobą m.in. technologią akwizycji chmury punktów, liczbą sensorów, czasem przetwarzania czy typem konstrukcji (np. kabiny z zamontowanymi na stałe czujnikami, obrotowe podesty dla ciała lub czujników oraz skanery ręczne). Na Rysunku 2.23 przedstawiono przykłady komercyjnych rozwiązań dla różnych metod pomiarowych (patrz podrozdział 2.3.2 wyżej) i form wykonywania pomiaru. Bardziej szczegółowe zestawienie i porównanie parametrów systemów skanowania ciała można znaleźć m.in. w załączniku A opracowania [25] czy aktualnym katalogu internetowym Aniwa [283].


W dziedzinie analizy powierzchni ciała człowieka można zaobserwować dwa główne trendy pozyskiwania danych 3D. Pierwszy z nich, z pomocą stacjonarnych skanerów, zaspokaja potrzebę wysokiej jakości statycznych skanów, które są nieodzowne w przypadku przeprowadzania zaawansowanych badań antropometrycznych społeczeństw i do pozyskiwania referencyjnych zbiorów danych. Podejście to zastosowano m.in. w projektach CAESAR [104], SIZE-UK [293], Scan DB [294] czy FAUST [295]. Wysoka cena i brak mobilności systemów stacjonarnych jest rekompensowana przez krótszy czas skanowania i bardziej przewidywalne wyniki [25]. Drugi nurt w dziedzinie skanowania skierowany jest na tworzenie ekonomicznych, mobilnych i przyjaznych dla użytkownika rozwiązań, przeznaczonych do stosowania w domu lub w sklepie [21], [25]. Do rozwiązań przenośnych należą skanery z platformą obrotową oraz manualne. Te pierwsze pojawiły się na rynku wcześniej, jako tańsza alternatywa dla skomplikowanych, wielosensorowych systemów. Czas skanowania w ich przypadku wynosi z reguły ok. 30-40 sekund [284], [286], [288] przez co trudno o utrzymanie stabilnej pozycji w trakcie pomiaru, co ma wpływ na jego dokładność. Skanery ręczne z kolei są stosunkowo od niedawna na rynku, a ich zastosowania w antropometrii ograniczone z powodu jeszcze dłuższego czasu potrzebnego na pomiar, który liczony jest w minutach [25]. Niemniej jednak są rozwiązaniem znacznie tańszym i dużo bardziej mobilnym, które nadal może być z sukcesem wykorzystane do przeprowadzenia badań antropometrycznych [77], [296], [297]. Ich zaletą jest też możliwość pełniejszego pomiaru przesłoniętych miejsc na ciele [21]. Decyzja o najbardziej odpowiednim sprzęcie zależy zatem od unikalnych wymagań projektu antropometrycznego [4].



Rysunek 2.23 Przykłady komercyjnych skanerów 3D ciała człowieka dla różnych metod pomiarowych i form przeprowadzania pomiaru: a) Vitus Bodyscan – triangulacja laserowa, skanowanie ruchomą poziomą wiązką lasera w stacjonarnej kabinie, b) Styku S100 – czas przelotu wiązki światła podczerwonego, mobilny stół obrotowy, c) Botspot Botscan Neo – fotogrametria, pomiar symultaniczny ze wszystkich kamer zamontowanych statycznie w stacjonarnej kabinie, d) Artec Leo – światło strukturalne, mobilny pomiar ręczny (źródła rysunków: a) [31], b) [286], c) [290], d) [292]).

Do większości wyżej wymienionych systemów pomiarowych dostarczane jest dedykowane oprogramowanie do przeprowadzania analizy antropometrycznej rozwijane przez producenta lub podmiot z nim bezpośrednio związany (m.in. w przypadku Size Stream, Styku czy Vitronic). Jednakże nie jest to regułą i na rynku dostępne są również skanery 3D ciała

człowieka ogólnego przeznaczenia takie jak Botspot Botscan Neo. W takim przypadku możliwe jest wykorzystanie uniwersalnego oprogramowania jakim jest 3D Measure Up [298]. W jednym i drugim przypadku dostarczane programy komputerowe lub zdalne usługi obliczeniowe to zamknięte rozwiązania. Na rynku brakuje rozwiązań otwartych, które mogłyby zostać wykorzystane do ujednolicenia i standaryzacji systemów [27], [207], a także ułatwiłyby weryfikację algorytmów pomiarowych oraz porównywanie ich pomiędzy sobą. Przykładem niejasności i niespójności jest sposób wyznaczenia punktów antropometrycznych na ciele, gdyż różne aplikacje potrafią zwrócić nieidentyczne wyniki dla tych samych danych [244]. Przykład komercyjnego oprogramowania do wyznaczania wymiarów ciała człowieka na podstawie skanów 3D został przedstawiony na Rysunku 2.24.




Rysunek 2.24 Przykład komercyjnego oprogramowania do wyznaczania wymiarów ciała AVALUTION Anthroscan (przed zmianą marki szerzej znane w literaturze jako Human Solutions Anthroscan, aplikacja dedykowana skanerom Vitronic; źródło rysunku: [299]).

2.4.2. Systemy 4D


Zastosowania technologii 4D do skanowania i śledzenia ruchu człowieka nie ograniczają się jedynie do gier, efektów specjalnych [300] czy diagnostyki medycznej [24], ale obejmują również antropometrię [98], [301], [302]. Rozmiar i kształt ludzkiego ciała zmienia się istotnie w trakcie ruchu, co ma wpływ na dopasowanie ubrań, ich komfort noszenia i ergonomię [21].

Do śledzenia położenia i pozy człowieka w czasie używane są głównie systemy MoCap (z ang. *Motion Capture* – przechwytywanie ruchu) [300]. W nowoczesnej antropometrii stosowane są z reguły w sposób pośredni do lokalizacji punktów na ciele takich jak np. środki stawów, a dane zdobyte za ich pośrednictwem odgrywają ważną rolę w procesie uczenia modeli estymujących położenie szkieletu [25]. Niemniej jednak pełna i dokładna analiza antropometryczna 4D wymaga pozyskania danych o całej powierzchni człowieka. Wykorzystuje się do tego zazwyczaj wielosensorowe stacjonarne systemy i metody pomiarowe, takie jak fotogrametria czy światło strukturalne [21]. Technologie wysokorozdzielczego skanowania 4D są rozwijane m.in. przez firmy, takie jak Mnemosis [303], 3dMD [304], Microsoft [305], Volucap [306], Human Engine [307] czy IBV [308]. Przykłady komercyjnych skanerów 4D całego ciała wraz z informacją o zastosowanej technice pomiarowej zaprezentowano na Rysunku 2.25.




Rysunek 2.25 Przykłady komercyjnych skanerów 4D ciała człowieka i zastosowane metody pomiarowe: a) 3dMDbody – fotogrametria, b) Move 4D – fotogrametria, c) Mnemosis – fotogrametria, SL, SfS (źródła rysunków: a) [304], b) [308], c) [303]).

Dzięki skanerom tego typu możliwe jest m.in. śledzenie ruchu tkanki miękkiej [98] czy przeprowadzenie pomiarów funkcjonalnych [21]. Większość dotychczasowych badań w antropometrii dynamicznej polegała jednak na wykorzystaniu stacjonarnych skanerów 3D i przyjmowaniu przez osobę mierzoną skrajnych póz [21], [301], [309], co zostało zilustrowane na Rysunku 2.26. Wpływał na to brak dostępności rozwiązań o wysokiej częstotliwości akwizycji, zbyt mała objętość skanowania lub duży koszt. Ich przykładowe rezultaty zostały przedstawione na Rysunku 2.27.



Rysunek 2.26 Pomiary funkcjonalne obwodu talii dla skrajnych pozycji ciała: rekonstrukcja 3D (z lewej), przekroje poprzeczne (z prawej) (źródło rysunku: [309]).




Rysunek 2.27 Dynamiczny pomiar szerokości pleców (u góry) i obwodu talii (na dole) w czasie z wykorzystaniem systemu Move 4D (źródło rysunku: [301]).

2.4.3. Aplikacje mobilne

Dzięki telefonom komórkowym technologia skanowania 3D staje się coraz łatwiej dostępna dla szerokiego grona osób [21], [25]. Na rynku dostępne są rozwiązania takie jak Scandy Pro, które do rekonstrukcji 3D wykorzystują wbudowane czujniki LiDAR w produktach iPhone czy iPad firmy Apple [310]. Z kolei urządzenia pozbawione wbudowanych sensorów głębi mogą być podłączone do ich zewnętrznych odpowiedników. Przykładowo za pomocą aplikacji itSeez3D możliwe jest przeprowadzanie skanowania ciała z wykorzystaniem czujników Structure Sensor czy Intel RealSense [311]. Niemniej jednak większość istniejących aplikacji mobilnych do pomiaru człowieka wykorzystuje pojedynczą kamerę telefonu. Na podstawie podanych przez użytkownika danych, takich jak wzrost, waga czy płeć, oraz najczęściej jednego lub dwóch zdjęć sylwetki możliwe jest wygenerowanie statystycznego modelu 3D i obliczanie wymiarów ciała na jego podstawie. Powyższe techniki pomiaru ciała z wykorzystaniem uczenia maszynowego i modeli parametrycznych zostały dokładniej opisane w podrozdziale 2.3.5. Aplikacje mobilne, które dzięki tej technologii upraszczają dobór rozmiaru ubrania, umożliwiają zamówienie odzieży szytej na miarę czy pozwalają na śledzenie postępów ćwiczeń to m.in. Sizer [312], Nettelo [313], MTailor [314],

3D Avatar Body [315], Zalando Meepl [316], MirrorSize [317], MeThreeSixty czy Formcut 3D [285]. Ich przykłady wraz z zastosowaniami zostały przedstawione na Rysunku 2.28.



Rysunek 2.28 Przykłady mobilnych aplikacji do pomiaru ciała wraz z zastosowaniami: a) MeThreeSixty – śledzenie postępów ćwiczeń, b) Formcut 3D – odzież szyta na miarę, c) 3D Avatar Body – ogólnego przeznaczenia (źródła rysunków: a, b) [285], c) [315]).

2.4.4. Bazy danych antropometrycznych i narzędzia do ich analizy


Gromadzenie i analiza danych antropometrycznych dostarcza podstawowych informacji na temat różnic w cechach fizycznych pomiędzy różnymi grupami ludzi [4]. Jeszcze przed końcem XX wieku dane te były rzadkie i przede wszystkim liniowe. Udostępniano je w formie wykresów i tabel rozmiarów, które kategoryzowały pomiary ciała populacji z różnych krajów. Nadejście technologii skanowania 3D ciała i rosnące zapotrzebowanie klientów na lepiej dopasowane produkty spowodowało wzrost zainteresowania szeroko zakrojonymi badaniami antropometrycznymi ze strony prywatnych firm i rządów. W efekcie przemysł odzieżowy dysponuje danymi w relatywnie nowych dla niego formatach 2D i 3D, takich jak skany ciała 3D, obrazy z wielu perspektyw, kontury ciała itp. Wobec tej obfitości i różnorodności danych zwiększyła się potrzeba skutecznej analizy i zarządzania danymi [21].

Dane antropometryczne można kupić online z różnych źródeł m.in. za pomocą konsorcjum WEAR (z ang. *World Engineering Anthropometry Resource*), które udostępnia dostęp do prawie 200 zestawów danych antropometrycznych z 20 krajów [318] czy poprzez witrynę iSize firmy Avalution [319], która jest jednym z największych producentów antropometrycznych skanerów 3D. Na rynku istnieje również darmowe oprogramowanie, które pozwala na pobranie baz danych antropometrycznych i ich statystyczną analizę. Dostęp do baz antropometrycznych takich jak ANSUR II lub NHANES możliwy jest dzięki systemom udostępnianym przez Open Design Labs Uniwersytetu Stanowego Pensylwanii [320] i DINED uczelni TU Delft [321]. Udostępniane narzędzia obejmują badanie korelacji wymiarów ciała i ich wpływu na wymiary produktu, generowanie wirtualnych modeli 3D ludzi czy ocenę jak daleko osoba może sięgnąć w określonym kierunku. Funkcjonalności tych systemów zostały zaprezentowane na Rysunku 2.29.

a)



b)



Rysunek 2.29 Przykłady systemów do analizy i statystycznego modelowania ciała człowieka na podstawie bazy danych antropometrycznych: a) DINED – wirtualny manekin 3D dla populacji o zadanym wzroście i długości twarzy, b) Open Design Lab Manikin Fetcher – wirtualny manekin 3D dla populacji o zadanym wzroście i BMI (źródła rysunków: a) [322], b) [320]).

2.5. Podsumowanie

Wybór technologii do pomiaru ciała ludzkiego wymaga uwzględnienia kwestii, takich jak spodziewana dokładność, łatwość w obsłudze, mobilność, czas trwania procedury czy koszt urządzenia. W związku z tym rozważając zalety i wady różnych metod ważne jest zrozumienie zarówno ich możliwości, jak i ograniczeń. Metody manualne z jednej strony wydają się stosunkowo proste i nie potrzebują skomplikowanego sprzętu, ale z drugiej wymagają jednak znacznej wiedzy i doświadczenia ze strony osoby mierzącej, aby pomiary osób o różnych kształtach, wieku, wadze, rasie czy płci były spójne, powtarzalne i porównywalne, co nie zawsze jest osiągalne [23], [274]. Konwencjonalna antropometria jest też mniej efektywna i bardziej czasochłonna. Warto tu przytoczyć przykład pomiarów personelu armii Stanów Zjednoczonych w ramach projektu ANSUR I, które trwały średnio 4 godziny na osobę [17], [37]. Dzięki wykorzystaniu najnowszych technologii możliwe jest przeprowadzanie szybkich, dokładnych, powtarzalnych i bezdotykowych pomiarów ciała człowieka w sposób zautomatyzowany i z wykorzystaniem informacji o jego całej objętości. Pozyskane modele 3D umożliwiają analizę rozmiaru i kształtu człowieka za pomocą metryk, które są poza zasięgiem tradycyjnej antropometrii – objętości, powierzchni i innych pomiarów geometrycznych [46].

Jednym z głównych aspektów wiarygodnego pomiaru ciała jest stosowanie odpowiednich standardów antropometrycznych. Różnice w typach kształtów ciała i niejednoznaczność opisów pomiarów nadal budzą wątpliwości co do sposobu, w jaki powinny być wykonywane. Przyjmuje się domyślnie, że pomiary z różnych badań są przeprowadzane dokładnie w ten sam sposób, gdy ich nazwa jest identyczna. Niestety jednak normy często różnią się od siebie nie tylko w zależności od zastosowania, ale też niejednokrotnie sposobem przeprowadzania teoretycznie takiego samego pomiaru [46]. Przykładem może być talia, której obwód bywa definiowany zarówno jako największy tułowia (o ile mierzona osoba nie jest otyła), jak i w połowie odległości między najwyższym punktem grzebienia kości biodrowej a najniższym punktem żeber czy przechodzący przez pępek [323]. Aby uzyskać koherentne i porównywalne wyniki, konieczne jest zatem dokładne i konsekwentne stosowanie tych standardów. Odmienne postawy przyjmowane w trakcie pomiaru stanowią kolejne źródło niespójności. Oprócz ograniczeń systemów i technik pomiarowych, takich jak wymuszenie podparcia rąk na stolikach obrotowych czy unikanie przesłonięć ciała poprzez podniesienie rąk i rozstawienie nóg, istotne są również czynniki, takie jak pochylenie ciała, zmieniająca się objętość płuc podczas oddychania czy nawet pora dnia.

Inną często podnoszoną kwestią jest spójność i powtarzalność pomiarów manualnych przez różnych ekspertów [23], [274], gdyż to od ich rzetelności, wiedzy i doświadczenia zależy jakość analizy porównawczej technik antropometrycznych. Rzeczywiste wymiary są bowiem bardzo trudne do określenia w jednoznaczny sposób, gdyż „ciało ludzkie ma bardzo mało ostrych krawędzi, jego kontury są zaokrąglone i jest ono ogólnie miękkie i niestabilne” [1]. Dyskusyjne jest zatem to, czy tradycyjne ręczne podejście pomiarowe powinno być zawsze traktowane jako miarodajny złoty standard, zwłaszcza w porównaniu z wynikami uzyskanymi przez antropometryczne skanery ciała 3D o wysokiej precyzji i powtarzalności. Z drugiej strony pomiar ręczny jest nadal najlepszym dostępnym dla takich porównań i nie ma obecnie rozwiązania 3D, które mogłoby je całkowicie zastąpić w tej roli. Manualne badania pozostają też kluczowe dla zdefiniowania heurystycznej praktyki oraz zrozumienia nieliniowych zależności pomiędzy ciałem a przylegającą do niego odzieżą [46].

Wiele badań poświęconych zostało ocenie porównywalności i skuteczności systemów cyfrowej antropometrii 3D w odniesieniu do pomiarów manualnych [26], [46], [50], [233], [324]–[330]. W tym kontekście warte uwagi są przeprowadzone w ostatnich latach analizy porównawcze pomiędzy antropometrycznymi skanerami 3D trzech różnych producentów [331], aplikacją mobilną a skanerem 3D i pomiarami manualnymi [332], a także zbiorcze zestawienie wyników pozyskanych za pomocą 4 skanerów 3D, 4 aplikacji mobilnych i 5 ekspertów [46]. Próby znalezienia wspólnego mianownika dla pomiarów tradycyjnych i nowoczesnych oraz optymalizacja procedur nowoczesnej antropometrii są też ciągłym przedmiotem badań organizacji standaryzacyjnych [27], [32], [49]. Niestety zamknięty kod źródłowy rozwiązań dostępnych na rynku utrudnia porównanie wyników pomiędzy metodami [26].

Spośród wszystkich omówionych cyfrowych metod wymiarowania (patrz 2.3.5 wyżej), te operujące bezpośrednio na chmurach punktów ze skanera 3D cechuje najworniejsze odwzorowanie rzeczywistego przebiegu linii pomiarowej. Niemniej jednak są one wrażliwe na szum, jakość i kompletność danych. Dla odmiany algorytmy wykorzystujące modele parametryczne obchodzą to ograniczenie poprzez dopasowanie szablonu o znanej topologii do danych wejściowych (patrz podrozdział 2.3.2 wyżej, sekcja modele parametryczne). Dzięki temu metody te są w stanie wygenerować model kompletnego ciała ludzkiego nawet na podstawie niepełnych informacji [275]. Algorytmy modelowania człowieka mają jednakże trudności z generowaniem szczegółowej geometrii i dokładnym dopasowaniem szablonu do konturów ludzkiego ciała [61]. Wynikowy model jest jedynie przybliżeniem, a technologia ta

uzależniona jest od jakości zbioru uczącego. Przekłada się to na dokładność generowanych wyników, zwłaszcza jeśli dane uczące nie są dostatecznie reprezentatywne dla danej populacji. Ponadto większość istniejących technik rekonstrukcji ciała, które nie korzystają ze danych pozyskanych za pomocą skalibrowanego skanera 3D, nie uwzględnia wiedzy o parametrach wewnętrznych kamery lub skali, a zatem nie może zagwarantować oczekiwanej dokładności metrycznej [103], [279].

Ograniczeniem zastosowania systemów 3D jest najczęściej wysoka cena, brak mobilności i niska dostępność dla masowego odbiorcy. Biorąc pod uwagę koszty i wymagania dotyczące przestrzeni pomiarowej, skanowanie 3D jest bardziej wskazane do pozyskiwania danych na dużą skalę [4]. Bardziej przystępne rozwiązania, które są oparte jedynie o zdjęcia wykonane np. za pomocą telefonu lub łatwe do pozyskania dane o wzroście, wadze, wieku czy płci, nie są jeszcze w pełni dojrzałe, lecz mimo to mogą zostać wykorzystane do podstawowych badań antropometrycznych. Metody te zasługują na szczególną uwagę z racji na swą przystępność i bardzo dynamiczny rozwój wspierających je technik głębokiego uczenia oraz coraz większą dostępność wysokiej jakości danych uczących.

Kolejnym, naturalnym i wartym śledzenia krokiem rozwoju antropometrii jest wykorzystanie informacji o zmienności ciała w ruchu. Wraz z rozwojem najnowszych technik 4D, przeprowadzanie pomiarów funkcjonalnych na potrzeby procesu projektowania ubrań staje się coraz bardziej przystępne. Wymiary ciała, które są podstawą tworzenia odzieży, potrafią istotnie się różnić w zależności od przyjętej pozycji. Jak pokazuje wybiórczy przykład z badania [21], różnica w długości konturu pleców między pozycją stojącą a pochyloną może wynosić 12 cm. Z kolei obwód klatki piersiowej, będący jednym z głównych parametrów doboru odzieży, może różnić się o 8 cm pomiędzy luźnym odwodzeniem rąk a napiętym, imitującym lekkie podnoszenie przedmiotu. Tak duży rozrzut wyników obejmuje aż 3 przedziały w tabeli rozmiarów. Uwzględnieniu tego aspektu podczas projektowania odzieży umożliwia zapewnienie jej odpowiedniej elastyczności.

Należy pamiętać, że w przypadku przemysłu odzieżowego ostatnim, a zarazem najważniejszym ogniwem są jego klienci, którzy najczęściej dokonują pomiarów własnoręcznie i z reguły nie są odpowiednio wyszkoleni. Co więcej, tabele rozmiarów stosowane przez producentów różnią pomiędzy sobą w wyniku czego wielu osób ma w garderobie odzież w teoretycznie wykluczających się rozmiarach. Dodatkową komplikacją jest to, że osoby mierzące się we własnym zakresie mają tendencję do zaniżania swoich

wymiarów, co najlepiej widać na przykładzie pomiaru talii wśród kobiet [333]. Zwiększenie dostępności rozwiązań cyfrowych może przyczynić się do poprawy tej sytuacji. Niemniej jednak konsumenci mogą być niechętni do skanowania swojego ciała z obawy o prywatność i bezpieczeństwo danych osobistych, niepewność co do dokładności technologii czy po prostu brak komfortu związany z tym procesem.

3. Materiały


Opracowanie automatycznej metody pomiaru człowieka na podstawie chmury punktów nie byłoby możliwe bez specjalistycznego skanera 3D całego ciała. Dane do przeprowadzenia badań zostały pozyskane za pomocą opracowanego w ramach projektu Formfit skanera światła strukturalnego [334]. Skaner ten, wraz z dedykowanym oprogramowaniem do jego obsługi oraz wyznaczania wymiarów wg metody omawianej w rozprawie, zwany jest dalej Mobilnym System Pomiarowym (MSP). Do celów porównawczych wykorzystano światowej klasy komercyjne rozwiązanie firmy Human Solutions (HS), które obejmowało skaner laserowy Vitronic Vitus Smart XXL i oprogramowanie do antropometrycznej analizy danych Anthroscan ScanWorX.

Skaner MSP składał się z czterech modułów po dwa skanery 3D każdy. Celem zapewnienia optymalnej objętości pomiaru obejmującej całą sylwetkę człowieka, w tym z obszarów takich jak pachy, krocze oraz wierzchnia część barków, wymagane było rozstawienie ich w czterech narożnikach pomieszczenia o minimalnych wymiarach 5,2 m x 5,2 m x 2,3 m. Główne komponenty każdego modułu akwizycyjnego stanowiły:


- dwa układy projekcyjne: projektory DLP (z ang. *Digital Light Processing*) Casio XJ-A250,
- dwa układy detekcyjne: kamery CCD (z ang. *Charge Coupled Device*) Point Grey Flea FL3-FW-14S3M-C,
- komputer ogólnego przeznaczenia odpowiedzialny m.in. za generowanie prążków sinusoidalnych, akwizycję obrazów z kamer oraz wyznaczanie wynikowej chmury punktów.

Pary naprzeciwległych kolumn skanujących pracowały w trybie synchronicznym, co pozwalało na skrócenie czasu pomiaru względem sekwencyjnej akwizycji. Było to możliwe dzięki zastosowaniu separacji spektralnej wzajemnie prześwietlających się par projektor – kamera. Dwa projektory wyświetlały niebiesko-czarne prążki, a pozostałe czerwono-czarne, a przypisane im kamery miały zamontowane filtry spektralne. Ponadto system MSP był wyposażony w wagę Mensor WM150P1 40X50G, która dodatkowo pełniła rolę podestu. Uproszczony schemat budowy i sposób działania zastosowanego skanera 3D wykorzystującego oświetlenie strukturalne zaprezentowany jest na Rysunku 3.1.

a)



b)



Rysunek 3.1 Zastosowany skaner 3D MSP: a) schemat budowy, b) działanie oświetlenia strukturalnego w trakcie pomiaru.

Konkurencyjny skaner 3D ciała VITUS smart XXL firmy Human Solutions również składał się z czterech kolumn, ale dodatkowo usztywnionych w konstrukcji ramowej (patrz Rysunek 3.2). Do rekonstrukcji geometrii wykorzystano w nim projekcję wiązki laserowej i analizę deformacji kształtu rastra.




Rysunek 3.2 Skaner laserowy VITUS smart XXL.

W przypadku obu skanerów od osoby mierzonej oczekiwano, aby stała nieruchomo podczas trwania pomiaru. Akwizycja za pomocą systemu MSP trwała krócej, co było korzystniejsze w kontekście wystąpienia błędów spowodowanych mimowolnym ruchem ciała. Dokładność skanera MSP określono poprzez obliczenie maksymalnego dopuszczalnego błędu zgodnie z normą kalibracji ISO 103608 [335] i zaleceniami VDI/VDE 2634 (z niem. *Verein Deutscher Ingenieure/Verband Deutscher Elektrotechniker*) [336]. Porównanie parametrów obu systemów zawarte jest w Tabeli 3.1. Z kolei przykładowe wyniki skanowania reprezentujące powierzchnię ciała uzyskaną za pomocą obu rozwiązań przedstawione są na Rysunku 3.3.

Tabela 3.1 Porównanie specyfikacji technicznej wykorzystywanych skanerów 3D.


	Skaner MSP	VITUS smart XXL
Dokładność	< 0,3 mm	< 1 mm
Czas akwizycji danych	ok. 3 s	ok. 10 s
Objętość pomiarowa	1,5 m x 1,5 m x 2,2 m	1,2 m x 1,0 m x 2,1 m
Liczba punktów na skan	od 1 do 2 * 10 ⁶	ok. 0.4 * 10 ⁶



Rysunek 3.3 Przykładowe wyniki skanowania w postaci chmur punktów reprezentujących całą powierzchnię ciała: A) skaner światła strukturalnego MSP, B) skaner laserowy Vitronic VITUS smart XXL.

4. Metoda pomiaru ciała z wykorzystaniem chmury punktów

W ramach realizacji prac badawczych opracowano i zaimplementowano szereg algorytmów służących do automatycznego wyznaczania wymiarów ciała człowieka istotnych w zastosowaniach konstrukcji odzieży (patrz Tabela 1.1 wyżej). Na podstawie analizy i oceny istniejących procedur i technologii zaproponowano uogólnioną ścieżkę przetwarzania, która zaprezentowana jest na Rysunku 4.1 poniżej.




Rysunek 4.1 Schemat ścieżki przetwarzania danych.

4.1. Przetwarzanie wstępne chmury punktów

4.1.1. Przygotowanie danych

Bezpośrednim wynikiem procesu skanowania jest 8 chmur punktów, po jednej na każdą z głowic pomiarowych systemu MSP. Surowe dane pochodzące ze skanerów 3D wymagają usunięcia punktów szumowych, wzajemnego wyrównania i połączenia w jedną, kompletną chmurę punktów reprezentującą całe ciało badanej osoby. Schemat procesu przygotowania danych wejściowych na potrzeby kolejnych kroków algorytmów pomiarowych zaprezentowany jest na Rysunku 4.2 poniżej.



Rysunek 4.2 Schemat procesu przygotowania danych od ich pozyskania za pomocą skanera 3D w surowej formie, przez filtrację i łączenie częściowych chmur punktów, po wygenerowanie pełnowymiarowego modelu ciała człowieka.

Nieprzetworzone chmury punktów, pochodzące bezpośrednio ze skanera, charakteryzują się dużą liczbą pojedynczych i odizolowanych grup punktów szumowych. Jednym ze źródeł błędnej rekonstrukcji w wykorzystywanej w badaniach metodzie SL jest niedostateczna jakość odwzorowania rejestrowanych obrazów prążkowych, która zależy od kontrastu i jest niższa w przypadku powierzchni niedoświetlonych lub odbijających światło. Powoduje to powstawanie szumu m.in. blisko krawędzi obiektu skanowanego. Natomiast duże skupiska punktów to zwykle fragmenty zrekonstruowanego tła, takie jak podest, podłoga czy kolumny pomiarowe. Mając na uwadze to, że proces wymiarowania jest szczególnie wrażliwy na jakość zrekonstruowanej geometrii [271], wymagane jest usunięcie błędnych punktów chmury (patrz podrozdział 2.3.3 wyżej, sekcja filtracja szumu).

Proces filtracji danych pomiarowych składa się z trzech etapów. W pierwszym kroku odizolowane grupy punktów szumowych segmentowane są za pomocą algorytmu wykorzystującego metrykę Hausdorffa. Na jej podstawie klasteryzowane są punkty leżące blisko siebie, a te z grup, których liczność jest poniżej ustalonego progu, są eliminowane. W kolejnym etapie usuwane są punkty krawędziowe, które uznać można za potencjalnie najmniej dokładne, co wynika z niestabilnych własności optycznych na granicach obiektów. W ostatnim etapie chmura jest wygładzana, co pozwala na zredukowanie wpływu punktów szumowych występujących na powierzchni. W tym celu, na podstawie punktów sąsiadujących każdego z elementów chmury, dopasowywana jest płaszczyzna za pomocą metody najmniejszych kwadratów [337]. Po rzutowaniu punktów na odpowiadające im lokalne płaszczyzny powstaje nowa, wygładzona chmura, której przypisane są wektory normalne dopasowywanych płaszczyzn. Technika ta jest odpowiednikiem filtracji dolnoprzepustowej, dla której promień wyboru sąsiadujących punktów wpływa nie tylko na poziom usuwanego szumu, ale równocześnie na utratę szczegółów.


Częściowe chmury punktów są zgrubnie zorientowane wzajemnie dzięki wykorzystaniu kalibracji globalnej dostarczanej przez system MSP. Jego mobilność i związana z nią niepewność położenia kolumn pomiarowych wymusza przeprowadzenie dodatkowego, dokładnego wyrównania, do którego stosowana jest metoda ICP [187]. W efekcie powstaje dookolny i kompletny model 3D ciała człowieka.

W ostatnim kroku oczyszczona, wyrównana i scalona chmura punktów transformowana jest do ustalonego układu współrzędnych. Układ ten jest lewoskrętny, a jego środek znajduje się w środku ciężkości ciała, za wyjątkiem pionowej osi Z, dla której poziomem zerowym jest podłoga. Chmura punktów osoby skanowanej obracana jest w przestrzeni wokół znanej osi Z tak, aby oś Y przechodziła przez środki stóp, a ich palce wskazywały ujemną oś X.


4.1.2. Segmentacja

Proces segmentacji przefiltrowanej chmury punktów ciała człowieka wykorzystuje informację o wymaganym, standardowym ułożeniu ciała podczas pomiaru i rozpoczyna się od podzielenia chmury na poziome przekroje. Punkty wewnątrz nich grupowane są w oddzielne klasy na podstawie wzajemnej bliskości. Następnie grupy te są scalane ze sobą w oparciu o wiedzę o budowie ciała. Docelowe części ciała, takie jak ręce, nogi, górna i dolna część tułowia, biodra i głowa, znajdują się w obszarach ograniczonych przez pomocnicze linie

i punkty antropometryczne pach, krocza, szyi i bioder. Do ich lokalizacji wykorzystywana jest analiza konturów sylwetki obejmująca wyznaczanie lokalnych ekstremów i punktów przegięcia czy badanie zmienności ich szerokości. Stosowane są dwa typy konturów – w płaszczyźnie strzałkowej wykrywana jest górna linia bioder, a reszta analizy odbywa się w płaszczyźnie czołowej. Przykład wyznaczania punktów do określenia granic segmentów górnych części ciała zaprezentowano na Rysunku 4.3 poniżej. W ostatnim kroku wyodrębnione grupy punktów, które znajdują się wewnątrz nich i mają zbliżone właściwości (np. środek masy, obwód i licznosc), łączone są we właściwą część ciała. Etapy segmentacji oraz przykładowe rezultaty przedstawiono na Rysunku 4.4.



Rysunek 4.3 Analiza konturu sylwetki na potrzeby detekcji punktów wyznaczających granice szyi i pach: a) kontur sylwetki w płaszczyźnie czołowej, dla którego punkty pach na podstawie lokalnych maksimów oznaczone są żółtymi okręgami, a obszar wyszarzony tuż nad poziomem pach poddany jest analizie w celu znalezienia linii szyi w kolejnych krokach, b) wykres szerokości przekrojów poprzecznych konturu w obrębie wyszarzonego obszaru i c) wykres pochodnej szerokości przekrojów poprzecznych konturu pozwalający na wyznaczenie numeru przekroju odpowiadającego linii podziału szyi jako punktu przegięcia, który cechuje się największym spadkiem szerokości licząc od poziomu pach.



Rysunek 4.4 Proces segmentacji: A) analiza przekrojów, gdzie kolory – grupy punktów na podstawie przekrojów (widok ogólny) i sąsiedztwa (przybliżenie), czarne linie – obszar ograniczony punktami antropometrycznymi, B i C) wyodrębnione części ciała po scaleniu podgrup punktów odpowiednio dla mężczyzny i kobiety, gdzie kolory – chmury punktów kolejnych części ciała (rąk, nóg, górnej/dolnej części tułowia, bioder oraz głowy).

Dzięki segmentacji odpowiednie procedury pomiarowe są w stanie operować na ograniczonym zestawie danych obejmującym jedynie istotny fragment ciała człowieka. To nie tylko znacznie upraszcza proces obliczeniowy, ale również go przyspiesza umożliwiając efektywną analizę danych i późniejsze obliczenia wymiarów antropometrycznych. Pseudokod algorytmu segmentacji znajduje się w Tabeli 4.1 poniżej.

Tabela 4.1 Pseudokod algorytmu segmentacji.

Algorytm 1 Segmentacja Wejście: human body scan in form of an XYZ point cloud Wyjście: eight segmented body parts - left/right arm, left/right leg, upper/lower torso, hips and head Procedura: Begin - divide the scan into horizontal slices for each of the horizontal slices do - group points within proximity defined by sphere radius based on the average distance between points in scan, ignore groups with insignificant numbers of points end for - find coarse body landmarks based on contour analysis: - project points onto coronal plane, create contour: - crotch as a peak point formed by contour between the legs - armpits similarly to crotch but between arm and torso - neck as height with rapid change of width between it and shoulders - line between upper and lower torso as a line defined by the lower of the armpits - project half of the points around the middle of the scan onto sagittal plane to avoid the influence of the arms, create contour:

```

- line between hips and lower torso defined by inflection point between the buttocks most protruding point
and lordosis as a convex point right above it
for each of the groups do
- search for the nearest group
if both groups have similar properties (center of mass, circumference, points number) and are within the areas
constrained by the body landmarks then
- merge them
end if
end for
- append corresponding groups to certain body parts based on the body landmark constraints
End

```

4.1.3. Krzywizna Gaussa

Kolejnym krokiem przetwarzania wstępnego jest obliczenie krzywizny Gaussa dla każdego punktu w chmurze. Dzięki niej możliwe jest określenie dokładnej lokalizacji punktów ciała, takich jak sutki, pępek czy łokcie [240]. Wartość krzywizny punktów oszacowana jest za pomocą metody dopasowania kwadryki do lokalnej powierzchni ich otoczenia [230]. Dla analizowanego punktu p rozpatrywany jest wektor normalny powierzchni $\hat{n}$, który został wyliczony w trakcie procesu wygładzania chmury (patrz podrozdział 4.1.1 wyżej). W pierwszym kroku współrzędne punktów muszą być przetransformowane za pomocą macierzy rotacji R tak, aby globalna oś X była zrzutowana na płaszczyznę styczną zdefiniowaną przez $\hat{n}$. Tę macierz opisuje zestaw Równań 4.1, a transformację punktów z globalnego układu współrzędnych do lokalnego kwadryki Równanie 4.2:

$$R = [r_1, r_2, r_3]^T$$

$$r_3 = \hat{n}, \quad r_1 = \frac{(I - \hat{n}\hat{n}^T)\hat{i}}{\|I - \hat{n}\hat{n}^T\|\hat{i}}, \quad r_2 = r_3 \times r_1 \quad (4.1)$$

$$x' = R(x_w - p_w) \quad (4.2)$$

gdzie:

R – macierz rotacji z globalnego układu współrzędnych na lokalny kwadryki,

r_1, r_2, r_3 – wektory macierzy rotacji,

$\hat{n}$ – wektor normalny powierzchni,

I – macierz jednostkowa,

$\hat{i}$ – wektor globalnej osi X w postaci $[1,0,0]^T$,

x' – współrzędne punktu sąsiedztwa w lokalnym układzie,

x_w – współrzędne punktu sąsiedztwa w globalnym układzie,

p_w – współrzędne analizowanego punktu krzywizny w globalnym układzie.

Po transformacji punktów dopasowywana jest rozszerzona kwadryka opisana Równaniem 4.3:

$$Z' = aX'^2 + bX'Y' + cY'^2 + dX' + eY' \quad (4.3)$$

gdzie:

X', Y', Z' – dopasowywany układ współrzędnych,
 a, b, c, d, e – współczynniki rozszerzonej kwadryki.

Wartości współczynników wyliczane są poprzez rozwiązanie układu równań liniowych opisanych Równaniem 4.4:

$$\begin{bmatrix} x_1'^2 & x_1'y_1' & y_1'^2 & x_1' & y_1' \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ x_n'^2 & x_n'y_n' & y_n'^2 & x_n' & y_n' \end{bmatrix} \begin{bmatrix} a \\ b \\ c \\ d \\ e \end{bmatrix} = \begin{bmatrix} z_1' \\ \vdots \\ z_n' \end{bmatrix} \quad (4.4)$$

gdzie:

$x'_{1...n}, y'_{1...n}, z'_{1...n}$ – współrzędne punktów sąsiadujących po transformacji na podstawie wcześniej wyznaczonego wektora normalnego $\hat{n}$,
 n – liczba punktów,

co pozwala wyznaczyć krzywiznę Gaussa za pomocą Równania 4.5:


$$K = \frac{4ac - b^2}{(1 + d^2 + e^2)^2} \quad (4.5)$$

gdzie:

K – krzywizna Gaussa.

W przypadku powyższego algorytmu rozmiar analizowanego otoczenia zależny jest od szumu pomiarowego. Empiryczne ustalenie promienia przeszukiwania otoczenia na poziomie 10 mm pozwoliło na zredukowanie wpływu szumu przy jednoczesnym zachowaniu wystarczającej szczegółowości krzywizny powierzchni ciała. Zastosowanie większego promienia skutkuje wygładzeniem krzywizny, a co za tym idzie możliwą utratą precyzji i zatarciem subtelnych

szczegółów, takich jak wypukłość wyrostka kolczystego kręgu C7. Z kolei im jest on mniejszy, tym większy jest szum i niestabilność wyników dalszej analizy. Przykładowe chmury punktów pokolorowane wg wartości krzywizny Gaussa przedstawiono na Rysunku 4.5 poniżej.




Rysunek 4.5 Chmury punktów mężczyzny i kobiety pokolorowane wg krzywizny Gaussa: niebieski – ujemna krzywizna (min), zielony – zerowa krzywizna, czerwony – dodatnia krzywizna (max).

4.2. Detekcja punktów antropometrycznych

Właściwe algorytmy pomiarowe są bezpośrednio związane z punktami antropometrycznymi ciała człowieka, które definiują miejsce przebiegu linii wymiarowania. Wśród nich znajdują się zarówno punkty wykorzystywane do konstrukcji odzieży np. X_p , S_v i S_y , jak i pomocnicze typu U_o , K_o i H_o stosowane do pośrednich pomiarów wysokości lub podczas lokalizacji płaszczyzny pomiarowej. Pierwsze znajdują się na powierzchni ciała i są to m.in. punkty barkowe R_v , talii pod piersią T_p lub łokci El , drugie zaś obejmują głównie środki ciężkości obwodów kończyn w charakterystycznych miejscach, takich jak kolana K_o , przewężenia kostki H_o czy talii T_v . Ich detekcja odbywa się automatycznie na podstawie zestawu indywidualnych kryteriów uwzględniających m.in. ich cechy antropometryczne, kształt czy krzywiznę powierzchni. W związku z tym ścieżka przetwarzania nie jest jednolita dla wszystkich punktów. Niemniej jednak wszystkie algorytmy operują na wycinkach chmury punktów w obrębie wyznaczonego wcześniej segmentu lub jego otoczenia. Na potrzeby wyznaczania części z nich przeprowadzana jest analiza lokalnych konturów utworzonych czy

to przez cały segment ciała (S_v), czy to jego przekrój w danej płaszczyźnie (P_c i P_l). Kolejne są wynikiem przecięcia płaszczyzn z chmurą (T_p i T_y) lub charakteryzują się lokalnym ekstremum krzywizny Gaussa (S_x , S_y , El i X_p u mężczyzn). Położenie innych, takich jak Ho , Ko , T_v i X_p u kobiet, określane jest równoległe z właściwymi wymiarami ciała. W tym wypadku w wyniku operacji poszukiwania najmniejszej otoczki wypukłej ze zbioru kolejnych przekrojów poprzecznych kończyn lub tułowia uzyskiwane jest nie tylko położenie danego punktu antropometrycznego lub odpowiadającego mu przekroju, ale i docelowego wymiaru. Proces ten jest dokładniej opisany w kolejnym podrozdziale dotyczącym pomiarów obwodowych 4.3.1. Szczególnym przypadkiem takiego podejścia jest wyznaczanie położenia kolana Ko , gdzie dodatkowo do kolejnych przekrojów dopasowywana jest elipsa. Mając na uwadze charakterystykę kształtu rzepki, punkt Ko został określony jako środek ciężkości przekroju, dla którego różnica pomiędzy obwodem elipsy a długością otoczki wypukłej jest największa. Ostatnia grupa metod detekcji obejmuje punkty wyznaczone pośrednio, tak jak X_l , X_c i R_v , które są przesunięte względem pachy lub znajdują się nie w środku ciężkości wytypowanego przekroju, a na powierzchni ciała, jak w przypadku nadgarstka N_v . Przykładowe wyniki detekcji punktów antropometrycznych w obszarze torsu przedstawia Rysunek 4.6. Z kolei Tabela 4.2 zawiera ich definicje położenia w przestrzeni 3D, które są podstawą automatyzacji ich lokalizacji.



Rysunek 4.6 Przykład automatycznie wyznaczonych punktów antropometrycznych.

Tabela 4.2 Definicje punktów antropometrycznych służące do ich automatycznej lokalizacji.

Akronim	Opis antropometryczny	Opis 3D
<i>Rv</i>	wyrostek barkowy	najwyższy punkt nad pachą
<i>Sv</i>	ramiona-szyja	punkt o największym zagięciu pomiędzy szyją a ramieniem na podstawie konturu w płaszczyźnie czołowej
<i>Sy</i>	kręgi C7	punkt pośrodku tylnej części szyi cechujący się najwyższą wartością krzywizny Gaussa, blisko linii obwodu szyi
<i>Sx</i>	dół szyjny pomiędzy obojczykami	punkt cechujący się najniższą wartością krzywizny Gaussa tuż poniżej środka frontu obwodu szyi
<i>Pl</i>	przód pachy	najniższy punkt styku torsu i ramienia na konturze przekroju w płaszczyźnie czołowej przechodzącej przez pachę wyznaczoną w procesie segmentacji; punkt przodu pachy jest przesunięty w kierunku przodu ciała tak, aby znajdował się tuż pod krawędzią ramienia nad nim
<i>Pc</i>	tył pachy	punkt wyznaczany analogicznie jak w przypadku przodu pachy <i>Pl</i> , ale przesunięty w kierunku tyłu ciała
<i>Xp</i>	brodawki sutkowe	mężczyźni: punkty w obrębie klatki piersiowej o najwyższej krzywiznie Gaussa, po jednym po lewej i prawej stronie kobiety: w oparciu o największą otoczkę wypukłą klatki piersiowej (<i>opx</i>) i odpowiadający jej przekrój, zdefiniowane jako najbardziej wysunięte punkty lewej i prawej części stanika
<i>Xl</i>	przód pachy na wysokości brodawek sutkowych	punkt na tułowiu najbliższy <i>Pl</i> obniżony do wysokości brodawki sutkowej <i>Xp</i>
<i>Xc</i>	tył pachy na wysokości sutków	punkt na tułowiu najbliższy <i>Pc</i> obniżony do wysokości brodawki sutkowej <i>Xp</i>
<i>Tp</i>	talia pod piersią	punkt na tułowiu na linii przecięcia konturu płaszczyzny poziomej przechodzącej przez talię (<i>Tv</i>) z płaszczyzną strzałkową przechodzącą przez brodawkę sutkową (<i>Xp</i>)
<i>Ty</i>	talia pod kręgiem C7	punkt na tylnej części konturu wyznaczonego przez płaszczyznę strzałkową przechodzącą przez <i>Sy</i> na poziomie tali (<i>Tv</i>)
<i>El</i>	łokieć	punkt o najwyższej krzywiznie w otoczeniu położony najdalej od osi przebiegającej przez pachę i nadgarstek
<i>Nv</i>	nadgarstek	punkt leżący na najmniejszym obwodzie ręki i najdalej od tułowia
<i>Tv</i>	talia	środek ciężkości najmniejszego obwodu tułowia w płaszczyźnie poziomej
<i>Uo</i>	krocze	środek ciężkości poziomego przekroju, który znajdują się pomiędzy nogami a miednicą na wysokości punktu krocza na konturze z etapu segmentacji
<i>Ko</i>	kolano	środek ciężkości środkowego poziomego przekroju nogi, dla którego różnica pomiędzy obwodem dopasowanej elipsy oraz otoczki wypukłej jest największa
<i>Ho</i>	kostka	środek ciężkości poziomego przekroju najmniejszego obwodu nogi (<i>oh</i>)

4.3. Wymiarowanie


Ostatni krok przetwarzania zależy od charakteru wymaganego pomiaru. Opis algorytmów obliczania wymiarów obwodowych, łukowych i liniowych na podstawie uprzednio wyznaczonych punktów antropometrycznych został przedstawiony kolejno poniżej.

4.3.1. Pomiary obwodowe


Pomiar długości obwodów rozpoczyna się od zdefiniowania objętości zainteresowania (z ang. *Volume of Interest*, VOI), w obrębie której znajduje się poszukiwany wymiar. Obszar tułowia, ramion czy łydki określany jest na podstawie wcześniej przeprowadzonej segmentacji chmur punktów. Kolejnym krokiem jest ustalenie płaszczyzny pomiarowej. W kontekście obwodów tułowia, takich jak obwód talii *ot* czy obwód bioder *ob*, zakładana jest jej równoległość do podłoża. Z kolei w przypadku obwodów kończyn płaszczyzna ta jest prostopadła do osi kości, wokół której obwody są mierzone (np. dla największego obwodu uda *ou* jest to kość udowa a dla największego obwodu ramienia *or* – kość ramienna). Osi kończyn szacowane są na podstawie środków ciężkości przekrojów stawów, które wyznaczają ich początek i koniec.

Sposób lokalizacji dokładnego miejsca pomiarowego jest indywidualny dla każdego z pomiarów. Wykorzystywane są zarówno wcześniej wyznaczone punkty antropometryczne, takie jak brodawki sutkowe *Xp* do wyznaczenia obwodu przez piersi *opx*, jak i tymczasowa pomocnicza analiza wszystkich przekrojów w obrębie danego segmentu ciała by znaleźć np. najmniejszy obwód jak w przypadku talii.

Po zlokalizowaniu punktu przecięcia wyodrębniany jest fragment chmury punktów o określonej grubości, która w tradycyjnej antropometrii odpowiada szerokości taśmy mierniczej. W proponowanym podejściu wartość ta została ustalona na poziomie 15 mm, analogicznie do zalecanej przez normę PN-EN 13402 [36] szerokości taśmy. Następnie punkty wybranego przekroju rzutowane są na płaszczyznę pomiarową danego obwodu, co umożliwia wykonanie ostatecznych obliczeń jego długości. Krzywa pomiarowa, jaką tworzy tradycyjna miarka owijana wokół badanego obszaru, pokrywa się w przybliżeniu z dwuwymiarową otoczką wypukłą utworzoną przez rzutowane punkty, co oznacza, że długość obwodu jest równa sumie boków wielokąta przez nią utworzonego (patrz podrozdział 2.3.5 wyżej). Diagram typowej ścieżki przetwarzania dla pomiarów obwodowych przedstawia Rysunek 4.7, a odpowiadający jej pseudokod znajduje się w Tabeli 4.3 poniżej. Szczególnym przypadkiem jest obwód bioder z uwzględnieniem wypukłości brzucha *obt*, do którego obliczenia wykorzystywane jest spłaszczona chmura pomiędzy przekrojem brzucha jako najbardziej wystającego w płaszczyźnie strzałkowej a biodrami wg największego obwodu pośladków. Przypadek ten przedstawiony jest na Rysunku 4.8 poniżej.



Rysunek 4.7 Schemat wyznaczania długości obwodów na przykładzie obwodu talii ot.



Rysunek 4.8 Pomiar obwodu bioder z uwzględnieniem wypukłości brzucha obt: a) na zielono objętość zainteresowania, którą ogranicza od dołu przekrój obwodu bioder ob a od góry wypukłość brzucha jako najbardziej odstający w osi X przekrój, b) zrzutowane na płaszczyznę poprzeczną punkty i na czerwono dopasowana docelowa otoczka wypukła, c) przebieg wynikowej linii obwodu obt podzielony na potrzeby wizualizacji na część górną wypukłości brzucha i dolną bioder.


Tabela 4.3 Pseudokod algorytmu wyznaczania długości obwodów.

Algorytm 2 Pomiar długości obwodu
Wejście: corresponding body part's XYZ point cloud, anthropometric point, virtual_tape_thickness
Wyjście: girth length
Procedura:
Begin
- define the measurement plane to cross the anthropometric point and to be parallel to the ground level or perpendicular to the body part centerline depending on the measurement type
- extract point cloud from VOI around measurement plane with the given virtual_tape_thickness
- project extracted points onto the measurement plane
- compute convex hull on the projected point set
return convex hull perimeter line length
End

4.3.2. Pomiary łukowe

Łuki łączą określone punkty antropometryczne. Niektóre z nich można analizować wprost, gdyż ograniczają się jedynie do dwóch punktów, tak jak w przypadku łuku szerokości barków tyłu pomiędzy dwoma wyrostkami barkowymi $RvRv$. Z kolei krzywa pomiaru w przypadku bardziej złożonych wymiarów, takich jak $SySvXp$, przecina więcej punktów orientacyjnych (w tym wypadku krąg $C7$ Sy , punkt na styku ramion i szyi Sv oraz brodawkę sutkową Xp). W związku z tym musi zostać podzielona na podstawowe segmenty przed właściwą analizą, gdzie każdy z fragmentów jest wymiarowany oddzielnie a na koniec sumowane są częściowe wyniki.

Podobnie jak dla pomiarów obwodowych, omawiany algorytm rozpoczyna się od wyznaczenia objętości zainteresowania. Tym razem jednak jest ona ograniczona przez punkty łuku, a nie segmenty ciała. Następnym krokiem jest znalezienie optymalnej płaszczyzny pomiarowej, która pokrywa się z punktami krańcowymi poszukiwanej krzywej, a zarazem dla której obliczony łuk jest najkrótszy. W tym celu sprawdzana jest długość łuku dla wszystkich płaszczyzn z predefiniowanego pęku, zależnego od tego z której strony i na której części ciała leży łuk. Punkty chmury rzutowane są na każdą z tymczasowych płaszczyzn, a na ich podstawie wyliczana jest otoczka wypukłą, podobnie jak w przypadku pomiarów obwodowych. Długość łuku definiowana jest jako jej fragment ograniczony analizowanymi punktami antropometrycznymi. Dla ułatwienia przycięcia wynikowego obwodu i zachowania zbieżności pomiędzy otoczką wypukłą i łukiem, dodawany jest punkt pomocniczy wewnątrz ciała. Wyjątkiem jest długość barku $SvRv$, dla którego punkt ten leży na zewnątrz w celu imitacji docięnięcia taśmy do ciała. Rysunek 4.9 prezentuje kolejne kroki algorytmu na przykładzie łuku pomiędzy punktem łączenia szyi z barkiem i brodawką sutkową $SvXp$. Z kolei Tabela 4.4 przedstawia pseudokod tej metody.



Rysunek 4.9 Schemat wyznaczania długości łuków na przykładzie odcinka $SvXp$ będącego częścią długości przodu do piersi $SySvXp$.

Tabela 4.4 Pseudokod algorytmu wyznaczania długości łuków.

Algorytm 3 Pomiar długości łuków
Wejście: corresponding body part's XYZ point cloud, arc defined by set of anthropometric points, angular_search_range, virtual_tape_thickness, measurement_type Wyjście: arc length Procedura: Begin if arc is complex, i.e., has more than 2 anthropometric points, then - split the original arc into simple point-to-point arcs - sum = 0 for each simple arc do - sum += call Arc length measurement algorithm given the simple arc end for return sum; else if arc is simple then - define the arc axis as a line between start and end point of the arc - rotate the coordinate system in a way that arc axis coincides with Z-axis - define angular search range based on measurement type, e.g., from -15° to 15° - declare possible lengths vector for each angle within angular search range do - define measurement plane as one of the 3 main planes, XY, YZ, or XZ, based on the measured body part type and ensure that both start and end points of the arc belong to it - rotate the coordinate system by the given angle around the arc axis - select VOI as a bounding box constrained by the arc anthropometric points - extract point cloud from VOI around measurement plane with the virtual_tape_thickness - project extracted points onto the measurement plane if measurement_type == SvRv then


```

- append auxiliary point "outside" the body to the projected point set to resemble tape pressure against the
surface of the body
else
- append auxiliary point "inside" the body to the projected point set to imitate typical tape measurement
end if
- compute convex hull on the projected point set
- clip the resulting convex hull perimeter line by removing the unwanted line segments between arc anthropometric
points and previously added auxiliary point
- append clipped convex hull perimeter line length to possible lengths vector
end for
return minimum value from possible lengths vector
end if
End

```

4.3.3. Pomiary liniowe

Pomiary liniowe składają się z obliczeń szerokości i wysokości. Pierwsze wyznaczane są bezpośrednio jako odległości euklidesowe pomiędzy wybranymi parami punktów antropometrycznych. Przykładem jest szerokość międzypiersiowa $XpXp$ określana jako dystans między lewą i prawą brodawką sutkową. Z kolei pomiary wysokości są nieco bardziej złożone z uwagi na konieczność uwzględnienia rozstawu nóg, który wpływa na położenie punktów orientacyjnych względem podłoża. Efekt ten kompensowany jest poprzez wyznaczenie osi każdej kończyny dolnej, co pozwala na przetransformowanie chmury punktów na podstawie kąta rozstawu nóg tak, aby odpowiadała pozycji stojącej z nogami prostopadłymi do podłoża. Dzięki temu możliwe jest zasymulowanie postawy stojącej ze złączonymi nogami definiowanej m.in. przez ISO 8559 [35], która wykorzystywana jest w przypadku tradycyjnych pomiarów antropometrycznych. Pseudokod tego algorytmu zaprezentowany jest w Tabeli 4.5, a wynik pomiaru na przykładzie szerokości międzypiersiowej $XpXp$ przedstawia Rysunek 4.10.



Rysunek 4.10 Przykład pomiaru liniowego szerokości międzypiersiowej $XpXp$.

Tabela 4.5 Pseudokod algorytmu wyznaczania długości liniowych.

Algorytm 4 Pomiar długości liniowych
Wejście: XYZ anthropometric_point_1 and/or anthropometric_point_2, type Wyjście: linear length Procedura: Begin if type == width then return Euclidean distance between anthropometric_point_1 and anthropometric_point_2 else if type == height then if anthropometric_point_1 == ankle then return ankle.Z – floor.Z else if anthropometric_point_1 == crotch then - project ankle and crotch onto coronal plane - find leg center of mass at the crotch.Z level - leg_centerline_length = Euclidean distance between ankle center of mass and leg center of mass - crotch_to_ankle_Z_length = crotch.Z – ankle.Z - spread_ratio = leg_centerline_length to crotch_to_ankle_Z_length ratio - save spread_ratio for further measurements return ankle_height + leg_centerline_length else if (anthropometric_point_1).Z < crotch height then - calculate ankle_to_anthropometric_point_1 distance using spread_ratio and Tales theorem return ankle height + ankle_to_anthropometric_point_1 else return crotch height + (anthropometric_point_1).Z – crotch.Z end if end if end if End

Wyżej opisane algorytmy wymiarowania zostały zweryfikowane nie tylko poprzez szereg testów i analiz statystycznych, ale i w praktyce, co opisano w kolejnym rozdziale.

5. Walidacja algorytmów wymiarowania


5.1. Pozyskanie danych testowych

Walidacja działania algorytmów wymiarujących systemu była oparta na pomiarach porównawczych pomiędzy systemami MSP, HS oraz referencyjnym manualnym podejściem. Grupa testowa liczyła 40 ochotników (21 mężczyzn i 19 kobiet), których dane demograficzne zostały zaprezentowane w Tabeli 5.1. Pomiary wszystkimi trzema metodami przeprowadzono w możliwie najkrótszym czasie by uniknąć wahań wymiarów ciała w ciągu doby. Każda z osób została zmierzona jednokrotnie ręcznie oraz trzykrotnie automatycznie przez każdy z systemów. Dokonywany przez wykwalifikowanego eksperta pomiar taśmą mierniczą cechował się dokładnością 1 mm.

Tabela 5.1 Dane demograficzne 40 uczestników badania (21 mężczyzn i 19 kobiet).


	Średnia i odchylenie standardowe	Zakres
Wiek [lata]	34,9 ± 7,6	22–55
Wzrost [cm]	173,1 ± 9,6	150–205
Waga [kg]	72,0 ± 10,8	55–105

Procedura skanowania była analogiczna dla obu analizowanych systemów. Wszystkie osoby były zobligowane do założenia jasnej bielizny oraz przyjęcia pozycji A w przestrzeni pomiarowej, która wymagała rozstawienia nóg na szerokość barków i odsunięcia rąk od ciała z równoczesnym ich zgięciem w łokciach (patrz podrozdział 2.3.4 wyżej). Mając na uwadze uzyskanie możliwie najwyższej jakości danych, uczestnicy proszeni byli o pozostanie w bezruchu przez cały czas skanowania. Do wykonania obliczeń za pomocą systemu MSP potrzebny był tylko skan w jednej pozycji, podczas gdy rozwiązanie HS wymagało drugiego, uzupełniającego skanu ze zmienioną pozycją (ręce podparte na miednicy). Pozycje skanowania dla obu systemów przedstawione są na Rysunku 5.1.



Rysunek 5.1 Pozycje skanowania: A) typu A – wspólna dla obydwu systemów MSP oraz HS, ręce oddalone od tułowia i zgięte w łokciach, B) podparta – wykorzystywana jedynie w systemie HS.

Po przeprowadzeniu skanowania dane były przekazywane do oprogramowania analitycznego, którego zadaniem było wyznaczenie właściwych wymiarów (patrz podrozdział 6.1 niżej). Kończącym etapem był pomiar manualny uczestnika badania przez wykwalifikowanego eksperta. Należy zaznaczyć, iż pozycja pomiarowa przyjęta w tym wypadku nie pokrywała się z tą stosowaną w systemach automatycznych – była zgodna z klasycznymi standardami antropometrycznymi, które nie borykają się z problemami takimi jak przesłanianie skanowanego obiektu przez siebie, co wymaga np. odsunięcia rąk od tułowia. Przykładowe linie pomiarowe wyznaczone opracowaną metodą zostały zilustrowane na Rysunku 5.2.



Rysunek 5.2 Wizualizacje przykładowych linii pomiarowych i punktów antropometrycznych pozyskanych opracowaną metodą.

5.2. Analiza dokładności pomiarów

W celu oceny jakości działania algorytmów przeprowadzono serię testów porównawczych, dla których wyniki pomiarów zastosowanych metodą tradycyjną posłużyły za punkt odniesienia. Jednakże nie wszystkie zdefiniowane pomiary w projekcie zostały uwzględnione w tej analizie. Skoncentrowano się na tych, które można było uzyskać zarówno za pomocą systemu MSP, jak i HS. W związku z tym pomiary $XlXl$, $SySvXpTp$, $PcRvPl$, $PcPl$, $XcXc$, ZSv , ZRv oraz ZPc zostały pominięte w analizie porównawczej.

W pierwszym teście przeprowadzono porównanie pomiędzy pomiarem automatycznym a manualnym. Na podstawie różnic między nimi obliczono bezwzględny błąd wyrażony w milimetrach (patrz Równanie 5.1) oraz względny błąd procentowy (patrz Równanie 5.2).

$$\Delta m = m_a - m_{\text{man}} \quad (5.1)$$

$$\delta_m = \frac{\Delta m}{m_{\text{man}}} \cdot 100\% \quad (5.2)$$

gdzie:


Δm – bezwzględny błąd wyrażony w milimetrach,

δ_m – procentowy błąd względny,


m_a – wartość wyznaczona automatycznie,

m_{man} – wynik pomiaru manualnego (wzorcowego).


Jak wspomniano wcześniej, pomiar ręczny został uznany za referencyjny, czyli w tym wypadku o zerowym błędzie. Dokładność wyznaczenia zestawu wymiarów, uwzględniająca każdy ze skanów, zaprezentowano poniżej w formie skonsolidowanych wykresów pudełkowych Tukey'a [338] oddzielnie dla wszystkich badanych na Rysunku 5.3 oraz z podziałem na płeć na Rysunku 5.4 (mężczyźni) i Rysunku 5.5 (kobiety).



Rysunek 5.3 Wykresy pudełkowe Tukey'a błędów względnych oraz bezwzględnych dla mężczyzn i kobiet: wąsy – najniższe i najwyższe wartości danych mieszczących się w zakresie 1,5 rozstępu ćwiartkowego IQR (z ang. Interquartile Range) od granic kolorowych pudełek IQR, które zawierają 50% wyników zawartych pomiędzy pierwszą i trzecią ćwiartką dla każdego z systemów, czerwone krzyżyki – wartości odstające, okręgi – mediany.



Rysunek 5.4 Wykresy pudełkowe Tukey'a błędów względnych oraz bezwzględnych dla mężczyzn: wąsy – najniższe i najwyższe wartości danych mieszczących się w zakresie 1,5 rozstępu ćwiartkowego IQR od granic kolorowych pudełek IQR, które zawierają 50% wyników zawartych pomiędzy pierwszą i trzecią ćwiartką dla każdego z systemów, czerwone krzyżyki – wartości odstające, okręgi – mediany.



Rysunek 5.5 Wykresy pudełkowe Tukey'a błędów względnych oraz bezwzględnych dla kobiet: wąsy – najniższe i najwyższe wartości danych mieszczących się w 1,5 rozstępie ćwiartkowego IQR od granic kolorowych pudełek IQR, które zawierają 50% wyników zawartych pomiędzy pierwszą i trzecią ćwiartką dla każdego z systemów, czerwone krzyżyki – wartości odstające, okręgi – mediany.

Interpretacja wykresów zamieszczonych na Rysunkach 5.3-5.5 wskazuje na zbliżony poziom dokładności obu analizowanych systemów automatycznych. Wyniki uzyskane za pomocą zaproponowanej w pracy metody cechowały się nieco mniejszym średnim błędem procentowym oraz błędem bezwzględnym w porównaniu do systemu HS. Największą dokładnością i stabilnością charakteryzowały się pomiary obwodowe. Pomiary długości liniowych prezentowały tylko połowicznie zadowalający poziom dokładności – w przypadku wysokości od uda w górę (ZUo, ZTv, ZSy, Zwo). Z kolei pomiary łukowe cechowały się największą rozpiętością błędów i niepewnością, co zostało również potwierdzone w kolejnych testach zaprezentowanych w dalszej części rozdziału. Rozbieżności te są zrozumiałe, biorąc pod uwagę skomplikowany proces wyznaczania wymiarów łukowych. Definicja punktów antropometrycznych oraz przebiegu linii pomiarowej była zwykle znacznie prostsza dla obwodów i długości liniowych niż dla łuków. Co więcej, większość pomiarów łukowych składa się z kilku sekcji, co skutkuje kumulacją błędów. Założony w pracy błąd opracowanej metody na poziomie $< 10\%$ względem referencyjnych danych, pozyskanych manualnie przez

ekspertów, został osiągnięty dla większości typów pomiarów w przypadku minimum 50% osób mierzonych. Niemniej jednak nie dla wszystkich, co wskazuje na potrzebę przeprowadzenia dogłębnej analizy każdego z problematycznych pomiarów (*SvRv*, *RvSxRv*, *XpXp*, *Zho* i *Zko*). Ponadto, biorąc pod uwagę wszystkie wyniki z wyłączeniem obserwacji odstających o ponad 1,5 IQR, zauważyć można, że różnica wartości także innych wymiarów, takich jak *os*, *opp*, *obt*, *on*, *oh*, *SySvXp*, *RvRv*, *SyTy*, *RvNv*, *XpXp*, nie zawsze mieściła się w oczekiwanym przedziale. Szczegółowa analiza konkretnych źródeł błędów i rozbieżności ma miejsce w ostatnim podrozdziale 5.6 niżej.

5.3. Ocena spójności oraz zgodności absolutnej pomiędzy metodami

Kolejny etap walidacji algorytmów obejmował ocenę wiarygodności algorytmów wymiarowania. Zastosowanie analizy statystycznej w postaci metody korelacji wewnątrzklasowej ICC [29] pozwoliło na oszacowanie stopnia spójności i zgodności absolutnej pomiędzy pomiarami przeprowadzonymi przez trzech sędziów, tj. eksperta oraz automatyczne systemy HS i MSP. Poprawne obliczenie ICC wymaga wyboru odpowiedniego modelu. W omawianej sytuacji każdy z pomiarów jest oceniany przez identyczną liczbę sędziów. Zgodnie z literaturą [339], [340] w takim przypadku właściwe podejście jest opisane jako dwukierunkowy model mieszany, gdzie spójność to $ICC(C, 1)$, a zgodność absolutna $ICC(A, 1)$. Zakładając, że rzędy macierzy obserwacji to obiekty pomiarów, a kolumny sędziowie, ich formuły obliczeniowe można przedstawić w następujący sposób (patrz Równania 5.3 i 5.4):

$$ICC(C, 1) = \frac{MS_R - MS_E}{MS_R + (k - 1) \cdot MS_E} \quad (5.3)$$

$$ICC(A, 1) = \frac{MS_R - MS_E}{MS_R + (k - 1) \cdot MS_E + \frac{k}{n} \cdot (MS_C - MS_E)} \quad (5.4)$$

gdzie:

$ICC(C, 1)$ – spójność,

$ICC(A, 1)$ – zgodność absolutna,

MS_R – średnia kwadratowa dla każdego z pomiarów,

MS_E – błąd średniokwadratowy,

MS_C – średnia kwadratowa dla sędziów,


k – liczba sędziów,

n – liczba zmierzonych osób.

Współczynniki $ICC(A, 1)$ oraz $ICC(C, 1)$ dostarczają różnych i uzupełniających się informacji na temat wiarygodności metody i oba powinny być prezentowane wraz z ich przedziałami ufności [341]. W związku z tym analiza ICC obejmowała wyznaczenie górnych i dolnych granic 95% tych przedziałów. Wartości te mogą wahać się między -1 a +1, jednakże dla lepszego zilustrowania rezultatów wszelkie ujemne dolne granice zastąpiono zerem, gdyż były nieistotne. Interpretacja współczynników ICC została dokonana na podstawie kryteriów przedstawionych w Tabeli 5.2. Z kolei wyniki obliczeń dla zestawu pomiarów, oddzielne dla każdej z par sędziów, przedstawia Rysunek 5.6.

Tabela 5.2 Kryteria oceny spójności oraz zgodności absolutnej dla współczynnika ICC (opracowanie własne na podstawie źródła: [30]).

Spójność/zgodność absolutna	Dolna granica	Górna granica
Słaba	0,00	0,40
Średnia	0,40	0,59
Dobra	0,60	0,74
Doskonała	0,75	1,00



Rysunek 5.6 Wyniki testów spójności i zgodności absolutnej ICC dla kombinacji par systemów MSP i HS oraz manualnego podejścia: kropki – wartości współczynnika korelacji wewnątrzklasowej, linie – dolne oraz górne granice błędów wyznaczenia współczynników na poziomie ufności 95%.

Zarówno spójność, jak i zgodność absolutna została wyznaczona nie tylko dla każdego z typów pomiarów oddzielnie, ale również zbiorczo dla grup pomiarów obwodowych, łukowych i długości liniowych (szerokości i wysokości). Tabela 5.3 przedstawia wyniki powyższej analizy.

*Tabela 5.3 Zbiorcze wyniki spójności oraz zgodności absolutnej dla każdej z kombinacji par sędziów w podziale na grupy pomiarów (obwodowe, łukowe, długości liniowe i łącznie):
s – spójność, z – zgodność absolutna.*

	Manualne i MSP		Manualne i HS		MSP i HS	
	s	z	s	z	s	z
Obwody	0,93	0,90	0,93	0,87	0,94	0,92
Łuki	0,73	0,67	0,60	0,54	0,70	0,69
Długości liniowe	0,79	0,71	0,75	0,68	0,79	0,71
Wszystkie	0,84	0,80	0,80	0,74	0,85	0,81

Uzyskane wartości ICC dla pomiarów obwodowych, zgodnie z wytycznymi przedstawionymi w Tabeli 5.2 powyżej, jednoznacznie potwierdziły doskonałą spójność i zgodność absolutną manualnych pomiarów względem obu systemów automatycznych. Z kolei pomiary długości liniowych prezentowały jedynie dobrą zgodność absolutną pomimo doskonałej spójności. Najgorsze wyniki odnotowano dla długości łuków. W przypadku MSP korelacja była na poziomie dobrym dla obu parametrów, natomiast w HS zaobserwowano dobrą spójność, ale jedynie średnią zgodność absolutną. Wartości ICC dla MSP i wszystkich typów pomiarów łącznie mieściły się w założonym w celu pracy doskonałym przedziale i wyniosły 0,84 i 0,80 odpowiednio dla spójności i zgodności absolutnej (patrz Tabela 5.3 powyżej). Niemniej jednak taka forma oceny jest niepełna i zbyt uogólniona. Ze szczegółowej analizy wynika bowiem, że zaproponowane algorytmy wymiarowania spełniają jedynie połowicznie swoje zadanie co do oczekiwanej korelacji na poziomie doskonałym. Z drugiej strony każda z wartości ICC dla poszczególnych grup pomiarów klasyfikowała się przynajmniej do kategorii dobrej, a poszczególne wyniki były zaniżane przez konkretne problematyczne typy wymiarów omówione w podrozdziale 5.2 wyżej.

Chociaż działanie opracowanych algorytmów można w ogólności uznać za satysfakcjonujące, proponowane rozwiązanie nie jest pozbawione wad. Jak widać na Rysunku 5.6 dla 95% przedziału ufności na 26 przeanalizowanych typów pomiarów, 16 charakteryzowało się doskonałą spójnością, 4 dobrą, 5 średnią i 1 słabą. Wyniki systemu HS były nieco gorsze, z 15 typami pomiarów wykazującymi doskonałą spójność, 3 dobrą, 4 średnią i 4 słabą. Natomiast weryfikacja zgodności absolutnej systemu MSP wskazała na doskonałą zgodność w 10 przypadkach, dobrą w 3, średnią w 5 i słabą w 8. W przypadku systemu HS wyniki były nieco gorsze, bo jedynie 7 typów pomiarów zmieściło się w kategorii doskonałej, 1 w dobrej, 4 w średniej i aż 14 w słabej. Podsumowując, wartości ICC dla proponowanych algorytmów

okazały się wyższe niż w przypadku systemu HS, co oznacza, że są one bardziej spójne i wykazują lepszą zgodność absolutną w stosunku do pomiarów manualnych. Niemniej jednak, jak wspomniano wyżej, wyniki te nie są idealne i nie wszystkie mieszczą się oczekiwanym, doskonałym przedziale.

5.4. Ocena powtarzalności wymiarowania

Jak wspomniano wcześniej, każda osoba była skanowana trzy razy pod rząd, co umożliwiło ocenę powtarzalności wymiarowania za pomocą odchylenia standardowego. W pierwszej kolejności określono wariancję dla każdej grupy trzech pomiarów tej samej osoby. Potem obliczono średnią wariancję wszystkich indywidualnych wariancji uczestników. Na koniec wyznaczono odchylenie standardowe dla danego pomiaru jako pierwiastek kwadratowy średniej wariancji. Wyniki testu powtarzalności przedstawiono w Tabeli 5.4 poniżej.

Tabela 5.4 Ocena powtarzalności w postaci odchylenia standardowego dla każdego pomiaru.

Pomiar	os	opx	opp	ot	obt	ob	or	orl	on	ou	ok	ol
MSP [mm]	13,0	13,2	20,3	6,9	6,4	5,2	8,6	5,0	5,2	12,1	6,3	4,4
HS [mm]	7,0	10,4	12,3	7,7	4,1	4,0	3,9	2,0	1,9	3,0	3,6	0,6
Pomiar	oh	SySvXp	RvRv	SyTy	RvNv	XpXp	Zwo	ZSy	ZTv	ZUo	ZKo	ZHo
MSP [mm]	7,6	12,3	12,1	13,7	8,8	11,8	5,1	4,8	9,9	9,7	14,9	4,2
HS [mm]	0,6	11,5	7,8	5,4	7,1	3,9	3,7	2,7	5,9	4,4	2,0	0,4

Powyższe rezultaty wskazują na większy rozrzut błędów systemu MSP niż HS, pomimo bardziej zbliżonych do referencyjnych średnich wartości wyników. Jedną z przyczyn może być zbyt łagodne przetwarzanie końcowe danych w celu uniknięcia niepożądanego wpływu szumu. Analiza wyników systemu HS wskazuje na to, że zastosowana w nim filtracja i uśrednianie danych są silniejsze. Dodatkowe wygładzanie oraz uzupełnianie dziur w chmurze punktów powinno ustabilizować wyniki wymiarowania, ale jednym z celów testów było zaprezentowanie wydajności algorytmów na danych, które możliwie najdokładniej odwzorowują powierzchnię skanowaną. System HS wykorzystuje również dwie pozycje pomiarowe w odróżnieniu do jednej w przypadku proponowanego podejścia, co może zostać wykorzystane do uśredniania części wyników. Ponadto należy pamiętać, że system HS istnieje od wielu lat na rynku, co z pewnością pozwoliło na rozwiązanie jego problemów wieku dziecięcego. Pomimo tego większość typów wymiarów mieści się w założonym w celach pracy limicie odchylenia standardowego na poziomie < 15 mm.

Wyjątkiem jest obwód pod piersiami *opp*, który u kobiet zależy jest od ułożenia i typu biustonosza oraz fałd tkanki miękkiej wokół niego.


5.5. Porównywalność pomiarów manualnych i automatycznych

Analiza jakościowa obejmowała również test kompatybilności pomiędzy wynikami pozyskanymi automatycznie i manualnie. W tym celu zastosowano się do zaleceń normy ISO 20685, która umożliwia ocenę zgodności pomiarów technikami 3D z tradycyjnym, manualnym podejściem antropometrycznym. Zdefiniowane przez nią poziomy akceptacji błędów zostały zaprezentowane w Tabeli 5.5 niżej. Norma ta wymaga również opracowania skanów co najmniej 40 osób, co zostało uwzględnione w trakcie analizy. Wyniki przeprowadzonego testu porównywalności pomiarów przedstawiono na Rysunku 5.7 niżej.

Tabela 5.5 Poziomy akceptacji błędów wg ISO 20685 do oceny porównywalności pomiarów antropometrycznych 3D z tradycyjnymi (opracowanie własne na podstawie źródła: [32]).

Typ pomiaru	Akceptowalny błąd [mm]
Wysokości	±4
Długości odcinków	±5
Głębokości	±5
Szerokości	±4
Małe obwody	±4
Duże obwody	±9
Wymiary stóp i głowy (z włosami)	±4
Wymiary dłoni i głowy (bez włosów)	±1

Test porównywalności ISO 20685



Rysunek 5.7 Wyniki testów porównywalności pomiarów manualnych z automatycznymi: wyszarzone pole – dopuszczalny zakres błędów wg normy ISO 20685, okręgi – średnie błędy, prostokąty – dolne oraz górne granice błędów pomiarowych dla poziomu ufności 95%.

Eksperyment ten miał na celu ocenę możliwości zastąpienia wprost pomiarów manualnych przez automatyczne metody. Z analizy przedstawionej na Rysunku 5.7 powyżej jednoznacznie wynika, że większość analizowanych typów pomiarów nie spełniła kryteriów dokładnościowych tego rygorystycznego testu (patrz Tabela 5.5 wyżej). W przypadku opracowanej metodyki wymiarowania jedynie 5 rodzajów pomiarów (*ot*, *orl*, *ok*, *Zwo* i *ZHo*) pomyślnie go przeszło. Natomiast w systemie HS było ich jeszcze mniej i tylko 3 (*ok*, *RvNv* i *ZHo*) spełniły kryteria normy. Warto nadmienić, że w porównaniu z innymi pomiarami, które przeszły ten test, spójność i zgodność absolutna *ZHo* (wysokość kostki) jest słaba


i nieakceptowalna dla obu systemów 3D (patrz Rysunek 5.6 wyżej). Wartości współczynnika ICC dla pomiarów liniowych okazały się być skorelowane z ich długością. Im krótszy był odcinek mierzony, tym gorsze wyniki go cechowały. Potwierdza to przypadek najmniejszej wysokości *ZHo* o najslabszych wynikach ICC. Związane jest to głównie z faktem, że względny błąd procentowy tego pomiaru jest wysoki. Co więcej, tego typu pomiary nie są bezwzględne, tak jak obwody i długości łuków, lecz wyznaczane są w relacji do podłoża, którego wysokość szacowana jest z pewną dokładnością w procesie obarczonym własnymi błędami.

Podobne problemy i źródła błędów występują nie tylko w przypadku metod rozwijanych w ramach niniejszej pracy, ale również w innych obecnie stosowanych systemach antropometrii 3D. Wiele badań przeprowadzonych w tym zakresie pokazuje, że spełnienie wymagań normy ISO 20685 jest w większości przypadków niemożliwe, nawet biorąc pod uwagę tylko najprostsze rodzaje pomiarów obwodów i długości liniowych [46], [328]–[330], [342], [343]. Z drugiej strony, o ile spełnione są odpowiednie warunki, takie jak dobra spójność wyników danego systemu 3D, możliwe jest zastosowanie współczynnika korekcji i zmodyfikowanie rezultatów na jego podstawie. W takim wypadku porównywalność pomiarów ręcznych z automatycznymi może być zadowalająca [26], [330]. Różnice w wynikach można przypisać m.in. niespójnej interpretacji i detekcji punktów antropometrycznych wykorzystywanych do wyznaczenia przebiegu linii pomiarowych oraz odmiennej pozycji pomiarowej. Niemniej jednak poprawa dokładności i stabilności ich lokalizacji na skanie 3D, zwłaszcza w przypadku miejsc podskórnych, powinna pozwolić na osiągnięcie lepszych rezultatów. Automatyczna identyfikacja punktów antropometrycznych bywa zdecydowanie bardziej skomplikowana, ale pozwala osiągnąć lepszą powtarzalność i przewidywalność wyników w odróżnieniu do metod tradycyjnych, co zostało omówione w podrozdziale 2.5 wyżej.


Przydatność tej metody ISO do oceny zgodności między metodami ręcznymi i cyfrowymi bywa poddawana w wątpliwość przez niektórych badaczy ze względu na swą restrykcyjność i niespójność definicji antropometrycznych [46]. Alternatywnie do oceny niezawodności i powtarzalności pomiarów dokonywanych zarówno przez eksperta, jak i systemy automatyczne stosuje się również m.in. maksymalny dopuszczalny błąd pomiaru MAD (z ang. *Mean Absolute Difference*) [344]. Szeroko stosowane kryteria akceptacji lub odrzucenia wyników na podstawie MAD dla pomiarów antropometrycznych zostały opracowane na podstawie doświadczeń i wyników badań ANSUR I [17].

5.6. Rozbieżności między wynikami automatycznych i manualnych pomiarów


W celu lepszego zrozumienia źródeł błędów przeprowadzono szczegółową analizę dokładności w postaci histogramów rozkładu procentowych błędów względnych (patrz Równanie 5.2 wyżej). Pozwoliło to na zidentyfikowanie mocnych i słabych stron omawianych metod oraz wykrycie różnic w zastosowanych podejściach. Wyniki mieszczące się w obrębie 1,5 rozstępu ćwiartkowego podzielono na klasy. Każda z wartości w danym przedziale obliczona została jako procent całkowitej liczby pomiarów, a różnica między kolejnymi klasami wynosiła 2%. Ze względu na znaczną liczbę typów pomiarów wyselekcjonowano i opisano poniżej jedynie te uznane za istotne. Wybrane znormalizowane histogramy dokładności wyznaczania dla głównych grup pomiarów zostały zaprezentowane na Rysunkach 5.8-5.10. Rysunek 5.11 ilustruje przykład nieobsługiwanego pomiaru przez system HS, a Rysunek 5.12 przedstawia problematyczny przypadek.




Rysunek 5.8 Przykładowe znormalizowane histogramy dokładności wyznaczania obwodów: os – obwód szyi, ok – obwód kolana.




Rysunek 5.9 Przykładowe znormalizowane histogramy dokładności wyznaczania łuków: SySvXp – długość przodu do piersi, SyTy – długość pleców.



Rysunek 5.10 Przykładowe znormalizowane histogramy dokładności wyznaczania szerokości i wysokości: *XpXp* – szerokość międzypiersiowa, *Zko* – wysokość kolana.



Rysunek 5.11 Przykładowe znormalizowane histogramy dokładności wyznaczania pomiaru nieobsługiwanego przez system HS: *SySvXpTp* – łuk długości przodu przez pierś.



Rysunek 5.12 Przykładowe znormalizowane histogramy dokładności wyznaczania problematycznego wymiaru: *SvRv* – łuk barków tyłu.

Wyniki obliczeń obwodu szyi os w systemie MSP były zazwyczaj bliższe uzyskanym manualnie niż w przypadku HS (patrz Rysunek 5.8 wyżej). Dla odmiany przypadek *ok* (obwód kolana) prezentował znacznie lepszą zbieżność wyników. Jednak patrząc na Rysunek 5.10 powyżej, gdzie *ZKo* to wysokość kolana, można zauważyć, że żaden z automatycznych systemów nie obliczył wysokości w taki sam sposób, w jaki zrobił to ekspert manualnie. Oprogramowanie Human Solutions z reguły lokalizowało kolano ok. 20 mm niżej, podczas gdy MSP 40 mm wyżej niż ekspert w trakcie pomiaru ręcznego. Mimo to wyniki obliczeń *ok* dla obu systemów można uznać za wystarczająco dokładne wg ISO 20685, ponieważ ich błędy są mniejsze niż 4 mm. Oznacza to, że wartość obwodu kolana jest mało zmienna


w obrębie pewnego przedziału wysokości. Testy ICC potwierdzają tę hipotezę. Spójność i zgodność absolutna z 95% przedziałem ufności dla *ok* są na poziomie doskonałym, ale dla *Zko* tylko dobrym lub słabym. Źródłem problemu jest nieprecyzyjna definicja środka kolana. Jak widać na tym przykładzie, lokalizacja punktów antropometrycznych nie zawsze jest oczywista, co czasami może prowadzić do nieprawidłowego pomiaru. Taki scenariusz miał również miejsce podczas wymiarowania kobiecego biustu. Histogram dokładności szerokości międzypiersiowej *XpXp* można zobaczyć na Rysunku 5.10. Punkty sutków nie były zwykle widoczne podczas skanowania kobiet ze względu na sztywne biustonosze, co uniemożliwiało ich łatwe wykrycie na podstawie tylko krzywizny Gaussa tak jak u mężczyzn. W związku z tym konieczne było przyjęcie pewnych przybliżonych założeń dotyczących lokalizacji brodawek. W rezultacie długość *XpXp* była nieco krótsza niż zmierzona ręcznie.

Następna kategoria histogramów została przedstawiona na Rysunku 5.9 wyżej i obejmuje dwa pomiary łukowe: *SySvXp* (długość przodu do piersi) i *SyTy* (długość pleców). W przypadku *SySvXp* wyniki wymiarowania są zbliżone do tych uzyskanych ręcznie, ale ich wartość jest z reguły nieco zaniżona. Uzupełnieniem tego pomiaru, nieuwzględnionym w HS, ale istotnym z punktu widzenia celów projektu Formfit, jest pomiar *SySvXpTp* (długość przodu przez pierś) przedstawiony na Rysunku 5.11 wyżej. Charakteryzuje się on akceptowalnymi wynikami pomimo kumulacji błędów wynikających z niedokładności wykrywania kolejnych punktów orientacyjnych ciała, przez które przebiega linia wymiarowania. Nieprecyzyjna lokalizacja punktów wynika z powodów, takich jak niewidoczne sutki czy niejednoznaczna definicja nasady szyi *Sv*. Przykładowo punkt *Sv*, zdefiniowany w założeniach metody jako ten o największym zagięciu pomiędzy szyją a ramieniem, znajduje się w teorii w miejscu przecięcia linii szyi z mięśniem czworobocznym z jej boku. Jego opis wywodzi się z dziedziny konstrukcji odzieży i nie jest naturalny dla antropometrii, co powoduje, że jest trudny do zlokalizowania również w manualny sposób [21]. Wyżej omawiane pomiary cechuje ponadto słaba powtarzalność, nie tylko w przypadku systemów automatycznych, ale i pomiędzy różnymi ekspertami. Wartości *SyTy* są w większości również zaniżone względem referencyjnych, jednak ma to raczej związek z charakterem tego typu pomiarów, a nie z metodą lokalizacji punktów antropometrycznych *Sy* (krąg C7) i *Ty* (talia pod kręgiem C7). Dokładność detekcji tych punktów jest na stosunkowo zadowalającym poziomie, na co wskazują inne pomiary bezpośrednio z nimi związane – wysokość szyi *ZSy* i talii *ZTv*, co można zaobserwować na Rysunkach 5.3-5.5 wyżej. Rozbieżność wyznaczonych długości wyżej wspomnianych łuków może wynikać z faktu, iż podczas ręcznego pomiaru taśma

miernicza przylega do większej powierzchni pleców i nie znajduje się tak blisko kręgosłupa, jak w przypadku pomiarów automatycznych. Może to budzić wątpliwości, czy pomiar ręczny jest zawsze najlepszym wyborem do zastosowań antropometrycznych, mając dodatkowo na uwadze jego niejednokrotnie słabą powtarzalność.

Wyniki uzyskane w tradycyjny sposób mogą się różnić w zależności od osoby mierzącej, postawy ciała w trakcie badań czy jakości narzędzi mierniczych. Pomiar obwodu bioder z uwzględnieniem wypukłości brzucha *obt* stanowi przykład słabości podejścia manualnego. Ręczne obliczanie *obt* nie jest trywialnym zadaniem, ponieważ wymaga przystawienia do brzucha pomocniczego arkusza papieru, który musi być sztywny i stabilny przez cały czas trwania pomiaru. Dla odmiany, przypisany mu algorytm komputerowy jest dość prosty i przewidywalny, gdyż operuje bezpośrednio na geometrii powierzchni ciała i pozwala na jej swobodną analizę, przez co jego wynik można uznać za bardziej wiarygodny.

Część pomiarów długości, takich jak np. łuku barku *SvRv*, barków przodu *RvSxRv* czy barków tyłu *RvRv*, charakteryzuje wysoki rozrzut w przypadku obu automatycznych systemów, co można zaobserwować na Rysunku 5.12 dla przypadku *SvRv* i zbiorczym zestawieniu na Rysunkach 5.3-5.5 wyżej. Wyniki HS dla *SvRv* cechują mniejsze wartości niż te wyznaczone ręcznie czy za pomocą proponowanych algorytmów MSP. Jak widać na Rysunku 5.13 poniżej, zaniżone wartości pomiaru *SvRv* uzyskane za pomocą systemu HS wynikają z niespójnej definicji pozornie takich samych wymiarów. Po pierwsze, linia pomiarowa HS jest prosta i nie leży na powierzchni ramienia, a co za tym idzie jest krótsza. Po drugie, pomiędzy systemami występują różnice w sposobie lokalizacji punktu szyi *Sv* i wyrostka barkowego *Rv*. Pozycja przyjęta przez osobę badaną ma istotny wpływ na położenie punktu *Rv*. Odsunięcie ramion od tułowia, charakterystyczne dla postawy A, powoduje uniesienie tego punktu oraz zmianę geometrii linii barku. Ponadto nie zawsze osoby mierzone są w stanie unieść ręce w ten sam sposób. W przypadku ręcznego pomiaru ten problem nie miał miejsca. Niespójność położenia wyrostka barkowego ma też wpływ na wymiary *RvRv*, *RvSxRv* i *RvNv* (długość kończyny górnej). W przypadku *RvSxRv* rozrzut wyników jest jednak nieco mniejszy dzięki relatywnie łatwo lokalizowanej charakterystycznej krzywiźnie dołu szyjnego pomiędzy obojczykami *Sx* będącego częścią tego pomiaru. Analogiczna sytuacja ma miejsce dla *RvNv*, gdzie *Nv* to punkt nadgarstka.



Rysunek 5.13 Różnice w sposobach pomiaru łuku barku SvRv pomiędzy omawianym podejściem a systemem HS na przykładzie danych ze skanera HS.

Warto zwrócić uwagę na inny problem związany z pomiarami obwodów klatki piersiowej przez piersi *opx* i pod nimi *opp*. Ich wyniki uzyskane za pomocą automatycznych metod mają z reguły większą wartość niż w przypadku manualnego podejścia. Niemniej jednak testy ICC pokazują, że długości te są spójne. Powodem tej rozbieżności jest m.in. to, że ludzie mają tendencję do cofania łopatek podczas skanowania. Ponadto klatka piersiowa rozszerza się w trakcie oddychania nawet o 6-8 cm [345], co może stanowić dodatkowy problem. Z kolei błędy w pomiarach obwodów piersi u kobiet mogą też mieć źródło w źle dobranym biustonoszu [346]. W tradycyjnej antropometrii oczekiwana pozycja klatki piersiowej jest na bieżąco kontrolowana przez eksperta.

Warto podkreślić, że raportowana dokładność wyznaczenia geometrii powierzchni przez użyte skanery 3D dotyczy obiektów statycznych (patrz Tabela 3.1 wyżej). W przypadku skanera MSP akwizycja danych trwała ok. 3 s, a HS 10 s. Przy takim czasie skanowania mimowolne ruchy rąk czy tułowia są nieuniknione, co ma istotny wpływ na błędy odwzorowania powierzchni człowieka. Orientacja danych z poszczególnych sensorów zakłada, że dopasowywane dane są ciałem sztywnym. W przypadku proponowanego systemu pomiar obwodu nadgarstka *on* był często utrudniony przez niedokładność złożenia chmur na krańcach rąk. Wynikało to z tego, że dłonie są najbardziej oddalone w łańcuchu kinematycznym szkieletu ciała licząc od sztywnego położenia stóp na podłożu. Jest to jeden z powodów, dla którego pomiary były każdorazowo powtarzane (patrz podrozdział 5.1

wyżej)). Najefektywniejszym rozwiązaniem byłoby zastosowanie nowoczesnych skanerów fotogrametrycznych, które pozwalają skrócić ten czas nawet do 0,01 s [290], ale wiąże się to z reguły bardzo wysoką ceną urządzenia. Przytoczony skaner Botspot Neo o takich parametrach kosztuje 200 tysięcy dolarów amerykańskich [283]. Alternatywą są bardziej zaawansowane algorytmy orientacji wzajemnej danych wielosensorowych uwzględniające opisywaną nieszttywność.

Inne powody różnic w wynikach pomiarów pomiędzy omawianymi automatycznymi podejściami mogą obejmować różnice w grubości dobieranego przekroju, poziom szum pomiarowego, stopień pokrycia skanowanego ciała i związane z nim braki w danych czy odmienne podejście do pomiaru (np. zastosowany w systemie HS przekrój w poziomie przez nogę zamiast prostopadle do jej osi kości).

6. Praktyczne zastosowanie metody w przemyśle odzieżowym

6.1. Opracowane aplikacje

Algorytmy służące do wymiarowania ciała człowieka zostały napisane w języku programowania C++. Zaimplementowano je w postaci wtyczek środowiska FRAMES (z ang. *Framework and Robust Algorithms for Models of Extreme Size*). Oprogramowanie to, opracowane przez zespół badawczy OGX|OPTOGRAPHX Wydziału Mechatroniki Politechniki Warszawskiej, jest kompleksowym środowiskiem do wizualizacji oraz przetwarzania dużych i skomplikowanych obliczeniowo danych 3D/4D. Wtyczki składają się z metod zawierających implementację kolejnych etapów przetwarzania, do których odniesienia prezentowane są w formie *NazwaWtyczki.Metoda* w niniejszej pracy.

Zaimplementowane narzędzia zostały zintegrowane z systemem do ewidencji i analizy danych antropometrycznych AWiOR oraz aplikacją graficzną MSP służącą do obsługi skanera. Oprogramowanie to było częścią demonstratora technologii wykonanego we współpracy z konsorcjantem projektu Formfit – firmą Medcore. Połączenie opracowanego procesu przetwarzania z wyżej wymienionymi zewnętrznymi programami było możliwe dzięki dodaniu modułu komunikacji międzyprocesowej IPC (z ang. *Interprocess Communication*) do środowiska FRAMES. Pozwala on na płynną wymianę danych, poleceń i wzajemne sterowanie pomiędzy dwiema niezależnymi aplikacjami. W tym celu zaimplementowano klasy *IPCServer* oraz *IPClient* w oparciu o mechanizm tzw. łącz nazwanych klasy *QLocalSocket* biblioteki Qt [347]. Funkcjonalność ta wykorzystywana jest przez aplikację użytkownika końcowego systemu. Oprogramowanie MSP pracuje jako serwer IPC, który uruchamia środowisko FRAMES będące klientem. Dzięki temu może wywoływać odpowiednie metody wtyczek oraz otrzymuje status przeprowadzanych operacji.


Za koordynację całego procesu przetwarzania (patrz rozdział 4 wyżej) od strony środowiska FRAMES odpowiada wtyczka *Formfit*, której działanie obejmuje cztery główne etapy:

- inicjację skanowania 3D i obróbkę danych pozyskanych bezpośrednio z sensorów,
- wstępne przetwarzanie chmury punktów,
- właściwy proces wymiarowania, który zależy od typu oczekiwanego wymiaru,
- eksport danych.

6.1.1. Skanowanie 3D

Algorytmy odpowiedzialne za przygotowanie gotowego modelu 3D powierzchni ciała człowieka w postaci chmury punktów zostały zaimplementowane we wtyczce *FormfitScan*. Jej metody wywoływane są jako pierwsze przez nadrzędny moduł *Formfit*.

W pierwszej kolejności wtyczka *FormfitScan* uruchamia kolumny pomiarowe skanera w celu przeprowadzenia procesu skanowania 3D i pozyskania surowych chmur punktów. Do tego celu wykorzystywana jest metoda *FormfitController.CloudsManager*, która odpowiedzialna jest za komunikację ze skanerem. Użytkownik ma możliwość modyfikacji parametru określającego typ pomiaru – synchroniczny lub sekwencyjny. Należy nadmienić, iż metody do niskopoziomowej obsługi systemu skanującego zostały zaimplementowane przez innych członków zespołu badawczego w ramach projektu Formfit. Niemniej jednak ich integracja z zewnętrznym oprogramowaniem MSP była częścią niniejszej pracy. Zaimplementowana komunikacja IPC umożliwiła konfigurację parametrów skanowania, uruchomienie i przerwanie akwizycji, wizualizację postępu procesu czy wyświetlenie statusu obecnego etapu przetwarzania. Rysunek 6.1 przedstawia widok aplikacji MSP w trakcie pomiaru.



Rysunek 6.1 Widok aplikacji MSP w trakcie pomiaru obsługiwanego przez moduł komunikacji IPC.

W kolejnym kroku przetwarzania wtyczki *FormfitScan* usuwane są punkty szumowe za pomocą dostępnych w środowisku FRAMES metod *Clouds_Segmentation.HausdorffFiltering* oraz *Clouds_Segmentation.Boundary*. Algorytm w *Clouds_Segmentation.HausdorffFiltering* opiera się na wykorzystaniu przestrzeni Hausdorffa do podziału punktów pozyskanych ze skanera na grupy i eliminuje te o niewielkiej liczbie punktów. Z kolei metoda *Clouds_Segmentation.Boundary* jest odpowiedzialna za identyfikację i usunięcie krawędzi chmury punktów, które cechują się dużym poziomem szumu.

Bezpośrednie dane zwrócone przez skaner poprzez *FormfitController.CloudsManager* obejmują 8 wstępnie skalibrowanych ze sobą wzajemnie chmur punktów (górne i dolne dla każdej z 4 kolumn). Dane te wymagają dodatkowej, dokładnej orientacji wzajemnej, do której wykorzystywana jest wtyczka *ICP.NodeToNode* wbudowana w środowisko FRAMES. Zaimplementowana w niej metoda ICP pozwala na wyznaczenie optymalnej transformacji pomiędzy chmurami. Po zakończonym procesie orientacji chmur punktów dochodzi do ich scalenia. W celu usunięcia potencjalnie dużych, niepożądanych obiektów, które mogły zostać przypadkowo zeskanowane (np. podest) i nie zostały wyeliminowane w pierwszym etapie filtracji, ponownie stosowana jest metoda *Clouds_Segmentation.HausdorffFiltering*.

Ostatni etap przekształcenia surowych chmur punktów w pełny model 3D sylwetki ciała człowieka obejmuje zastosowanie algorytmów do wyznaczania wektorów normalnych *Clouds_NormalVectors.CalculateUsingLocalBestFitPlane*, ujednolicenie ich kierunków *Clouds_NormalVectors.ConsistentNormalReorientation* oraz wygładzenie przy pomocy dopasowania płaszczyzn *Clouds_SmoothingPlaneFitting.SmoothingPlaneFitting*, co pozwala zredukować szum pomiarowy na powierzchni skanowanej.

Podstawa działania powyższych algorytmów została opisana dokładniej w podrozdziale 4.1.1 wyżej.

6.1.2. Algorytmy wymiarowania

Detekcja punktów antropometrycznych i właściwe algorytmy wymiarowania poprzedzone są przetwarzaniem wstępnym, które składa się z dwóch głównych etapów: segmentacji oraz wyznaczenia krzywizny Gaussa modelu. Algorytmy segmentacji zawarte zostały we wtyczce *FormfitSegmentation*, a obliczenie krzywizny Gaussa modelu w *CurvatureEstimation*. Szczegółowy opis obu etapów, wraz z pseudokodem w przypadku segmentacji (patrz Tabela 4.1) i zaimplementowanymi równaniami dla krzywizny (patrz zestaw Równań 4.1), można

znaleźć odpowiednio w podrozdziałach 4.1.2 i 4.1.3 wyżej. Do rozwiązywania układów liniowych i operacji na macierzach wykorzystywane były funkcje biblioteki Eigen [348].

Zarówno algorytmy wymiarowania wirtualnego modelu, jak i metody detekcji punktów antropometrycznych zostały zaimplementowane we wtyczce *FormfitMeasure*. W każdym przypadku linia wymiarowania ma unikalny przebieg, który obejmuje jeden lub więcej punktów orientacyjnych. Implementacja metod ich wykrywania została oparta wprost o opis 3D, który przedstawiony został w Tabeli 4.2 wyżej.

Do wyznaczenia otoczki wypukłej, będącej częścią wymiarowania obwodów i łuków, wykorzystano bibliotekę Qhull [349]. Pseudokod algorytmu obliczania długości obwodów zaprezentowany jest w Tabeli 4.3, łuków w Tabeli 4.4 a długości liniowych w Tabeli 4.5.

Koncepcja działania powyższych algorytmów została opisana dokładniej w podrozdziałach 4.2 i 4.3 wyżej.

6.1.3. Eksport danych

Na wyjściu głównej wtyczki *Formfit* powstaje tzw. paczka pomiarowa, która składa się z następujących elementów:

- *measurements.xml* – plik zawierający kompletne wyniki pomiarów ciała,
- *scan.ply* – binarny plik w formacie PLY (z ang. *Polygon File Format*) [350], który przechowuje model 3D sylwetki w formie chmury punktów, a także pomocnicze punkty linii wymiarowania wykorzystywane do ich wizualizacji,
- *front.jpg* oraz *side.jpg* – pliki zawierające widoki od frontu i profilowy w postaci zrzutów ekranów okna renderowania aplikacji FRAMES.

Do paczki pomiarowej dołączany jest ponadto wygenerowany przez aplikację MSP plik *metric.xml* z danymi metrykalnymi. Tak przygotowana paczka może być wczytana i przekazywana zarówno w trybie offline, jak i online pomiędzy instancjami systemu AWiOR.

Za eksport wyników pracy wtyczki wymiarującej *FormfitMeasure* odpowiadają następujące metody: *ExportXML*, *ExportPLY* i *ExportScreenshots*.

ExportXML

Do zapisu wyników wymiarowania ciała używany jest format pliku XML (z ang. *Extensible Markup Language*) [351], który przechowuje informacje o czasie wykonania pomiaru, jednostce miary oraz szczegółowe dane dotyczące poszczególnych wymiarów, takie jak liczba porządkowa, nazwa, numer i wynik. W związku z ograniczeniami wizualizacyjnymi oprogramowania AWiOR eksportowane są jedynie wysokości lewych części ciała. Struktura przykładowego pliku XML została przedstawiona w Tabeli 6.1 poniżej.

Tabela 6.1 Przykładowy plik measurement.xml zawierający komplet wymiarów ciała osoby skanowanej pozyskanych za pomocą wtyczki FramesMeasure.

<pre><?xml version="1.0"?> <Measurements created="01-01-2018 00:00:00" unit="cm"> <measurement id="1" name="os" measurementNumber="1520">42.09</measurement> ... <measurement id="47" name="ZHo" measurementNumber="0120">8.27</measurement> </Measurements></pre>	– deklaracja XML – data utworzenia pliku, jednostka miary – wynik pomiaru o liczbie porządkowej <i>id</i>, nazwie <i>name</i> oraz numerze pomiaru <i>measurementNumber</i>
--	---

ExportPLY

Chmurę punktów osoby skanowanej oraz pomocnicze punkty do wizualizacji linii wymiarowania zapisywane są w formacie binarnym PLY z kolejnością bajtów little endian [352]. Każdemu punktowi modelu przypisane są współrzędne, wektor normalny oraz numer klasy, który określa jego przynależność (0 – element modelu 3D, 1-47 – punkt linii wymiarowania o danej liczbie porządkowej). Przykładowy plik *scan.ply* jest przedstawiony w Tabeli 6.2.

Tabela 6.2 Przykładowy plik scan.ply zawierający skan 3D wraz z liniami wymiarowania.

<pre>nagłówek pliku ply format binary_little_endian 1.0 comment Author: MSP Formfit obj_info Generated by MSP Formfit element vertex 1244517 property float x property float y property float z property float nx property float ny property float nz property char dla end_header sekcja danych w postaci binarnej ...</pre>	– format zapisu danych – informacje o autorze i oprogramowaniu generującym plik – liczba punktów w pliku – wartość współrzędnej x punktu – wartość współrzędnej y punktu – wartość współrzędnej z punktu – wartość wektora normalnego x punktu – wartość wektora normalnego y punktu – wartość wektora normalnego z punktu – nr klasy określający przynależność punktu; 0 – model 3D, 1-47 punkt linii wymiarowania wg liczby porządkowej wymiaru (measurement id z pliku <i>measurement.xml</i> opisanego wyżej)
--	---

ExportScreenshots

Rzuty 2D widoków od frontu oraz lewego profilu sylwetki eksportowane są do formatu JPEG (z ang. *Joint Photographic Experts Group*) [353]. Obrazy te wykorzystywane są przez oprogramowanie AWiOR jako podgląd, który pozwala uniknąć wolniejszego ładowania całego modelu 3D. Możliwość wykonania zrzutów ekranu jest częścią funkcjonalności środowiska FRAMES. Odpowiednie ustawienie kamery w przestrzeni 3D możliwe jest dzięki wcześniejszej transformacji chmury punktów do znanego układu współrzędnych w procesie przygotowania danych (patrz podrozdział 4.1.1 wyżej).

Przekazana do aplikacji MSP paczka pomiarowa została zaprezentowana na Rysunku 6.2 poniżej. Z kolei Rysunek 6.3 przedstawia poglądowy widok ekranów aplikacji AWiOR do analizy statystycznej bazy wymiarów skanowanej populacji i podglądu poszczególnych wyników pomiarów danej osoby, które zostały przekazane do bazy danych w formie paczki pomiarowej.


The screenshot displays the MSP application interface. At the top, there's a navigation bar with icons for home, scan, and measurement. The main area is divided into two sections: 'Sylwetka' (Body Model) on the left and 'Metryka' (Metrics) on the right. The 'Sylwetka' section shows a 3D model of a human figure. The 'Metryka' section contains a form with various input fields for personal data, including name, date of birth, and weight. Below these sections is a table titled 'Cechy pomiarowe' (Measurement Features) which lists various body measurements and their corresponding values.

Id	cecha	wartość	symbol	algorytm	opis
107	Wzrost	178,8	Zwz	1.0	Wzrost Mierzony od podstawy do wierzchołka głowy
109	Wysokość 7 kregu szyi	157,89	Z5y	1.0	Wysokość 7 kregu szyi z boku
116	Wysokość talii	109,1	ZTv	1.0	Wysokość talii
119	Wysokość krocza	79,82	ZUo	1.0	Wysokość krocza
120	Wysokość kolana	56,69	ZKo	1.0	Wysokość kolana
121	Wysokość kostki	9,02	ZKo	1.0	Wysokość kostki
3	Obwód szyi	47,8	os	1.0	Obwód szyi mierzony z przodu poniżej chrząstki tarczycowej, a z tyłu powyżej punktu karkowego
10	Łuk barków z tyłu	50,41	RvRv	1.0	Łuk szerokości barków tyłu
11	L łuk długości barku	13,31	SvRv_L	1.0	L łuk długości barku
12	P łuk długości barku	14,77	SvRv_p	1.0	P łuk długości barku
15	Łuk barków z przodu	46,55	RvSvRv	1.0	Łuk szerokości barków przodu
17	Szerokość międzypleciowa	23,61	XpRv	1.0	Szerokość międzypleciowa
24	Obwód klatki piersiowej przez piersi	111,3	ops	1.0	Obwód klatki piersiowej przez piersi- mierzony poziomo przez punkty brodawkowe
26	Obwód klatki piersiowej pod piersiami	104,91	opp	1.0	Obwód klatki piersiowej pod piersiami- mierzony poziomo pod piersiami

Rysunek 6.2 Końcowy etap procesu skanowania i wymiarowania – wczytanie przekazanej przez wtyczkę FormfitMeasure paczki pomiarowej do aplikacji MSP.

sylwetek stosowanych w konstrukcji odzieży specjalistycznej i wyznaczenia nowych tabel rozmiarów dla służb mundurowych.

Analiza statystyczna i testy pokrycia starych typoszeregów ubrań zostały wykonane przy użyciu zewnętrznej aplikacji AWiOR, omówionej w podrozdziale 6.1 wyżej. Okazało się, że w przypadku niektórych popularnych typów odzieży, np. zimowych spodni Straży Granicznej, wymiary prawie połowy osób nie mieszczą się w żadnym z przedziałów tabeli rozmiarów. Przypadek ten przedstawiono na Rysunku 6.4 poniżej. Ponadto analiza pozwoliła na wyodrębnienie nowych typów sylwetek, nie branych pod uwagę wcześniej w procesie projektowania odzieży dla funkcjonariuszy. Potwierdziło to nie tylko zasadność realizacji projektu Formfit, ale i ujawniło skalę problemu. Naturalnie, niektóre z nieprawidłowo dopasowanych mundurów są używane pomimo tego, ale prowadzi to do dyskomfortu i wiąże się z kosztownymi poprawkami krawieckimi. Regularna aktualizacja typoszeregów ubrań jest niezbędna, aby zapobiec niepotrzebnym stratom magazynowym drogiej odzieży specjalistycznej. O ile nadal nie będzie możliwe zapewnienie idealnie dopasowanej garderoby dla każdej osoby, to ogólny komfort jej noszenia może ulec znacznej poprawie.



Rysunek 6.4 Widok zewnętrznego narzędzia AWiOR do analizy i optymalizacji tabel rozmiarów dla spodni służbowych zimowych: oś X – wzrost, oś Y – obwód w talii, niebieskie prostokąty – stare tabele rozmiarów, zielone kropki – dane zmierzonych osób w ramach projektu Formfit.

W ostatniej fazie projektu Formfit zeskanowano 32 funkcjonariuszy Policji w celu ostatecznej weryfikacji systemu i proponowanej metodyki. Umożliwiło to przygotowanie dla nich ubrań szytych na miarę, bez potrzeby wykonywania pomiarów ręcznych.

7. Podsumowanie

7.1. Realizacja celów badawczych

Przedmiot niniejszej rozprawy doktorskiej dotyczył opracowania oraz weryfikacji metody automatycznego pomiaru ciała człowieka na potrzeby przemysłu odzieżowego na podstawie danych ze skanera 3D. Główny cel pracy został osiągnięty poprzez zaproponowanie, implementację i przetestowanie procedury, która umożliwia przetwarzanie danych w postaci chmury punktów do formy zestawu wymiarów użytecznych dla projektowania odzieży i szeroko pojętych badań antropometrycznych. Opracowanie koncepcji poprzedzono było przeglądem literaturowym przedstawionym w rozdziale 2 wyżej, który to został później zaktualizowany na potrzeby niniejszej rozprawy by przedstawiać możliwe pełny i aktualny stan wiedzy w zakresie dynamicznie rozwijających się technik pomiaru ciała człowieka. Szczegółowe cele i założenia pracy przedstawione zostały pokrótce w podrozdziale 1.2 wyżej, a komentarz co do rezultatów ich realizacji poniżej.

Pierwszym celem naukowym było stworzenie w pełni udokumentowanej metodyki automatycznego wyznaczania wymiarów antropometrycznych o błędzie procentowym względem wyników pomiarów manualnych poniżej 10%, powtarzalnością z odchyleniem standardowym mniejszym niż 15 mm oraz doskonałym współczynnikiem spójności i zgodności absolutnej ICC. W rozdziale 4 niniejszej pracy przedstawiono pełną ścieżkę przetwarzania dla cyfrowej antropometrii, począwszy od przygotowania surowych danych pozyskanych za pomocą skanera 3D do postaci pełnego modelu geometrii ciała człowieka, a skończywszy na szczegółowym opisie złożonych pomiarów wielosegmentowych. Opis metody uzupełniają pseudokody pozwalające na reprodukcję opracowanych w trakcie pracy algorytmów.

Z analizy przedstawionej w rozdziale 5 wynika, że pomimo starań, założony w pracy procentowy błąd metody względem danych referencyjnych zebranych ręcznie przez specjalistów został osiągnięty jedynie połowicznie biorąc pod uwagę wszystkie wyniki z wyłączeniem obserwacji odstających. Jednakże, zakładając mniej restrykcyjne minimum 50% przypadków, jedynie 5 typów pomiarów nie spełniło oczekiwań. Pomiary obwodowe wyróżniały się największą dokładnością. Liniowe wykazały się silną zależnością od długości i dokładności wyznaczenia punktów antropometrycznych i pomocniczych. Podobna sytuacja miała miejsce w przypadku pomiarów łukowych, które cechowała największa rozbieżność wyników spowodowana głównie wpływem niekompatybilnej pozycji pomiarowej względem

manualnej procedury oraz kumulacją błędów lokalizacji punktów antropometrycznych. Dla odmiany precyzja i powtarzalność metody wymiarowania, zbadana na podstawie kolejnych pomiarów tej samej osoby, mieściła się w założonym w celach pracy limicie odchylenia standardowego. Wyjątkiem był jedynie obwód pod piersiami, na który istotny wpływ ma ruch klatki piersiowej, a dodatkowo u kobiet bielizna.

Analiza spójności i zgodności absolutnej technik antropometrycznych, przeprowadzona za pomocą testów ICC, wykazała doskonały stopień korelacji pomiędzy pomiarami obwodowymi wykonanymi manualnie i za pomocą zaproponowanej metody. Z kolei pomiary długości liniowych, pomimo doskonałej spójności, cechowały się jedynie dobrą zgodnością absolutną. Najgorsze wyniki odnotowano dla wyznaczania długości łuków, w przypadku których oba parametry uzyskały jedynie dobrą korelację. Analiza poszczególnych rodzajów pomiarów oddzielnie wykazała, że nie zawsze korelacja na poziomie doskonałym była możliwa do osiągnięcia. Niemniej jednak zbiorcza ocena spójności i zgodności absolutnej dla wszystkich typów pomiarów i całego systemu była doskonała, z wartościami ICC wynoszącymi odpowiednio 0,84 i 0,80.

Kompleksowa analiza jakości algorytmów wymiarowania utrudniona jest poprzez różnorodność potencjalnych problemów charakteryzujących poszczególne typy pomiarów. W rozdziale 5 wyżej podjęto dyskusję w tym zakresie i omówiono szczegółowo źródła błędów dla poszczególnych typów pomiarów, a ograniczenia metody podsumowano w podrozdziale 7.2.2 niżej.

Kolejny cel naukowy obejmował zapewnienie automatyczności procesu przetwarzania danych. W związku z tym poszczególne etapy, takie jak filtracja, segmentacja i wzajemna orientacja skanu, detekcja punktów antropometrycznych czy wyznaczanie linii pomiarowej, zaprojektowano tak, aby były bezobsługowe. Cel ten był możliwy do zrealizowania poprzez wykorzystanie zaawansowanych technik przetwarzania danych 3D oraz wiedzy a priori o charakterystyce powierzchni ciała człowieka, co opisano w rozdziale 4 wyżej. Przebieg linii pomiarowej proponowanej metody jest wyznaczany zgodnie z zasadami działania taśmy mierniczej dla krzywych i obwodów oraz cyrkla antropometrycznego dla długości i szerokości. Do imitacji ułożenia taśmy na ciele stosowana jest metoda otoczki wypukłej, a analizowana grubość przekroju odpowiada szerokości taśmy mierniczej. Naśladownictwo działania cyrkla antropometrycznego obejmuje z kolei bezpośrednie obliczenie odległości euklidesowej pomiędzy punktami antropometrycznymi.

Wyniki i wnioski wyciągnięte z pracy mogą przyczynić się do zobiektywizowania i usprawnienia metod przeprowadzania nowoczesnych badań antropometrycznych, co było ostatnim celem naukowym prezentowanej rozprawy. Automatyczny pomiar ciała na podstawie chmury punktów jest znacznie szybszy od tradycyjnych technik pomiarowych i cechuje go mniejsza podatność na błędy związane z czynnikiem ludzkim. Pozwala to na przeprowadzanie badań na większej próbie populacji w krótszym czasie, co może zwiększyć zakres i wiarygodność analizy antropometrycznej. Zastosowanie danych 3D umożliwia ponadto pełniejsze zrozumienie kształtu i proporcji ciała, oferując narzędzia do analizy niemożliwej do przeprowadzenia manualnie. Na rynku istnieją systemy 3D odpowiadające na tę potrzebę, co zostało przedstawione w 2.4 wyżej. Niemniej jednak wśród obecnie stosowanych metod do przeprowadzania badań 3D ciała człowieka na dużą skalę brak jest rozwiązań otwartych, o jasnym schemacie działania algorytmów wymiarowania. Z reguły deklarowana jest przez nie jedynie niepodparta oficjalnie dostępną weryfikacją zgodność ze standardami, które to zresztą najczęściej nie powstawały z myślą o analizie danych 3D. W odpowiedzi na to wyzwanie zawarto w pracy holistyczny opis algorytmów cyfrowego pomiaru ciała człowieka, który pozwala na zreprodukowanie omawianego procesu obliczeń danych, zewnętrzną walidację, a także podjęcie szerszej dyskusji w celu poprawy ew. błędów w sposobie działania czy rozwoju metody w przyszłości. Dzięki możliwości wersjonowania algorytmów dane można też przeliczyć ponownie i porównać skuteczność modyfikacji.

Pierwszym celem aplikacyjnym było przystosowanie algorytmów do obsługi kompleksowego zestawu wymiarów, który może być zastosowany do projektowania różnych typów ubrań. Wymagania zostały określone przez zespół ekspertów z Instytutu Włókiennictwa w Łodzi w oparciu o doświadczenie w konstrukcji odzieży, przedyskutowane w ramach konsultacji interdyscyplinarnych oraz odpowiednio zaadaptowane mając na uwadze charakter skanowania 3D i różnice względem tradycyjnego pomiaru krawieckiego. Pozwoliło to przygotować dokładny opis 3D sposobu wyznaczenia 13 pomiarów obwodowych, 9 łukowych, 3 szerokości i 9 wysokości na podstawie 17 punktów antropometrycznych rozmieszczonych na całym ciele (patrz spisy w Tabelach 1.1 i 1.2 oraz opis metody w rozdziale 4 wyżej).

Weryfikacja konkurencyjności i zasadności tworzenia nowego systemu do cyfrowej antropometrii 3D stanowiła kolejny istotny element omawianych badań. Przeprowadzona w rozdziale 5 wyżej analiza jakości działania metody obejmowała nie tylko skonfrontowanie jej wyników z pomiarami ręcznymi, uznawanymi powszechnie za złoty standard w dziedzinie

antropometrii, ale i z automatycznymi. Opracowany w ramach projektu system porównano z rozwiązaniem firmy Human Solutions będącej jednym z liderów na światowym rynku. Na podstawie opisanej wcześniej wstępnej analizy dokładności i powtarzalności wyników można stwierdzić, że jakość uzyskana za pomocą proponowanej metodologii jest porównywalna, a w niektórych aspektach nawet lepsza, niż w przypadku konkurencyjnego podejścia. Z drugiej strony ani rozwijany system MSP, ani referencyjny HS nie przeszedł testu zaproponowanego w normie ISO 20685, który ocenia porównywalność między pomiarami ręcznymi i automatycznymi (patrz podrozdział 5.5 wyżej). Oznacza to, że bezpośrednie przełożenie wyników pozyskanych automatycznie na tradycyjne nie zawsze jest oczywiste lub w ogóle możliwe. Praca nad pełną kompatybilnością stanowi kolejny obszar do doskonalenia w celu zwiększenia konkurencyjności proponowanego rozwiązania. Jednakże pytaniem otwartym pozostaje to czy jest to w każdym scenariuszu projektowania odzieży konieczne będąc świadomym różnic i specyfiki pomiaru 3D.

Przeprowadzone badania wykazały, że podstawowe założenia, zgodnych z obowiązującymi normami, pomiarów manualnych i automatycznych nie są w pełni kompatybilne. W związku z tym różnice pomiędzy nimi muszą być brane pod uwagę podczas projektowania odzieży i wyznaczania jej nowych tabel rozmiarów w celu zminimalizowania niejednoznaczności i błędów. Niespójność postawy pomiarowej, czy niemożność palpacyjnego określenia położenia punktów antropometrycznych na i pod powierzchnią skóry ciała, to jedne z przykładów rozbieżności pomiędzy tymi technikami. Ponadto różne standardy cechują często rozmyte i niespójne definicje położenia punktów antropometrycznych czy miejsc przebiegu linii pomiarowej, co tym bardziej utrudnia wiarygodną automatyzację procesu. Niepewność w detekcji punktów antropometrycznych dotyczy nie tylko technik automatycznych. Manualnie wyznaczone punkty orientacyjne również nie gwarantują najlepszej korelacji między ciałem a odzieżą. Pomiar 3D powierzchni ciała może w tym przypadku dostarczyć dodatkowych informacji, które mogą być wykorzystane w projektowaniu odzieży, a które nie są dostępne w tradycyjny sposób. Zastosowanie zaproponowanej metody cyfrowej pozwala również na wykonanie większej liczby pomiarów w krótkim czasie. Podsumowując, metoda ta może być zastosowana z sukcesem w praktyce przemysłowej, czego dowodem jest tego przykład opisany poniżej.

Po etapie wstępnej walidacji algorytmów (patrz rozdział 5 wyżej), zaproponowana metoda została użyta do przeprowadzenia badań antropometrycznych 565 funkcjonariuszy służb mundurowych, w tym 117 kobiet i 448 mężczyzn. Wyniki analizy stanowiły część wkładu

potrzebnego do aktualizacji typoszeregów odzieży służbowej. Pozostałe dane, dotyczące ok. 2800 osób, dostarczył system HS. Tabele rozmiarów ubrań funkcjonariuszy mundurowych zostały zoptymalizowane tak, aby zapewnić maksymalne możliwe pokrycie populacji. Dzięki temu liczba źle dopasowanych mundurów powinna ulec znaczącemu zmniejszeniu. Ze względu na dynamikę zmian w budowie ciała ludzkiego i charakterystyki populacji funkcjonariuszy zalecane jest okresowe powtarzanie tego procesu, które może być dokonane przy użyciu omawianego systemu. Chociaż same tabele zostały opracowane przez innych konsorcjantów projektu Formfit, dane antropometryczne są wynikiem zastosowania opisywanej metody. Ostatnia faza praktycznej walidacji systemu obejmowała pomiar grupy 32 funkcjonariuszy policji jedynie za pomocą opracowanych algorytmów. Pozwoliło to na zaprojektowanie dla nich mundurów szytych na miarę. Pomiary dla celów projektu Formfit zostały szczegółowo opisane w podrozdziale 6.2 wyżej.

W toku prac opracowano ponadto szereg narzędzi do przetwarzania danych począwszy od wtyczek środowiska FRAMES odpowiedzialnych za poszczególne etapy procesu pozyskiwania wymiarów, przez międzyprocesowy moduł komunikacji z aplikacją użytkownika końcowego do obsługi systemu MSP, aż po eksporter wyników w formacie zgodnym z wymaganiami zewnętrznego oprogramowania do analizy i przechowywania danych AWiOR (patrz podrozdział 6.1 wyżej).

Wyniki wyżej opisanych badań, wraz z całościowym opisem procesu wymiarowania na podstawie chmury punktów oraz jego zastosowaniem w kontekście przygotowania nowych typoszeregów ubrań funkcjonariuszy służb mundurowych, zostały opublikowane w ramach artykułu [354] (liczba cytowań na dzień 5 maja 2024 r. oraz 2-letni IF (z ang. *Impact Factor* – wskaźnik cytowań) za 2022 r.):

- **Ł. Markiewicz**, M. Witkowski, R. Sitnik, i E. Mielicka, „3D Anthropometric Algorithms for the Estimation of Measurements Required for Specialized Garment Design”, *Expert Syst. Appl.*, t. 85, s. 366–385, 2017, doi: 10.1016/j.eswa.2017.04.052 (liczba cytowań: 45, IF: 8,5)

oraz zaprezentowane na konferencji 3DBODY.TECH 2017 w Kanadzie [355]:

- **Ł. Markiewicz**, E. Mielicka, G. Wasilewski, K. Mularczyk, L. Napieralska, i R. Sitnik, „Unification Process for Uniforms with Use of 3D Body Scanning”, w *Proceedings of 3DBODY.TECH 2017 - 8th International Conference and*

Exhibition on 3D Body Scanning and Processing Technologies, Montreal, Canada: Hometrica Consulting - Dr. Nicola D'Apuzzo, 2017, s. 170–178. doi: 10.15221/17.170.

Ponadto zdobyte w trakcie realizacji niniejszej pracy doświadczenie i wiedza pozwoliły wspomóc dalsze badania w dziedzinie detekcji punktów antropometrycznych z wykorzystaniem sieci CNN [255] oraz rekonstrukcji ciała człowieka na podstawie zdjęć metodą SfS [68], które zostały opublikowane w czasopismach naukowych i były podstawą obrony dwóch prac magisterskich:

- M. Koźbiał, **Ł. Markiewicz**, i R. Sitnik, „Algorithm for Detecting Characteristic Points on a Three-Dimensional, Whole-Body Human Scan”, *Appl. Sci.*, t. 10, nr 4, sty. 2020, doi: 10.3390/app10041342 (liczba cytowań: 4, IF 2,7),
- W. Krajnik, **Ł. Markiewicz**, i R. Sitnik, „sSfS: Segmented Shape from Silhouette Reconstruction of the Human Body”, *Sensors*, t. 22, nr 3, 2022, doi: 10.3390/s22030925 (liczba cytowań: 4, IF 3,9).

7.2. Wnioski wynikające z badań

7.2.1. Korzyści z zastosowania metody

Chociaż opracowana metoda nie spełnia w pełni wszystkich założonych kryteriów jakościowych, jej efektywne wykorzystanie w badaniach antropometrycznych dla potrzeb przemysłu odzieżowego nadal jest możliwe. Jak wykazano w trakcie badań, jej zastosowanie umożliwia identyfikację nowych typów sylwetek, tworzenie dokładnych tabel rozmiarów oraz zwiększanie efektywności procesu poprzez skrócenie czasu pozyskiwania i przetwarzania danych. Efekty pracy mogą pomóc w obiektywizacji i ulepszeniu procedur przeprowadzania nowoczesnych badań antropometrycznych oraz usystematyzowaniu wiedzy o nowoczesnych technikach pomiaru ciała, co opisano powyżej w podsumowaniu osiągniętych celów.

Automatyczna analiza danych 3D pozwala na wyeliminowanie błędów i niespójności pomiędzy różnymi ekspertami, co ma kluczowe znaczenie w przypadku nieprecyzyjnych bądź niejednoznacznych definicji miejsc pomiarowych. Z kolei bezpośrednie wykorzystanie chmury punktów umożliwiła przeprowadzanie linii pomiarowych możliwie blisko rzeczywistej geometrii ciała ludzkiego. Pozwala to na osiągnięcie powtarzalnych, precyzyjnych i dokładnych pomiarów, o ile uwzględnione zostaną nieuniknione rozbieżności pomiędzy tradycyjnym podejściem antropometrycznym, a nowoczesnym cyfrowym.

Dzięki dotychczasowym wynikom pozyskanym za pomocą opracowanej metody, możliwe stało się podjęcie działań mających na celu zwiększenie komfortu noszenia odzieży, redukcję strat magazynowych i ujednolicenie tabel rozmiarów pomiędzy różnymi polskimi służbami mundurowymi. Możliwość przeprowadzania powtarzalnych, modyfikowalnych i rozszerzalnych pomiarów otwiera nowe perspektywy w przyszłym monitorowaniu zmian ciała ludzkiego na przestrzeni czasu. To z kolei przekłada się na zmniejszenie skumulowanego kosztu iteracyjnego procesu aktualizacji typoszeregów odzieży.

Opracowane w trakcie pracy narzędzia przetwarzania chmury punktów do postaci danych antropometrycznych mają potencjał do szerszego zastosowania w przemyśle odzieżowym. Dzięki ich integracji z zewnętrznym oprogramowaniem do analizy i ewidencji danych, powstały system umożliwia szybkie, wiarygodne i powtarzalne zbieranie informacji o charakterystyce wymiarów ciała, co jest niezbędne do usprawnienia procesu projektowania i produkcji odzieży. Co więcej, proponowana ścieżka przetwarzania nie jest ograniczona jedynie do zastosowań w odzieżownictwie, lecz po niewielkiej adaptacji może być z powodzeniem stosowana w innych dziedzinach, takich jak monitorowanie postępów ćwiczeń czy rehabilitacji.

7.2.2. Ograniczenia

Największy wpływ na wyniki wymiarowania ma dokładność wyznaczenia punktów antropometrycznych oraz jakość analizowanej powierzchni, na podstawie której wyznaczana jest linia pomiarowa. Zaproponowana metoda antropometrii 3D jest o tyle efektywna, precyzyjna oraz powtarzalna, o ile zapewnione są dobrej jakości i przewidywalne dane wejściowe, co nie zawsze jest możliwe. Mimowolna zmiana postawy w trakcie skanowania osoby mierzonej podczas trwania tego procesu wpływa istotnie na jakość zeskanowanych danych, a co za tym idzie na końcowe wyniki algorytmów wymiarowania. Główne źródła potencjalnych błędów są następujące:

- niekompletność danych i niepoprawność odwzorowania geometrii w wyniku przesłoneń, szumu, bielizny, włosów czy niedoskonałości zastosowanej metody skanowania 3D,
- czynnik ludzki obejmujący zmienność kształtu ciała w zależności od przyjętej postawy, oddechu, kołysania się, napięcia lub drżenia mięśni czy nawet pory dnia, a także niedopatrzenia operatora systemu lub koordynatora sesji pomiarowej,

- niespójność pozycji pomiarowej zarówno w obrębie kolejnych powtórzeń pomiaru tej samej osoby, jak i pomiędzy różnymi ludźmi, która wymaga ciągłego monitorowania,
- czas skanowania, który przekłada się bezpośrednio na trudność w utrzymaniu stałej pozycji, krótszy pozwoliłby uniknąć problemów z orientacją wzajemną chmur punktów z różnych chwil czasowych,
- rozbieżności pomiędzy standardami antropometrycznymi w obrębie definicji oraz niepełna kompatybilność pomiędzy tradycyjnym podejściem a cyfrowym (prace prowadzone m.in. przez IEEE P3141 nad standaryzacją przetwarzania ciała człowieka w 3D są cały czas w toku, a ich zakończenie nadal nie gwarantuje rozwiązania wszystkich problemów),
- niedokładność wyznaczenia punktów antropometrycznych wynikająca często ze zbyt rozmytych definicji ze względu na ich nienamacalny charakter, zwłaszcza w przypadku osób z wysokim poziomem tkanki tłuszczowej utrudniającym detekcję podskórnych punktów szkieletowych, dla których analiza krzywizny powierzchni nie jest oczywista,
- wady oprogramowania, skanera 3D czy niedokładność kalibracji.

Powyższe problemy są typowe nie tylko dla zaproponowanego rozwiązania, ale dla wszystkich systemów cyfrowej antropometrii 3D. Pomimo znacznych postępów w dziedzinie automatycznej lokalizacji punktów orientacyjnych ciała, będących podstawą pomiaru antropometrycznego, jak dotąd nie znaleziono metody, która byłaby w pełni niezawodna, wszechstronna i jednocześnie wydajna. W związku z tym ważne jest dokładne przedstawienie sposobu pomiaru i przyjętych założeń. W przypadku współpracy z przemysłem odzieżowym konieczne są konsultacje interdyscyplinarne, aby osiągnąć zamierzoną dokładność i adaptowalność wyników. Wymagać to może dostosowania się do oczekiwań danego producenta odzieży i przyjętych przez niego standardów. Wadą zaproponowanego systemu jest również cena i niska dostępność dla masowego odbiorcy. Warto zatem śledzić równoległe rozwój mobilnych skanerów 3D i metod wykorzystujących techniki głębokiego uczenia do estymacji wymiarów ciała na podstawie ograniczonych danych pozyskanych za pomocą łatwo dostępnych narzędzi.

Część z powyższych problemów wydaje się być nieunikniona. Niemniej jednak dotychczasowe wyniki pokazały, że pomimo tego metoda może być z sukcesem zastosowana do przeprowadzenia profesjonalnych badań antropometrycznych na szeroką skalę. Wyniki

dotychczasowych prac wykazały się wysokim potencjałem rozwojowym i nie odbiegały znacząco od rezultatów pozyskanych za pomocą uznanego systemu komercyjnego, co może stanowić solidną podstawę do dalszych badań, których plan zaprezentowano poniżej.

7.3. Perspektywy dalszych badań i rozwoju metody

Dalsze prace nad rozwojem zaproponowanej metody pomiaru ciała na podstawie chmury punktów obejmują:

- zwiększenie dokładności, precyzji i niezawodności pomiaru poprzez:
 - uzupełnianie ubytków w skanach na etapie przygotowania danych, co pozwoli na pełniejsze odwzorowanie powierzchni człowieka,
 - wykorzystanie uczenia maszynowego do uniezależnienia algorytmów segmentacji i detekcji punktów antropometrycznych od pozycji pomiarowej i budowy ciała osoby mierzonej, co powinno zwiększyć uniwersalność, skuteczność i powtarzalność metody,
 - zastosowanie szybszego skanera w celu minimalizacji wpływu błędów wynikających z ruchu mierzonej osoby w trakcie badania i/lub metod rejestracji ciała deformującego się do łączenia chmur punktów z poszczególnych sensorów,
 - wspomoczenie operatora systemu pomiarowego poprzez opracowanie algorytmu detekcji błędnej postawy i zgłaszanie nieprawidłowości na bieżąco,
- szeroko zakrojone testy algorytmów na zróżnicowanej anatomicznie grupie osób, co umożliwi ocenę skuteczności metody na większej próbie populacji i zaproponowanie odpowiednich optymalizacji rozwiązania w razie potrzeby,
- testy porównawcze wyników wymiarowania na podstawie chmury punktów z danymi poddanymi dodatkowej rekonstrukcji 3D ciała najnowszymi metodami, obejmującymi dopasowanie modeli parametrycznych czy swobodną deformację siatki trójkątów.

Ponadto planowane jest zbadanie możliwości wykorzystania zaproponowanych algorytmów w następujących obszarach:

- tworzenia nowych standardów pomiarów antropometrycznych dla specjalistycznej odzieży, co pozwoli na lepsze dopasowanie ubrań do potrzeb wymagających użytkowników (np. dla komandosów, sportowców czy osób z nietypową budową ciała), gdzie wymagana jest większa dokładność pomiaru i uwzględnienie

niesymetryczności czy specyfiki budowy ciała danego człowieka tak, aby proces projektowania oraz produkcji był bardziej zautomatyzowany,

- pomiarów funkcjonalnych 4D obejmujących analizę zmian wymiarów ciała człowieka w ruchu, co pomoże lepiej zrozumieć i zidentyfikować kluczowe parametry ciała, a co za tym idzie zwiększyć komfort użytkowania ubrań zaprojektowanych z wykorzystaniem tej metody,
- monitorowania oraz analizy medycznej nie tylko za pomocą wymiarów 1D pozyskiwanych opracowaną metodą, ale też wykorzystując przewagę danych 3D i 4D, które w odróżnieniu od metod manualnych umożliwiają m.in. śledzenie całego płata fragmentu powierzchni ciała człowieka.

8. Bibliografia

- [1] S. Pheasant i C. M. Haslegrave, *Bodyspace: Anthropometry, Ergonomics, and the Design of Work*. Boca Raton, FL, USA: CRC Press, 2005. doi: 10.1177/106480460701500210.
- [2] J. Strzałko i in., *Słownik terminów biologicznych*. Poznań: Wydawnictwo Naukowe UAM, 2006. Dostęp: 15 maj 2024. [Online]. Dostępne na: <https://wydawnictwo.pwn.pl/content/download/32191/1319221/version/1/file/Słownik+terminów+biologicznych+całość.pdf>
- [3] F. W. G. Foat, „Anthropometry of Greek Statues”, *J. Hell. Stud.*, t. 35, s. 225–259, lis. 1915, doi: 10.2307/624543.
- [4] L. Ma i J. Niu, „Three-Dimensional (3d) Anthropometry and Its Applications in Product Design”, w *Handbook of Human Factors and Ergonomics*, John Wiley & Sons, Ltd, 2021, s. 281–302. doi: 10.1002/9781119636113.ch11.
- [5] A. Albrizio, „Biometry and Anthropometry: From Galton to Constitutional Medicine”, *J. Anthropol. Sci.*, t. 85, s. 101–123, sty. 2007.
- [6] J. Komlos, „Anthropometric History: An Overview of a Quarter Century of Research”, *Anthropol. Anz. Ber. Uber Biol.-Anthropol. Lit.*, t. 67, nr 4, s. 341–356, grudz. 2009, doi: 10.1127/0003-5548/2009/0027.
- [7] P. R. M. Jones i M. Rioux, „Three-Dimensional Surface Anthropometry: Applications to the Human Body”, *Opt. Lasers Eng.*, t. 28, s. 89–117, 1997, doi: 10.1016/S0143-8166(97)00006-7.
- [8] N. Werghi, „Segmentation and Modeling of Full Human Body Shape from 3-D Scan Data: A Survey”, *IEEE Trans. Syst. Man Cybern. Part C Appl. Rev.*, t. 37, nr 6, s. 1122–1136, lis. 2007, doi: 10.1109/TSMCC.2007.905808.
- [9] „Apparel Market Worldwide”, *Statista*. <https://www.statista.com/topics/5091/apparel-market-worldwide/> (dostęp 15 maj 2024).
- [10] W. Leal Filho i in., „An Overview of the Contribution of the Textiles Sector to Climate Change”, *Front. Environ. Sci.*, t. 10, wrz. 2022, doi: 10.3389/fenvs.2022.973102.
- [11] „Improving Returns Management for Apparel Companies”, McKinsey. Dostęp: 15 maj 2024. [Online]. Dostępne na: <https://www.mckinsey.com/industries/retail/our-insights/returning-to-order-improving-returns-management-for-apparel-companies#/>
- [12] „Rynek Mody w Polsce”, KPMG, lis. 2018. Dostęp: 15 maj 2024. [Online]. Dostępne na: <https://assets.kpmg.com/content/dam/kpmg/pl/pdf/2018/11/pl-Raport-KPMG-pt-Rynek-mody-w-polsce.pdf>
- [13] S. Zheng i S. Winnick, „The True Cost of Apparel Returns: Alarming Return Rates Require Loss-Minimization Solutions”, *Coresight Research*, 4 kwiecień 2023. <https://coresight.com/research/the-true-cost-of-apparel-returns-alarming-return-rates-require-loss-minimization-solutions/> (dostęp 15 maj 2024).

- [14] J. Fugiel, K. Kochan-Jacheć, D. Koźlenia, i J. Domaradzki, „Changes in Anthropometric Measurements and Physical Fitness of Polish Students in 20-Year Period”, *Int. J. Environ. Res. Public. Health*, t. 19, nr 24, 2022, doi: 10.3390/ijerph192416885.
- [15] A. Rodriguez-Martinez i in., „Height and Body-Mass Index Trajectories of School-Aged Children and Adolescents from 1985 to 2019 in 200 Countries and Territories: A Pooled Analysis of 2181 Population-Based Studies with 65 Million Participants”, *The Lancet*, t. 396, nr 10261, s. 1511–1524, lis. 2020, doi: 10.1016/S0140-6736(20)31859-6.
- [16] W. Yu, „9 - Human Anthropometrics and Sizing Systems”, w *Clothing Appearance and Fit*, J. Fan, W. Yu, i L. Hunter, Red., Woodhead Publishing, 2004, s. 169–195. doi: 10.1533/9781845690380.169.
- [17] C. Gordon i in., „Anthropometric Survey of U.S. Army Personnel: Summary Statistics, Interim Report for 1988”, *Anthropol. Res. Proj. Inc*, sty. 1989.
- [18] C. Gordon i in., „2012 Anthropometric Survey of U.S. Army Personnel: Methods and Summary Statistics”.
- [19] „NHANES - National Health and Nutrition Examination Survey”. <https://www.cdc.gov/nchs/nhanes/index.htm> (dostęp 15 maj 2024).
- [20] G. S. Daniels, *The Average Man?* w Technical note WCRD. Wright-Patterson Air Force Base, 1952. Dostęp: 15 maj 2024. [Online]. Dostępne na: <https://books.google.pl/books?id=NxmdHAAACAAJ>
- [21] N. Zakaria i D. Gupta, *Anthropometry, Apparel Sizing and Design*. Woodhead Publishing, 2019.
- [22] J. Fan, W. Yu, i L. Hunter, „3D Body Scanning”, w *Clothing Appearance and Fit*, J. Fan, W. Yu, i L. Hunter, Red., Woodhead Publishing, 2004, s. 135–168. doi: 10.1533/9781845690380.135.
- [23] D. Tyler, A. Mitchell, i S. Gill, „Recent Advances in Garment Manufacturing Technology: Joining Techniques, 3D Body Scanning and Garment Design”, w *The Global Textile and Clothing Industry: Technological Advances and Future Challenges*, 2012, s. 131–170. doi: 10.1533/9780857095626.131.
- [24] P. Liberadzki, **Ł. Markiewicz**, M. Witkowski, i R. Sitnik, „Novel 4D Whole Body Scanning Solution and Its Medical Application”, w *Proceedings of 3DBODY.TECH 2018 - 9th International Conference and Exhibition on 3D Body Scanning and Processing Technologies*, Lugano, Switzerland: Hometrica Consulting - Dr. Nicola D’Apuzzo, 2018, s. 47–56. doi: 10.15221/18.047.
- [25] K. Bartol, D. Bojanic, T. Petkovic, i T. Pribanic, „A Review of Body Measurement Using 3D Scanning”, *IEEE Access*, t. 9, s. 67281–67301, 2021, doi: 10.1109/ACCESS.2021.3076595.

- [26] A. Kuehnappel, P. Ahnert, M. Loeffler, A. Broda, i M. Scholz, „Reliability of 3D Laser-Based Anthropometry and Comparison with Classical Anthropometry”, *Sci. Rep.*, t. 6, s. 26672, maj 2016.
- [27] S. Gill, E. Scott, C. McDonald, A. Klepser, i I. Dabolina, „IEEE 3D Body Processing Industry Connections—Landmarking for Product Development”, *IEEE 3D Body Process. Ind. Connect. Prod. Dev.*, s. 1–48, 2022.
- [28] C. K. Chua, C. H. Wong, i W. Y. Yeong, „Software and Data Format”, *Stand. Qual. Control Meas. Sci. 3D Print. Addit. Manuf.*, s. 75–94, 2017.
- [29] P. E. Shrout i J. L. Fleiss, „Intraclass Correlations: Uses in Assessing Rater Reliability.”, *Psychol. Bull.*, t. 86, nr 2, s. 420–428, 1979, doi: 10.1037/0033-2909.86.2.420.
- [30] D. V. Cicchetti, „Guidelines, Criteria, and Rules of Thumb for Evaluating Normed and Standardized Assessment Instruments in Psychology”, *Psychol. Assess.*, t. 6, s. 284–290, 1994, doi: 10.1037/1040-3590.6.4.284.
- [31] „Vitronic”, *3D Bodyscan for Customized Clothing*. <https://www.vitronic.com/en-us/3d-bodyscan/body-scan-for-made-to-measure> (dostęp 15 maj 2024).
- [32] „ISO 20685-1:2018”, *3-D scanning methodologies for internationally compatible anthropometric databases — Part 1: Evaluation protocol for body dimensions extracted from 3-D body scans*. <https://www.iso.org/standard/63260.html> (dostęp 15 maj 2024).
- [33] I. T. i T. D. TRICOTEXTIL, *Tabele szczegółowych wymiarów dzieci, dziewcząt, chłopców, kobiet i mężczyzn*. Łódź, 1997.
- [34] „ISO 7250-1:2017”, *Basic human body measurements for technological design — Part 1: Body measurement definitions and landmarks*. <https://www.iso.org/standard/65246.html> (dostęp 15 maj 2024).
- [35] „ISO 8559-1:2017”, *Size designation of clothes — Part 1: Anthropometric definitions for body measurement*. <https://www.iso.org/standard/61686.html> (dostęp 15 maj 2024).
- [36] „PN-EN 13402-3:2017-11”, *Oznaczenie wielkości odzieży - Część 3: Przedstawianie wielkości odzieży na etykiecie na podstawie wymiarów ciała i wielkości interwałów*. <https://sklep.pkn.pl/pn-en-13402-3-2017-11e.html> (dostęp 15 maj 2024).
- [37] C. L. Istook i S.-J. Hwang, „3D Body Scanning Systems with Application to the Apparel Industry”, *J. Fash. Mark. Manag. Int. J.*, t. 5, nr 2, s. 120–132, 2001.
- [38] E. L. Scott, „2 - The Role of 3D Measurement Technology and Anthropometric Data for Improved Garment Fit and Sustainable Manufacturing”, w *Digital Manufacturing Technology for Sustainable Anthropometric Apparel*, N. Zakaria, Red., w The Textile Institute Book Series. Woodhead Publishing, 2022, s. 23–48. doi: 10.1016/B978-0-12-823969-8.00002-2.
- [39] „ISO”, *International Organization for Standardization*, 28 kwiecień 2023. <https://www.iso.org/home.html> (dostęp 15 maj 2024).

- [40] „CEN”, *European Committee for Standardization*. <https://www.cencenelec.eu/> (dostęp 15 maj 2024).
- [41] „PKN”, *Polski Komitet Normalizacyjny*. <https://www.pkn.pl/> (dostęp 15 maj 2024).
- [42] „ASTM”, *American Society for Testing and Materials*. <https://www.astm.org/> (dostęp 15 maj 2024).
- [43] „IEEE Standards Association”, *Industry Connections (IC) 3D Body Processing*. <https://standards.ieee.org/industry-connections/3d/bodyprocessing/> (dostęp 15 maj 2024).
- [44] „ISAK”, *The International Society for the Advancement of Kinanthropometry*. <https://www.isak.global/> (dostęp 15 maj 2024).
- [45] „The WHO Child Growth Standards”. <https://www.who.int/tools/child-growth-standards/standards> (dostęp 15 maj 2024).
- [46] A. Ballester i in., „IEEE SA 3D Body Processing Industry Connections—Comparative Analysis of Anthropometric Methods: Past, Present, and Future”, *Comp. Anal. Anthr. Methods Past Present Future*, s. 1–52, maj 2022.
- [47] „ISO 15535:2012”, *General requirements for establishing anthropometric databases*. <https://www.iso.org/standard/57179.html> (dostęp 15 maj 2024).
- [48] „ASTM D5219-15”, *Standard Terminology Relating to Body Dimensions for Apparel Sizing*. <https://www.astm.org/d5219-15.html> (dostęp 15 maj 2024).
- [49] „IEEE P3141”, *Standard for 3D Body Processing*. <https://standards.ieee.org/ieee/3141/10825/> (dostęp 15 maj 2024).
- [50] C. Viviani, P. M. Arezes, S. Bragança, J. Molenbroek, I. Dianat, i H. I. Castellucci, „Accuracy, Precision and Reliability in Anthropometric Surveys for Ergonomics Purposes in Adult Working Populations: A Literature Review”, *Int. J. Ind. Ergon.*, t. 65, s. 1–16, maj 2018, doi: 10.1016/j.ergon.2018.01.012.
- [51] K. Norton, „Standards for Anthropometry Assessment”, 2018, s. 68–137. doi: 10.4324/9781315385662-4.
- [52] H. M. Daanen i G. J. van de Water, „Whole Body Scanners”, *Displays*, t. 19, nr 3, s. 111–120, 1998.
- [53] N. D’Apuzzo, „3D Body Scanning Technology for Fashion and Apparel Industry”, w *Videometrics IX*, SPIE, 2007, s. 203–214.
- [54] T. Olds i F. Honey, „The Use of 3D Whole-Body Scanners in Anthropometry”, w *Proceedings of the 9th International Conference of the International Society for the Advancement of Kinanthropometry*, Taylor & Francis, 2006, s. 1–12.
- [55] P. Treleaven i J. Wells, „3D Body Scanning and Healthcare Applications”, *Computer*, t. 40, nr 7, s. 28–34, 2007.

- [56] H. a. M. Daanen i F. B. Ter Haar, „3D Whole Body Scanners Revisited”, *Displays*, t. 34, nr 4, s. 270–275, paź. 2013, doi: 10.1016/j.displa.2013.08.011.
- [57] S. Giancola, M. Valenti, i R. Sala, *A Survey on 3D Cameras: Metrological Comparison of Time-of-Flight, Structured-Light and Active Stereoscopy Technologies*. Springer, 2018.
- [58] A. Haleem i M. Javaid, „3D Scanning Applications in Medical Field: A Literature-Based Review”, *Clin. Epidemiol. Glob. Health*, t. 7, nr 2, s. 199–210, 2019.
- [59] M. Daneshmand i in., „3D Scanning: A Comprehensive Survey”, sty. 2018.
- [60] S. Kolose, P. Hume, A. Stewart, i G. Tomkinson, „Part II: An Overview of 3D Body Scanning Technology”, 2021, Dostęp: 15 maj 2024. [Online]. Dostępne na: <http://hdl.handle.net/10292/15648>
- [61] H. A. Correia i J. H. Brito, „3D Reconstruction of Human Bodies from Single-View and Multi-View Images: A Systematic Review”, *Comput. Methods Programs Biomed.*, t. 239, s. 107620, wrz. 2023, doi: 10.1016/j.cmpb.2023.107620.
- [62] G. Turk, „The Stanford Bunny”. <http://graphics.stanford.edu/data/3Dscanrep/> (dostęp 15 maj 2024).
- [63] E. Camuffo, D. Mari, i S. Milani, „Recent Advancements in Learning Algorithms for Point Clouds: An Updated Overview”, *Sensors*, t. 22, nr 4, Art. nr 4, sty. 2022, doi: 10.3390/s22041357.
- [64] I.-F. Leong, J.-J. Fang, i M.-J. Tsai, „Automatic Body Feature Extraction from a Marker-Less Scanned Human Body”, *Comput.-Aided Des.*, t. 39, nr 7, s. 568–582, lip. 2007, doi: 10.1016/j.cad.2007.03.003.
- [65] M.-J. J. Wang, W.-Y. Wu, K.-C. Lin, S.-N. Yang, i J.-M. Lu, „Automated Anthropometric Data Collection from Three-Dimensional Digital Human Models”, *Int. J. Adv. Manuf. Technol.*, t. 32, nr 1–2, s. 109–115, luty 2007, doi: 10.1007/s00170-005-0307-3.
- [66] F. Remondino i S. El-Hakim, „Image-Based 3D Modelling: A Review”, *Photogramm. Rec.*, t. 21, nr 115, s. 269–291, 2006.
- [67] D. Krawczyk i R. Sitnik, „Segmentation of 3D Point Cloud Data Representing Full Human Body Geometry: A Review”, *Pattern Recognit.*, t. 139, s. 109444, lip. 2023, doi: 10.1016/j.patcog.2023.109444.
- [68] W. Krajnik, **L. Markiewicz**, i R. Sitnik, „SSfS: Segmented Shape from Silhouette Reconstruction of the Human Body”, *Sensors*, t. 22, nr 3, 2022, doi: 10.3390/s22030925.
- [69] R. G. Dorsch, G. Häusler, i J. M. Herrmann, „Laser Triangulation: Fundamental Uncertainty in Distance Measurement”, *Appl. Opt.*, t. 33, nr 7, s. 1306–1314, 1994.
- [70] S. Foix, G. Alenya, i C. Torras, „Lock-in Time-of-Flight (ToF) Cameras: A Survey”, *IEEE Sens. J.*, t. 11, nr 9, s. 1917–1926, 2011.

- [71] T. Raj, F. H. Hashim, A. B. Huddin, M. F. Ibrahim, i A. Hussain, „A Survey on LiDAR Scanning Mechanisms”, *Electronics*, t. 9, nr 5, Art. nr 5, maj 2020, doi: 10.3390/electronics9050741.
- [72] J. Geng, „Structured-Light 3D Surface Imaging: A Tutorial”, *Adv. Opt. Photonics*, t. 3, nr 2, s. 128–160, 2011.
- [73] M. Goesele, B. Curless, i S. M. Seitz, „Multi-View Stereo Revisited”, w *2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06)*, cze. 2006, s. 2402–2409. doi: 10.1109/CVPR.2006.199.
- [74] M. R. James i S. Robson, „Straightforward Reconstruction of 3D Surfaces and Topography with a Camera: Accuracy and Geoscience Application”, *J. Geophys. Res. Earth Surf.*, t. 117, nr F3, 2012.
- [75] T. Alldieck, M. Magnor, B. L. Bhatnagar, C. Theobalt, i G. Pons-Moll, „Learning to Reconstruct People in Clothing from a Single RGB Camera”. arXiv, 8 kwiecień 2019. doi: 10.48550/arXiv.1903.05885.
- [76] Z. Huang i in., „Deep Volumetric Video From Very Sparse Multi-View Performance Capture”, w *Computer Vision – ECCV 2018*, V. Ferrari, M. Hebert, C. Sminchisescu, i Y. Weiss, Red., w *Lecture Notes in Computer Science*, vol. 11220. Cham: Springer International Publishing, 2018, s. 351–369. doi: 10.1007/978-3-030-01270-0_21.
- [77] M. A. Trujillo-Jiménez i in., „Body2vec: 3D Point Cloud Reconstruction for Precise Anthropometry with Handheld Devices”, *J. Imaging*, t. 6, nr 9, Art. nr 9, wrz. 2020, doi: 10.3390/jimaging6090094.
- [78] V. Choutas, L. Muller, C.-H. P. Huang, S. Tang, D. Tzionas, i M. J. Black, „Accurate 3D Body Shape Regression Using Metric and Semantic Attributes”. arXiv, 14 czerwiec 2022. doi: 10.48550/arXiv.2206.07036.
- [79] S. Pujades i in., „The Virtual Caliper: Rapid Creation of Metrically Accurate Avatars from 3D Measurements”, *IEEE Trans. Vis. Comput. Graph.*, t. 25, nr 5, s. 1887–1897, maj 2019, doi: 10.1109/TVCG.2019.2898748.
- [80] M. T. Nguyen, T. V. Dang, M. K. Tran Thi, i P. The Bao, „Generating Point Cloud from Measurements and Shapes Based on Convolutional Neural Network: An Application for Building 3D Human Model”, *Comput. Intell. Neurosci.*, t. 2019, s. e1353601, wrz. 2019, doi: 10.1155/2019/1353601.
- [81] S. Wuhler i C. Shu, „Estimating 3D Human Shapes from Measurements”, *Mach. Vis. Appl.*, t. 24, nr 6, s. 1133–1147, sie. 2013, doi: 10.1007/s00138-012-0472-y.
- [82] S. Yan i J.-K. Kämäräinen, „Learning Anthropometry from Rendered Humans”. arXiv, 7 styczeń 2021. doi: 10.48550/arXiv.2101.02515.
- [83] K. Bartol, D. Bojanić, T. Petković, S. Peharec, i T. Pribanić, „Linear Regression vs. Deep Learning: A Simple Yet Effective Baseline for Human Body Measurement”, *Sensors*, t. 22, nr 5, Art. nr 5, sty. 2022, doi: 10.3390/s22051885.

- [84] S. Streuber *i in.*, „Body Talk: Crowdshaping Realistic 3D Avatars with Words”, *ACM Trans. Graph.*, t. 35, nr 4, s. 54:1-54:14, lip. 2016, doi: 10.1145/2897824.2925981.
- [85] C. Ionescu, D. Papava, V. Olaru, i C. Sminchisescu, „Human3.6M: Large Scale Datasets and Predictive Methods for 3D Human Sensing in Natural Environments”, *IEEE Trans. Pattern Anal. Mach. Intell.*, t. 36, nr 7, s. 1325–1339, lip. 2014, doi: 10.1109/TPAMI.2013.248.
- [86] L. Sigal, A. O. Balan, i M. J. Black, „HumanEva: Synchronized Video and Motion Capture Dataset and Baseline Algorithm for Evaluation of Articulated Human Motion”, *Int. J. Comput. Vis.*, t. 87, nr 1, s. 4–27, mar. 2010, doi: 10.1007/s11263-009-0273-6.
- [87] G. Varol *i in.*, „Learning from Synthetic Humans”, w *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, lip. 2017, s. 4627–4635. doi: 10.1109/CVPR.2017.492.
- [88] A. Pumarola, J. Sanchez, G. P. T. Choi, A. Sanfeliu, i F. Moreno, „3DPeople: Modeling the Geometry of Dressed Humans”, w *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, Seoul, Korea (South): IEEE, paź. 2019, s. 2242–2251. doi: 10.1109/ICCV.2019.00233.
- [89] D. Mehta *i in.*, „Monocular 3D Human Pose Estimation In The Wild Using Improved CNN Supervision”. arXiv, 4 październik 2017. doi: 10.48550/arXiv.1611.09813.
- [90] T.-Y. Lin *i in.*, „Microsoft COCO: Common Objects in Context”. arXiv, 20 luty 2015. doi: 10.48550/arXiv.1405.0312.
- [91] Z. Wang, L. Chen, S. Rathore, D. Shin, i C. Fowlkes, „Geometric Pose Affordance: 3D Human Pose with Scene Constraints”. arXiv, 8 grudzień 2021. doi: 10.48550/arXiv.1905.07718.
- [92] C. Lassner, J. Romero, M. Kiefel, F. Bogo, M. J. Black, i P. V. Gehler, „Unite the People: Closing the Loop Between 3D and 2D Human Representations”. arXiv, 24 lipiec 2017. doi: 10.48550/arXiv.1701.02468.
- [93] M. Andriluka, L. Pishchulin, P. Gehler, i B. Schiele, „2D Human Pose Estimation: New Benchmark and State of the Art Analysis”, w *2014 IEEE Conference on Computer Vision and Pattern Recognition*, Columbus, OH, USA: IEEE, cze. 2014, s. 3686–3693. doi: 10.1109/CVPR.2014.471.
- [94] S. Yan, J. Wirta, i J.-K. Kämäräinen, „Silhouette Body Measurement Benchmarks”, w *2020 25th International Conference on Pattern Recognition (ICPR)*, sty. 2021, s. 7804–7809. doi: 10.1109/ICPR48806.2021.9412708.
- [95] R. Shao *i in.*, „DoubleField: Bridging the Neural Surface and Radiance Fields for High-Fidelity Human Reconstruction and Rendering”. arXiv, 27 marzec 2022. doi: 10.48550/arXiv.2106.03798.
- [96] „Human 3D Body Model Datasets for Research (from 3D Scans)”, *Twindom*. <https://web.twindom.com/human-3d-body-scan-dataset-for-research-from-3d-scans/> (dostęp 15 maj 2024).

- [97] G. Pavlakos *i in.*, „Expressive Body Capture: 3D Hands, Face, and Body from a Single Image”. arXiv, 11 kwiecień 2019. doi: 10.48550/arXiv.1904.05866.
- [98] F. Bogó, J. Romero, G. Pons-Moll, i M. J. Black, „Dynamic FAUST: Registering Human Bodies in Motion”, w *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, lip. 2017, s. 5573–5582. doi: 10.1109/CVPR.2017.591.
- [99] C. Zhang, S. Pujades, M. Black, i G. Pons-Moll, „Detailed, Accurate, Human Shape Estimation from Clothed 3D Scan Sequences”. arXiv, 19 kwiecień 2017. doi: 10.48550/arXiv.1703.04454.
- [100] T. Alldieck, M. Magnor, W. Xu, C. Theobalt, i G. Pons-Moll, „Video Based Reconstruction of 3D People Models”. arXiv, 16 kwiecień 2018. doi: 10.48550/arXiv.1803.04758.
- [101] „Skeletex Research | Datasets”. <https://skeletex.xyz/portfolio/datasets> (dostęp 15 maj 2024).
- [102] „Renderpeople”, *Over 4,000 Scanned 3D People Models*. <https://renderpeople.com/> (dostęp 15 maj 2024).
- [103] N. Ruiz *i in.*, „Human Body Measurement Estimation with Adversarial Augmentation”, *2022 Int. Conf. 3D Vis. 3DV*, s. 219–230, wrz. 2022, doi: 10.1109/3DV57658.2022.00034.
- [104] S. Blackwell *i in.*, *Civilian American and European Surface Anthropometry Resource (CAESAR): Final Report: Descriptions*. Air Force Research Laboratory, Human Effectiveness Directorate, Crew System Interface Division, Air Force Materiel Command, 2002.
- [105] D. Škorvánková, A. Riečický, i M. Madaras, „Automatic Estimation of Anthropometric Human Body Measurements”, s. 537–544, grudz. 2021, doi: 10.5220/0010878100003124.
- [106] Y. Chen, T.-K. Kim, i R. Cipolla, „Silhouette-Based Object Phenotype Recognition Using 3D Shape Priors”, w *2011 International Conference on Computer Vision*, lis. 2011, s. 25–32. doi: 10.1109/ICCV.2011.6126221.
- [107] I. Baran i J. Popović, „Automatic Rigging and Animation of 3D Characters”, *ACM Trans. Graph.*, t. 26, nr 3, s. 72-es, lip. 2007, doi: 10.1145/1276377.1276467.
- [108] D. Anguelov, P. Srinivasan, D. Koller, S. Thrun, J. Rodgers, i J. Davis, „SCAPE: Shape Completion and Animation of People”, *ACM Trans. Graph. TOG*, t. 24, s. 408–416, lip. 2005, doi: 10.1145/1073204.1073207.
- [109] M. Loper, N. Mahmood, J. Romero, G. Pons-Moll, i M. J. Black, „SMPL: A Skinned Multi-Person Linear Model”, *ACM Trans. Graph.*, t. 34, nr 6, s. 248:1-248:16, lis. 2015, doi: 10.1145/2816795.2818013.
- [110] A. A. A. Osman, T. Bolkart, i M. J. Black, „STAR: Sparse Trained Articulated Human Body Regressor”, w *Computer Vision – ECCV 2020*, A. Vedaldi, H. Bischof, T. Brox, i

- J.-M. Frahm, Red., w *Lecture Notes in Computer Science*. Cham: Springer International Publishing, 2020, s. 598–613. doi: 10.1007/978-3-030-58539-6_36.
- [111] H. Xu, E. G. Bazavan, A. Zanfır, W. T. Freeman, R. Sukthankar, i C. Sminchisescu, „GHUM & GHUML: Generative 3D Human Shape and Articulated Pose Models”, w *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle, WA, USA: IEEE, cze. 2020, s. 6183–6192. doi: 10.1109/CVPR42600.2020.00622.
- [112] H. Joo, T. Simon, i Y. Sheikh, „Total Capture: A 3D Deformation Model for Tracking Faces, Hands, and Bodies”. arXiv, 4 styczeń 2018. doi: 10.48550/arXiv.1801.01615.
- [113] V. Tan, I. Budvytis, i R. Cipolla, „Indirect Deep Structured Learning for 3D Human Body Shape and Pose Prediction”, sty. 2017. doi: 10.5244/C.31.15.
- [114] N. Kolotouros, G. Pavlakos, M. J. Black, i K. Daniilidis, „Learning to Reconstruct 3D Human Pose and Shape via Model-Fitting in the Loop”. arXiv, 27 wrzesień 2019. Dostęp: 15 maj 2024. [Online]. Dostępne na: <http://arxiv.org/abs/1909.12828>
- [115] E. Dibra, H. Jain, C. Öztireli, R. Ziegler, i M. Gross, „Human Shape from Silhouettes Using Generative HKS Descriptors and Cross-Modal Neural Networks”, w *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, lip. 2017, s. 5504–5514. doi: 10.1109/CVPR.2017.584.
- [116] B. Jiang, J. Zhang, J. Cai, i J. Zheng, „Disentangled Human Body Embedding Based on Deep Hierarchical Neural Network”, *IEEE Trans. Vis. Comput. Graph.*, t. 26, nr 8, s. 2560–2575, sie. 2020, doi: 10.1109/TVCG.2020.2988476.
- [117] Q. Tan, L. Gao, Y.-K. Lai, i S. Xia, „Variational Autoencoders for Deforming 3D Mesh Models”. arXiv, 28 marzec 2018. doi: 10.48550/arXiv.1709.04307.
- [118] E. Tretschk, A. Tewari, M. Zollhöfer, V. Golyanik, i C. Theobalt, „DEMEA: Deep Mesh Autoencoders for Non-Rigidly Deforming Objects”. arXiv, 4 sierpień 2020. doi: 10.48550/arXiv.1905.10290.
- [119] O. Litany, A. Bronstein, M. Bronstein, i A. Makadia, „Deformable Shape Completion with Graph Convolutional Autoencoders”. arXiv, 3 kwiecień 2018. doi: 10.48550/arXiv.1712.00268.
- [120] F. Bogo, A. Kanazawa, C. Lassner, P. Gehler, J. Romero, i M. J. Black, „Keep It SMPL: Automatic Estimation of 3D Human Pose and Shape from a Single Image”. arXiv, 27 lipiec 2016. doi: 10.48550/arXiv.1607.08128.
- [121] B. M. Smith, V. Chari, A. Agrawal, J. M. Rehg, i R. Sever, „Towards Accurate 3D Human Body Reconstruction from Silhouettes”, w *2019 International Conference on 3D Vision (3DV)*, Québec City, QC, Canada: IEEE, wrz. 2019, s. 279–288. doi: 10.1109/3DV.2019.00039.
- [122] E. Dibra, H. Jain, C. Öztireli, R. Ziegler, i M. Gross, „HS-Nets: Estimating Human Body Shape from Silhouettes with Convolutional Neural Networks”, w *2016 Fourth International Conference on 3D Vision (3DV)*, Stanford, CA, USA: IEEE, paź. 2016, s. 108–117. doi: 10.1109/3DV.2016.19.

- [123] N. Kolotouros, G. Pavlakos, i K. Daniilidis, „Convolutional Mesh Regression for Single-Image Human Shape Reconstruction”. arXiv, 8 maj 2019. doi: 10.48550/arXiv.1905.03244.
- [124] Z. Yu, L. Yang, S. Chen, i A. Yao, „Local and Global Point Cloud Reconstruction for 3D Hand Pose Estimation”, *arXiv.org*, 13 grudzień 2021. <https://arxiv.org/abs/2112.06389v1> (dostęp 15 maj 2024).
- [125] V. Gabeur, J.-S. Franco, X. Martin, C. Schmid, i G. Rogez, „Moulding Humans: Non-Parametric 3D Human Shape Estimation From Single Images”, zaprezentowano na Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019, s. 2232–2241. Dostęp: 15 maj 2024. [Online]. Dostępne na: https://openaccess.thecvf.com/content_ICCV_2019/html/Gabeur_Moulding_Humans_Non-Parametric_3D_Human_Shape_Estimation_From_Single_Images_ICCV_2019_paper.html
- [126] N. Lunscher i J. Zelek, „Deep Learning Whole Body Point Cloud Scans From a Single Depth Map”, zaprezentowano na Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2018, s. 1095–1102. Dostęp: 15 maj 2024. [Online]. Dostępne na: https://openaccess.thecvf.com/content_cvpr_2018_workshops/w17/html/Lunscher_Deep_Learning_Whole_CVPR_2018_paper.html
- [127] H. Jiang, J. Cai, i J. Zheng, „Skeleton-Aware 3D Human Shape Reconstruction From Point Clouds”, zaprezentowano na Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019, s. 5431–5441. Dostęp: 15 maj 2024. [Online]. Dostępne na: https://openaccess.thecvf.com/content_ICCV_2019/html/Jiang_Skeleton-Aware_3D_Human_Shape_Reconstruction_From_Point_Clouds_ICCV_2019_paper.html
- [128] K. Wang, J. Xie, G. Zhang, L. Liu, i J. Yang, „Sequential 3D Human Pose and Shape Estimation From Point Clouds”, w *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, cze. 2020, s. 7273–7282. doi: 10.1109/CVPR42600.2020.00730.
- [129] X. Zuo, S. Wang, Q. Sun, M. Gong, i L. Cheng, „Self-Supervised 3D Human Mesh Recovery from Noisy Point Clouds”. arXiv, 26 listopad 2021. doi: 10.48550/arXiv.2107.07539.
- [130] G. Varol i in., „BodyNet: Volumetric Inference of 3D Human Body Shapes”, zaprezentowano na Proceedings of the European Conference on Computer Vision (ECCV), 2018, s. 20–36. Dostęp: 15 maj 2024. [Online]. Dostępne na: https://openaccess.thecvf.com/content_ECCV_2018/html/Gul_Varol_BodyNet_Volumetric_Inference_ECCV_2018_paper.html
- [131] A. S. Jackson, C. Manafas, i G. Tzimiropoulos, „3D Human Body Reconstruction from a Single Image via Volumetric Regression”, zaprezentowano na Proceedings of the European Conference on Computer Vision (ECCV) Workshops, 2018, s. 0–0. Dostęp: 15 maj 2024. [Online]. Dostępne na: https://openaccess.thecvf.com/content_eccv_2018_workshops/w20/html/Jackson_3D_

Human_Body_Reconstruction_from_a_Single_Image_via_Volumetric_ECCVW_2018_paper.html

- [132] Z. Zheng, T. Yu, Y. Wei, Q. Dai, i Y. Liu, „DeepHuman: 3D Human Reconstruction From a Single Image”, zaprezentowano na Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019, s. 7739–7749. Dostęp: 15 maj 2024. [Online]. Dostępne na: https://openaccess.thecvf.com/content_ICCV_2019/html/Zheng_DeepHuman_3D_Human_Reconstruction_From_a_Single_Image_ICCV_2019_paper.html
- [133] H. Onizuka, Z. Hayirci, D. Thomas, A. Sugimoto, H. Uchiyama, i R. Taniguchi, „TetraTSDF: 3D Human Reconstruction From a Single Image With a Tetrahedral Outer Shell”, zaprezentowano na Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020, s. 6011–6020. Dostęp: 15 maj 2024. [Online]. Dostępne na: https://openaccess.thecvf.com/content_CVPR_2020/html/Onizuka_TetraTSDF_3D_Human_Reconstruction_From_a_Single_Image_With_a_CVPR_2020_paper.html
- [134] X. Zhao, Y.-T. Hu, Z. Ren, i A. G. Schwing, „Occupancy Planes for Single-View RGB-D Human Reconstruction”, *arXiv.org*, 4 sierpień 2022. <https://arxiv.org/abs/2208.02817v2> (dostęp 15 maj 2024).
- [135] J. Chibane, T. Alldieck, i G. Pons-Moll, „Implicit Functions in Feature Space for 3D Shape Reconstruction and Completion”, zaprezentowano na Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020, s. 6970–6981. Dostęp: 15 maj 2024. [Online]. Dostępne na: https://openaccess.thecvf.com/content_CVPR_2020/html/Chibane_Implicit_Functions_in_Feature_Space_for_3D_Shape_Reconstruction_and_CVPR_2020_paper.html
- [136] S. Saito, Z. Huang, R. Natsume, S. Morishima, A. Kanazawa, i H. Li, „PIFu: Pixel-Aligned Implicit Function for High-Resolution Clothed Human Digitization”. *arXiv*, 3 grudzień 2019. Dostęp: 15 maj 2024. [Online]. Dostępne na: <http://arxiv.org/abs/1905.05172>
- [137] S. Saito, T. Simon, J. Saragih, i H. Joo, „PIFuHD: Multi-Level Pixel-Aligned Implicit Function for High-Resolution 3D Human Digitization”. *arXiv*, 1 kwiecień 2020. doi: 10.48550/arXiv.2004.00452.
- [138] K. Y. Chan, G. Lin, H. Zhao, i W. Lin, „IntegratedPIFu: Integrated Pixel Aligned Implicit Function for Single-View Human Reconstruction”, w *Computer Vision – ECCV 2022*, S. Avidan, G. Brostow, M. Cissé, G. M. Farinella, i T. Hassner, Red., w Lecture Notes in Computer Science. Cham: Springer Nature Switzerland, 2022, s. 328–344. doi: 10.1007/978-3-031-20086-1_19.
- [139] T. He, J. Collomosse, H. Jin, i S. Soatto, „Geo-PIFu: Geometry and Pixel Aligned Implicit Functions for Single-View Human Reconstruction”, w *Advances in Neural Information Processing Systems*, Curran Associates, Inc., 2020, s. 9276–9287. Dostęp: 15 maj 2024. [Online]. Dostępne na: <https://proceedings.neurips.cc/paper/2020/hash/690f44c8c2b7ded579d01abe8fdb6110-Abstract.html>

- [140] B. L. Bhatnagar, C. Sminchisescu, C. Theobalt, i G. Pons-Moll, „Combining Implicit Function Learning and Parametric Models for 3D Human Reconstruction”, w *Computer Vision – ECCV 2020*, A. Vedaldi, H. Bischof, T. Brox, i J.-M. Frahm, Red., w Lecture Notes in Computer Science. Cham: Springer International Publishing, 2020, s. 311–329. doi: 10.1007/978-3-030-58536-5_19.
- [141] P. Liu, G. Zhang, S. Zhang, Y. Li, i Z. Zeng, „Skeleton-Aware Implicit Function for Single-View Human Reconstruction”, *CAAI Trans. Intell. Technol.*, t. n/a, nr n/a, 2023, doi: 10.1049/cit2.12193.
- [142] Y. Cao, G. Chen, K. Han, W. Yang, i K.-Y. K. Wong, „JIFF: Jointly-Aligned Implicit Face Function for High Quality Single View Clothed Human Reconstruction”, zaprezentowano na Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022, s. 2729–2739. Dostęp: 15 maj 2024. [Online]. Dostępne na: https://openaccess.thecvf.com/content/CVPR2022/html/Cao_JIFF_Jointly-Aligned_Implicit_Face_Function_for_High_Quality_Single_View_CVPR_2022_paper.html
- [143] L. Chen, J. Su, i S. Luo, „TransPIFu: Combining Transformer and Pixel-Aligned Implicit Function for Single-View Clothed Human Reconstruction”, *Comput. Graph.*, t. 111, s. 1–13, kwi. 2023, doi: 10.1016/j.cag.2022.12.009.
- [144] Y. Xiu, J. Yang, D. Tzionas, i M. J. Black, „ICON: Implicit Clothed Humans Obtained from Normals”. arXiv, 28 marzec 2022. doi: 10.48550/arXiv.2112.09127.
- [145] Z. Zheng, T. Yu, Y. Liu, i Q. Dai, „PaMIR: Parametric Model-Conditioned Implicit Representation for Image-Based Human Reconstruction”. arXiv, 2021. doi: 10.48550/arXiv.2007.03858.
- [146] S.-Y. Su, F. Yu, M. Zollhoefer, i H. Rhodin, „A-NeRF: Articulated Neural Radiance Fields for Learning Human Shape, Appearance, and Pose”. arXiv, 28 październik 2021. doi: 10.48550/arXiv.2102.06199.
- [147] S. Athar, Z. Shu, i D. Samaras, „FLAME-in-NeRF: Neural Control of Radiance Fields for Free View Face Animation”, w *2023 IEEE 17th International Conference on Automatic Face and Gesture Recognition (FG)*, sty. 2023, s. 1–8. doi: 10.1109/FG57933.2023.10042553.
- [148] H. Xu, T. Alldieck, i C. Sminchisescu, „H-NeRF: Neural Radiance Fields for Rendering and Temporal Reconstruction of Humans in Motion”. arXiv, 2 listopad 2021. doi: 10.48550/arXiv.2110.13746.
- [149] Z. Fan i in., „Voxel Grid Performer: Efficient Radiance Fields Generalization for Human Novel View Synthesis”, w *Optical Metrology and Inspection for Industrial Applications IX*, SPIE, grudz. 2022, s. 118–125. doi: 10.1117/12.2643856.
- [150] S. Zhou, X. Liu, C. Wang, i B. Yang, „Non-Iterative Denoising Algorithm Based on a Dual Threshold for a 3D Point Cloud”, *Opt. Lasers Eng.*, t. 126, s. 105921, mar. 2020, doi: 10.1016/j.optlaseng.2019.105921.

- [151] X. Ning, F. Li, G. Tian, i Y. Wang, „An Efficient Outlier Removal Method for Scattered Point Cloud Data”, *PLOS ONE*, t. 13, nr 8, s. e0201280, sie. 2018, doi: 10.1371/journal.pone.0201280.
- [152] J. Wang i in., „Consolidation of Low-Quality Point Clouds from Outdoor Scenes”, *Comput. Graph. Forum*, t. 32, nr 5, s. 207–216, 2013, doi: 10.1111/cgf.12187.
- [153] R. B. Rusu, Z. C. Marton, N. Blodow, M. Dolha, i M. Beetz, „Towards 3D Point Cloud Based Object Maps for Household Environments”, *Robot. Auton. Syst.*, t. 56, nr 11, s. 927–941, lis. 2008, doi: 10.1016/j.robot.2008.08.005.
- [154] C. Chenot, J. Bobin, i J. Rapin, „Robust Sparse Blind Source Separation”, *IEEE Signal Process. Lett.*, t. 22, nr 11, s. 2172–2176, lis. 2015, doi: 10.1109/LSP.2015.2463232.
- [155] Q. Shan, B. Curless, Y. Furukawa, C. Hernandez, i S. M. Seitz, „Occluding Contours for Multi-View Stereo”, w *2014 IEEE Conference on Computer Vision and Pattern Recognition*, cze. 2014, s. 4002–4009. doi: 10.1109/CVPR.2014.511.
- [156] P. Merrell i in., „Real-Time Visibility-Based Fusion of Depth Maps”, w *2007 IEEE 11th International Conference on Computer Vision*, Rio de Janeiro, Brazil: IEEE, 2007, s. 1–8. doi: 10.1109/ICCV.2007.4408984.
- [157] K. Zhang, M. Hutter, i H. Jin, „A New Local Distance-Based Outlier Detection Approach for Scattered Real-World Data”. arXiv, 18 marzec 2009. doi: 10.48550/arXiv.0903.3257.
- [158] E. Tola, C. Strecha, i P. Fua, „Efficient Large-Scale Multi-View Stereo for Ultra High-Resolution Image Sets”, *Mach. Vis. Appl.*, t. 23, nr 5, s. 903–920, wrz. 2012, doi: 10.1007/s00138-011-0346-8.
- [159] Y. Lipman, D. Cohen-Or, D. Levin, i H. Tal-Ezer, „Parameterization-Free Projection for Geometry Reconstruction”, *ACM Trans. Graph.*, t. 26, nr 3, s. 22-es, lip. 2007, doi: 10.1145/1276377.1276405.
- [160] H. Huang, S. Wu, M. Gong, D. Cohen-Or, U. Ascher, i H. (Richard) Zhang, „Edge-Aware Point Set Resampling”, *ACM Trans. Graph.*, t. 32, nr 1, s. 1–12, sty. 2013, doi: 10.1145/2421636.2421645.
- [161] H. Huang, D. Li, H. Zhang, U. Ascher, i D. Cohen-Or, „Consolidation of Unorganized Point Clouds for Surface Reconstruction”, *ACM Trans. Graph.*, t. 28, nr 5, s. 1–7, grudz. 2009, doi: 10.1145/1618452.1618522.
- [162] O. Schall, A. Belyaev, i H.-P. Seidel, „Robust Filtering of Noisy Scattered Point Data”, w *Proceedings Eurographics/IEEE VGTC Symposium Point-Based Graphics, 2005.*, cze. 2005, s. 71–144. doi: 10.1109/PBG.2005.194067.
- [163] Z. Yang i D. Xiao, „A Systemic Point-Cloud de-Noiseing and Smoothing Method for 3D Shape Reuse”, w *2012 12th International Conference on Control Automation Robotics & Vision (ICARCV)*, grudz. 2012, s. 1722–1727. doi: 10.1109/ICARCV.2012.6485409.

- [164] J. Gong i C. H. Caldas, „Data Processing for Real-Time Construction Site Spatial Modeling”, *Autom. Constr.*, t. 17, nr 5, s. 526–535, lip. 2008, doi: 10.1016/j.autcon.2007.09.002.
- [165] C. Lange i K. Polthier, „Anisotropic Smoothing of Point Sets”, *Comput. Aided Geom. Des.*, t. 22, nr 7, s. 680–692, paź. 2005, doi: 10.1016/j.cagd.2005.06.010.
- [166] M. Desbrun, M. Meyer, P. Schröder, i A. H. Barr, „Implicit Fairing of Irregular Meshes Using Diffusion and Curvature Flow”, w *Proceedings of the 26th annual conference on Computer graphics and interactive techniques - SIGGRAPH '99*, New York: ACM Press, 1999, s. 317–324. doi: 10.1145/311535.311576.
- [167] M. Shao, Y. Ijiri, i K. Hattori, „Grouped Outlier Removal for Robust Ellipse Fitting”, w *2015 14th IAPR International Conference on Machine Vision Applications (MVA)*, maj 2015, s. 138–141. doi: 10.1109/MVA.2015.7153152.
- [168] T. Weyrich, M. Pauly, R. Keiser, S. Heinzle, S. Scandella, i M. Gross, „Post-Processing of Scanned 3D Surface Data”, zaprezentowano na SPBG'04 Symposium on Point - Based Graphics 2004, sty. 2004. doi: 10.2312/SPBG/SPBG04/085-094.
- [169] C. Wu, D. Shu, H. Zhou, i Z. Fu, „Robust Denoising-Oriented Point Cloud Plane Fitting Method Based on a Combined Model of Improved Cook's Distance and WTLS”, *J. Intell. Manuf. Spec. Equip.*, t. 3, nr 2, s. 134–155, sty. 2022, doi: 10.1108/JIMSE-08-2022-0013.
- [170] M. Pauly i M. Gross, „Spectral Processing of Point-Sampled Geometry”, w *Proceedings of the 28th annual conference on Computer graphics and interactive techniques*, ACM, sie. 2001, s. 379–386. doi: 10.1145/383259.383301.
- [171] M. Kazhdan i H. Hoppe, „Screened Poisson Surface Reconstruction”, *ACM Trans. Graph.*, t. 32, nr 3, s. 29:1-29:13, lip. 2013, doi: 10.1145/2487228.2487237.
- [172] L. Tekumalla i E. Cohen, „A Hole-Filling Algorithm for Triangular Meshes”, sty. 2004.
- [173] J. Davis, S. R. Marschner, M. Garr, i M. Levoy, „Filling Holes in Complex Surfaces Using Volumetric Diffusion”, w *First International Symposium on 3D Data Processing Visualization and Transmission Proceedings*, cze. 2002, s. 428–441. doi: 10.1109/TDPVT.2002.1024098.
- [174] P. Chalmovianský i B. Jüttler, „Filling Holes in Point Clouds”, w *Mathematics of Surfaces*, M. J. Wilson i R. R. Martin, Red., w *Lecture Notes in Computer Science*. Berlin, Heidelberg: Springer, 2003, s. 196–212. doi: 10.1007/978-3-540-39422-8_14.
- [175] M. Nowak, J. Michoński, i R. Sitnik, „Filling Cavities in Point Clouds Representing Human Body Surface Using Bezier Patches”, *Multimed. Tools Appl.*, t. 80, nr 10, s. 15093–15134, kwi. 2021, doi: 10.1007/s11042-020-10120-3.
- [176] Q. Wang, Y. Tan, i Z. Mei, „Computational Methods of Acquisition and Processing of 3D Point Cloud Data for Construction Applications”, *Arch. Comput. Methods Eng.*, t. 27, nr 2, s. 479–499, kwi. 2020, doi: 10.1007/s11831-019-09320-4.

- [177] P. Foryś, K. Lech, J. Michoński, **Ł. Markiewicz**, E. Bunsch, i R. Sitnik, „Semi-Automated Method for Views Integration Based on Alternative Color and Geometry Characteristics”, w *Optical Sensors 2019*, SPIE, kwi. 2019, s. 359–368. doi: 10.1117/12.2521135.
- [178] D. Bojanić, K. Bartol, J. Forest, T. Petković, i T. Pribanić, „Deep Learning vs. Traditional 3d Registration: A Featureless 3d Registration Baseline”. Rochester, NY, 19 kwiecień 2023. doi: 10.2139/ssrn.4423685.
- [179] D. Bojanić, K. Bartol, T. Petković, i T. Pribanić, „A Review of Rigid 3D Registration Methods”, s. 286–296, 2020.
- [180] B. Deng, Y. Yao, R. M. Dyke, i J. Zhang, „A Survey of Non-Rigid 3D Registration”. arXiv, 16 marzec 2022. doi: 10.48550/arXiv.2203.07858.
- [181] Y. Díez, F. Roure, X. Lladó, i J. Salvi, „A Qualitative Review on 3D Coarse Registration Methods”, *ACM Comput. Surv.*, t. 47, nr 3, s. 45:1-45:36, luty 2015, doi: 10.1145/2692160.
- [182] P. J. Besl i N. D. McKay, „A Method for Registration of 3-D Shapes”, *IEEE Trans. Pattern Anal. Mach. Intell.*, t. 14, nr 2, s. 239–256, 1992, doi: 10.1109/34.121791.
- [183] R. Bergevin, M. Soucy, H. Gagnon, i D. Laurendeau, „Towards a General Multi-View Registration Technique”, *IEEE Trans. Pattern Anal. Mach. Intell.*, t. 18, nr 5, s. 540–547, maj 1996, doi: 10.1109/34.494643.
- [184] K.-H. Bae i D. Lichti, „Automated Registration Of Unorganised Point Clouds From Terrestrial Laser Scanners”, *Int. Arch. Photogramm. Remote Sens.*, t. 35, lip. 2004.
- [185] A. Censi, „An ICP Variant Using a Point-to-Line Metric”, w *2008 IEEE International Conference on Robotics and Automation*, maj 2008, s. 19–25. doi: 10.1109/ROBOT.2008.4543181.
- [186] J. Minguetz, L. Montesano, i F. Lamiroux, „Metric-Based Iterative Closest Point Scan Matching for Sensor Displacement Estimation”, *IEEE Trans. Robot.*, t. 22, nr 5, s. 1047–1054, paź. 2006, doi: 10.1109/TRO.2006.878961.
- [187] S. Rusinkiewicz i M. Levoy, „Efficient Variants of the ICP Algorithm”, w *Proceedings Third International Conference on 3-D Digital Imaging and Modeling*, Quebec City, Que., Canada: IEEE Comput. Soc, 2001, s. 145–152. doi: 10.1109/IM.2001.924423.
- [188] J. S. Markiewicz, **Ł. Markiewicz**, i P. Foryś, „The Comparison of 2D and 3D Detectors for TLS Data Registration- Preliminary Results”, *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.*, t. XLII-2-W9, s. 467–472, sty. 2019, doi: 10.5194/isprs-archives-XLII-2-W9-467-2019.
- [189] M. A. Fischler i R. C. Bolles, „Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography”, *Commun. ACM*, t. 24, nr 6, s. 381–395, cze. 1981, doi: 10.1145/358669.358692.

- [190] Z. Zhang, Y. Dai, i J. Sun, „Deep Learning Based Point Cloud Registration: An Overview”, *Virtual Real. Intell. Hardw.*, t. 2, nr 3, s. 222–246, cze. 2020, doi: 10.1016/j.vrih.2020.05.002.
- [191] J. H. Nurre, J. Connor, E. A. Lewark, i J. S. Collier, „On Segmenting the Three-Dimensional Scan Data of a Human Body”, *IEEE Trans. Med. Imaging*, t. 19, nr 8, s. 787–797, 2000, doi: 10.1109/42.876304.
- [192] C. C. L. Wang, T. K. K. Chang, i M. M. F. Yuen, „From Laser-Scanned Data to Feature Human Model: A System Based on Fuzzy Logic Concept”, *CAD Comput. Aided Des.*, t. 35, s. 241–253, 2003, doi: 10.1016/S0010-4485(01)00209-3.
- [193] Y. Zhong i B. Xu, „Automatic Segmenting and Measurement on Scanned Human Body”, *Int. J. Cloth. Sci. Technol.*, t. 18, s. 19–30, 2006, doi: 10.1016/j.chroma.2006.02.065.
- [194] H. Han i Y. Nam, „Automatic Body Landmark Identification for Various Body Figures”, *Int. J. Ind. Ergon.*, t. 41, nr 6, s. 592–606, lis. 2011, doi: 10.1016/j.ergon.2011.07.002.
- [195] J. Jo i in., „Automatic Human Body Segmentation Based on Feature Extraction”, *Int. J. Cloth. Sci. Technol.*, t. 26, nr 1, s. 4–24, sty. 2014, doi: 10.1108/IJCST-10-2012-0062.
- [196] Z. Wen, Y. Yan, i H. Cui, „Study on Segmentation of 3D Human Body Based on Point Cloud Data”, w *2012 Second International Conference on Intelligent System Design and Engineering Application*, sty. 2012, s. 657–660. doi: 10.1109/ISdea.2012.676.
- [197] M. Đonlić, T. Petković, S. Peharec, F. Berryman, i T. Pribanić, „On the Segmentation of Scanned 3D Human Body Models”, w *8th International Scientific Conference on Kinesiology, Opatija, Croatia*, 2017, s. 694–697.
- [198] Y. Xiao, N. Werghi, i P. Siebert, „A Topological Approach for Segmenting Human Body Shape”, w *12th International Conference on Image Analysis and Processing, 2003.Proceedings.*, wrz. 2003, s. 82–87. doi: 10.1109/ICIAP.2003.1234029.
- [199] Y. Xiao, P. Siebert, i N. Werghi, „A Discrete Reeb Graph Approach for the Segmentation of Human Body Scans”, w *Proceedings of International Conference on 3-D Digital Imaging and Modeling, 3DIM*, 2003, s. 378–385. doi: 10.1109/IM.2003.1240272.
- [200] N. Werghi, Y. Xiao, i J. P. Siebert, „A Functional-Based Segmentation of Human Body Scans in Arbitrary Postures”, *IEEE Trans. Syst. Man Cybern. Part B Cybern.*, t. 36, nr 1, s. 153–165, lut. 2006, doi: 10.1109/TSMCB.2005.854503.
- [201] Y. Xiao, P. Siebert, i N. Werghi, „Topological Segmentation of Discrete Human Body Shapes in Various Postures Based on Geodesic Distance”, w *Proceedings of the 17th International Conference on Pattern Recognition, 2004. ICPR 2004.*, sie. 2004, s. 131–135 Vol.3. doi: 10.1109/ICPR.2004.1334486.
- [202] Y. Xiao i J. Siebert, „Building Superquadric Men from 3-D Whole-Body Scan Data”, sty. 2005.

- [203] L. Shapira, S. Shalom, A. Shamir, D. Cohen-Or, i H. Zhang, „Contextual Part Analogies in 3D Objects”, *Int. J. Comput. Vis.*, t. 89, nr 2–3, s. 309–326, wrz. 2010, doi: 10.1007/s11263-009-0279-0.
- [204] R. Hu, L. Fan, i L. Liu, „Co-Segmentation of 3D Shapes via Subspace Clustering”, *Comput. Graph. Forum*, t. 31, nr 5, s. 1703–1713, 2012, doi: 10.1111/j.1467-8659.2012.03175.x.
- [205] C.-W. Chu, O. C. Jenkins, i M. Matarić, „Towards Model-Free Markerless Motion Capture”, 2002. Dostęp: 15 maj 2024. [Online]. Dostępne na: <https://www.semanticscholar.org/paper/Towards-Model-free-Markerless-Motion-Capture-Chu-Jenkins/35d25b5a694fb8a3d7f624bda3b7c21df619765b>
- [206] P. Cerveri, K. J. Sarro, M. Marchente, i R. M. L. Barros, „Isomap Transform for Segmenting Human Body Shapes”, *Comput. Methods Biomech. Biomed. Engin.*, t. 14, nr 9, s. 783–795, wrz. 2011, doi: 10.1080/10255842.2010.495065.
- [207] A. Giachetti, C. Lovato, F. Piscitelli, C. Milanese, i C. Zancanaro, „Robust Automatic Measurement of 3D Scanned Models for the Human Body Fat Estimation.”, *IEEE J. Biomed. Health Inform.*, t. 19, nr 2, s. 660–667, mar. 2015, doi: 10.1109/JBHI.2014.2314360.
- [208] C. Lovato, U. Castellani, i A. Giachetti, „Automatic Segmentation of Scanned Human Body Using Curve Skeleton Analysis”, w *Computer Vision/Computer Graphics Collaboration Techniques*, A. Gagalowicz i W. Philips, Red., w *Lecture Notes in Computer Science*, vol. 5496. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009, s. 34–45. doi: 10.1007/978-3-642-01811-4_4.
- [209] J. Cheng, M. Qiao, W. Bian, i D. Tao, „3D Human Posture Segmentation by Spectral Clustering with Surface Normal Constraint”, *Signal Process.*, t. 91, nr 9, s. 2204–2212, wrz. 2011, doi: 10.1016/j.sigpro.2011.04.003.
- [210] S. Handrich i A. Al-Hamadi, „Full-Body Human Pose Estimation by Combining Geodesic Distances and 3D-Point Cloud Registration”, w *Advanced Concepts for Intelligent Vision Systems*, S. Battiato, J. Blanc-Talon, G. Gallo, W. Philips, D. Popescu, i P. Scheunders, Red., w *Lecture Notes in Computer Science*. Cham: Springer International Publishing, 2015, s. 287–298. doi: 10.1007/978-3-319-25903-1_25.
- [211] M. Hilaga, Y. Shinagawa, T. Kohmura, i T. L. Kunii, „Topology Matching for Fully Automatic Similarity Estimation of 3D Shapes”, w *Proceedings of the 28th annual conference on Computer graphics and interactive techniques*, ACM, sie. 2001, s. 203–212. doi: 10.1145/383259.383282.
- [212] I. Mikić, M. Trivedi, E. Hunter, i P. Cosman, „Human Body Model Acquisition and Tracking Using Voxel Data”, *Int. J. Comput. Vis.*, t. 53, nr 3, s. 199–223, lip. 2003, doi: 10.1023/A:1023012723347.
- [213] D. Anguelov i in., „Discriminative Learning of Markov Random Fields for Segmentation of 3D Scan Data”, w *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR’05)*, cze. 2005, s. 169–176 t. 2. doi: 10.1109/CVPR.2005.133.

- [214] C. Plagemann, V. Ganapathi, D. Koller, i S. Thrun, „Real-Time Identification and Localization of Body Parts from Depth Images”, w *2010 IEEE International Conference on Robotics and Automation*, Anchorage, AK: IEEE, maj 2010, s. 3108–3113. doi: 10.1109/ROBOT.2010.5509559.
- [215] E. Kalogerakis, A. Hertzmann, i K. Singh, „Learning 3D Mesh Segmentation and Labeling”, w *ACM SIGGRAPH 2010 papers*, w SIGGRAPH '10. New York, NY, USA: Association for Computing Machinery, lip. 2010, s. 1–12. doi: 10.1145/1833349.1778839.
- [216] J. Shotton i in., „Real-Time Human Pose Recognition in Parts from Single Depth Images”, *Commun. ACM*, t. 56, nr 1, s. 116–124, sty. 2013, doi: 10.1145/2398356.2398381.
- [217] J. Shotton i in., „Efficient Human Pose Estimation from Single Depth Images”, *IEEE Trans. Pattern Anal. Mach. Intell.*, t. 35, nr 12, s. 2821–2840, grudz. 2013, doi: 10.1109/TPAMI.2012.241.
- [218] J. Y. Chang i S. W. Nam, „Fast Random-Forest-Based Human Pose Estimation Using a Multi-Scale and Cascade Approach”, *ETRI J.*, t. 35, nr 6, s. 949–959, 2013, doi: 10.4218/etrij.13.2013.0063.
- [219] S. Ghosh, E. Sudderth, M. Loper, i M. Black, „From Deformations to Parts: Motion-Based Segmentation of 3D Objects”, grudz. 2012. doi: 10.13140/2.1.3352.9924.
- [220] M. Qiao, J. Cheng, W. Bian, i D. Tao, „Biview Learning for Human Posture Segmentation from 3D Points Cloud”, *PLOS ONE*, t. 9, nr 1, s. e85811, sty. 2014, doi: 10.1371/journal.pone.0085811.
- [221] H. Maron i in., „Convolutional Neural Networks on Surfaces via Seamless Toric Covers”, *ACM Trans. Graph.*, t. 36, nr 4, s. 71:1-71:10, lip. 2017, doi: 10.1145/3072959.3073616.
- [222] H. Xu, M. Dong, i Z. Zhong, „Directionally Convolutional Networks for 3D Shape Segmentation”, w *2017 IEEE International Conference on Computer Vision (ICCV)*, Venice: IEEE, paź. 2017, s. 2717–2726. doi: 10.1109/ICCV.2017.294.
- [223] L. Seoud, J. Boisvert, M.-A. Drouin, M. Picard, i G. Godin, „Increasing the Robustness of CNN-Based Human Body Segmentation in Range Images by Modeling Sensor-Specific Artifacts”, w *Computer Vision – ECCV 2018 Workshops*, L. Leal-Taixé i S. Roth, Red., w *Lecture Notes in Computer Science*, vol. 11131. Cham: Springer International Publishing, 2019, s. 729–743. doi: 10.1007/978-3-030-11015-4_55.
- [224] A. Poulenard i M. Ovsjanikov, „Multi-Directional Geodesic Neural Networks via Equivariant Convolution”, *ACM Trans. Graph.*, t. 37, nr 6, s. 236:1-236:14, grudz. 2018, doi: 10.1145/3272127.3275102.
- [225] P. Wang i in., „3D Shape Segmentation via Shape Fully Convolutional Networks”. arXiv, 25 maj 2018. doi: 10.48550/arXiv.1702.08675.
- [226] N. Haim, N. Segol, H. Ben-Hamu, H. Maron, i Y. Lipman, „Surface Networks via General Covers”. arXiv, 18 sierpień 2019. doi: 10.48550/arXiv.1812.10705.

- [227] D. Zhang *i in.*, „Deep Patch-Based Human Segmentation”, *arXiv.org*, 11 lipiec 2020. <https://arxiv.org/abs/2007.05661v1> (dostęp 15 maj 2024).
- [228] Y. Yang, S. Liu, H. Pan, Y. Liu, i X. Tong, „PFCNN: Convolutional Neural Networks on 3D Surfaces Using Parallel Frames”, *arXiv.org*, 15 sierpień 2018. <https://arxiv.org/abs/1808.04952v2> (dostęp 15 maj 2024).
- [229] A. Jerzec, D. Bojanić, K. Bartol, T. Pribanic, T. Petković, i S. Petrak, „On Using PointNet Architecture for Human Body Segmentation”, wrz. 2019, s. 253–257. doi: 10.1109/ISPA.2019.8868844.
- [230] R. V. Garimella i B. K. Swartz, „Curvature Estimation for Unstructured Triangulations of Surfaces”, Los Alamos National Laboratory, 2003.
- [231] M. Aubry, U. Schlickewei, i D. Cremers, „The Wave Kernel Signature: A Quantum Mechanical Approach to Shape Analysis”, w *2011 IEEE International Conference on Computer Vision Workshops (ICCV Workshops)*, lis. 2011, s. 1626–1633. doi: 10.1109/ICCVW.2011.6130444.
- [232] K. Simonyan i A. Zisserman, „Very Deep Convolutional Networks for Large-Scale Image Recognition”. *arXiv*, 10 kwiecień 2015. doi: 10.48550/arXiv.1409.1556.
- [233] M. Kouchi i M. Mochimaru, „Errors in Landmarking and the Evaluation of the Accuracy of Traditional and 3D Anthropometry”, *Appl. Ergon.*, t. 42, nr 3, s. 518–527, 2011.
- [234] S. Luo, Q. Zhang, i J. Feng, „Automatic Location and Semantic Labeling of Landmarks on 3D Human Body Models”, *Comput. Vis. Media*, t. 8, nr 4, s. 553–570, grudz. 2022, doi: 10.1007/s41095-021-0254-4.
- [235] J. Steimle *i in.*, „On-Skin Interaction Using Body Landmarks”, *Computer*, t. 50, nr 10, s. 19–27, 2017.
- [236] D. Burnside, M. Boehmer, i K. Robinette, „3-D Landmark Detection and Identification in the CAESAR Project”, w *Proceedings Third International Conference on 3-D Digital Imaging and Modeling*, maj 2001, s. 393–398. doi: 10.1109/IM.2001.924485.
- [237] J. Michoński, W. Glinkowski, M. Witkowski, i R. Sitnik, „Automatic Recognition of Surface Landmarks of Anatomical Structures of Back and Posture”, *J. Biomed. Opt.*, t. 17, nr 5, maj 2012, doi: 10.1117/1.JBO.17.5.056015.
- [238] J. Lu i M. Wang, „Automated Anthropometric Data Collection Using 3D Whole Body Scanners”, *Expert Syst. Appl.*, t. 35, nr 1–2, s. 407–414, lip. 2008, doi: 10.1016/j.eswa.2007.07.008.
- [239] F. Stief, „Variations of Marker Sets and Models for Standard Gait Analysis”, w *Handbook of Human Motion*, Cham: Springer International Publishing, 2018, s. 509–526. doi: 10.1007/978-3-319-14418-4_26.

- [240] M. M. Kawale i in., „Automated Identification of Fiducial Points on 3D Torso Images.”, *Biomed. Eng. Comput. Biol.*, t. 5, s. 57–68, sty. 2013, doi: 10.4137/BECB.S11800.
- [241] E. Vezzetti i F. Marcolin, „3D Landmarking in Multiexpression Face Analysis: A Preliminary Study on Eyebrows and Mouth”, *Aesthetic Plast. Surg.*, t. 38, nr 4, s. 796–811, sie. 2014, doi: 10.1007/s00266-014-0334-2.
- [242] C. Creusot, N. Pears, i J. Austin, „A Machine-Learning Approach to Keypoint Detection and Landmarking on 3D Meshes”, *Int. J. Comput. Vis.*, t. 102, nr 1–3, s. 146–179, mar. 2013, doi: 10.1007/s11263-012-0605-9.
- [243] J. W. Niu, Y. M. Wu, F. Hou, A. L. Feng, i X. Chen, „Automatic Landmark Identification from Three Dimensional (3D) Human Body Data Using Geometric Characteristics”, w *Advances in Physical Ergonomics and Safety*, CRC Press, 2012, s. 575–584.
- [244] J. C. Liu, L. Zhang, X. Chen, i J. W. Niu, „Facial Landmark Automatic Identification from Three Dimensional (3D) Data by Using Hidden Markov Model (HMM)”, *Int. J. Ind. Ergon.*, t. 57, s. 10–22, sty. 2017, doi: 10.1016/j.ergon.2016.11.001.
- [245] Z. Zhou i S. Hao, „Anatomical Landmark Detection on 3D Human Shapes by Hierarchically Utilizing Multiple Shape Features”, *Neurocomputing*, t. 253, s. 162–168, sie. 2017, doi: 10.1016/j.neucom.2016.09.131.
- [246] A. E. Johnson i M. Hebert, „Using Spin Images for Efficient Object Recognition in Cluttered 3D Scenes”, *IEEE Trans. Pattern Anal. Mach. Intell.*, t. 21, nr 5, s. 433–449, maj 1999, doi: 10.1109/34.765655.
- [247] J. Sun, M. Ovsjanikov, i L. Guibas, „A Concise and Provably Informative Multi-Scale Signature Based on Heat Diffusion”, *Comput. Graph. Forum*, t. 28, nr 5, s. 1383–1392, lip. 2009, doi: 10.1111/j.1467-8659.2009.01515.x.
- [248] A. Giachetti i in., „Automatic Location of Landmarks Used in Manual Anthropometry”, sty. 2014, s. 93–100. doi: 10.2312/3dor.20141055.
- [249] J. Ren, A. Poulenard, P. Wonka, i M. Ovsjanikov, „Continuous and Orientation-Preserving Correspondences via Functional Maps”, *arXiv.org*, 12 czerwiec 2018. <https://arxiv.org/abs/1806.04455v3> (dostęp 15 maj 2024).
- [250] R. Marin, S. Melzi, E. Rodolà, i U. Castellani, „FARM: Functional Automatic Registration Method for 3D Human Bodies”, *arXiv.org*, 27 lipiec 2018. <https://arxiv.org/abs/1807.10517v1> (dostęp 15 maj 2024).
- [251] J. Guo, H. Wang, Z. Cheng, X. Zhang, i D. Yan, „Learning Local Shape Descriptors for Computing Non-Rigid Dense Correspondence”, *Comput. Vis. Media*, t. 6, mar. 2020, doi: 10.1007/s41095-020-0163-y.
- [252] Z. Ben Azouz, C. Shu, i A. Mantel, „Automatic Locating of Anthropometric Landmarks on 3D Human Models”, w *Third International Symposium on 3D Data Processing, Visualization, and Transmission (3DPVT'06)*, Chapel Hill, NC, USA: IEEE, cze. 2006, s. 750–757. doi: 10.1109/3DPVT.2006.34.

- [253] T. Xiaohui, P. Xiaoyu, L. Liwen, i X. Qing, „Automatic Human Body Feature Extraction and Personal Size Measurement”, *J. Vis. Lang. Comput.*, t. 47, s. 9–18, sie. 2018, doi: 10.1016/j.jvlc.2018.05.002.
- [254] H. Wang, J. Guo, D.-M. Yan, W. Quan, i X. Zhang, „Learning 3D Keypoint Descriptors for Non-Rigid Shape Matching”, w *Computer Vision – ECCV 2018*, V. Ferrari, M. Hebert, C. Sminchisescu, i Y. Weiss, Red., w *Lecture Notes in Computer Science*. Cham: Springer International Publishing, 2018, s. 3–20. doi: 10.1007/978-3-030-01237-3_1.
- [255] M. Koźbiał, **L. Markiewicz**, i R. Sitnik, „Algorithm for Detecting Characteristic Points on a Three-Dimensional, Whole-Body Human Scan”, *Appl. Sci.*, t. 10, nr 4, s. 1342, sty. 2020, doi: 10.3390/app10041342.
- [256] P. Xi, C. Shu, i R. Goubran, „Localizing 3-D Anatomical Landmarks Using Deep Convolutional Neural Networks”, w *2017 14th Conference on Computer and Robot Vision (CRV)*, maj 2017, s. 197–204. doi: 10.1109/CRV.2017.11.
- [257] Y. Wang, Y. Sun, Z. Liu, S. E. Sarma, M. M. Bronstein, i J. M. Solomon, „Dynamic Graph CNN for Learning on Point Clouds”, *arXiv.org*, 24 styczeń 2018. <https://arxiv.org/abs/1801.07829v2> (dostęp 15 maj 2024).
- [258] W. Wu, Z. Qi, i L. Fuxin, „PointConv: Deep Convolutional Networks on 3D Point Clouds”. *arXiv*, 9 listopad 2020. doi: 10.48550/arXiv.1811.07246.
- [259] Y. Xu, T. Fan, M. Xu, L. Zeng, i Y. Qiao, „SpiderCNN: Deep Learning on Point Sets with Parameterized Convolutional Filters”, *arXiv.org*, 30 marzec 2018. <https://arxiv.org/abs/1803.11527v3> (dostęp 15 maj 2024).
- [260] L. Jiang, J. Yao, B. Li, F. Fang, Q. Zhang, i M. Meng, „Automatic Body Feature Extraction from Front and Side Images”, *J. Softw. Eng. Appl.*, t. 05, s. 94–100, sty. 2012, doi: 10.4236/jsea.2012.512B019.
- [261] Y.-L. Lin i M.-J. J. Wang, „Automated Body Feature Extraction from 2D Images”, *Expert Syst. Appl.*, t. 38, nr 3, s. 2585–2591, mar. 2011, doi: 10.1016/j.eswa.2010.08.048.
- [262] Y.-L. Lin i M.-J. J. Wang, „Constructing 3D Human Model from Front and Side Images”, *Expert Syst. Appl.*, t. 39, nr 5, s. 5012–5018, kwi. 2012, doi: 10.1016/j.eswa.2011.10.011.
- [263] M. Aslam, F. Rajbdad, S. Khattak, i S. Azmat, „Automatic Measurement of Anthropometric Dimensions Using Frontal and Lateral Silhouettes”, *IET Comput. Vis.*, t. 11, nr 6, s. 434–447, 2017, doi: 10.1049/iet-cvi.2016.0406.
- [264] S. Ouellet i F. Michaud, „Enhanced Automated Body Feature Extraction from a 2D Image Using Anthropomorphic Measures for Silhouette Analysis”, *Expert Syst. Appl.*, t. 91, s. 270–276, sty. 2018, doi: 10.1016/j.eswa.2017.09.006.
- [265] A. Saint i in., „3DBodyTex: Textured 3D Body Dataset”, wrz. 2018. doi: 10.1109/3DV.2018.00063.

- [266] Y. Chen, Y. Tian, i M. He, „Monocular Human Pose Estimation: A Survey of Deep Learning-Based Methods”, *Comput. Vis. Image Underst.*, t. 192, s. 102897, mar. 2020, doi: 10.1016/j.cviu.2019.102897.
- [267] W. Liu, Q. Bao, Y. Sun, i T. Mei, „Recent Advances in Monocular 2D and 3D Human Pose Estimation: A Deep Learning Perspective”. arXiv, 23 kwiecień 2021. doi: 10.48550/arXiv.2104.11536.
- [268] N. Sarafianos, B. Boteanu, B. Ionescu, i I. A. Kakadiaris, „3D Human Pose Estimation: A Review of the Literature and Analysis of Covariates”, *Comput. Vis. Image Underst.*, t. 152, s. 1–20, lis. 2016, doi: 10.1016/j.cviu.2016.09.002.
- [269] J. Wang i in., „Deep 3D Human Pose Estimation: A Review”, *Comput. Vis. Image Underst.*, t. 210, s. 103225, wrz. 2021, doi: 10.1016/j.cviu.2021.103225.
- [270] Z. Cao, G. Hidalgo, T. Simon, S.-E. Wei, i Y. Sheikh, „OpenPose: Realtime Multi-Person 2D Pose Estimation Using Part Affinity Fields”, *arXiv.org*, 18 grudzień 2018. <https://arxiv.org/abs/1812.08008v2> (dostęp 15 maj 2024).
- [271] I.-F. Leong, J.-J. Fang, i M. Tsai, „A Feature-Based Anthropometry for Garment Industry”, *Int. J. Cloth. Sci. Technol.*, t. 25, luty 2013, doi: 10.1108/09556221311292183.
- [272] P. Tikuisis, P. Meunier, i C. E. Jubenville, „Human Body Surface Area: Measurement and Prediction Using Three Dimensional Body Scans”, *Eur. J. Appl. Physiol.*, t. 85, nr 3–4, s. 264–271, sie. 2001, doi: 10.1007/s004210100484.
- [273] S. Yan, J. Wirta, i J.-K. Kämäräinen, „Anthropometric Clothing Measurements from 3D Body Scans”, *Mach. Vis. Appl.*, t. 31, nr 1, s. 7, sty. 2020, doi: 10.1007/s00138-019-01054-4.
- [274] A. Tsoli, M. Loper, i M. J. Black, „Model-Based Anthropometry: Predicting Measurements from 3D Human Scans in Multiple Poses”, *IEEE Winter Conf. Appl. Comput. Vis.*, s. 83–90, mar. 2014, doi: 10.1109/WACV.2014.6836115.
- [275] N. N. Kaashki, P. Hu, i A. Munteanu, „Anet: A Deep Neural Network for Automatic 3D Anthropometric Measurement Extraction”, *IEEE Trans. Multimed.*, t. 25, s. 831–844, 2023, doi: 10.1109/TMM.2021.3132487.
- [276] A. Sengupta, I. Budvytis, i R. Cipolla, „Probabilistic Estimation of 3D Human Shape and Pose with a Semantic Local Parametric Model”. arXiv, 30 listopad 2021. doi: 10.48550/arXiv.2111.15404.
- [277] O. Wasenmüller, J. Peters, V. Golyanik, i D. Stricker, „Precise and Automatic Anthropometric Measurement Extraction Using Template Registration”, paź. 2015. doi: 10.15221/15.155.
- [278] J. Boisvert, C. Shu, S. Wuhler, i P. Xi, „Three-Dimensional Human Shape Inference from Silhouettes: Reconstruction and Validation”, *Mach. Vis. Appl.*, t. 24, nr 1, s. 145–157, sty. 2013, doi: 10.1007/s00138-011-0353-9.

- [279] N. N. Kaashki, P. Hu, i A. Munteanu, „Deep Learning-Based Automated Extraction of Anthropometric Measurements From a Single 3-D Scan”, *IEEE Trans. Instrum. Meas.*, t. 70, s. 1–14, 2021, doi: 10.1109/TIM.2021.3106126.
- [280] X. Gan, H. Ibrahim, i D. Ramli, „A Simple Vision Based Anthropometric Estimation System Using Webcam”, *J. Phys. Conf. Ser.*, t. 1529, s. 022067, kwi. 2020, doi: 10.1088/1742-6596/1529/2/022067.
- [281] „Naked”. <https://nakedlabs.com/> (dostęp 15 maj 2024).
- [282] „Mantis Vision 3iosk”. <https://mantis-vision.com/3d-studio-3iosk/> (dostęp 15 maj 2024).
- [283] „Aniwaa”, *3D scanner catalog*. <https://www.aniwaa.com/catalog/3d-scanners/> (dostęp 15 maj 2024).
- [284] „Fit3D”. <https://www.fit3d.com/> (dostęp 15 maj 2024).
- [285] „Size Stream”, *Size Stream*. <https://www.sizestream.com> (dostęp 15 maj 2024).
- [286] „Styku”, *3D Body Scanning for Fitness, Health, & Wellness*. <https://www.styku.com> (dostęp 15 maj 2024).
- [287] „[TC]² Labs LLC”, *[TC]² Labs LLC*. <http://www.tc2.com/tc2-19m-3d-body-scanner.html> (dostęp 15 maj 2024).
- [288] „Texel”, 14 sierpień 2019. <https://texel.graphics/3d-scanners/portal-bx/>, <https://texel.graphics/3d-scanners/portal-bx/> (dostęp 15 maj 2024).
- [289] „Twinstant Mobile Full Body 3D Scanner Bundle”, *Twindom*. <https://web.twindom.com/twinstant-mobile-full-body-3d-scanner/> (dostęp 15 maj 2024).
- [290] „Botspot Botscan Neo”, *Full Body 3D-Scanner: Digital twins with BOTSCAN NEO*. <https://www.botspot.de/botscan-neo> (dostęp 15 maj 2024).
- [291] „TG3D 3D Body Scanner”, *Digital Fashion Evolution with 3D Fashion Technologies | TG3D Studio*. <https://www.tg3ds.com/3d-body-scanner> (dostęp 15 maj 2024).
- [292] „Artec 3D”, *Portable 3D scanners*. <https://www.artec3d.com/portable-3d-scanners> (dostęp 15 maj 2024).
- [293] „UK National Size Survey”. <http://www.size.org/> (dostęp 15 maj 2024).
- [294] N. Hasler, C. Stoll, M. Sunkel, B. Rosenhahn, i H.-P. Seidel, „A Statistical Model of Human Pose and Body Shape”, *Comput. Graph. Forum*, t. 28, nr 2, s. 337–346, kwi. 2009, doi: 10.1111/j.1467-8659.2009.01373.x.
- [295] F. Bogo, J. Romero, M. Loper, i M. J. Black, „FAUST: Dataset and Evaluation for 3D Mesh Registration”, w *2014 IEEE Conference on Computer Vision and Pattern Recognition*, cze. 2014, s. 3794–3801. doi: 10.1109/CVPR.2014.491.

- [296] M. Salleh, H. Lazim, i H. Lamsali, „Body Measurement Using 3D Handheld Scanner”, *Mov. Health Exerc.*, t. 7, sty. 2018, doi: 10.15282/mohe.v7i1.213.
- [297] J. Conkle, U. Ramakrishnan, R. Flores-Ayala, P. S. Suchdev, i R. Martorell, „Improving the Quality of Child Anthropometry: Manual Anthropometry in the Body Imaging for Nutritional Assessment Study (BINA)”, *PLOS ONE*, t. 12, nr 12, s. e0189332, grudz. 2017, doi: 10.1371/journal.pone.0189332.
- [298] „3D Measure Up”, *3D - Virtual Body Measurements Simulator*. <https://3dmeasureup.com/> (dostęp 15 maj 2024).
- [299] ES&T Redakction, „3D-Reihenmessung in Der Bundeswehr”, 14 luty 2023. <https://esut.de/2023/02/fachbeitraege/39554/3d-reihenmessung-in-der-bundeswehr/> (dostęp 15 maj 2024).
- [300] M. Menolotto, D.-S. Komaris, S. Tedesco, B. O’Flynn, i M. Walsh, „Motion Capture Technology in Industrial Applications: A Systematic Review”, *Sensors*, t. 20, nr 19, Art. nr 19, sty. 2020, doi: 10.3390/s20195687.
- [301] J. Uriel i in., „A Methodology to Obtain Anthropometric Measurements from 4D Scans”, w *Proceedings of the 7th International Digital Human Modeling Symposium* -, University of Iowa Libraries Publishing, sie. 2022. doi: 10.17077/dhm.31758.
- [302] K. Abdel-Malek i in., „Improved Motion Capture Processing for High-Fidelity Human Models Using Optimization-Based Prediction of Posture and Anthropometry”, lip. 2017. doi: 10.1007/978-3-319-60591-3_50.
- [303] „Mnemosiis”. <https://mnemosiis.pl/> (dostęp 15 maj 2024).
- [304] „3dMD”, *3dMDbody*, 2 maj 2023. <https://3dmd.com/> (dostęp 15 maj 2024).
- [305] „Mixed Reality Capture Studios for Volumetric Video | Microsoft”. <https://www.microsoft.com/en-us/mixed-reality/capture-studios> (dostęp 15 maj 2024).
- [306] „Volucap - Authentic Digital Avatars”, *Volucap*. <https://volucap.com/> (dostęp 15 maj 2024).
- [307] „Human Engine | 3D Scanning - Virtual Humans”, *Human-Engine LLC*. <https://www.human-engine.com> (dostęp 15 maj 2024).
- [308] „Move 4D”, *Dynamic Body Scanner*. <https://www.move4d.net/> (dostęp 15 maj 2024).
- [309] Y. Kang i S. Kim, „Analyzing the Changes in Anthropometric Measurements with Various Postures Using Three-Dimensional Scanning Technology”, *J. Eng. Fibers Fabr.*, t. 18, s. 15589250231165990, sty. 2023, doi: 10.1177/15589250231165990.
- [310] „Scandy - 3D Creation Made Easy”. <https://www.scandy.co/> (dostęp 15 maj 2024).
- [311] „ItSeez3D”. <https://itseez3d.com/> (dostęp 15 maj 2024).
- [312] G. Ben-Horin, „Sizer: AI-Powered Body Measuring Technology for the Fashion Industry”, *Sizer*. <https://sizer.me/> (dostęp 15 maj 2024).

- [313] „Nettelo - Mobile 3D Body Scan, Analysis & Product Matching”, *Nettelo*. <http://nettelo.com/> (dostęp 15 maj 2024).
- [314] „MTailor Custom Clothes”. <https://www.matailor.com> (dostęp 15 maj 2024).
- [315] „3D Avatar Body”, *Instituto de Biomecánica*. <https://www.ibv.org/en/3d-avatar-body-3/> (dostęp 15 maj 2024).
- [316] „Meep1”. <https://play.google.com/store/apps/details?id=com.fision&hl=en> (dostęp 15 maj 2024).
- [317] „3D Body Measurement Mobile App and Web-Based Solution-Mirrorsize”. <https://www.mirrorsize.com/> (dostęp 15 maj 2024).
- [318] „WEAR”, *World Engineering Anthropometry Resource*. <https://www.bodysizeshape.com/page-1855750> (dostęp 15 maj 2024).
- [319] „ISize”. <https://portal.i-size.net/> (dostęp 15 maj 2024).
- [320] „The OPEN Design Lab”. <https://www.openlab.psu.edu/tools/> (dostęp 15 maj 2024).
- [321] „DINED”. <https://dined.io.tudelft.nl/en> (dostęp 15 maj 2024).
- [322] „DINED Announces Open Platform for 3D Body Models: Mannequin”, *TU Delft*. <https://www.tudelft.nl/en/2020/io/april/dined-announces-open-platform-for-3d-body-models-mannequin> (dostęp 15 maj 2024).
- [323] D. Veitch, „Waist Measurements Compared: Definitions (ISO vs CAESAR) and Instruments (Manual vs 3D Scanned Data)”, w *Proceedings of the 1st Asian Workshop on 3D Body Scanning Technologies, Tokyo, Japan, 17-18 April 2012*, Tokyo, Japan: Hometrica Consulting - Dr. Nicola D’Apuzzo, kwi. 2012, s. 123–131. doi: 10.15221/A12.123.
- [324] L. Rumbo-Rodríguez, M. Sánchez-SanSegundo, R. Ferrer-Cascales, N. García-D’Urso, J. A. Hurtado-Sánchez, i A. Zaragoza-Martí, „Comparison of Body Scanner and Manual Anthropometric Measurements of Body Shape: A Systematic Review”, *Int. J. Environ. Res. Public. Health*, t. 18, nr 12, s. 6213, cze. 2021, doi: 10.3390/ijerph18126213.
- [325] C. Beaumont i in., „Three-Dimensional Surface Scanners Compared with Standard Anthropometric Measurements for Head Shape”, *J. Cranio-Maxillofac. Surg.*, t. 45, mar. 2017, doi: 10.1016/j.jcms.2017.03.003.
- [326] E. Mocini i in., „Digital Anthropometry: A Systematic Review on Precision, Reliability and Accuracy of Most Popular Existing Technologies”, *Nutrients*, t. 15, nr 2, s. 302, sty. 2023, doi: 10.3390/nu15020302.
- [327] C. J. Parker, S. Gill, A. Harwood, S. G. Hayes, i M. Ahmed, „A Method for Increasing 3D Body Scanning’s Precision: Gryphon and Consecutive Scanning”, *Ergonomics*, t. 65, nr 1, s. 39–59, sty. 2022, doi: 10.1080/00140139.2021.1931473.

- [328] H. Han, Y. Nam, i K. Choi, „Comparative Analysis of 3D Body Scan Measurements and Manual Measurements of Size Korea Adult Females”, *Int. J. Ind. Ergon.*, t. 40, nr 5, s. 530–540, wrz. 2010, doi: 10.1016/j.ergon.2010.06.002.
- [329] S. Bragança, M. Carvalho, B. Xu, P. Arezes, i S. Ashdown, „A Validation Study of a Kinect Based Body Imaging (KBI) Device System Based on ISO 20685 : 2010”, *5th Int. Conf. 3D Body Scanning Technol.*, s. 21–22, 2014, doi: 10.15221/14.372.
- [330] M. Tiwari i N. Anand, „Validation and Reliability of Sizestream 3D Scanner for Human Body Measurement”, w *Functional Textiles and Clothing 2020*, A. Majumdar, D. Gupta, i S. Gupta, Red., Singapore: Springer Singapore, 2021, s. 13–23.
- [331] N. Ashby i in., „Translating Digital Anthropometry Measurements Obtained from Different 3D Body Image Scanners”, *Eur. J. Clin. Nutr.*, s. 1–9, maj 2023, doi: 10.1038/s41430-023-01289-5.
- [332] B. Smith, C. McCarthy, M. E. Dechenaud, M. C. Wong, J. Shepherd, i S. B. Heymsfield, „Anthropometric Evaluation of a 3D Scanning Mobile Application”, *Obes. Silver Spring Md*, t. 30, nr 6, s. 1181–1188, cze. 2022, doi: 10.1002/oby.23434.
- [333] F. L. Wright, J. Green, G. Reeves, V. Beral, B. J. Cairns, i on behalf of the Million Women Study collaborators, „Validity over Time of Self-Reported Anthropometric Variables during Follow-up of a Large Cohort of UK Women”, *BMC Med. Res. Methodol.*, t. 15, nr 1, s. 81, paź. 2015, doi: 10.1186/s12874-015-0075-1.
- [334] R. Sitnik, M. Kujawińska, i J. Woźnicki, „Digital Fringe Projection System for Large-Volume 360-Deg Shape Measurement”, *Opt. Eng.*, t. 41, nr 2, s. 443–449, 2002, doi: 10.1117/1.1430422.
- [335] „ISO 10360-8:2013”, *Geometrical product specifications (GPS) — Acceptance and reverification tests for coordinate measuring systems (CMS) — Part 8: CMMs with optical distance sensors*. <https://www.iso.org/standard/54522.html> (dostęp 15 maj 2024).
- [336] *VDI/VDE 2634 Blatt 3 - Optical 3D-Measuring Systems - Multiple View Systems Based on Area Scanning*. 2008. Dostęp: 15 maj 2024. [Online]. Dostępne na: <https://www.vdi.de/en/home/vdi-standards/details/vdivde-2634-blatt-3-optical-3d-measuring-systems-multiple-view-systems-based-on-area-scanning>
- [337] B. Muralikrishnan i R. Jay, „Least-Squares Best-Fit Line and Plane”, w *Computational Surface and Roundness Metrology*, London: Springer London, 2009, s. 121–130. doi: 10.1007/978-1-84800-297-5_15.
- [338] J. W. Tukey, *Exploratory Data Analysis*, t. 2. Reading, MA, 1977.
- [339] K. O. McGraw i S. P. Wong, „Forming Inferences about Some Intraclass Correlations Coefficients”, *Psychol. Methods*, t. 1, s. 30–46, 1996, doi: 10.1037/1082-989X.1.4.390.
- [340] T. Koo i M. Li, „A Guideline of Selecting and Reporting Intraclass Correlation Coefficients for Reliability Research”, *J. Chiropr. Med.*, t. 15, mar. 2016, doi: 10.1016/j.jcm.2016.02.012.

- [341] D. Liljequist, B. Elfving, i K. Skavberg Roaldsen, „Intraclass Correlation – A Discussion and Demonstration of Basic Features”, *PLoS ONE*, t. 14, nr 7, s. e0219854, lip. 2019, doi: 10.1371/journal.pone.0219854.
- [342] J.-M. Lu i M.-J. J. Wang, „The Evaluation of Scan-Derived Anthropometric Measurements”, *IEEE Trans. Instrum. Meas.*, t. 59, nr 8, s. 2048–2054, sie. 2010, doi: 10.1109/TIM.2009.2031847.
- [343] F. Schwarz-Müller, R. Marshall, i S. Summerskill, „Development of a Positioning Aid to Reduce Postural Variability and Errors in 3D Whole Body Scan Measurements”, *Appl. Ergon.*, t. 68, s. 90–100, kwi. 2018, doi: 10.1016/j.apergo.2017.11.001.
- [344] S. Yitzhaki, „Gini’s Mean Difference: A Superior Measure of Variability for Non-Normal Distributions”, *Metron - Int. J. Stat.*, t. LXI, s. 285–316, luty 2003.
- [345] J. M. Moll i V. Wright, „An Objective Clinical Study of Chest Expansion.”, *Ann. Rheum. Dis.*, t. 31, nr 1, s. 1–8, sty. 1972, doi: 10.1136/ard.31.3.225.
- [346] I. Dāboliņa, A. Viļumsone, J. Dāboliņš, E. Strazdiene, i E. Lapkovska, „Usability of 3D Anthropometrical Data in CAD/CAM Patterns”, *Int. J. Fash. Des. Technol. Educ.*, t. 11, nr 1, s. 41–52, sty. 2018, doi: 10.1080/17543266.2017.1298848.
- [347] „Qt | Tools for Each Stage of Software Development Lifecycle”. <https://www.qt.io> (dostęp 15 maj 2024).
- [348] „Eigen”. <https://eigen.tuxfamily.org/> (dostęp 15 maj 2024).
- [349] „Qhull Code for Convex Hull, Delaunay Triangulation, Voronoi Diagram, and Halfspace Intersection about a Point”. <http://www.qhull.org/> (dostęp 15 maj 2024).
- [350] K. McHenry i P. Bajcsy, „An Overview of 3d Data Content, File Formats and Viewers”, *Natl. Cent. Supercomput. Appl.*, t. 1205, s. 22, 2008.
- [351] T. Bray, J. Paoli, C. M. Sperberg-McQueen, E. Maler, i F. Yergeau, „Extensible Markup Language (XML) 1.0”, 1998.
- [352] D. Cohen, „On Holy Wars and a Plea for Peace”, *Computer*, t. 14, nr 10, s. 48–54, paź. 1981, doi: 10.1109/C-M.1981.220208.
- [353] G. K. Wallace, „The JPEG Still Picture Compression Standard”, *Commun. ACM*, t. 34, nr 4, s. 30–44, 1991.
- [354] **Ł. Markiewicz**, M. Witkowski, R. Sitnik, i E. Mielicka, „3D Anthropometric Algorithms for the Estimation of Measurements Required for Specialized Garment Design”, *Expert Syst. Appl.*, t. 85, s. 366–385, 2017, doi: 10.1016/j.eswa.2017.04.052.
- [355] **Ł. Markiewicz**, E. Mielicka, G. Wasilewski, K. Mularczyk, L. Napieralska, i R. Sitnik, „Unification Process for Uniforms with Use of 3D Body Scanning”, w *Proceedings of 3DBODY.TECH 2017 - 8th International Conference and Exhibition on 3D Body Scanning and Processing Technologies*, Montreal, Canada: Hometrica Consulting - Dr. Nicola D’Apuzzo, 2017, s. 170–178. doi: 10.15221/17.170.