

POLITECHNIKA WARSZAWSKA

DYSCYPLINA NAUKOWA INŻYNIERIA LĄDOWA, GEODEZJA I TRANSPORT
DZIEDZINA NAUK INŻYNIERYJNO-TECHNICZNYCH

Rozprawa doktorska

mgr inż. Kamila Barbara Kalinowska

**Opracowanie metodyki wykorzystania uczenia głębokiego
i automatycznego modelowania 3D w badaniu obrażeń ciała
na podstawie obrazów post-mortem**

Promotor

dr hab. inż. Dorota Zawieska, prof. uczelni

Promotor pomocniczy

dr. n. med. Marcin Fudalej

WARSZAWA 2025

Żyj tak, jakbyś miał umrzeć jutro. Ucz się tak, jakbyś miał żyć wiecznie.

Gandhi Mahatma

Podziękowania

Pragnę złożyć wyrazy głębokiej wdzięczności osobom, których obecność i wsparcie stanowiły nieocenioną pomoc na drodze prowadzącej do ukończenia tej rozprawy.

Szczególnie pragnę podziękować **Pani dr hab. inż. Dorocie Zawieska**, z którą wspólna podróż w obszarach nauki rozpoczęła się jeszcze w czasach pisania mojej pracy magisterskiej. To dzięki Pani zyskałam dostęp do niezliczonych, inspirujących doświadczeń naukowych. Pani wyrozumiałość, ogromne pokłady cierpliwości i nieustająca wiara w moją osobę były latarnią w chwilach wątpliwości, pozwalającą ukończyć ten etap naukowy i wkroczyć na szerokie wody otwartych możliwości.

Dziękuję **Panu dr. n. med. Marcinowi Fudalej**, którego otwartość, gotowość do pomocy i poświęcony czas – bez względu na okoliczności, nawet w trakcie zasłużonego wypoczynku – pozwalały mi zawsze na Pana liczyć. Pana zaangażowanie i życzliwość stały się dla mnie nieocenionym wsparciem.

Moje podziękowania kieruję także do **Pana prof. dr hab. Pawła Krajewskiego**, który otworzył przede mną drzwi do fascynującego świata medycyny sądowej, umożliwiając mi zgłębianie tej dziedziny w Zakładzie Medycyny Sądowej Warszawskiego Uniwersytetu Medycznego. Pańska otwartość na nowe pomysły oraz wsparcie w rozwoju naukowym miały kluczowe znaczenie dla mojej pracy badawczej.

Wyrazy szczególnej wdzięczności kieruję również do **Pana dr hab. n. med. Ireneusza Sołtyszewskiego**, którego wykłady z medycyny sądowej, podczas moich studiów prawniczych, ostatecznie ukierunkowały moje zainteresowania naukowe. Pańska życzliwość, cenne wskazówki oraz gotowość do współpracy inspirowały mnie i motywowały na każdym etapie mojej drogi badawczej.

Na końcu, ale z najgłębszym uczuciem wdzięczności, pragnę podziękować moim **Rodzicom, Dorocie i Zdzisławowi**, którzy zawsze we mnie wierzyli. Wasze wsparcie, nieustająca motywacja i niezachwiana wiara w moje możliwości były fundamentem, na którym budowałam swoje osiągnięcia. To Wasza siła dodawała mi odwagi, by sięgać po więcej i nie zatrzymywać się w obliczu wyzwań.

Ta rozprawa jest również wyrazem wdzięczności wobec wszystkich, którzy wspierali mnie przez cały okres jej powstawania.

Streszczenie

Sekcja zwłok jako czynność niepowtarzalna przeprowadzana jest tylko raz. Jej wyniki są kluczowe zarówno dla medycyny sądowej, jak i dla toczących się postępowań. Z tego powodu dokumentacja z sekcji zwłok odgrywa istotną rolę w procesie dowodowym, zapewniając transparentność i umożliwiając późniejszą analizę przez ekspertów. Znaczenie medycyny sądowej dla wymiaru sprawiedliwości jest więc niepodważalne, ujawniając informacje o przestępstwie, jak do niego doszło, a nawet kto mógł je popełnić. Pod tym względem podczas zewnętrznej sekcji zwłok następuje klasyfikacja ujawnionych obrażeń, gdzie jako jedno z istotniejszych i najczęściej występujących wymienia się podbiegnięcia krwawe i otarcia naskórka. Podbiegnięcia krwawe (ang. *bruises*) to wylew krwi do tkanek podskórnych w wyniku uderzenia lub ściśnięcia co w konsekwencji powoduje miażdżenie tkanek miękkich i rozrywanie naczyń krwionośnych jednak bez naruszania skóry. Ten typ obrażeń jest niezwykle istotny w przypadkach wykrywania przemocy. Z kolei, otarcia naskórka (ang. *abrasions*) pojawiają się w wyniku urazu, kiedy działające na ciało narzędzie ociera skórę z warstwy zrogowaciałej, tym samym obnażając brodawki skóry właściwej. Wielkość otarcia przyjmuje różne formy, od niewielkich do pokrywających znaczne obszary ciała. Natomiast kształt w dużej mierze uzależniony jest od użytego narzędzia oraz kąta jego oddziaływania. Właściwa analiza otarcia znacząco przyczynia się do ustalenia przebiegu zdarzenia czy użytego narzędzia (rozumianego również jako obiekt), które spowodowało dane obrażenie. Tradycyjne metody analizy obrażeń, opierają się na ocenie wzrokowej i często uzależnione są nie tylko od doświadczenia lekarza medycyny sądowej, jak również od jego subiektywnych spostrzeżeń. Postęp rozwoju technologii cyfrowych analiz, skłonił autorkę do próby ich implementacji w obszarze medycyny sądowej.

Wobec powyższego niniejsza rozprawa doktorska, w oparciu o obrazy post-mortem, przedstawia wybrane algorytmy uczenia głębokiego do detekcji i klasyfikacji dwóch typów obrażeń (podbiegnięcia krwawe i otarcia naskórka) oraz ich zapisu na wygenerowanych cyfrowych modelach 3D. Opracowane przez autorkę rozwiązania cyfrowe dodatkowo umożliwiły przeprowadzenie zaawansowanych analiz morfologicznych w przestrzeni 2D przyczyniając się do poprawy wyrazistości, granic i konturów obrażeń dzięki operacjom na macierzach konwolucji. Natomiast analizy morfometryczne przeprowadzone w przestrzeni 3D pozwoliły na precyzyjne określenie takich cech obrażeń, jak ich kształt, wielkość, głębokość czy kierunek powstania, co znacząco usprawniło klasyfikację oraz rekonstrukcję mechanizmu

ich powstawania. Opracowane rozwiązania znacząco przyspieszyły czas rozpoznania i rejestracji obrazów w porównaniu z tradycyjnymi metodami. Dodatkowo, wyeliminowano wpływ subiektywnych czynników, takich jak pośpiech czy doświadczenie lekarza. Proponowane rozwiązania pozwoliły na stworzenie unikatowej bazy danych dla medycyny sądowej oraz wykazały, że elementy zewnętrzne, takie jak płyny czy zabrudzenia, nie wpływają znacząco na jakość cyfrowej dokumentacji ciał i umożliwiają precyzyjną segmentację semantyczną, modelowanie 3D ciał oraz analizę obrazów bez konieczności uprzedniego ich przygotowania. Dzięki temu proces dokumentacji i analizy stał się bardziej efektywny, tym samym osiągając:

- możliwość wsparcia sekcji zewnętrznych w medycynie sądowej poprzez szybką, precyzyjną i nieinwazyjną metodę wspomagającą istniejące tradycyjne metody analizy obrazów. Podejście to może odnaleźć zastosowanie w sytuacjach, gdzie czas ma kluczowe znaczenie, obrażenia są drobne lub trudne do zauważenia, lub gdy występuje ich wiele;
- udoskonalenie analizy przypadków klinicznych dotyczących ofiar przemocy poprzez zastosowanie automatycznej metody dokumentowania obrazów umożliwiając zrozumienie dynamiki i przyczyny, szczególnie w przypadkach obrazów sugerujących charakter celowy ich zadania. Wspomaganie dochodzenia w sytuacjach przemocy jest kluczowe i wymagające szczególnej uwagi. Liczne podbiegnięcia krwawe i otarcia naskórka w różnych stadiach gojenia, zwykle wskazują na powtarzającą się przemoc;
- analizę wykrytych i udokumentowanych obrazów stosując zaawansowane technologie cyfrowe do szczegółowego badania wykrytych obrazów poprzez analizy morfologiczne i morfometryczne. Takie podejście umożliwia precyzyjne określenie cech obrazów, takich jak ich kształt, wielkość, głębokość czy kąt/kierunek powstania, co wspiera klasyfikację i ocenę ich charakteru. Dodatkowo, przeprowadzenie takich analiz pomaga w identyfikacji potencjalnych wzorców, a to z kolei wspiera rekonstrukcję mechanizmu powstawania obrazów oraz w przygotowaniu ekspertyz sądowych.

Należy podkreślić, że powstała w ten sposób cyfrowa dokumentacja w postaci wirtualnego modelu 3D ciała wraz wyrytymi i naniesionymi obrażeniami, stanowi trwały zapis stanu ciała ofiary. Dokumentacja ta może być wielokrotnie analizowana w dowolnym czasie, nawet w sytuacjach, gdy ciało jest już niedostępne lub wymagałoby ekshumacji.

Słowa kluczowe: fotogrametria, medycyna sądowa, modelowanie 3D, obrażenia, segmentacja semantyczna, uczenie głębokie, widzenie komputerowe, zdjęcia post-mortem

Abstract

Title: Development of a methodology for using deep learning and automated 3D modelling in the study of body injuries based on post-mortem images.

The post-mortem examination, as a unique activity, is carried out only once. Its results are crucial for both forensic medicine and ongoing investigations. For this reason, post-mortem documentation plays an important role in the evidentiary process, ensuring transparency and enabling subsequent analysis by experts. The importance of forensic medicine for justice is therefore undeniable, revealing information about a crime, how it happened, and even who may have committed it. In this respect, the external post-mortem examination identifies the injuries revealed where bruises and abrasions are listed as some of the most common and important. A bruise is a sign of haemorrhage into the skin, the tissues beneath the skin, or both. It is typically caused by a blow or squeeze that crushes soft tissues and ruptures blood vessels but does not break the skin. This type of injury is extremely important in cases of abuse recognition. An abrasion occurs when the skin's superficial layers are scraped away. The size of the abrasion varies from small to large areas of the body. In contrast, the shape depends mainly on the tool used and the angle of its impact. A proper analysis of the abrasion contributes significantly to determining the course of the incident or the tool (also understood as an object) used to cause it. Traditional methods of injury analysis rely on visual assessment and are often dependent not only on the experience of the forensic pathologist but also on their subjective observations. Advances in digital analysis technologies have prompted the author to explore their implementation in forensic medicine, identifying the main challenge as ensuring high-quality and precise data, which is essential for obtaining reliable and accurate results.

Given the above, this doctoral dissertation, based on post-mortem images, presents selected deep learning algorithms for the detection and classification of two types of injuries (bruises and abrasions) and their documentation on generated 3D digital models. The digital solutions developed by the author additionally enabled advanced morphological analyses in 2D space, enhancing the clarity, boundaries, and contours of injuries through operations on convolution matrices. Meanwhile, morphometric analyses conducted in 3D space allowed for the precise determination of injury characteristics such as shape, size, depth, and direction of occurrence, significantly improving the classification and reconstruction of the mechanism of injury formation. The developed solutions considerably accelerated the recognition and recording of

injuries compared to traditional methods. Furthermore, they eliminated the influence of subjective factors, such as haste or the physician's level of experience. The proposed solutions facilitated the creation of a unique forensic database and demonstrated that external elements, such as fluids or contaminants, do not significantly affect the quality of digital body documentation. This enables precise semantic segmentation, 3D body modelling, and injury analysis without prior preparation of the body. As a result, the documentation and analysis process became more efficient, achieving::

- the ability to support external examinations in forensic medicine through a rapid, precise, and non-invasive method that complements existing traditional methods of injury analysis. This approach can be particularly valuable in cases when time plays a crucial role, we have minor or low-visibility injuries that may be missed easily or we have a large set of injuries on one body;
- improvements in the analysis of clinical cases involving victims of violence by applying an automated method for documenting injuries. This facilitates the understanding of injury dynamics and causes, particularly in cases where injuries suggest deliberately infliction. Supporting investigations in cases of violence is crucial and requires particular attention, especially in cases involving child abuse. Multiple bruises and abrasions in varying stages of healing may indicate repetitive physical assault;
- the analysis of detected and documented injuries using advanced digital technologies for detailed examinations through morphological and morphometric analyses. This approach enables precise determination of injury characteristics, such as their shape, size, depth, or angle/direction of occurrence, thereby supporting their classification and evaluation. Additionally, such analyses help identify potential patterns, which support the reconstruction of injury mechanisms and the preparation of forensic reports.

It should be emphasised that the resulting digital documentation of the victim, in the form of a 3D virtual body model with marked and recorded injuries, constitutes a permanent record of the victim's condition. This documentation can be analysed repeatedly at any time, even in situations where the body is no longer accessible or would require exhumation.

Keywords: 3D modelling, computer vision, deep learning, forensic medicine, injuries, photogrammetry, post-mortem images, semantic segmentation

Spis treści

Wykaz wykorzystanych skrótów	15
1. Wprowadzenie	17
1.1. Teza rozprawy	19
1.2. Cel rozprawy i zadania badawcze	19
1.3. Struktura rozprawy	20
2. Sądowo-lekarskie zewnętrzne oględziny zwłok	24
2.1. Sprawozdanie z sądowo-lekarskich oględzin zwłok	26
2.1.1. Dokumentacja obrażeń występujących na powłokach ciała	28
2.2. Rodzaje obrażeń występujących na powłokach ciała	34
2.2.1. Podbicie krwi	36
2.2.1.1. Plama opadowa	37
2.2.2. Otarcie naskórka	39
2.3. Stosowane metody wymiarowania obrażeń	40
2.4. Podsumowanie	41
3. Pośmiertne kryminalistyczne metody obrazowania 3D	42
3.1. Radiologiczne techniki obrazowania medycznego	43
3.2. Klasyczna fotografia z elementami fotogrametrii	45
3.3. Skanery powierzchniowe	49
3.4. Zintegrowane metody obrazowania 3D	51
3.5. Podsumowanie	54
4. Podstawy teoretyczne automatycznego modelowania 3D	55
4.1. Detektory wykrywania cech charakterystycznych w zadaniu rekonstrukcji 3D powierzchni	56
4.2. Algorytmy automatycznego dopasowania obrazów	60
4.2.1. Algorytm Structure-from-Motion	62
4.2.1.1. Algorytmy SfM-MVS	63
4.2.2. Parametryczne modelowanie powierzchniowe	68
4.2.3. Wizualizacja modelu 3D	73
4.3. Podsumowanie	74
5. Głębokie sieci neuronowe w klasyfikacji obrazów medycznych	76
5.1. Analiza aktualnego stanu wiedzy w badaniu obrażeń zewnętrznych	76
5.2. Uczenie głębokie w zadaniach segmentacji obrazów	82

5.2.1. Sieci w pełni konwolucyjne	85
5.2.2. Przykładowe architektury sieci	91
5.3. Podsumowanie	98
6. Struktura i sekwencja przeprowadzonych badań.....	99
6.1. Informacje o kwestiach etycznych	99
6.2. Koncepcja wykorzystania multimodalnych metod do analizy obrazów na obrazach post-mortem	99
7. Charakterystyka danych źródłowych – CZĘŚĆ I badań	102
7.1. Protokół pozyskania danych.....	102
7.2. Struktura danych wejściowych.....	107
7.2.1. Obrazy ze zbioru danych 3D-TIP	108
7.2.1. Obrazy ze zbioru danych 2D-TIP	109
8. Automatyczne modelowanie w procesie tworzenia cyfrowej dokumentacji medycznej 3D sylwetki człowieka – CZĘŚĆ II badań.....	114
8.1. Platforma badawcza: hardware i software	114
8.2. Weryfikacja wygenerowanych modeli	115
8.3. Ocena otrzymanych wyników	118
9. Sieci w pełni konwolucyjne w zadaniu detekcji i klasyfikacji obrazów – CZĘŚĆ III badań.....	126
9.1. Augmentacja danych ze zbioru 2D-TIP	128
9.2. Platforma badawcza: hardware i software	130
9.3. Weryfikacja działania segmentacji semantycznej na obrazach post-mortem	131
9.4. Ocena otrzymanych wyników	138
10. Przeniesienie wyników segmentacji na model 3D – CZĘŚĆ IV badań	146
10.1. Rodzaj wykorzystanych danych	147
10.2. Platforma badawcza: hardware i software	149
10.3. Weryfikacja działania integracji masek segmentacji semantycznej z modelem 3D	150
10.4. Ocena otrzymanych wyników	153
11. Analiza morfometryczna i morfologiczna obrazów jako cyfrowe wspomaganie obrazowej diagnostyki – CZĘŚĆ V badań	157
11.1. Platforma badawcza: hardware i software	157
11.2. Przeprowadzenie analiz morfologicznych w przestrzeni 2D – operacje na macierzach konwolucji	159

11.3. Przeprowadzenie analiz morfometrycznych w przestrzeni 3D	165
11.3.1. Topologia ukształtowania obrażenia z wykorzystaniem krzywizn głównych .	166
11.3.2. Obliczenie odległości rzeczywistej obrażenia z wykorzystaniem grafów ważonych	175
11.3.3. Metodyka analizy ilościowej obrażenia z wykorzystaniem PCA i interpolacji <i>cubic spline</i> w przestrzeni 3D	180
11.4. Ocena otrzymanych wyników analiz morfometrycznych i morfologicznych.....	190
12. Podsumowanie i wnioski.....	192
12.1. Kluczowe wyniki pracy	194
12.2. Wnioski szczegółowe	195
12.3. Zidentyfikowanie krytycznych priorytetów	196
12.4. Kierunek dalszych badań.....	197
13. Bibliografia	199
Wykaz ilustracji.....	219
Wykaz tabel	229

Wykaz wykorzystanych skrótów

ASIFT	–	ang. <i>Affine-SIFT</i>
CAD	–	ang. <i>Computer-Aided Design</i>
CNN	–	ang. <i>Convolutional Neural Network</i>
CT	–	ang. <i>Computed Tomography</i>
CV	–	ang. <i>Computer Vision</i>
CVAT	–	ang. <i>Computer Vision Annotation Tool</i>
DoG	–	ang. <i>Difference-of-Gaussian</i>
DNN	–	ang. <i>Deep Neural Network</i>
FAST	–	ang. <i>Features from Accelerated Segment Test</i>
FCN	–	ang. <i>Fully Convolutional Network</i>
GSD	–	ang. <i>Ground Sampling Distance</i>
KNN	–	ang. <i>K-Nearest Neighbors algorithm</i>
k.p.k.	–	Kodeksu Postępowania Karnego
MRI	–	ang. <i>Magnetic Resonance Imaging</i>
MVS	–	ang. <i>Multi-View-Stereo</i>
NCHS	–	ang. <i>The National Center for Health Statistics</i>
PCA-SIFT	–	ang. <i>Principal Component Analysis-SIFT</i>
R-CNN	–	ang. <i>Region-based Convolutional Neural Network</i>
ReLU	–	ang. <i>Rectified Linear Unit</i>
ROI	–	ang. <i>Region Of Interest</i>
RTG	–	ang. <i>Radiography</i>
SEM	–	ang. <i>Standard Error of Mean</i>
SfM	–	and. <i>Structure-from-Motion</i>
SIFT	–	ang. <i>Scale-Invariant Feature Transform</i>
SURF	–	ang. <i>Speeded Up Robust Features</i>
SVM	–	ang. <i>Support-Vector Machines</i>
TL	–	ang. <i>Transfer Learning</i>
TLS	–	ang. <i>Terrestrial Laser Scanning</i>

Skróty od nazw własnych:

2D-TIP	–	ang. <i>2D Tissue-Injuries of Post-mortem</i>
3D-TIP	–	ang. <i>3D Tissue-Injuries of Post-mortem</i>
TIP	–	ang. <i>Tissue-Injuries of Post-mortem</i>
TIPPI	–	ang. <i>Targeted-Injury Post-mortem Perception and Identification system</i>

1. Wprowadzenie

Liczba zgonów na całym świecie z każdym rokiem stale rośnie. Od kilku lat można zaobserwować bardzo duży wzrost, który szczególnie notuje się dla przypadków nagłych zgonów. Narodowe Centrum Statystyki Zdrowia (NCHS, ang. *The National Center for Health Statistics*) stwierdziło, że do 2020 roku wskaźnik zabójstw w Stanach Zjednoczonych wzrósł o 49%, natomiast w latach 2019-2020 odnotowano najwyższy roczny wzrost tego wskaźnika we współczesnej historii (Curtin & Garnett, 2023). Z kolei w Wielkiej Brytanii, w Londynie w 2021 roku, przyczyną 74,4% wszystkich zabójstw były ataki z wykorzystaniem noży lub innych narzędzi ostrych co w porównaniu z rokiem 2020 stanowi wzrost o 15,6% (*London teen homicides: Boy's stabbing is record 30th killing*, 2021). Ponadto w 2021 roku, prawie połowa zgonów zgłaszanych koronerom wymagała przeprowadzenia dochodzenia w sprawie udziału osób trzecich (*Coroners statistics 2021: England and Wales*, 2022). Należy zauważyć, że przemoc domowa stanowi obecnie narastający problem występujący na całym świecie, również w Polsce. Zgodnie ze statystykami europejskimi, Polska należy do krajów z największym odsetkiem młodych ludzi (>15 roku życia), którzy doświadczyli przemocy domowej lub seksualnej (Graduszyńska i in., 2022). Sama przemoc domowa, która ma tendencję wzrostową, przyczynia się do zwiększenia liczby zabójstw aż o 500%. Jest to również jedna z przyczyn rosnącej liczby wykonywania sądowo-lekarskich sekcji zwłok, przy wciąż ograniczonej liczbie wykwalifikowanych lekarzy medycyny sądowej (Alfsen i in., 2022; *Increasing the Number, Retention and Quality of Board Certified Forensic Pathologists*, b.d.). Niezaprzeczalnie obserwuje się, że rosnąca liczba przeprowadzanych sekcji zwłok ma również związek ze wzrastającą liczbą konfliktów zbrojnych. Zaostrzone działania wojenne pomiędzy Ukrainą a Rosją trwające od 2022 r. pochłonęły ponad 10 675 ofiar cywilnych (*Report on the human rights situation in Ukraine, 1 December 2023 – 29 February 2024 [EN/UK]*, 2024) i 31 tys. ofiar militarnych po stronie Ukrainy oraz ponad 180 tys. ofiar militarnych po stronie Federacji Rosyjskiej („Zelensky: 31,000 Ukrainian soldiers killed in Russia's war”, 2024). Ponadto od momentu ataku organizacji terrorystycznej Hamas na terytorium Izraela od 2023 r., zginęło ponad 1200 cywili i 259 żołnierzy po stronie Izraelskiej oraz ponad 33 tys. cywili i 432 osoby zaangażowane w walki zbrojne po stronie Gazy (UNOCHA, 2024). W wyniku działań wojennych, niektóre instytuty na świecie, w tym *Unit of Forensic Medicine at the University*

Center of Legal Medicine Lausanne-Geneva, proszone są o tymczasowe wsparcie w postaci wysłania wykwalifikowanego personelu¹.

Istotnym z punktu widzenia dochodzenia w sprawach o znęcanie się, przemoc czy zabójstwo oraz jako dowód w sprawach sądowych jest rozpoznanie i dokumentacja obrażeń na powłokach ciała. Tradycyjne metody wciąż powszechnie stosowane, opierają się na ocenie wzrokowej i często uzależnione są nie tylko od doświadczenia lekarza medycyny sądowej, jak również od jego subiektywnych spostrzeżeń. Takie podejście stwarza możliwości popełniania błędów i wystąpienie braku spójności w ocenie. Istotny jest również fakt, że w praktyce nie zostały wprowadzone standardowe protokoły postępowania i istnieją spore rozbieżności uzależnione od wewnętrznie przyjętych norm danego instytutu (Sasidharan & Al-Kandary, 2019). Ponadto, badania nad szybkim wykrywaniem i klasyfikacją obrażeń w kontekście konfliktów zbrojnych mogą okazać się niezbędne nie tylko do skutecznego zarządzania kryzysowego, ale także ze względu na potrzebę dokumentowania przypadków masowych grobów umożliwiając dochodzenie prawdy historycznej i zapobieganie bezkarności sprawców.

W ciągu ostatnich kilku dekad rozwój i przyspieszony postęp technologii cyfrowej spowodował zmiany w wielu dziedzinach medycyny. Rozwijające się możliwości wykorzystania w medycynie przetwarzania danych w chmurze, sztucznej inteligencji, uczenia maszynowego, blockchaina, cyfrowej diagnostyki itd. określono mianem cyfrowego zdrowia. Cyfrowe zdrowie ewoluowało jako szeroki termin obejmujący elektronicznie przechwytywane dane, wraz z infrastrukturą techniczną i komunikacyjną oraz aplikacjami w ekosystemie opieki zdrowotnej. Wykorzystanie nowoczesnych technologii w obszarach medycznych to przede wszystkim potencjał w przyspieszeniu diagnozy i leczenia, zapewnienia ciągłości opieki, ułatwienie zarządzania pacjentem poza placówką itp. Pomimo znacznego rozwoju wielu dziedzin medycyny pod kątem nowoczesnych technologii wciąż pozostaje wiele innych, niezbadanych obszarów ich zastosowania (Iwanaga i in., 2021; McGinnis i in., 2021).

Medycyna sądowa, będąca specjalistycznym obszarem medycyny, skoncentrowana jest głównie na kompleksowej analizie pacjentów, u których nie stwierdza się funkcji życiowych. Jest to jedna z dziedzin medycyny, w której zauważalna jest obecnie niedostateczna inkorporacja zaawansowanych technologii cyfrowych pomimo istnienia niezwykle dużego

¹ Autorka niniejszej rozprawy doktorskiej w okresie intensywnych działań wojennych w Izraelu przebywała na stażu naukowym w instytucie *Unit of Forensic Medicine at the University Center of Legal Medicine Lausanne-Geneva*, który jako jeden z kilku europejskich ośrodków został poproszony o wsparcie w przeprowadzaniu sekcji zwłok. W tym celu zespół specjalistów z medycyny sądowej został wysłany do pracy na terenie Izraela na okres kilku tygodni.

potencjału ich wdrożenia. Niektóre ośrodki medycyny sądowej na świecie rozpoczęły prace nad etapowym wprowadzaniem nowych rozwiązań (więcej w rozdziale: 3. *Pośmiertne kryminalistyczne metody obrazowania 3D*). Mimo to, nadal brakuje wystarczających technik oceny obrażeń zewnętrznych na ciele badanego, innych niż powszechnie stosowane techniki wizualne. Wskazuje to na pilną potrzebę opracowania nowych systemów medycznych, które zapewnią biegłym przystępną metodę automatycznego wykrywania i klasyfikacji obrażeń. Uzyskane w ten sposób wsparcie obecnych praktyk sądowo-lekarskich i ratunkowych wykorzystywanych do interpretacji zmian urazowych u ofiar, może przyczynić się do rozwoju metrycznej technologii zautomatyzowanego procesu rozpoznania obrażeń oraz ujednolicenia ich oceny. Dodatkowym atutem jest archiwizacja sylwetki ofiary w postaci dokumentacji cyfrowej 3D z wykorzystaniem zdjęć post-mortem celem możliwości przeprowadzania wielokrotnej weryfikacji przez biegłych sądowych.

W kontekście powyższych rozważań, niniejsza rozprawa doktorska ma na celu przedstawienie możliwości wykorzystania metod uczenia głębokiego i automatycznego modelowania 3D w procesie klasyfikacji i interpretacji obrażeń znajdujących się na powłokach ciała ofiary. Opracowanie określonej metodyki wykonywania i przetwarzania zdjęć post mortem nie tylko zautomatyzuje proces rozpoznawania obrażeń, ale stworzy możliwość opracowania cyfrowego zapisu 3D sylwetki ofiary z możliwością wielokrotnej oceny badanych obrażeń biegłych sądowych czy też wykorzystanie tych danych w rozprawach sądowych. Dodatkowo stworzy możliwość ujednolicenia protokołu zapisu i oceny obrażeń badanej ofiary.

1.1. Teza rozprawy

Teza postawiona w niniejszej rozprawie doktorskiej brzmi: **Wykorzystanie wybranych algorytmów uczenia głębokiego umożliwi automatyczną detekcję i klasyfikację obrażeń ciała na podstawie zdjęć post-mortem a opracowana metodyka ich zapisu na wirtualnych modelach 3D ciał zautomatyzuje proces badania obrażeń w diagnostyce sądowej.**

1.2. Cel rozprawy i zadania badawcze

Przedstawiony we wstępie motyw przewodni niniejszej pracy, dotyczący analizy obrażeń, pozwolił na ukształtowanie głównego celu rozprawy jako zbadania możliwości automatycznej interpretacji obrażeń znajdujących się na powłokach ciała człowieka, powstałych na krótko przed zgonem. W pracy rozważono obrażenia ujawnione na ciele ludzkim w stadium rozkładu

1-3 dni (tzw. wczesne stadium rozkładu) z uwagi na zachodzące zmiany wraz z jego postępowaniem. Występujące przeobrażenia znacząco mogą wpływać na wygląd obrażenia, jak również samą pigmentację skóry. Ponadto, uwzględnienie obrazów dla wczesnego stadium rozkładu stwarza w przyszłości możliwość implementacji opracowanych rozwiązań również dla pacjentów u których nie stwierdzono zgonu (np. w przypadku badań w obszarze przemocy). Realizację tematyki rozprawy doktorskiej podzielono na następujące zadania badawcze:

1. Utworzenie zintegrowanej bazy danych 2D-TIP i 3D-TIP, obejmującej obrazy post-mortem przedstawiające ofiary przestępstw lub zdarzeń o charakterze kryminalnym.
2. Określenie parametrów ekspozycji, geometrii zdjęć i procesu modelowania 3D sylwetki człowieka z wykorzystaniem sieci zdjęć post-mortem, w celu stworzenia cyfrowej dokumentacji medycznej.
3. Implementacja i walidacja metod głębokiego uczenia do segmentacji semantycznej z wykorzystaniem zdjęć post-mortem (2D) dwóch kategorii zmian pourazowych (tj. podbiegnięć krwawych i otarć naskórka) powstałych na ciele człowieka na krótko przed jego zgonem.
4. Integracja wykrytych obrażeń z opracowanym cyfrowym modelem 3D, która stanowić będzie pilotażowy system wizyjny.
5. Przeprowadzenie kompleksowych analiz morfometrycznych i morfologicznych obrażeń w celu uzyskania ich pełnej charakterystyki ilościowej i jakościowej.
6. Identyfikacja krytycznych obszarów zaproponowanego podejścia oraz wskazanie priorytetów wymagających optymalizacji w kontekście dalszego rozwoju systemu.
7. Analiza wpływu zaproponowanych rozwiązań na efektywność i standaryzację procesu przeprowadzania sądowo-lekarskich zewnętrznych oględzin zwłok.

1.3. Struktura rozprawy

Rozprawa podzielona została na 13 rozdziałów. Rozdziały 2-5 stanowią część teoretyczną wraz z pogłębionym przeglądem literatury przedmiotu. Rozbudowana część teoretyczna została celowo zaprojektowana jako interdyscyplinarny pomost łączący perspektywę medyczną i inżynierską, umożliwiając pełne zrozumienie problematyki badawczej przez specjalistów z obu dziedzin. Oryginalne prace badawcze autorki, stanowiące zasadniczy wkład naukowy rozprawy, zostały przedstawione w rozdziałach 6-12.

Poniżej opisano zawartość poszczególnych rozdziałów:

- **Rozdział 2** stanowi ogólne wprowadzenie do zagadnienia sądowo-lekarskich zewnętrznych oględzin zwłok ze szczególnym naciskiem na pojęcie „obrażenie” i związane z nim zagadnienia wiążące. Oprócz omówienia formy dokumentowania zmian pourazowych ujawnionych na ciele ofiary, wskazano również rodzaje obrażeń na powłokach ciała z wyszczególnieniem podbiegnięć krwawych i otarć naskórka, a także wskazano stosowane metody do opisu ich charakterystyki.
- **Rozdział 3** przedstawia przegląd nowoczesnych metod obrazowania zmian pourazowych, które w ostatnich kilku latach z powodzeniem odnalazły zastosowanie w niektórych ośrodkach medycyny sądowej na świecie. Poza wprowadzeniem przedstawiającym daną metodę, rozdział ten zawiera także praktyczne przykłady w oparciu o publikacje wyników ich autorów.
- **Rozdział 4** przedstawia metody ekstrakcji cech charakterystycznych z obrazów cyfrowych przy wykorzystaniu operatorów opartych na macierzach konwolucji. Ponadto w rozdziale wskazano na znaczący potencjał zastosowania technik automatycznego modelowania 3D w kontekście tworzenia cyfrowej dokumentacji medycznej ciała człowieka. Szczególną uwagę poświęcono algorytmom SfM-MVS, które poprzez zaawansowane techniki dopasowania punktów charakterystycznych i triangulacji, umożliwiają rekonstrukcję przestrzenną obiektów, co ma kluczowe znaczenie w dokumentowaniu i analizie obrażeń w przestrzeni trójwymiarowej.
- **Rozdział 5** przedstawia wykorzystanie głębokich sieci neuronowych w zadaniu segmentacji obrazów, koncentrując się na sieciach w pełni konwolucyjnych (FCN). Omówiono budowę sieci FCN, w tym warstwy splotowe, funkcje aktywacji i znaczenie *transfer learningu*. Rozdział kończy szczegółowa charakterystyka wybranych architektur dekodek (U-Net, FPN, LinkNet) i enkoderów (ResNet50, EfficientNetB3), których zastosowanie przedstawiono w części eksperymentalnej rozprawy.
- **Rozdział 6** otwiera część eksperymentalną badań poprzez opis struktury zaplanowanych działań oraz prac związanych ze stworzeniem autorskich zbiorów danych nazwanych 2D-TIP (ang. *2D Tissue-Injuries of post-mortem*) oraz 3D-TIP (ang. *3D Tissue-Injuries of post-mortem*). Przedstawiona koncepcja badawcza rozprawy podzielona została na pięć głównych części: utworzenie własnego zbioru zdjęć post-mortem, określenie procesu automatycznego modelowania 3D w tworzeniu cyfrowej dokumentacji medycznej, wykorzystanie sieci FCN do segmentacji obrażeń na podstawie wybranych

zdjęć post-mortem i ich integrację z cyfrowym modelem 3D ciała człowieka oraz przeprowadzenie analiz morfometrycznych i morfologicznych badanych obrazów.

- **Rozdział 7** stanowi I część badań i przedstawia proces tworzenia dwóch autorskich zbiorów danych: 3D-TIP (3645 obrazów do modelowania 3D ciała) oraz 2D-TIP (3524 obrazów przedstawiających obrażenia na ciele). Dane pozyskano w Zakładzie Medycyny Sądowej Warszawskiego Uniwersytetu Medycznego w latach 2021-2022², wykorzystując kamerę Canon EOS 5D Mark II. Dla zbioru 3D-TIP opracowano metodykę fotografowania z wykorzystaniem osnowy fotogrametrycznej, rejestrując ciała w pozycjach *prone* i *supine*. Zbiór 2D-TIP zawierający obrazy podbiegnięć krwawych i otarć naskórka został manualnie poetykietowany z użyciem narzędzia CVAT, tworząc bazę 18 762 etykiet obrazów. Oba zbiory stanowią unikalne źródło danych do dalszych badań nad automatyczną analizą obrazów w medycynie sądowej.
- **Rozdział 8** stanowi II część badań i prezentuje proces tworzenia dokumentacji cyfrowej modelu 3D ciała ludzkiego z wykorzystaniem metody SfM-MVS w oprogramowaniu Agisoft Metashape Professional, przeprowadzony na autorskim zbiorze danych 3D-TIP. Proces rekonstrukcji obejmował sekwencyjne etapy od wyrównania zdjęć poprzez generowanie chmur punktów, po opracowanie fotorealistycznego modelu 3D ciała ludzkiego.
- **Rozdział 9** stanowi III część badań i skupia się na wykorzystaniu sieci w pełni konwolucyjnych (FCN) do segmentacji semantycznej obrazów. Badania przeprowadzono na autorskim zbiorze danych 2D-TIP, testując sześć modeli: U-Net, FPN i LinkNet z backbone EfficientNetB3 i ResNet50.
- **Rozdział 10** prezentuje IV część badań obejmującą wstępną integrację modelu 3D ciała człowieka (część II badań) z rozpoznanymi obrazami w wyniku segmentacji semantycznej (część III badań), stanowiąc pierwszy krok w kierunku utworzenia pilotażowego systemu wizyjnego.
- **Rozdział 11** obejmuje ostatnią, V część badań koncentrującą się na analizie morfometrycznej i morfologicznej obrazów w przestrzeni 2D i 3D. W przestrzeni 2D z wykorzystaniem operacji na macierzach konwolucji przeprowadzono analizę

² Autorka niniejszej rozprawy doktorskiej w okresie od lipca 2021 r. do września 2022 r. odbyła staż naukowy w Zakładzie Medycyny Sądowej Warszawskiego Uniwersytetu Medycznego. W trakcie stażu, pod kierunkiem specjalistów z dziedziny medycyny sądowej, zdobyła cenne doświadczenie oraz wiedzę, które pozwoliły jej na poszerzenie kompetencji niezbędnych do kontynuowania badań związanych z przygotowywaną rozprawą doktorską.

morfolologiczną skupiając się na wyrazistości, granicach, konturach, strukturze i cechach charakterystycznych badanego obrazu. W przestrzeni 3D z wykorzystaniem analiz krzywizn głównych, grafów ważonych przeprowadzono analizy morfometryczne uzyskując pomiar odległości rzeczywistej oraz przeprowadzono analizy ilościowe z wykorzystaniem PCA i interpolacji *cubic spline*.

- **Rozdział 12** poświęcony został krytycznej ocenie wyników przeprowadzonego badania zawierając holistyczne podejście, gdzie wskazane zostały mocne i słabe strony, jak również wskazano kierunek dalszych badań i rozwoju autorki.
- **Rozdział 13** prezentuje bibliografię wykorzystaną w niniejszej pracy.

2. Sądowo-lekarskie zewnętrzne oględziny zwłok

W polskim ustawodawstwie przepisy rozdziału 23 Kodeksu Postępowania Karnego (dalej: k.p.k.) (Ustawa z dnia 6 czerwca 1997 r.) odnoszą się do przeprowadzenia trzech dowodów szczególnie istotnych dla postępowania karnego:

- oględzin (art. 207, art. 208, art. 209 § 1 – 3 i 5 oraz art. 210 i art. 212);
- otwarcia zwłok (art. 209 § 1, 4 i 5 oraz art. 201 i art. 212);
- eksperymentu (art. 211 i art. 212).

W kontekście prawa karnego otwarcie zwłok i eksperyment są dowodami kategorii czynności dowodowej, która pozwala na przeprowadzenie działań mających na celu uzyskanie informacji i postawienie odpowiednich wniosków. Otwarcie zwłok polega na medycznym badaniu trzech podstawowych jam ciała (głowy, szyi i klatki piersiowej wraz z jamą brzuszną) osoby zmarłej w celu ustalenia przyczyny zgonu. Natomiast eksperymenty to działania mające na celu przetestowanie hipotez lub odtworzenie okoliczności zdarzenia lub przestępstwa. Ostatnim z dowodów są oględziny, które stanowią dowód rzeczowy opierając się na uzyskaniu informacji na podstawie bezpośrednich obserwacji i dowodów fizycznych poprzez badanie konkretnych przedmiotów (np. ubranie, ciało ofiary) lub ujawnienia śladów czy materiałów znalezionych na miejscu przestępstwa lub zdarzenia (Gruza i in., 2020; Ustawa z dnia 6 czerwca 1997 r.). W kontekście prawa formalnego oględziny ciała stanowią czynność procesową i jako procedura przeprowadzane są przez organ kierujący procesem. W tym celu, organ zwykle korzysta z pomocy lekarza medycyny sądowej kończąc przebieg oględzin wystawieniem protokołu ich przebiegu. Innym stosowanym pojęciem w medycynie sądowej jest badanie ciała, które również wchodzi w zakres ekspertyzy wykonywanej przez biegłego z tą różnicą, że bez obecności lub tylko z możliwym udziałem przedstawiciela organu procesowego, który jednak bezpośrednio nie kieruje tymi czynnościami. Dokumentem kończącym w tym przypadku jest sprawozdanie. Warto zaznaczyć, że w obszarze kryminalistyki i medycyny sądowej pojęcia „oględziny” i „badanie zwłok” oraz „protokół” i „sprawozdanie” traktowane są tożsamo (zgodnie z ich potocznym, ogólnie przyjętym rozumieniem) (Teresiński, 2021).

Prowadząc dalsze dywagacje, należy zauważyć, że w polskim ustawodawstwie nie zdefiniowano odrębnej definicji dla samych oględzin czy badania zwłok. Co więcej, pojawia się pytanie czy zwłoki należy traktować jako osobę, której dedykowany jest art. 209 § 1 k.p.k., czy jako rzecz i zastosowanie powinien mieć art. 207 § 2 i 3 k.p.k. W literaturze przeważa pogląd, że wobec przyjętej regulacji wyodrębniającej oględziny zwłok do innej jednostki redakcyjnej (art. 209 § 1 k.p.k.), powinno się potraktować je jako specyficzną rzecz.

Argumentem przemawiającym za takim podejściem jest również fakt, że martwe ciało człowieka nie jest osobą, a sam ustawodawca podzielił czynności na oględziny osoby i rzeczy, czego konsekwencją jest stosowanie dla badania zwłok także art. 207 § 2 k.p.k. Konkludując przyjmuje się, że oględziny zwłok stanowią specyficzną i ustawowo wyodrębnioną formę oględzin (Fudalej et al., 2023; Gruza et al., 2020; Ustawa z dnia 6 czerwca 1997 r.; Witkowska, 2013). Pomimo braku istnienia oficjalnej definicji oględzin zwłok, ustawodawca w art. 2 oraz art. 8 pkt. 1 Rozporządzenia Ministra Zdrowia z dnia 7 grudnia 2001 r. w sprawie postępowania ze zwłokami i szczątkami ludzkimi określił zakres przedmiotowy pojęcia samych zwłok zaliczając do nich ciała osób zmarłych i dzieci urodzone martwe (bez względu na czas trwania ciąży), popioły powstałe w wyniku spopielenia, pozostałości wydobyte przy kopaniu grobu lub w innych okolicznościach czy części ciała ludzkiego odłączone od całości (Fudalej i in., 2023).

Przeprowadzenie sądowo-lekarskich zewnętrznych oględzin zwłok wskazuje na procedurę mającą na celu dokładne zbadanie ciała osoby zmarłej bez jej otwierania (otwarcie ciała następuje podczas sekcji wewnętrznej) i stwierdzenie lub jego brak widocznych obrażeń lub ich oznak na powłokach ciała (Gruza i in., 2020). Służy to ustaleniu, jaka była przyczyna śmierci oraz jej rodzaj, a także określenie zjawisk i symptomów, które mogą stanowić pomoc przy wskazaniu, czy zgon nastąpił wskutek przestępstwa, nieszczęśliwego wypadku, czy z przyczyn naturalnych (Gruza i in., 2020; Marcinkowski, 2010). Wymogi formalne przeprowadzania oględzin zewnętrznych definiuje art. 209 § 3 k.p.k., który stanowi, że oględziny przeprowadza się w miejscu ich znalezienia, a ich przemieszczenie do czasu przybycia biegłego lekarza medycyny sądowej oraz prokuratora lub sądu może nastąpić jedynie w uzasadnionych przypadkach (np. odblokowanie ruchu komunikacyjnego) (Gruza i in., 2020). Również art. § 52 ust. 1 Regulaminu Wewnętrznego Urzędowania Powszechnych Jednostek Organizacyjnych Prokuratury wskazuje, że *„na miejscu zdarzenia, którego skutkiem jest śmierć człowieka, a także innych wskazanych przez kierownika jednostki, czynności procesowe wykonują osobiście prokuratorzy lub kierują ich przebiegiem”*. Dodatkowo istnieje wiele publikacji podkreślających istotę znaczenia oględzin, a jednak w praktyce, bardzo często umniejsza się jej rolę i jak zauważa autorka, prowadzi to do występowania wielu błędów. Subiektywne i nierozważne traktowanie oględzin, wyraża się poprzez zrutynizowane podejście, a także samo naruszenie w postaci nieuczestniczenia w nim prokuratora i/lub niewłaściwego doboru członków ekipy oględzinowej (Fudalej i in., 2023). Praktyka wskazuje jednak, że w instytucie medycyny sądowej otwarcie zwłok (sekcje wewnętrzną) poprzedzają dodatkowe i bardziej szczegółowe sądowo-lekarskie oględziny zwłok, zakończone udokumentowaniem w formie sprawozdania wraz z opinią końcową. Dokładne udokumentowanie jest o tyle istotne,

że w rozumieniu art. 316 k.p.k. badanie to stanowi *czynność niepowtarzalną* (Fudalej i in., 2023).

2.1. Sprawozdanie z sądowo-lekarskich oględzin zwłok

W kontekście sądowo-lekarskiego zewnętrznego badania zwłok, zgodnie z art. 200 k.p.k. badanie powinno zostać udokumentowane w formie sprawozdania z przeprowadzonych czynności i spostrzeżeń. Przyjmuje się, że powstałe sprawozdanie składa się z części formalno-metrykalnej ze wskazaniem danych instytucji i lekarza przeprowadzającego tę czynność, jak również datę jej przeprowadzenia, dane pokrzywdzonego, informacje o dodatkowej dokumentacji lekarskiej dostarczonej dla potrzeb sekcji, zleceniodawcę oraz ewentualnie inne osoby biorące udział w czynności (Teresiński, 2021). Jednak to zewnętrzne badanie zwłok stanowi najważniejszą część sprawozdania. Podczas jego przeprowadzania opisuje się (Fudalej i in., 2023):

- długość zwłok (wzrost);
- stan odżywienia;
- kolor (pigmentację) skóry;
- znamiona śmierci (brak reakcji na bodźce, brak samoistnego bądź odruchowego ruchu mięśni, brak samoistnego oddechu, brak odruchów z pnia mózgu i głębokich odruchów ścięgnistych);
- spojówki i gałki oczne (przykładowo w przypadku uduszenia gwałtownego obrażeniom towarzyszyć mogą wybroczyny krwawe);
- otwory uszu i nosa pod kątem obecności treści płynnej lub ciał obcych;
- czerwień wargową i jamę ustną wraz z uzębieniem i ewentualnymi świeżymi ubytkami (często występujące w przypadku przemocy);
- budowę i symetrię klatki piersiowej;
- patologiczną ruchomość kończyn;
- gruczoły piersiowe u kobiet pod kątem wyczuwalnych guzów lub wycieku treści z brodawek sutkowych;
- opis powłok brzusznych;
- zewnętrzne narządy płciowe pod kątem obrażeń.

W końcowym etapie zewnętrznego badania zwłok należy szczegółowo opisać tatuaże skóry i blizny oraz obrażenia stosując typowo przyjęty schemat, który zawiera następujące elementy (Fudalej i in., 2023):


- rodzaj obrażenia;
- lokalizację obrażenia;
- ułożenie, kształt i jego rozmiar;
- określenie barwy i ewentualnych cech, które mogłyby wskazywać na procesy zapalne czy procesy gojenia;
- inne pozostałe elementy obrażenia, takie jak np. zabrudzenie jego okolic czy ślady zaopatrzenia chirurgicznego;
- cechy przyżyciowości powstania obrażenia (np. podbiegnięcia krwawe w brzegach ran, podbiegnięcia krwawe w tkance podskórnej pod zasinieniami z opisem ich barwy). Ocena przyżyciowości stwierdzonych obrażeń jest istotna, gdyż wskazuje, które obrażenia powstały jeszcze za życia, a tym samym mogły przyczynić się do zgonu.

Ponadto, w posekcyjnej dokumentacji lekarz medycyny sądowej powinien przede wszystkim dokładnie wyjaśnić (Fudalej i in., 2023):

- czy wystąpił związek przyczynowo-skutkowy pomiędzy wykrytymi obrażeniami a zgonem (należy zauważyć, że wystąpienie wielu obrażeń na ciele niekoniecznie musi skutkować zgonem);
- określić czas powstania obrażenia: czy są one post-mortem (powstałe już po ustaniu funkcji życiowych) czy ante-mortem (powstałe jeszcze za życia), ew. czy widoczne obrażenia mogły powstać na dłuższy czas przed zgonem i nie pozostawać z nim w związku przyczynowo-skutkowym;
- czy wykryte obrażenia mogły powstać na skutek ustalonych w biegu postępowania okoliczności;
- czy wykryte obrażenia mogły powstać na skutek działania własnego (np. samobójcze rany cięte);
- czy na ciele zmarłego wykryte obrażenia mogą wskazywać na działania w obronie własnej lub aktywnym uczestnictwie np. w bójce.

Sądowo-lekarskie zewnętrzne badanie zwłok powinna uzupełniać dokumentacja fotograficzna lub szkic (schemat sylwetkowy), szczególnie jeżeli na zwłokach odnotowano obecność wielu obrażeń. Na rysunku 2.1 ukazano przykład schematu sylwetkowego dla kobiety i mężczyzny, podobne schematy występują dla dzieci. Dokumentacja fotograficzna lub schemat

sylwetkowy wpływają na zminimalizowanie zniekształceń oraz znacząco podnoszą jakość informacji zawartych w sprawozdaniu. Stosowanie obydwu metod nie jest obligatoryjne, jednak ze względu na ich wzajemne uzupełnianie się, zaleca się ich wykorzystanie. W przypadku wykonywania schematu sylwetkowego z naniesionymi obrażeniami zwykle korzysta się z kolorowych flamastrów lub kredek odpowiadających rodzajowi i zabarwieniu stwierdzonego obrażenia. Natomiast w przypadku fotografii, należy pamiętać, że kolorowy obraz cyfrowy bardzo dobrze może odwzorować kształt i zabarwienie danego obrażenia to jednak w przypadku źle dobranego oświetlenia czy wartości parametrów kamery może nie w pełni odzwierciedlić stan rzeczywisty (Teresiński, 2021).



Rysunek 2.1. Referencyjny schemat sylwetkowy służący do oznaczania ujawnionych obrażeń u kobiet i mężczyzn, wykorzystywany w Zakładzie Medycyny Sądowej Warszawskiego Uniwersytetu Medycznego (źródło: zasoby własne)

2.1.1. Dokumentacja obrażeń występujących na powłokach ciała

Jednym z najistotniejszych elementów sprawozdania z sądowo-lekarskiego zewnętrznego badania ciała jest poprawne udokumentowanie, ocena i interpretacja wykrytych obrażeń. Dokumentacja obrażeń powinna nastąpić zgodnie z przyjętym schematem ich opisu (rysunek 2.1) wskazującym na:


Rodzaj obrażenia

Szczególną uwagę przy opisywaniu rodzaju obrażenia zwraca się na stosowanie sformułowań prostych i jasnych, oraz posługiwania się medycznymi terminami określającymi dane obrażenie (więcej w rozdziale: 2.2. *Rodzaje obrażeń występujących na powłokach ciała*).


Posługiwanie się poprawnym nazewnictwem ma znacznie w ocenie możliwości użycia narzędzia do jego spowodowania. Opisując wygląd rany należy skupić się na charakterystyce jej brzegów i jeżeli istnieją stosowne okoliczności, również dna. Istotne jest również opisanie cech charakterystycznych, które mogłyby pomóc w identyfikacji narzędzia (np. odwzorowanie powierzchni styku opony samochodowej z ciałem, równoległe lub osobliwie rozłożone podbiegnięcia krwawe) itd. (Teresiński, 2021).

Lokalizacja obrażenia

Podobnie jak w przypadku określania rodzaju obrażenia, również w kontekście jego lokalizacji powinno się posługiwać medycznymi terminami poprawnie określającymi daną część anatomiczną i linie ciała. W przypadku braku dokumentacji fotograficznej lub schematu sylwetkowego, stosowanie właściwych pojęć pozwala na uniknięcie błędnej interpretacji sprawozdania w kolejnych etapach postępowania. Znajomość topologii ciała ludzkiego (rysunek 2.2, rysunek 2.3(a-b)) jest niezbędna, jednakże opisując lokalizację obrażenia na ciele można również zastosować uproszczony opis poprzez odniesienie się do pewnych stałych punktów anatomicznych (np. oczu, pępka itp.), linii oraz powierzchni i płaszczyzn ciała (rysunek 2.4(a-f)). Według opracowania Teresińskiego (Teresiński, 2021) wyróżniamy 162 pola anatomiczne, w tym 70 znajdujących się na płaszczyźnie czołowej przedniej (ang. *anterior*), 54 na płaszczyźnie czołowej tylnej (ang. *posterior*) i 35 w okolicy głowy, twarzy i szyi. Poza wskazaniem lokalizacji obrażenia należy również wyznaczyć kierunek jego powstania bądź zagłębiania się (dotyczy jedynie zmian drążących) i opisać orientację w przestrzeni.



Rysunek 2.2. Pola anatomiczne ciała ludzkiego (głowa, twarz, szyja) z zaznaczeniem kluczowych obszarów wykorzystywanych do oznaczania obrażeń, zgodnie z klasyfikacją anatomiczną (źródło: (Teresiński, 2021))



Rysunek 2.4. Linie, podstawowe płaszczyzny anatomiczne oraz orientacje przestrzenne, wykorzystywane w analizie topologicznej ciała ludzkiego: a) płaszczyzna poprzeczna z osią poprzeczną, b) płaszczyzna strzałkowa z osią strzałkową, c) płaszczyzna czołowa z osią pionową, d) linia topograficzna przedniej powierzchni tułowia, e) linia topograficzna tylnej powierzchni tułowia, f) linia topograficzna bocznej powierzchni tułowia (źródło: (Teresiński, 2021))

Cechy geometryczne obrażenia (rozmiar, kształt, ułożenie)

Kolejnym elementem należącym do opisu obrażeń jaki powinien znaleźć się w sprawozdaniu jest informacja o jego cechach geometrycznych. W pierwszej kolejności podaje się wielkość zmiany urazowej w jednostce centymetrów lub milimetrów mierzonych linijką lub podobnym narzędziem pomiarowym (rysunek 2.5). W przypadku trzeciego wymiaru (podania głębokości obrażenia) jest on niezwykle trudny do uzyskania stosując ocenę wizualną przez biegłego i zwykle nie jest określany w przypadku płytkich ran³. Ponadto, w zależności od rodzaju danego obrażenia, opis jego kształtu może się różnić. Część z nich może przyjąć postać bardzo regularnych (rysunek 2.6(a)), a pozostała wydawać się całkowicie przypadkowa (rysunek 2.6(b)). Jednak należy zwrócić uwagę, aby konsekwentnie stosować nazewnictwo geometryczne np. kształt liniowy, owalny, okrągły, trójkątny, pasmowaty itp. W przypadku, kiedy kształt obrażenia przybiera postać liniowego, gdzie jeden z wymiarów jest dłuższy,

³ W ramach prac nad niniejszą rozprawą doktorską autorka wskazała sposób wyznaczania głębokości obrażenia dla płytkich ran (rozdział 11.3.3. *Metodyka analizy ilościowej obrażenia z wykorzystaniem PCA i interpolacji cubic spline w przestrzeni 3D*).

powinno określić się jak położony on jest w stosunku do osi długiej tułowia lub kończyny, to znaczy czy równoległe (podłużnie), poprzecznie czy skośnie (w jakim stopniu i względem jakiej osi ciała). Opisując kształt obrażenia, oprócz stosowania nazewnictwa geometrycznego można również odnieść się do kształtu liter np. obrażenie przybiera kształt litery V (Teresiński, 2021).



Rysunek 2.5. Przykład dokumentowania wymiaru obrażenia. Ustalony wymiar należy zapisać w dokumentacji sprawozdawczej, ponadto jak ukazano na ilustracji powyżej jako dodatkową formę dokumentacji można wykorzystać zdjęcie z narzędziem pomiarowym służącym jako skala (źródło: zasoby własne)



a) przypadkowy kształt obrażeń

b) regularny kształt obrażeń

Rysunek 2.6. Przykład obrażeń o nieregularnym, przypadkowym kształcie (a) oraz o charakterystycznym, regularnym kształcie (b) (źródło: zasoby własne)

Barwa i cechy charakterystyczne

Opis barwy czy charakterystyki podobnie jak w przypadku kształtu uzależniony jest od rodzaju obrażenia, a także od karnacji osoby badanej (rasa kaukaska, rasa afroamerykańska itd.), wieku (u osób starszych występują tzw. plamy starcze, wylewy podskórne, wyraźnie zaznaczone użyłnienie itp.), pigmentacji skóry, wagi (kobiety, zwłaszcza otyłe, wydają się bardziej podatne na występowanie podbiegnięć, podczas gdy dobrze zbudowane, umięśnione osoby są bardziej odporne). W przypadku podbiegnięć krwawych należy opisać nie tylko samą barwę, która będzie zależna od upływu czasu jego powstania, ale również brzeg z zaznaczeniem czy obrażenie jest dobrze odgraniczone od skóry czy rozmyte⁴. Natomiast w przypadku otarć i ran należy opisać rysunek jego powierzchni - tzw. relief, czyli zwałczkowanie, które wskazuje na kierunek powstania obrażenia⁵ (Teresiński, 2021).

Cechy przyżyciowości powstania obrażenia

Ocena przyżyciowości wykrytych obrażeń opiera się na przypisaniu obrażenia do jednej z dwóch kategorii:

- obrażenie ante-mortem – powstałe za życia lub na krótko przed stwierdzeniem zgonu;
- obrażenie post-mortem – powstałe po ustaniu funkcji życiowych.

Praktyka wskazuje, że gdy obrażenie wystąpiło bardzo blisko momentu zgonu w wielu przypadkach trudno jest je odróżnić. Co prawda, obrażenia powstałe za życia wywołują pewne reakcje organizmu, które nie występują w ranach pośmiertnych, więc wskazanie, że taka reakcja nastąpiła jest wystarczające, aby potwierdzić obrażenie ante-mortem. Ponadto reakcje organizmu mają regularny i zależny od czasu przebieg np. w przypadku wynaczynień krwi do tkanek miękkich, a tym samym ocenę ich cech przemiany barwnikowej lub innych cech gojenia można ustalić wiarygodny czas gojenia się obrażenia (Fudalej i in., 2023; Oehmichen, 2004).

Występowanie obrażeń post-mortem jest rzadkie, ale jeżeli dochodzi do ich powstania to najczęściej zauważalne są one na tkance skórnej i tkankach miękkich pokrywających kości lub wyrostki kostne, takie jak głowa. Obecnie najpowszechniej stosowaną metodą ustalania przyżyciowości jest badanie mikroskopowe rany. Domniemuje się, że obecność krwawienia w tkance podskórnej wskazuje na to, że zmarły żył lub przynajmniej jego serce biło


⁴ W ramach prac nad niniejszą rozprawą doktorską autorka przeprowadziła analizy związane z teksturą oraz granicami obrażenia (rozdział 11.2. *Przeprowadzenie analiz morfologicznych w przestrzeni 2D – operacje na macierzach konwolucji*).

⁵ W ramach prac nad niniejszą rozprawą doktorską autorka w części dotyczącej reliefu wskazała kilka metod pomocnych w określaniu kierunku powstania obrażenia (rozdział 11.2. *Przeprowadzenie analiz morfologicznych w przestrzeni 2D – operacje na macierzach konwolucji* oraz rozdział 11.3.1. *Topologia ukształtowania obrażenia z wykorzystaniem krzywizn głównych*).

w momencie powstania urazu. Problem z tą zasadą polega na tym, że w przypadku wystąpienia obrażenia na krótko przed ustaniem funkcji życiowych wciąż może ono spowodować krwawienie do tkanek miękkich. Stosując metodę mikroskopową poszukuje się także występowania reakcji zapalnej, chociaż niektóre tkanki jej nie wykazują, chyba że ofiara przeżyła co najmniej kilka godzin po urazie (DiMaio & Molina, 2021). Z kolei badania eksperymentalne sugerują wykorzystanie technik biologii molekularnej w celu wykrycia zmian funkcjonalnych związanych z procesem śmierci, których nie można wykryć morfologicznie (Maeda i in., 2010; Ros i in., 2022). W tym kontekście wykazano, że wiele cytokin, czynników wzrostu i proteaz jest zaangażowanych w proces gojenia się obrażenia, a ich badanie jest praktyczne w celu określania przyżyciowości rany lub jej wieku (Kondo & Ishida, 2010). Konkludując, wypracowanie spójnego i odpowiedniego schematu wskaźnikowego do oceny przyżyciowości obrażenia wciąż pozostaje kwestią sporną i różni się w zależności od instytutu medycyny sądowej (Casse et al., 2016).

2.2. Rodzaje obrażeń występujących na powłokach ciała

Śmierć gwałtowna posiada charakter urazowy i występuje w momencie przekroczenia przez czynnik zewnętrzny możliwości adaptacyjnych organizmu. W medycynie sądowej odróżnia się znaczenie określenia uraz (ang. *trauma*) i obrażenie (ang. *laceratio/injury*). Urazem nazywamy energię, która zostaje przekazana ciału w sposób szkodliwy dla niego. W wyniku jej działania następuje widoczne naruszenie ciągłości struktur tkankowych określane jako obrażenie (rysunek 2.7) (Teresiński, 2019).

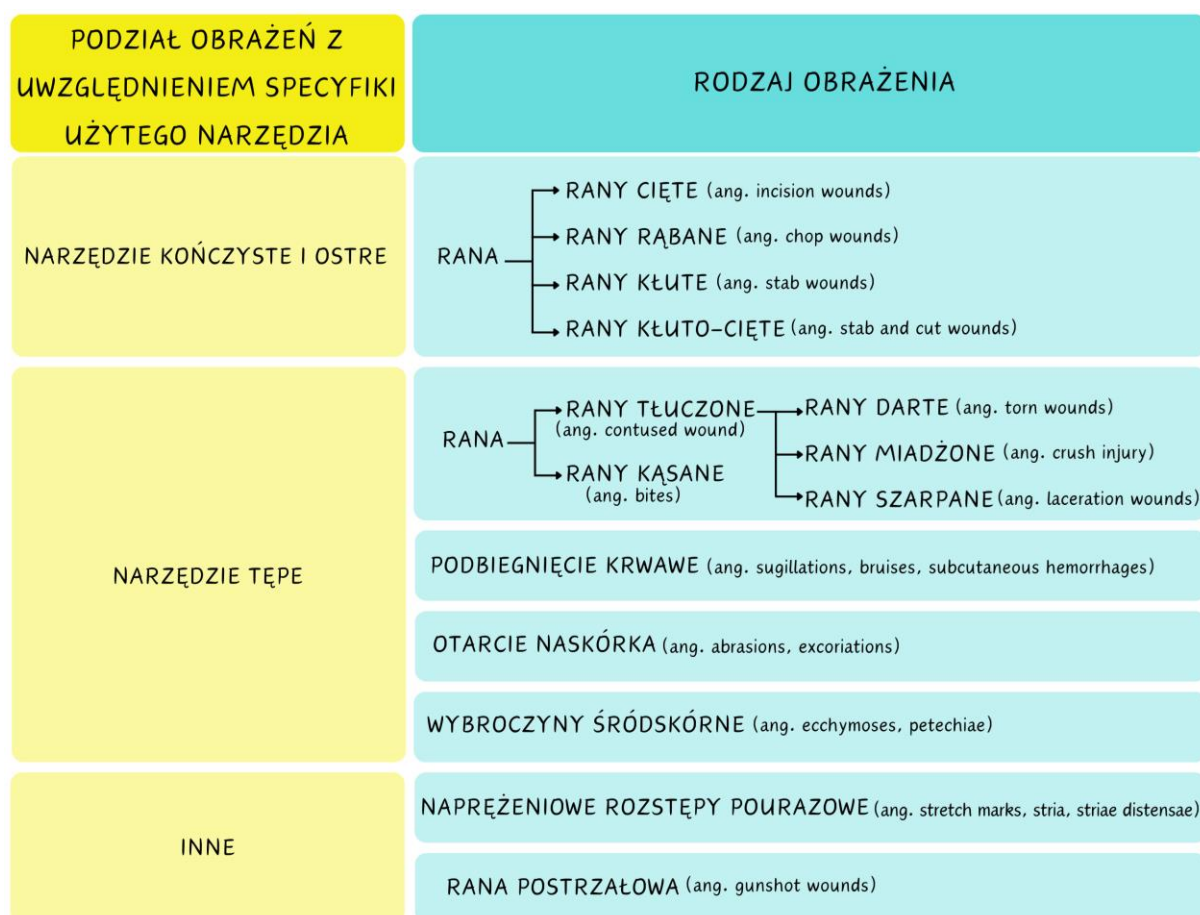


Rysunek 2.7. Przedstawienie zależności między pojęciami urazu i obrażenia: uraz jako energia przekazana ciału w sposób szkodliwy oraz obrażenie jako wynikające z niego naruszenie ciągłości struktur tkankowych (źródło: opracowanie własne)

Z punktu widzenia medycyny sądowej i przeprowadzania sądowo-lekarskich oględzin zwłok urazy mechaniczne klasyfikowane są jako jedne z ważniejszych. Powodem ich powstania jest wystąpienie jednego z trzech czynników (Teresiński, 2019):

- wystąpienie narzędzia znajdującego się w ruchu, gdy ciało pozostaje nieruchome (np. cios, pchnięcie, postrzał);
- wystąpienie ruchu ciała skierowanego w stronę narzędzia pozostającego w stanie nieruchomym (np. upadek z wysokości);
- wystąpienie ruchu zarówno narzędzia jak i ciała (np. większość wypadków komunikacyjnych).

Schemat występowania obrażeń zewnętrznych w następstwie działania urazu mechanicznego przedstawia rysunek 2.8. Spośród istniejących urazów spowodowanych narzędziem tępym, podbiegnięcia krwawe i otarcia naskórka są najistotniejszymi w ujawnianiu mechanizmu sprawczego (przyczyny ich powstania) (Eze & Ojifinni, 2022; Spitz & Spitz, 2006).



Rysunek 2.8. Klasyfikacja obrażeń z uwzględnieniem specyfiki wykorzystanego narzędzia (źródło: opracowanie własne)


2.2.1. Podbiegnięcia krwawe

Podbiegnięcia krwawe (ang. *bruises*) to wylew krwi do tkanek podskórnych w wyniku uderzenia lub ściśnięcia co powoduje miażdżenie tkanek miękkich i rozrywanie naczyń krwionośnych jednak bez naruszania skóry. Rozległość i intensywność wynaczyniania uzależniona jest nie tylko od zastosowanej siły, ale także od struktury i unaczynienia stłuczonej tkanki. W rezultacie urazy są bardziej prawdopodobne w obszarach o cienkiej, luźnej skórze i na obszarach występowania większej ilości tkanki tłuszczowej (DiMaio & Molina, 2021). W niektórych przypadkach pewne skupiska podbiegnięć odzwierciedlają kształt narzędzia wskutek którego wystąpiły, przykładowo (Knudsen i in., 2014; Teresiński, 2019; Thavarajah i in., 2012):

- ofiara uderzona płaskim przedmiotem, takim jak deska, często może posiadać równoległe, liniowe podbiegnięcia odpowiadające krawędziom deski, z normalnie wyglądającą tkanką pomiędzy nimi;
- skupisko niewielkich, mierzących około 1-2 cm, okrągłych bądź dyskoidalnych podbiegnięć może odpowiadać:
 - urazowi zadnemu opuszkami palców w okolicznościach związanych z bójką, szarpaniną, próbą obezwładnienia;
 - występujące na przyśrodkowych powierzchniach ramion, przedramionach i nadgarstkach mogą sugerować na próbę przemieszczenia osób o ograniczonej świadomości lub zdolności ruchowej, w tym dzieci lub osób starszych;
 - występujące na udach i pośladkach mogą sugerować charakter przestępstwa o podłożu seksualnym.

Podczas wykonywania sądowo-lekarskich zewnętrznych oględzin zwłok lekarz powinien określić czas powstania podbiegnięcia. Takie informacje mogą być niezwykle istotne w dochodzeniach związanych z takimi przestępstwami jak znęcanie się nad dziećmi, przemoc domowa czy zabójstwo. Oszacowanie czasu jest bezpośrednio związane z dokładnym opisem dotyczącym samego koloru (rysunek 2.9). Jednak z uwagi na fakt, że ocena barwy odbywa się wizualnie, jest ona bardzo subiektywna, a tym samym jej dokładność pozostawia pewne wątpliwości. Badania pokazują, że istnieje bardzo niska dokładność w klasyfikowaniu podbiegnięć według czasu ich powstania (Nuzzolese & Di Vella, 2012). Do przykładowych badań prowadzonych w zakresie określenia czasu powstania podbiegnięcia, zaliczamy takie metody jak:

- wykorzystanie kolorymetrii tristimulusowej (ang. *tristimulus colourimetric*) (K. N. Scafide i in., 2016; K. R. N. Scafide i in., 2013; Thavarajah i in., 2012);
- zastosowanie miernika bilirubiny (ang. *bilirubin meter*) (Mesli i in., 2019);
- alternatywne źródło światła w zakresie widzialnym i ultrafioletowym (K. N. Scafide i in., 2020);
- spektroskopia odbicia rozproszonego (DRS) (ang. *diffuse reflectance spectroscopy*) (Kim i in., 2012; Randeberg i in., 2006);
- fotografia cyfrowa (Black i in., 2019; Tirado & Mauricio, 2021).




Rysunek 2.9. Skala określania czasu powstania podbiegnięcia krwawego w zależności od jego barwy [liczone w dniach] (źródło: (a) opracowanie własne, (b) (Chang, 2024))

2.2.1.1. Plama opadowa

Omawiając podbiegnięcia krwawe należy również wspomnieć o plamach opadowych (ang. *livor mortis, lividity*), które zdarza się, że mylone są z podbiegnięciami. Plamy opadowe stanowią jedno z wczesnych znamion śmierci pojawiających się w ciągu 12 godzin po ustaniu funkcji życiowych tj. krążenia i oddychania. Poza stężeniem pośmiertnym, oziębieniem zwłok, błądnością pośmiertną i wysychaniem pośmiertnym; plamy opadowe i stężenie pośmiertne

uznawane są za najważniejsze i określane jako definitywne oznaki śmierci. Typowe plamy opadowe przybierają zabarwienie siniofioletowe (rysunek 2.10), a powodem ich występowania jest przemieszczanie się krwi pod wpływem działania siły grawitacji do naczyń żylnych i włosowatych znajdujących się w miejscach najniżej położonych. Oznacza to, że ich lokalizacja uzależniona jest od pozycji w jakiej nastąpił zgon. Należy zaznaczyć, że plama opadowa nie pojawia się w miejscu uciśniętym. Takie zjawisko obserwuje się w przypadku obszarów ciała, które przylegały do powierzchni styku (np. pośladki czy górna część pleców: w przypadku zgonu w pozycji *supine*) i miejsc uciskanych przez części garderoby (np. gumki od bielizny) (Teresiński, 2019).



Rysunek 2.10. Przedstawienie charakterystyki plamy opadowej wraz z zestawieniem miejsca styku ciała z podłożem (źródło: opracowanie własne)

Z uwagi na charakter zabarwienia, plamy opadowe mogą być mylone z podbiegnięciami krwawymi, szczególnie przez lekarza z mniejszym doświadczeniem. Pomocne w ich rozróżnianiu jest stosowanie metody nacisku w efekcie którego obszar plamy opadowej chwilowo zblednie. Inną z metod jest nacięcie skóry, czego skutkiem będzie widoczna plama opadowa na tle żółtawej i bladoróżowej tkanki podskórnej, która po ściśnięciu będzie broczyć krwią. W przypadku nacięcia podbiegnięcia krwawego będzie ono zauważalne jako jednolite, ciemnoczerwone i ograniczone zabarwienie w tkance podskórnej (DiMaio & Molina, 2021; Teresiński, 2019).

Intensywność zabarwienia plamy opadowej poza sugerowaniem stopnia ukrwienia ciała i narządów może także wskazywać na rodzaj zgonu (Teresiński, 2019):

- śmierć powolna (poprzedzona agonią i rozciągnięta w czasie, mogąca trwać nawet do kilku dni) – skąpe plamy;

- śmierć nagła (zgon następuje w krótkim czasie, po kilku sekundach lub minutach) – od średnioobfitych plam (przy ostrych i szybko przebiegających krwotokach) do obfitych i silnie wysyconych.

2.2.2. Otarcia naskórka

Otarcia naskórka (ang. *abrasions*) pojawiają się w wyniku urazu, kiedy działające na ciało narzędzie ociera skórę z warstwy zrogowaciałej, tym samym obnażając brodawki skóry właściwej. Tak powstałe otarcie zaczyna pokrywać warstwa czerwono-brunatnego lub miodowożółtawego strupa. W zależności od głębokości otarcia naskórka zauważa się występowanie niewielkich krwawień i nalotu surowiczokrwistego. Wielkość otarcia przyjmuje różne formy, od niewielkich do pokrywających znaczne obszary ciała. Natomiast kształt w dużej mierze uzależniony jest od użytego narzędzia oraz kąta jego oddziaływania (rysunek 2.11). Występowanie reliefu (rysunek 2.12) czyli tzw. zwałczkowania w przypadku przebiegu liniowych lub smugowatych otarć naskórka sugeruje kierunek przemieszczania się ciała w przypadku wleczenia lub odrzutu. Szczególnie, zauważalne jest to w przypadku wypadków komunikacyjnych lub wskutek tarcia powstałego w efekcie krępowania ciała (Teresiński, 2019).



Rysunek 2.11. Przykłady rodzajów otarć naskórka (źródło: (a) (Teresiński, 2019), (b-e) zasoby własne))



Rysunek 2.12. Przykład reliefu tzw. zwałeczkowania otarcia naskórka (źródło: zasoby własne)

2.3. Stosowane metody wymiarowania obrażeń

W treści sporządzanego sprawozdania z lekarsko-sądowych oględzin zewnętrznych zwłok, pomiar wielkości obrażenia i określenie jego pozycji na ciele uzależniony jest od standardów przyjętych w danej instytucji. Ponadto, w przeważającej ich liczbie sprawozdanie uzupełniane jest przez dokumentację fotograficzną i schemat sylwetkowy, które mogą wspomóc w ustaleniu pozycji czy wielkości obrażenia na późniejszym etapie postępowania (Sieberth i in., 2020). Przyjmuje się, że określenie wielkości obrażenia ustalane jest przy wykorzystaniu linijki lub suwmiarki i powinno zostać podane w centymetrach lub milimetrach. Dla niektórych osób, pomiary podane w jednostkach imperialnych mogą być łatwiejsze do zrozumienia, dlatego dopuszcza się również podanie równoważnego rozmiaru rany w calach. Zwykle, obrażenia posiadają również pewną głębokość, jednak często nie jest możliwe dokładne jej określenie (szczególnie w przypadku płytszych ran) (Payne-James i in., 2005). Istotnym przy zapisie wymiarów ujawnionego obrażenia jest precyzja jego pomiaru. Jednakże, z punktu widzenia powszechnego wykorzystywania tradycyjnych metod pomiarowych, należałoby również wskazać ich wady. Zaliczyć do nich można m.in. (Haghpanah i in., 2006; Rogers i in., 2010; Shamata & Thompson, 2018a):

- subiektywność pomiaru w np. określaniu największej osi obrażenia (zwłaszcza w przypadku obrażeń o nieregularnym kształcie);
- rutynowe szacowanie powierzchni obrażenia, gdzie pomiar dokonywany jest poprzez pomnożenie dwóch wymiarów (najdłuższa długość x największa szerokość y). W ten sposób przyjmuje się założenie, że kształt obrażenia jest prostokątny lub kwadratowy, co zawiąza rzeczywistą powierzchnię rany o 10% do 44%;

- niepewna dokładność, zwłaszcza w przypadku obrażeń o większych rozmiarach i nieregularnym kształcie;
- metoda inwazyjna (jako że wymaga bezpośredniego kontaktu z ciałem).

Pomimo przewagi wykorzystania tradycyjnych metod, niektóre ośrodki coraz częściej sięgają po nowocześniejsze technologie. W literaturze zauważa się wzrost znaczenia wykorzystania radiologicznych technik obrazowania czy fotogrametrii dla celów medycyny sądowej lub nawet integracji różnych metod (więcej w rozdziale: 3. *Pośmiertne kryminalistyczne metody obrazowania 3D*).

2.4. Podsumowanie

W tym rozdziale omówiono istotę przeprowadzania sądowo-lekarskich oględzin zewnętrznych zwłok podkreślając ich znaczenie w kontekście badań czy w zdarzeniu mogła brać udział osoba trzecia. Wskazano, że dokładne i rzetelne dokumentowanie obrażeń na powłokach ciała jest niezbędne dla poprawnego przebiegu procesu dochodzeniowego i sądowego. Dodatkowo, zawarta informacja o ujawnionych obrażeniach (ich wielkość, położenie, barwa czy cechy charakterystyczne) powinna być zrozumiała i możliwa do odtworzenia nawet do kilku lat po zamknięciu sprawy. Zwrócono również uwagę na sposób sporządzania sprawozdania przez lekarza medycyny sądowej z podkreśleniem możliwości uzupełnienia pisemnej części przez dokumentację fotograficzną i schemat sylwetkowy. W kolejnych podrozdziałach omówiono typy występujących obrażeń wraz ze wskazaniem mechanizmów ich powstawania. Szczególny nacisk zwrócono na podbiegnięcia krwawe i otarcia naskórka jako obrażenia możliwie najczęściej wskazujące udział osób trzecich w zdarzeniu. Kolejnym istotnym punktem omawianym w tym rozdziale były metody wymiarowania obrażeń, gdzie wyjaśniono, że dokładne określenie rozmiaru obrażenia jest kluczowe dla przeprowadzenia właściwej analizy i zrozumienia ich powstania.

Należy podkreślić, że omówione w tym rozdziale zagadnienia są kluczowe dla pracy lekarzy medycyny sądowej i wpływają na postępowanie prowadzone przez organ ścigania, a następnie wymiar sprawiedliwości. Dokładność, precyzja i rzetelność w procesie sądowo-lekarskich oględzin zewnętrznych zwłok oraz sporządzania sprawozdania jest niezbędne dla postawienia odpowiednich wniosków w przypadkach, gdy ciało ofiary stanowi główne źródło informacji.

3. Pośmiertne kryminalistyczne metody obrazowania 3D

Standardowa procedura dokumentacji obrażeń podczas przeprowadzania sądowo-lekarskich zewnętrznych oględzin zwłok obejmuje opis słowny, pomiary ręczne, szkice na schematach sylwetkowych i dokumentację fotograficzną (więcej w rozdziałach: *2.1. Sprawozdanie z sądowo-lekarskich oględzin zwłok*, *2.1.1. Dokumentacja obrażeń występujących na powłokach ciała*). Ograniczając dokumentację jedynie do tych elementów, można stwierdzić, że informacje o geometrii obrażenia nie są prawidłowo rejestrowane, gdyż w rzeczywistości pomiary liniowe i zdjęcia redukują ranę 3D do przestrzeni 2D (Villa, 2017).

Wewnętrzne i zewnętrzne obrazowanie ciała w przestrzeni 3D stworzyło możliwość rejestracji sądowych ustaleń patologicznych w sposób precyzyjny i mało inwazyjny, jednocześnie tworząc trwałe zbiory danych z dostępem w każdym miejscu i czasie. Jako najważniejsze techniki obrazowania kryminalistycznego wyróżnić można wykorzystywanie sensorów takich jak:

- radiologiczne techniki obrazowania medycznego:
 - tomografia komputerowa (CT);
 - rezonans magnetyczny (MRI);
 - rentgenodiagnostyka (RTG);
- klasyczna fotografia, w tym fotogrametria;
- skanery powierzchniowe;
- integracja wykorzystania różnych sensorów.

Wykorzystanie obrazowania 3D w medycynie sądowej ma na celu utworzenie dokumentacji w postaci modelu 3D całego ciała. Z pomocą technik tomografii komputerowej (CT), rezonansu magnetycznego (MR) czy rentgenodiagnostyki (RTG) można tworzyć modele 3D zarówno struktur wewnętrznych jak i zewnętrznych, co z powodzeniem stosowane jest już w kilku instytutach medycyny sądowej na całym świecie (Hayakawa i in., 2006; Leth, 2007; Villa i in., 2018). Jednakże rozdzielczość technik radiologicznych nie jest wystarczająca do dokładnej dokumentacji obrażeń widocznych na powłokach, a co istotne nie są pozyskiwane informacje o ich barwie (Villa, 2017). Prawidłowy zapis obrażeń można jednak uzyskać za pomocą skanerów powierzchniowych wykorzystujących światło strukturalne (Thali i in., 2003; Villa i in., 2018) lub fotogrametrię (Flies i in., 2019; Thali i in., 2000; Urbanová i in., 2015). Należy jednak zwrócić uwagę, że ograniczeniem skanowania powierzchni 3D jest niedostateczne pozyskanie informacji o kolorze, dlatego w tym celu stosuje się połączenie obu tych technik,

jako że kolorową teksturę można wygenerować na podstawie informacji przetworzonych przy użyciu fotogrametrii (Grabherr i in., 2016).

W ciągu ostatnich kilku lat istotną popularność w dziedzinie patologii sądowej uzyskał termin „wirtualna sekcja zwłok” (ang. *virtual autopsy*) tzw. VIRTOPSY (Wan i in., 2020). Początkowo stosowano oddzielną procedurę tworzenia wewnętrznej i zewnętrznej dokumentacji 3D całego ciała, jednak z czasem dane pozyskane z radiologicznych technik obrazowania zaczęto łączyć z danymi pozyskiwanymi za pomocą fotogrametrii i skanowania światłem strukturalnym (Kottner et al., 2017). Integracja tych sensorów umożliwiła uzyskanie bardzo szczegółowych i precyzyjnych danych, a ich przydatność w postępowaniach sądowo-karnych została wyraźnie wykazana (Buck i in., 2007, 2013). Jednakże pomimo uzyskania satysfakcjonujących wyników, procedura ta jeszcze nie odnalazła szerszego zastosowania w instytutach medycyny sądowej. Główną przyczyną jest konieczność przeprowadzenia pomiarów fotogrametrycznych i skanowania powierzchni tuż przed lub po wykonaniu skanowania CT. Jest to proces pracochłonny oraz wymaga posiadania odpowiedniego sprzętu i przestrzeni, czym niestety nie wszystkie jednostki dysponują. Większość instytutów medycyny sądowej nie posiada własnego tomografu komputerowego i polega na urządzeniach w szpitalach. Oznacza to, że ofiary są często skanowane w workach na zwłoki przed zdjęciem odzieży i oczyszczeniem ciała. Dla uzyskania poprawnych wyników należy odpowiednio przygotować zwłoki tj. odzież i wszelkie inne przedmioty powinny zostać usunięte, ciało należy dokładnie oczyścić i jeśli to konieczne ogolić (włosy stanowią znaczne utrudnienie dla skanerów powierzchniowych)⁶, następnie punkty osnowy fotogrametrycznej należy umieścić na ciele i wokół niego, ze szczególnym uwzględnieniem okolic obrażeń (Ebert i in., 2014, 2016). Co istotne i najważniejsze, ciało powinno znajdować się w tej samej pozycji w której wykonywano pomiar CT w szpitalu, a to z uwagi na konieczność transportu ciała do instytutu medycyny sądowej, jest niemożliwe.

3.1. Radiologiczne techniki obrazowania medycznego

Zastosowanie pośmiertnej diagnostyki obrazowej w postaci tomografii komputerowej i rzadziej, rezonansu magnetycznego oraz rentgenodiagnostyki umożliwia nieinwazyjną

⁶ Autorka niniejszej rozprawy doktorskiej podkreśla, że konieczność usunięcia owłosienia występuje jedynie w przypadkach ran zlokalizowanych na głowie pokrytej gęstymi i długimi włosami, które utrudniają ich właściwą obserwację. Natomiast w sytuacjach, gdy owłosienie jest krótkie (na przykład u mężczyzn z krótko ostrzyżonymi włosami) lub w przypadku owłosienia na nogach, nie ma potrzeby golenia, ponieważ skanery umożliwiają uzyskanie wyników przydatnych do dalszych analiz.

identyfikację przyczyny śmierci. Ta metoda jest szczególnie pomocna w przypadkach, kiedy lekarz medycyny sądowej nie ma dostępu do historii medycznej ofiary. Ponadto obrazowanie radiologiczne umożliwia patologom sądowym wgląd do obszarów ciała, które nie są rutynowo poddawane standardowej wewnętrznej sekcji zwłok (głowy, szyi i klatki piersiowej oraz jamy brzusznej) (Offiah & Dean, 2016).

Interpretacja obrazowa post-mortem tomografii komputerowej i rezonansu magnetycznego bardzo różni się od tej wykonywanej ante-mortem. Istnieje szereg zmian w tkankach, które występują pośmiertnie i mają znaczący wpływ na wygląd danych z CT i MRI. Przykładem może być efekt sedymentacji w naczyniach lub hipostazie płuc (tzw. wewnętrzny *livor mortis*), czasami zaciemniającej odczyt obrazu i występującej z uwagi na brak krążenia. Doświadczenie w zakresie rozpoznania tych zmian ma kluczowe znaczenie dla uniknięcia błędnej interpretacji. Podobnie, skutki przeprowadzenia resuscytacji krążeniowo-oddechowej mogą powodować szereg zmian, które mogą być widoczne w późniejszym obrazowaniu pośmiertnym i nie powinny zostać błędnie zinterpretowane jako patologiczne. W przeciwieństwie do obrazowania radiologicznego ante-mortem, obrazowanie pośmiertne jest w pełni bezpieczne i daje możliwość swobodnego doboru parametrów maksymalizując jakość uzyskanych danych bez czynnika zagrażającego pacjentowi (Flach i in., 2014).

W zależności od instytucji i kraju, przeprowadzanie obrazowania post-mortem różni się. W części zakładów medycyny sądowej stosowanie CT traktowane jest jako badanie podstawowe i wykonuje się je niezależnie od innych czynności. Natomiast obrazowanie MRI czy RTG traktowane jest jako uzupełniające, które wykonuje się w porozumieniu między radiologiem a patologiem sądowym w oparciu o wyniki diagnozy wstępnej z CT, wyniki sądowo-lekarskich oględzin zewnętrznych zwłok i historii zmarłego (Flach i in., 2014). Inna grupa instytucji wykorzystuje CT jako preselekcję przypadków z wystąpieniem potencjalnie nienaturalnych przyczyn śmierci tym samym zmniejszając liczbę codziennych sekcji zwłok (Rutty i in., 2008). Istnieją również pewne kręgi kulturowe i religijne, które sprzeciwiają się wykonywaniu wewnętrznej sekcji zwłok. W takich przypadkach wykorzystanie obrazowania radiologicznego jako potencjalnego substytutu jest nowym podejściem do przezwyciężenia tych problemów (Takahashi i in., 2012).

3.2. Klasyczna fotografia z elementami fotogrametrii

W medycynie sądowej dokumentacja fotograficzna stanowi uzupełnienie sprawozdania z sądowo-lekarskich oględzin zewnętrznych zwłok. Ma na celu zachowanie wartości dowodowej obrazów i umożliwia ich odtworzenie w późniejszym czasie.

Najczęściej dokumentację fotograficzną sporządza lekarz lub rezydent patologii sądowej (Giorgetti i in., 2023; Oliver, 2011). Do tego celu zwykle stosowane są aparaty cyfrowe. Wraz z postępem w rozwoju fotografii, istnieje szeroka gama dostępnych produktów, które oferują stosunkowo dobrą jakość za relatywnie niską cenę. Nawet niektóre telefony komórkowe są w stanie dobrze zobrazować obraz, należy jednak zaznaczyć, że ich wykorzystanie nie powinno mieć miejsca w przypadku tworzenia dokumentacji medycznej. Podstawowym czynnikiem jest jakość otrzymanych danych, ale również, co istotne, mogą wystąpić problemy z ochroną danych zawartych na takich nośnikach (Ozkalipci & Volpellier, 2010; Verhoff i in., 2012).

W fotodokumentacji kryminalistycznej najważniejsze jest dokładne i rzeczywiste dokumentowanie obrazów. Jednak wciąż występuje wiele problemów z akwizycją tego rodzaju danych przez co często jakość pozyskanego obrazu jest niewystarczająca. Najczęściej występujące błędy to (Verhoff i in., 2012):

- brak ostrości;
- przeświecenie lub niedoświecenie obrazu;
- słabe (przekłamane) odwzorowanie kolorów;
- szumy.

Podczas sporządzania dokumentacji fotograficznej, istotnym jest odwzorowanie odpowiedniej skali i barwy poprzez wykonanie zdjęcia z np. linijką policyjną oraz próbnikiem kolorów. Jednakże akceptowalne jest także zastosowanie linijek kątowych, standardowych linijek, taśm mierniczych, a także, w wyjątkowych okolicznościach, przedmiotów o znanych wymiarach, takich jak moneta lub zapalka. Wykorzystany element pomiarowy i dokumentowane obrazy powinny znajdować się w tej samej płaszczyźnie jak najbardziej prostopadłej do osi optycznej. W ten sposób możliwe będzie określenie rozmiaru obrazu. Ponadto, przydatne jest wykonanie serii zdjęć, zaczynając od zdjęcia ogólnego-podglądowego, a następnie skupiając się na szczegółach, co umożliwi nie tylko dokładne odwzorowanie, ale też pozwoli na wskazanie lokalizacji anatomicznej (Verhoff i in., 2012).

W medycynie sądowej najpowszechniejszym standardem dokumentowania obrazów jest fotografia. Techniczne cechy zdjęcia, takie jak ortogonalność, głębia i ostrość pożądanego


obszaru, mają kluczowe znaczenie dla uzyskania prawidłowego pomiaru. Niemniej jednak na obrazie 2D zawsze będzie pewna utrata informacji podczas próby wizualizacji geometrii obrażenia. W ostatnich latach do tego celu zaczęto coraz częściej wykorzystywać fotogrametrię bliskiego zasięgu (Koller i in., 2019). W medycynie sądowej procedura fotogrametryczna wykonywana jest manualnie lub za pomocą systemów wielokamerowych (Leipner i in., 2016). Fotogrametria wykorzystywana do tworzenia dokumentacji 3D i różnego rodzaju analiz zdążyła już ugruntować swoją pozycję jako cenne narzędzie w kontekście postępowania dochodzeniowego w takich przypadkach jak (Flies i in., 2019):

- dopasowanie narzędzia do obrażeń na ciele ofiary (dwa praktyczne przykłady omówiono w dalszej części tego rozdziału);
- tworzenie dokumentacji 3D⁷;
- przeprowadzenie pomiarów na fotogrametrycznym modelu 3D jako możliwość zastąpienia rzeczywistych pomiarów obrażeń dokonywanych podczas sądowo-lekarskich oględzin zewnętrznych zwłok⁸.

Interesujący przykład wykorzystania fotogrametrii w medycynie sądowej przedstawia opracowanie Thali M. (Thali i in., 2000), który podjął próbę dokumentacji obrażeń istotnych z punktu widzenia rekonstrukcji przebiegu zdarzenia. Wykorzystując fotogrametrię wspomaganą systemami CAD autor zwizualizował uraz tkanek miękkich twarzy spowodowanych przejechaniem przez oponę samochodową. W badanym przypadku ofiarą zdarzenia było dziecko, które podczas zabawy nagle i niespodziewanie wyskoczyło na ruchliwą ulicę. W efekcie dziewczynka została śmiertelnie potrącona przez samochód. Na skórze lewej strony twarzy znajdowały się podbiegnięcia krwawe o nietypowym wzorze oraz otarcia naskórka. Celem dochodzenia było ustalenie czy ślady na twarzy dziecka rzeczywiście pochodziły od jednej z opon pojazdu (rysunek 3.1), a jeśli tak, to z którego kierunku dziewczynka wybiegła na ulicę kiedy została potrącona. Badane obiekty (uraz na powierzchni anatomicznej ofiary i powierzchnia opony samochodu) zostały przetworzone w systemie RolleiMetric gdzie wygenerowano model 3D tych obiektów. Następnie korzystając z oprogramowania CAD, model 3D urazu porównywano z modelem potencjalnego narzędzia (powierzchnią opony) mogącego spowodować to obrażenie.


⁷ W ramach prac nad niniejszą rozprawą doktorską autorka opracowała metodykę tworzenia cyfrowej dokumentacji 3D ciała człowieka (rozdział 8. *Automatyczne modelowanie w procesie tworzenia cyfrowej dokumentacji medycznej 3D sylwetki człowieka – CZĘŚĆ II badań*).

⁸ W ramach prac nad niniejszą rozprawą doktorską autorka przeprowadziła analizy geometrycznej obrażenia (rozdział 11.3.2. *Obliczenie odległości rzeczywistej obrażenia z wykorzystaniem grafów ważonych* oraz rozdział 11.3.3. *Metodyka analizy ilościowej obrażenia z wykorzystaniem PCA i interpolacji cubic spline w przestrzeni 3D*).



Rysunek 3.1. Dokumentacja fotograficzna przypadku wykorzystania fotogrametrii w medycynie sądowej: a) charakterystyczny wzór obrażeń (podbiegnięć krwawych i otarć naskórka) na twarzy ofiary, umożliwiający analizę ich pochodzenia, b) bieżnik opony pojazdu biorącego udział w zdarzeniu, służący do porównania i ustalenia zgodności wzoru obrażeń z oponą pojazdu (źródło: (Thali i in., 2000))

Przeprowadzone analizy wykazały jednoznaczne dopasowanie między licznymi podbiegnięciami krwawymi a bieżnikiem profilu opony i dowiodły, że opona pojazdu powypadkowego przejechała po głowie ofiary i to w kierunku niemal podłużnym (rysunek 3.2).




Rysunek 3.2. Przedstawienie wyników analizy dopasowania obrażeń do wzoru bieżnika opony w omawianym przypadku: a) widok z boku na model 3D twarzy ofiary oraz bieżnika opony, wskazujący na ich wzajemne relacje, b) widok od strony czaszki na model 3D, podkreślający szczegóły dopasowania, c) wizualizacja dopasowania licznych podbiegnięć krwawych na twarzy ofiary do wzoru bieżnika opony, potwierdzająca, że opona pojazdu powypadkowego przejechała po głowie ofiary w niemal podłużnym (źródło: (Thali et al., 2000))

Nieco bardziej bieżącym przykładem zastosowania fotogrametrii jest opracowanie Kreul D. (Kreul i in., 2019) ukazujące dopasowanie obrażenia z narzędziem, gdy w procesie urazu doszło

do deformacji przedmiotu/broni i tkanek ofiary, powodując dynamiczny, a nie sztywny transfer kształtu. W omawianym przypadku podczas kłótni z elementami przemocy fizycznej, mężczyzna został uderzony szczotką do włosów po lewej stronie czoła. W efekcie powstały symetryczne, zgrupowane, małe, okrągłe otarcia naskórka z których niektóre zawierały ciemny, zaschnięty wysięk. Wyglądały one na ułożone w regularny geometryczny wzór. Mniej głębokie lub bardziej powierzchowne były liczne czerwone, prążkowane przebarwienia skóry, bezpośrednio przylegające lub połączone z punktowymi, głębszymi zmianami (rysunek 3.3). W omawianym przykładzie, dopasowanie 3D szczotki do włosów z zestawieniem punktowych i wydłużonych prążkowanych otarć naskórka czoła dało częściowe, ale nieidealne dopasowanie (rysunek 3.4). Jakościowa ocena medyczno-prawna uzyskanego wyniku dopasowania wyraźnie wskazywała na odkształcenie włosa szczotki po uderzeniu, wskazujące na odśrodkowy wzór pocierania, a tym samym dynamicznie przemieszczanie się początkowo stałego otarcia punktowego aż do okrągłego kształtu końcówki włosa. Dodatkowo zostało to potwierdzone zarówno przez elastyczność włosa, jak i pęknięcie ramy szczotki, której obecność i lokalizacja wskazywały na zastosowanie stosunkowo dużej siły. Omawiany przypadek ukazuje, w jaki sposób zastosowanie ukierunkowanej interpretacji w dziedzinie medycyny sądowej może wyjaśnić to, co od strony inżynieryjnej jest tylko częściowym dopasowaniem 3D.



Rysunek 3.3. Otarcia naskórka po lewej stronie czoła, powstałe w wyniku uderzenia szczotką do włosów. Obrażenie zawiera regularnie rozmieszczone i ułożone punktowe, otarte, okrągłe zmiany. Mniej głębokie lub bardziej powierzchowne są liczne czerwone, prążkowane przebarwienia skóry, bezpośrednio przylegające lub połączone z punktowymi, głębszymi zmianami: a) dokumentacja fotograficzna, b) model 3D obrażeń, c) model 3D narzędzia sprawczego ze wskazanym pęknięciem (źródło: (Kreul i in., 2019))




Rysunek 3.4. Przedstawienie graficzne obrażenia skóry z nałożonymi elementami narzędzia (końcówek włosia szczotki): a) nałożone włosie (beżowe punkty) pasuje do lokalizacji głębszych i ciemniejszych punktowych otarć, b) przerywane kontury podkreślają otarcia skóry, c) wyraźne ukazanie wzoru odśrodkowego, które zostało dodatkowo podkreślone i zilustrowane dodanymi strzałkami (źródło: (Kreul i in., 2019))

3.3. Skanery powierzchniowe

Nieinwazyjne skanery powierzchniowe 3D odnalazły zastosowanie również w medycynie sądowej, zwłaszcza w kontekście dokumentacji i analizy obrażeń ciała. Technologia ta umożliwia precyzyjne odwzorowanie kształtu i struktury powierzchni ciała ofiary bez konieczności bezpośredniego kontaktu. Skanery 3D działają w oparciu o projekcje światła laserowego o pojedynczej długości fali, która może przybierać formę plamki, pojedynczej linii lub serii równoległych linii na powierzchni obiektu. Wiązka lasera ulega deformacji w kontakcie z kształtem obiektu i odbija się od powierzchni w określonej pozycji, co pozwala na precyzyjne zarejestrowanie topografii badanego obszaru (D'Apuzzo & Gruen, 2009). Zastosowanie odnajduje również technika skanowania 3D w świetle strukturalnym, która działa na zasadzie projekcji zaprojektowanych wzorów strukturalnych ze strategią kodowania. Wzory te są rzutowane na powierzchnię obiektu, a następnie analizowane pod kątem deformacji wynikających z topologii skanowanego obrazienia. Analiza tych deformacji pozwala na odtworzenie trójwymiarowego modelu badanego obiektu. W praktyce skanowania powierzchni ciała ludzkiego stwarza pewne wyzwania. Owłosione, mokre czy bardzo ciemne obszary są niekiedy trudne do zarejestrowania za pomocą niektórych skanerów powierzchniowych. Włosy mogą powodować zakłócenia w projekcji światła, prowadząc do artefaktów w danych skanowania. Podobnie, mokre powierzchnie mogą odbijać światło w sposób nieprzewidywalny, a ciemne obszary mogą pochłaniać zbyt dużo światła, co utrudnia ich detekcję przez sensory skanera (Shamata & Thompson, 2018b).

Badania przeprowadzane przez Buck U. (Buck i in., 2018) wskazują różnice w wykorzystaniu dwóch komercyjnych systemów pomiarowych do rejestracji 3D ciała ofiary, obrażenia i potencjalnego narzędzia (w tym przypadku podeszwy buta). W opracowaniu wykorzystano skaner z projekcją światła strukturalnego TRITOP/ATOS (GOM, Braunschweig, Niemcy) oraz skaner ręczny Go!Scan 50 (Creaform/Ametek, Québec, Kanada). Jak twierdzą autorzy, wybrane skanery wielokrotnie udowodniły swoją skuteczność działania w zastosowaniach medycyny sądowej i obecnie stanowią najpowszechniej stosowane systemy. System ATOS pozyskuje najwyższą rozdzielczość modelu powierzchni 3D. Skaner działa w oparciu o światło strukturalne i składa się z projektora umieszczonego pośrodku oraz dwóch kamer cyfrowych po lewej i prawej stronie, z których każda została wyposażona w czujnik CCD o rozdzielczości 4 milionów pikseli. Projektor wyświetla na powierzchni wzór strukturalny, podczas gdy dwie kamery rejestrują obraz. Ponieważ znana jest odległość między dwoma kamerami i kąt między nimi, oprogramowanie oblicza współrzędne 3D punktów pikseli każdego czujnika, stosując metodę triangulacji. W każdym skanie określanych jest do 4 milionów punktów powierzchni 3D. Dzięki niekodowanym punktom osnowy poszczególne skany są automatycznie łączone w jeden zbiór danych. Minusem zastosowania ATOS jest brak pozyskania informacji o kolorze tekstury. CREAFORM Go!Scan 50 podobnie do ATOSu również wykorzystuje światło strukturalne. Skaner emituje wzór białego światła przypominający kod QR, podczas gdy dwie kamery obserwują zniekształcenie wzoru na skanowanym obiekcie. Trzecia kamera rejestruje informacje o kolorze obliczonych punktów 3D. Skaner pracuje z szybkością 550 000 pomiarów na sekundę i skanuje obszar 380×380 mm z rozdzielczością 0,5 mm i dokładnością punktową do 0,1 mm. Powierzchnia jest rejestrowana podczas przesuwania skanera ręcznego nad obiektem. Różnice w dokładności pomiędzy wysokorozdzielczym skanerem ATOS a skanerem ręcznym Go!Scan 50 zostały zilustrowane na rysunku 3.5. W praktyce oznacza to, że wybór odpowiedniego systemu skanowania powinien być podyktowany specyficznymi wymaganiami danego przypadku. Jeśli kluczowa jest najwyższa możliwa dokładność i szczegółowość modelu, np. w przypadku analizy drobnych śladów narzędzia na ciele ofiary, system ATOS może być preferowanym wyborem. Natomiast w sytuacjach, gdzie ważna jest szybkość działania i możliwość rejestrowania informacji o kolorze, np. w dokumentacji rozległych obrażeń z widocznymi zmianami barwnymi, skaner Go!Scan 50 może okazać się bardziej odpowiedni.




Rysunek 3.5. Przedstawienie i Porównanie systemów skanowania powierzchniowego oraz ich wyników: a) zasada działania systemu ATOS opartego na projekcji światła strukturalnego oraz skanera ręcznego Go!Scan 50, b) model 3D fragmentu podeszwy buta uzyskany przy użyciu obu systemów, c) model powierzchniowy ciała ofiary z uwzględnieniem szczegółowego obrazu pleców, ilustrujący różnice w dokładności pomiędzy analizowanymi systemami (źródło: (Buck i in., 2018))

3.4. Zintegrowane metody obrazowania 3D


Omawiane we wcześniejszych rozdziałach metody obrazowań kryminalistycznych są coraz częściej wykorzystywane w badaniach z zakresu medycyny sądowej w celu wzmocnienia dokumentacji obrazów (Thali i in., 2008). Metody radiologicznych obrazowań kryminalistycznych, dostarczają szczegółowych informacji na temat anatomii wewnętrznej,

urazów wewnętrznych czy występujących patologii ciała. Jednakże dla pełnej informacji sądowo-lekarskiej wymagana jest również cyfrowa dokumentacja topologii powierzchni ciała, która może być istotna do celów rekonstrukcyjnych. Metody radiologiczne nie mają dokładnej rozdzielczości umożliwiającej ocenę morfologii małych zmian powierzchniowych związanych z obrażeniami na powłokach skóry czy innymi widocznymi zmianami, niekoniecznie będącymi obrażeniami. Ponadto metody radiologiczne nie pozyskują informacji o kolorze tekstury, która może być istotna dla oceny stopnia ciężkości obrażenia lub rozróżnienia uderzenia stycznego, otarcia lub ortogonalnego (Campana i in., 2016; Ebert i in., 2016). Aby dodać te informacje o powierzchni ciała do danych cyfrowych w sposób umożliwiający pełną rekonstrukcję, konieczne są zatem inne techniki obrazowania, lepiej przystosowane do dokumentowania powierzchni skóry. Bardzo wysokiej jakości kolor tekstury można pozyskać technikami fotogrametrii, które jednak w porównaniu ze skanerami powierzchniowymi dają zdecydowanie niższą rozdzielczość. W niektórych przypadkach z zakresu medycyny sądowej taka rozdzielczość może być wystarczająca, ponieważ rzeczywiste odwzorowanie barwy obrażenia jest istotniejsze. Jednak, coraz częściej zauważa się wykorzystanie integracji omówionych metod. Zintegrowane obrazowanie pomimo wielu korzyści i coraz powszechniejszego zastosowania w medycynie sądowej wciąż posiada ograniczenie w postaci dostępności odpowiedniego oprogramowania i konieczności zastosowania różnych znaków kodowanych (Grabherr i in., 2017).

Przykładem integracji danych z trzech różnych sensorów, jest opracowanie Campana L. (Campana i in., 2016). Dane z tomografii komputerowej wykorzystano w celu wygenerowania modeli 3D powierzchni ciała i struktury kości ofiary. Dane pozyskane ze skanera powierzchniowego służą jako wysokiej rozdzielczości informacja o topologii powłok ciała, natomiast fotogrametria bliskiego zasięgu pozwala wstępnie zdefiniować punkty referencyjne wykorzystane do łączenia danych oraz uzyskać informacje o kolorze i teksturze (rysunek 3.6 i rysunek 3.7). Autorzy wykazali, że dokumentacja i wizualizacja trójwymiarowa zewnętrznych obrażeń poprzez integrację fotografii cyfrowej z zestawami danych CT/MRI jest odpowiednia do szczegółowej dokumentacji indywidualnych charakterystycznych obrażeń ciała. Niemniej jednak, ta metoda dokumentacji nie zastępuje w pełni fotogrametrii i skanowania powierzchniowego, zwłaszcza gdy wymagana jest rejestracja całej powierzchni ciała w trzech wymiarach, obejmująca wszystkie zewnętrzne obrażenia, oraz gdy niezbędne są precyzyjne dane do porównania wysoko szczegółowych cech obrażeń z narzędziem sprawczym.



Rysunek 3.6. Przykład integracji danych wewnętrznych i zewnętrznych: a) model 3D fragmentu nogi ofiary wygenerowany na podstawie danych CT, b) wizualizacja struktury kości (CT) oraz mięśni (MRI) w modelu 3D, c) zintegrowany model 3D z nałożoną kolorową teksturą uzyskaną z fotogrametrii, ilustrujący zewnętrzną topologię i charakterystykę powłok ciała (źródło: (Campana i in., 2016))



Rysunek 3.7. Dokumentacja obrażenia prawego podudzia z wykorzystaniem technik integracji danych: a) model 3D powierzchni urazu o wymiarach 91 mm × 17 mm wygenerowany na podstawie danych CT z nałożoną kolorową teksturą uzyskaną z fotogrametrii, b) model 3D urazu stworzony na podstawie danych ze skanowania powierzchniowego z nałożoną teksturą fotogrametryczną, umożliwiające porównanie metod i oceny szczegółowości wizualizacji (źródło: (Campana et al., 2016))

3.5. Podsumowanie

W tym rozdziale omówione zostały cztery metody obrazowania zmian pourazowych na powłokach ciała. Rozdział rozpoczął od wprowadzenia, w którym ponownie podkreślono znaczenie obrazów w procesie dochodzeniowym, jak również wskazano, że metody ich dokumentacji różnią się w zależności od instytutu, w którym są przeprowadzane. Następnie zauważano, że stosowanie wymienionych metod jest ograniczone do możliwości jakimi dysponuje dana instytucja, gdyż nie wszystkie ośrodki mogą pozwolić sobie na zakup odpowiedniej infrastruktury i/lub odpowiednie przeszkolenie pracowników.

Omówienie metod rozpoczęło od radiologicznych technik obrazowania medycznego. Wyjaśniono, że radiologia stanowi niezastąpione narzędzie w badaniu zwłok, pozwalając na obrazowanie struktur wewnętrznych ciała jednak z ograniczonymi możliwościami dla rejestracji powłok. Kolejną omawianą metodą była klasyczna fotografia z elementami fotogrametrii. Podkreślono znaczenie poprawnie wykonanej dokumentacji fotograficznej i jej wpływu na barwę i ostrość widocznego obrazu. Ponadto zauważono, że klasyczna fotografia pozwala jedynie na dokumentację informacji ograniczoną do przestrzeni 2D, natomiast zastosowanie fotogrametrii pozwala na zapis informacji w przestrzeni 3D, co może być pomocne przy analizie morfologicznej i morfometrycznej obrazu. Jako kolejną metodę obrazowania kryminalistycznego, wskazano skanery powierzchniowe pozwalające na tworzenie wysokiej rozdzielczości tekstury powierzchni ciała. Zauważono, że pomimo wysokiej jakości tekstury, odwzorowanie koloru jest nieporównywalnie gorsze w stosunku do fotogrametrii lub w niektórych przypadkach wręcz niemożliwie do pozyskania. W ostatniej części rozdziału przedstawiono zintegrowane metody obrazowania 3D. Zauważono, że możliwość wykorzystania danych pozyskanych różnymi sensorami znacznie podnosi wartość dokumentacji obrazu, jednak ograniczenie w postaci braku odpowiedniego oprogramowania zdecydowanie zmniejsza powszechność ich zastosowania.

4. Podstawy teoretyczne automatycznego modelowania 3D

Poza informacją jaką lekarz może odczytać z obrazów medycznych w przestrzeni 2D, należy zauważyć, że jednak większość zmian patologicznych i związanych z nimi parametrów możliwa jest do analizy jedynie w przestrzeni trójwymiarowej. Przestrzeń 3D posiada nie tylko potencjał dla lepszego określenia rzeczywistego procesu zmian patologicznych, jak również do stawiania odpowiednich diagnoz czy prognoz leczniczych. Z tego względu dokładna ekstrakcja informacji 3D ma fundamentalne znaczenie w większości sytuacji. Rozwój obecnych badań przyczynił się do transferu technologii między różnymi dyscyplinami i to właśnie synergia technologii z różnych dziedzin w ogromnym stopniu zmieniła diagnostykę medyczną i leczenie w ostatnich latach (Patias, 2002; Struck i in., 2019; Talevi i in., 2023). Ponadto, pod wieloma względami obecne wyzwania w obrazowaniu medycznym wykazują duże podobieństwo do problematyki fotogrametrycznej wskazując na duży potencjał ich rozwiązania. Fotogrametria (ang. *photogrammetry*) jako nauka i technologia pozwalająca na uzyskanie informacji przestrzennej o zarejestrowanym obiekcie na obrazie pozwala na odtworzenie kształtu, rozmiaru czy wzajemnego położenia obiektów z naciskiem na uzyskiwaną dokładność (Luhmann i in., 2023). W odróżnieniu od tradycyjnego manualnego modelowania 3D za pomocą oprogramowania CAD (ang. *Computer-Aided Design*) czy DCC (ang. *Digital Content Creation*), technologia ta wykorzystuje dane wejściowe z sensorów, takie jak zdjęcia (metoda pasywna) czy chmury punktów (metoda aktywna), automatyzując proces rekonstrukcji bez potrzeby manualnej interwencji (Remondino i in., 2017). Podstawowym zadaniem fotogrametrycznym jest identyfikacja i dopasowanie odpowiadających sobie cech na dwóch lub więcej obrazach (tzw. punktów homologicznych/wiązujących). Pomiar ten polega na wyborze punktu na jednym obrazie i odszukanie jego odpowiednika na pozostałych. Jednym z najwcześniejszych problemów w fotogrametrii i wciąż jednym z najczęściej badanych tematów jest dążenie do zautomatyzowania tego procesu (określanego również jako *automatic image matching*). Spośród różnych metod dopasowania istotnym jest wybór tej skutecznej. Zasadniczo w praktycznych zastosowaniach wyróżnić możemy dwa scenariusze (Luhmann i in., 2023):

- wybrane obrazy nie są jeszcze zorientowane, jednak orientacja wewnętrzna może zostać wyznaczona z wystarczającą dokładnością do dalszego przetwarzania;
- wybrane obrazy mają znaną orientację wewnętrzną i zewnętrzną kamery.

W przypadku pracy z obrazami medycznymi, najczęściej spotykany jest pierwszy z opisanych scenariuszy, który dotyczy głównie zestawu obrazów, które powinny zostać

automatycznie zorientowane. Proces ten zazwyczaj składa się z ekstrakcji cech na wszystkich obrazach, po której następuje dopasowanie oparte na cechach charakterystycznych. Operatory detekcji (tzw. detektory) stanowią więc pierwszy krok w procesie znajdowania cech.

4.1. Detektory wykrywania cech charakterystycznych w zadaniu rekonstrukcji 3D powierzchni

Do uzyskania informacji o pewnych wzorcach (cechach) na podstawie danych wejściowych stosuje się metody przetwarzania obrazów (tzw. detektory) pozwalające na opis (tzw. deskrytory) cech charakterystycznych na obrazie. Należy zauważyć, że interpretacja obrazu w przestrzeni 2D powinna umożliwić rozpoznanie nie tylko podstawowych cech zarejestrowanego obiektu, ale również jego szczegółów. Standardowe algorytmy przetwarzania obrazów obejmują stosowanie różnorodnych technik filtracji do akcentowania pewnych cech obiektów ułatwiając ich rozpoznanie i analizę (Patias, 2002; Struck i in., 2019; Talevi i in., 2023). W procesie rekonstrukcji 3D, najczęściej wykorzystywane detektory to (Laha, 2021; Repko i in., 2005) z rodzaju skupisk (ang. *blobs*), np. SIFT (Lowe, 1999), PCA-SIFT (Yan Ke & Sukthankar, 2004), ASIFT (Yu & Morel, 2011) czy SURF (Bay i in., 2008), oraz detektory punktowe i krawędziowe, np. FAST (Trajković & Hedley, 1998) czy detektor Harrisa (Harris & Stephens, 1988):


Detektor SIFT

Jednym z najpowszechniej wykorzystywanych detektorów BLOB jest detektor SIFT (ang. *Scale-Invariant Feature Transform*), składający się z czterech głównych etapów (Kulkarni i in., 2013):

- Wykrywanie ekstremów funkcji w różnych skalach (ang. *scale-space peak selection*) gdzie identyfikowane są potencjalne punkty charakterystyczne poprzez przeszukiwanie obrazu względem lokalizacji i skali. Efektywna implementacja tego procesu polega na konstrukcji piramidy Gaussa (ang. *gaussian pyramid*) oraz wyszukiwaniu lokalnych ekstremów na obrazach różnicowych utworzonych w wyniku różnicowej filtracji Gaussa (ang. *Difference-of-Gaussian*, DoG).
- Lokalizacja punktów charakterystycznych (ang. *keypoint localisation*) gdzie potencjalne punkty charakterystyczne są lokalizowani z dokładnością do subpiksela. Punkty uznawane za niestabilne z uwagi na zbyt mały kontrast są odrzucane wraz z punktami znajdującymi się wzdłuż krawędzi.

- Przypisanie orientacji (ang. *orientation assignment*) gdzie dla każdego punktu charakterystycznego określone są dominujące orientacje na podstawie odpowiadającego mu skali jednego z obrazów gaussowskich. Dzięki przypisaniu orientacji, skali i lokalizacji, SIFT opisuje każdy punkt w sposób niezależny od transformacji, takich jak skalowanie, obrót czy przesunięcie.
- Opis punktu charakterystycznego (ang. *keypoint descriptor*) stanowi ostatni etap, podczas którego powstaje opis punktu charakterystycznego oparty na gradientach obrazu w jego lokalnym otoczeniu. Obszar analizowany wokół punktu zostaje wcześniej wyrównany względem lokalizacji punktu, obrócony zgodnie z dominującą orientacją i przeskalowany do odpowiedniego rozmiaru. Standardowy opis punktu charakterystycznego w SIFT tworzony jest przez próbkowanie wielkości i orientacji gradientów obrazu w otoczeniu punktu, a następnie budowanie wygładzonych histogramów orientacji, które rejestrują istotne aspekty analizowanego fragmentu obrazu.

Na rysunku 4.1 przedstawiono algorytm SIFT do wykrywania punktów kluczowych pokazujący jedną oktawę z 6 gaussowskimi warstwami obrazu.



Rysunek 4.1. Schemat działania detektora SIFT w procesie detekcji punktów kluczowych (źródło: (G. Wang i in., 2013))

Detektor PCA-SIFT

Algorytm PCA-SIFT (ang. *Principal Component Analysis-SIFT*) to modyfikacja standardowego detektora SIFT. Dane wyjściowe z pierwszych trzech etapów (lokalizacja subpikseli, skala i dominujące orientacje) są wspólne dla obu algorytmów. Różnica polega na sposobie opisu lokalnych fragmentów obrazu. W przypadku metody PCA-SIFT wyznaczany jest obszar o rozmiarze 41×41 pikseli, wyśrodkowany względem lokalizacji punktu kluczowego o przyjętej skali i orientacji. Następnie dla każdego fragmentu obliczane są mapy

gradientów poziomych i pionowych o rozmiarze $2 \times 39 \times 39 = 3042$ elementów. Przed obliczeniami tworzona jest przestrzeń własna (tzw. eigenspace), gdzie dla danego fragmentu obrazu obliczany jest lokalny gradient. Następnie wektor gradientu obrazu jest rzutowany na przygotowaną przestrzeń własną. Wynikowy wektor cech jest znacznie mniejszy niż standardowy wektor SIFT, co przyspiesza obliczenia i redukuje wymaganą pamięć, a jednocześnie jest kompatybilny z algorytmami dopasowywania używanymi w SIFT. Do oceny podobieństwa między punktami kluczowymi w różnych obrazach stosuje się odległość euklidesową między wektorami cech (Yan Ke & Sukthankar, 2004).

Detektor ASIFT

Algorytm SIFT nie radzi sobie dobrze z obrazami poddanymi przekształceniom afinicznym. ASIFT (ang. *Affine-SIFT*) symuluje zmiany wynikające z rotacji osi optycznej kamery oraz nachylenia obrazu poprzez przekształcenia rotacyjne i afiniczne, które modyfikują orientację oraz perspektywę obrazu. ASIFT najpierw wykonuje rotację, a następnie stosuje "pochylenie" w kierunku poziomym, uwzględniając zmiany kątów długości i szerokości geograficznej. Po tych transformacjach wykrywa punkty kluczowe i tworzy ich deskryptory. W porównaniu do SIFT, ASIFT wykrywa więcej punktów kluczowych i generuje mniej błędnych dopasowań, co czyni go bardziej skutecznym przy analizie obrazów z różnymi deformacjami perspektywicznymi jednak proces obliczeń może trwać nawet o 180 razy dłużej niż przy zastosowaniu algorytmu SIFT (J. Wu i in., 2013).

Detektor SURF

Detektor SURF (ang. *Speeded Up Robust Features*) jest algorytmem detekcji i opisu punktów kluczowych, który również cechuje się odpornością na zmiany skali i rotacji z tą różnicą, że jest szybki w obliczeniach i porównaniach, a jednocześnie oferuje wysoką powtarzalność, rozróżnialność i odporność na zakłócenia. Algorytm wykorzystuje obrazy całkowite (ang. *integral images*), co znacząco przyspiesza obliczenia związane ze splotami obrazu. Wykrywając punkty kluczowe detektor bazuje na macierzy Hesjana, ale stosuje uproszczone podejście zwane Fast-Hessian, które jest analogiczne do uproszczenia Laplasjanu w detektorze DoG. Następnie deskryptor opisuje rozkład odpowiedzi falek Haara w sąsiedztwie punktu kluczowego. W tym celu również wykorzystuje obrazy całkowite, co zwiększa szybkość działania (Kulkarni i in., 2013).

Detektor FAST

Detektor FAST (ang. *Features from Accelerated Segment Test*) to jeden z najprostszych i najszybszych detektorów punktów kluczowych, opracowany z myślą o aplikacjach w czasie rzeczywistym. Jego głównym celem jest szybkie wykrywanie charakterystycznych punktów w

obrazie, takich jak narożniki, przy minimalnym nakładzie obliczeniowym. Proces przetwarzania zdjęć przez algorytm obejmuje pięć etapów (Trajković & Hedley, 1998):

- wybór analizowanego piksela, który można uznać jako punkt kluczowy;
- analiza pikseli wokół potencjalnego punktu kluczowego w układzie o stałym okręgu (zwykle 16 pikseli), tworzących tzw. okrąg Bresenhama o promieniu 3 pikseli;
- sprawdzenie warunku narożnika gdzie piksel uznawany jest za narożnik (punkt kluczowy), jeśli w okręgu znajduje się co najmniej 12 z tych pikseli, które są jaśniejsze lub ciemniejsze od intensywności badanego piksela;
- sprawdzenie wszystkich pikseli stosując zasadę, że jeżeli co najmniej trzy z czterech wybranych pikseli są powyżej lub poniżej wartości progu, wtedy sprawdzane są wszystkie 16 pikseli, aby upewnić się, że 12 pikseli spełnia wymagane kryterium;
- cała procedura jest powtarzana dla każdego piksela w obrazie.

Należy zauważyć, że algorytm FAST nie jest odporny na zmiany skali ani rotacji obrazu, dlatego często stosuje się go w połączeniu z innymi metodami, np. BRIEF lub ORB.

Detektor Harris

Detektor punktowy Harris wykorzystywany jest do wykrywania punktów charakterystycznych, określanych narożnikami. Detektor działa poprzez analizowanie zmian intensywności wokół każdego piksela w obrazie. Kluczowym elementem algorytmu jest obliczenie macierzy autokorelacji, która rejestruje zmiany intensywności w różnych kierunkach (poziomym i pionowym), wskazując na zmiany:

- w obu kierunkach – narożnik;
- głównie w jednym kierunku – krawędź;
- brak zmian – obszar płaski.

Algorytm wykorzystuje wartości własne tej macierzy do klasyfikacji punktów obrazu, która opisuje lokalne zmiany intensywności w obrazie. Na podstawie tej wartości wybiera się piksele o wysokim prawdopodobieństwie bycia punktami charakterystycznymi, odrzucając te poniżej ustalonego progu.

Powyżej, opisano detektory, które posiadają większe znaczenie w kontekście rekonstrukcji 3D⁹, natomiast na rysunku 4.2. przedstawiono pełną klasyfikację różnych metod wykrywania cech z podziałem na analizowaną strukturę.

⁹ W kontekście charakterystyki ogólnej detektorów, więcej informacji zamieszczono w rozdziale 5.2. *Uczenie głębokie w zadaniach segmentacji obrazów.*

ANALIZOWANA STRUKTURA	DETEKTOR			
KRAWĘDZIE	<u>SOBEL</u> , <u>PREWITT</u> , <u>ROBERTS-CROSS</u> , <u>LAPLACIAN OF GAUSSIAN</u> , ORIENTED ENERGY (OE),	<u>CANNY EDGE DETECTOR</u> , D-ISEF, COLOR BOUNDARY, PB, MS-PB,	GPB, TPB, NMX, BEL, DSC,	SKETCH TOKENS, SCG, SE.
NAROŻNIKI	<u>HARRIS DETECTOR</u> , KLT, SHI-TOMASI DETECTOR, LOCOCO, S-LOCOCO,	SUSAN, FAST , FAST-ER, AGAST, <u>DOG-CURVE</u> ,	ANDD, HYPERBOLA FITTING, ACJ.	
PUNKTY ZAINTERESOWANIA	<u>LOG</u> , <u>DOG</u> , DOH, HESSIAN-LAPLACIAN, <u>SIFT</u> ,	<u>ASIFT</u> , <u>PCA-SIFT</u> , <u>SURF</u> , CER-SURF, DART,	MO-GP, KAZE, A-KAZE, WADE, ORB,	BRISK, FREAK, RANK-SIFT, RLOG.
REGIONY ZAINTERESOWANIA	MSER, IBR, EBR, <u>SALIENT REGION</u> , PCBR,	BETA-STABLE FEATURE, MFD, MSCR, FLOG, BPLR.		
KONTURY	SOBEL, PREWITT, CANNY, GAUSSIAN OF LAPLACIAN, <u>NONLINEAR FILTERS</u> ,	<u>PB</u> , SCG, GPB, MCG,		

Rysunek 4.2. Klasyfikacja metod wykrywania cech na obrazie: przedstawienie różnych podejść do detekcji cech z uwzględnieniem analizowanych struktur, takich jak narożniki, krawędzie czy regiony. Najczęściej stosowane detektory zostały podkreślone. Detektory pogrubione zostały szczegółowo opisane i występują również w kontekście rekonstrukcji 3D (źródło: opracowanie własne)

4.2. Algorytmy automatycznego dopasowania obrazów

Człowiek opiera się na narzędzie wzroku do postrzegania i rekonstrukcji obiektów 3D w fizycznym świecie. Proces rekonstrukcji 3D w fotogrametrii może być podzielony na rekonstrukcję rzadkiej chmury punktów (ang. *sparse dense cloud*) i rekonstrukcję gęstej chmury punktów (ang. *dense point cloud*), w zależności od ilości i gęstości pozyskanych danych. Rzadka chmura punktów określa dokładne pozycje 3D punktów charakterystycznych, takich jak punkty kluczowe (ang. *keypoints*) lub cechy charakterystyczne (ang. *feature points*).

W tym procesie używa się technik takich jak dopasowywanie punktów charakterystycznych (ang. *feature matching*) i ekstrakcja punktów kluczowych (ang. *keypoint extraction*), aby odtworzyć geometryczny kształt badanego obiektu w postaci dyskretnej chmury punktów. Natomiast rekonstrukcja gęstej chmury punktów ma na celu uzyskanie dokładnych współrzędnych 3D dla każdego piksela. Proces ten opiera się na szacowaniu głębokości (ang. *depth estimation*) dla każdego piksela obrazu, co pozwala na wygenerowanie gęstej mapy głębi (ang. *dense depth map*), chmury punktów (ang. *point cloud*) lub siatki trójwymiarowej (ang. *3D mesh*), które określają pełną rekonstrukcję kształtu badanej powierzchni (L. Zhou i in., 2024).

Następnie, modelowanie przestrzenne powierzchni można zrealizować w postaci chmury punktów, wokseli (ang. *volumetric pixel*) i siatki. Chmury punktów składają się z dyskretnych danych zbieranych przez różne sensory lub urządzenia skanujące. Służą do reprezentowania zewnętrznej powierzchni obiektu lub przestrzennej struktury badanego otoczenia. Chmurę punktów określamy jako nieuporządkowany zbiór punktów w przestrzeni 3D gdzie przestrzeń ta dzielona jest na jednolite sześciennie jednostki. Każda jednostka sześcienna nazywana jest wokselem, który zawiera informacje reprezentujące przestrzenne atrybuty, takie jak kolor, gęstość lub głębokość. Magazynowanie wokseli wykorzystuje się do reprezentowania struktury i atrybutów w przestrzeni, ale wiąże się z wysoką złożonością przestrzenną. Natomiast siatka składa się z połączonych wierzchołków, krawędzi i ścian. Model siatki może być zbudowany z trójkątów, czworokątów lub wielokątów wyższego rzędu i może opisywać większość struktur topologicznych. Może dokładnie reprezentować złożone kształty geometryczne i detale. Powierzchnia opisana przez każdy trójkąt jest płaska, co sprawia, że jest odpowiednia dla licznych zastosowań w grafice komputerowej i inżynierii, gdzie powszechnie wykorzystywane są siatki trójkątne. Zapewnia to, że projekcja jest zawsze wypukła i łatwa do rasteryzacji (L. Zhou i in., 2024).

W niniejszej rozprawie doktorskiej wykorzystano obrazy cyfrowe do rekonstrukcji opartej o algorytm SfM-MVS celem stworzenia cyfrowego modelu 3D ciała ludzkiego. W związku z powyższym w następnym rozdziale zostały opisane kolejne etapy prowadzące do uzyskania w pełni użytecznego modelu 3D:

- dopasowanie obrazów cyfrowych (4.2.1. *Structure-from-Motion*, 4.2.1.1. *SfM-MVS*);
- generowanie powierzchni 3D na podstawie uzyskanej chmury punktów (4.2.2. *Parametryczne modelowanie powierzchniowe*);
- wizualizacja utworzonego modelu 3D (4.2.3. *Wizualizacja modeli 3D*);

4.2.1. Algorytm Structure-from-Motion

W 1979 roku Ullman i Shimon zaproponowali metodę odtwarzania trójwymiarowej struktury i ruchu obiektów na podstawie dwuwymiarowej transformacji wyświetlanego obrazu (Ullman, 1979). W 1981 roku Longuet-Higgins zaproponował metodę odtwarzania kształtu 3D z wielu obrazów, gdzie zmiana położenia kamery podczas kolejnych ekspozycji tworzy serię zdjęć na podstawie których można odtworzyć trójwymiarową strukturę fotografowanego obiektu czy przestrzeni (Longuet-Higgins, 1981). Czas przeprowadzania rekonstrukcji i potrzebna moc obliczeniowa zależne są od ilości danych na wejściu algorytmów przetwarzania. Z tego powodu, wyróżnić można cztery najczęściej występujące metody projektowania ścieżek przetwarzania dla algorytmu Structure-from-Motion (SfM) (Moulon & Monasse, 2016): iteracyjne SfM (C. Wu, 2013), globalne SfM (Hainan Cui i in., 2015), sekwencyjne SfM (Cui i in., 2017) i hierarchiczne SfM (Xu i in., 2021):

- SfM Iteracyjny - na początkowym etapie działania algorytmu wybierana jest początkowa para zdjęć, do której w kolejnych iteracjach dodawane jest następne zdjęcie, aż do wykorzystania wszystkich dostępnych danych;
- SfM Sekwencyjny - stanowi pochodną metody iteracyjnej, stosowaną głównie w przypadkach, gdy zdjęcia są wykonywane przez pojedynczą kamerę poruszającą się po ustalonej trasie. Typowym przykładem jest rekonstrukcja terenu na podstawie zdjęć z samolotu. Podobnie jak w metodzie iteracyjnej, wybierana jest początkowa para obrazów, ale w tym przypadku kolejne obrazy dodawane są sekwencyjnie w porządku czasowym, bez analizy ich pokrycia;
- SfM Hierarchiczny - w tej metodzie dostępne obrazy są dzielone na mniejsze podgrupy. Metoda ta jest używana w bardziej złożonych rekonstrukcjach, gdzie nie wszystkie zdjęcia obejmują kadrem ten sam obszar obiektu, co pozwala na ich niezależną analizę. Hierarchiczne podejście może być również stosowane w systemach, które umożliwiają segmentację zarejestrowanego obrazu, dzieląc zdjęcia na grupy w zależności od obserwowanych obiektów lub ich deskryptorów;
- SfM Globalny - różni się od innych metod tym, że jest stosowany w systemach skalibrowanych, gdzie znane są parametry wewnętrzne i zewnętrzne każdej kamery. Dzięki temu możliwa jest jednoczesna analiza wszystkich dostępnych danych, co skraca czas przetwarzania i zmniejsza margines błędu.

W metodzie SfM jako dane wejściowe służy sieć zdjęć o wspólnym pokryciu. Dane wyjściowe obejmują rekonstrukcję 3D obiektu oraz wewnętrzne i zewnętrzne parametry kamery uzyskane podczas procesu rekonstrukcji.

4.2.1.1. Algorytmy SfM-MVS

Opracowanie metody automatycznej detekcji punktów wiążących - SIFT (ang. *Scale-Invariant Feature Transform*) przyczyniło się do znacznego postępu w rozwoju prac nad SfM. SIFT jest skuteczny przy analizie obrazów o różnych skalach i różnym obrocie (zakres tych różnic zależy m.in. od takich czynników jak: rozdzielczość przestrzenna, kąt obserwacji, oświetlenie oraz tekstura obiektu). Ostatecznie, liczba punktów charakterystycznych na zdjęciu wynosi zwykle kilka do kilkunastu tysięcy, co zwiększa szanse na ich równomierne rozmieszczenie. To pozwala na wiarygodne oszacowanie parametrów wewnętrznych i zewnętrznych kamery oraz zniekształceń podczas aerotriangulacji z procesem samokalibracji. Równocześnie rozwijały się metody automatycznego, masowego pomiaru stereoskopowego (pary zdjęć) na obrazach o znanych parametrach kamery określane jako Multi-View-Stereo (MVS). Obie ścieżki badawcze znalazły wspólne zastosowanie w oprogramowaniach, co podkreśla ich połączenie w akronimie SfM-MVS (Pyka, 2023).

Proces SfM-MVS rozpoczyna się od wykrycia punktów charakterystycznych (ang. *key points*). Detekcja odbywa się oddzielnie na każdym zdjęciu, przy czym celowo poszukuje się bardzo dużej liczby punktów, ponieważ tylko część z nich zostanie zakwalifikowana jako punkty wiążące. Algorytm SIFT przypisuje każdemu punktowi wektor cech, który opisuje zmiany jasności w jego otoczeniu, uwzględniając kierunek i intensywność tych zmian. Dzięki temu wzrasta prawdopodobieństwo, że dany punkt będzie unikalny, nie tylko na danym zdjęciu, ale również w całym zbiorze obrazów. Na podstawie podobieństwa tych wektorów poszukuje się punktów homologicznych, które pojawiają się na dwóch nakładających się zdjęciach. Punkty charakterystyczne, dla których nie znaleziono odpowiedników na innych zdjęciach, są odrzucane. Każda potencjalna para zdjęć jest weryfikowana poprzez obliczenie wzajemnej orientacji. W tym celu na podstawie losowo wybranych co najmniej 8 punktów oblicza się macierz fundamentalną, a poprawność pozostałych punktów weryfikuje się przy użyciu algorytmu RANSAC. Punkty, które nie spełniają warunku linii epipolarnych, są odrzucane, a proces ten powtarza się iteracyjnie. Pary zdjęć, dla których nie uda się ustalić poprawnej orientacji wzajemnej, są eliminowane. Na końcu powstaje zbiór przedstawiający wzajemne relacje między zdjęciami. Kolejnym krokiem jest sekwencyjne dopasowanie orientacji

kolejnych zdjęć względem pary zdjęć przyjętej za inicjalną. Ten etap określany jest jako sukcesywne formowanie bloku, gdzie przeprowadza się kroki:

- orientacja wzajemna zdjęć tworzących model początkowy i obliczenie współrzędnych 3D punktów wiążących za pomocą wcięcia w przód;
- orientacja kolejnego zdjęcia metodą wcięcia wstecz, na podstawie punktów wiążących o wcześniej wyznaczonych współrzędnych 3D (zdjęcie otrzymuje parametry orientacji zewnętrznej kamery w układzie początkowym);
- powiększenie zbioru punktów 3D poprzez wcięcie w przód, wykonane dla nowej pary zdjęć, utworzonej po dodaniu kolejnego zdjęcia.

Znajomość przybliżonych wartości parametrów orientacji zewnętrznej kamery, wraz z przybliżonymi współrzędnymi punktów wiążących w układzie terenowym lub lokalnym, umożliwia przeprowadzenie estymacji parametrów orientacji zewnętrznej kamery metodą niezależnych wiązek. W przypadkach, gdzie nie jest konieczne powiązanie z terenowym układem współrzędnych, fotopunkty nie są wymagane; zamiast tego dostępna jest opcja skalowania poprzez wprowadzenie długości odcinka pomierzonego w terenie lub na obiekcie sfotografowanego na zdjęciach. Aerotriangulacja może zostać przeprowadzona z wykorzystaniem różnych wariantów danych wejściowych. Opisana procedura, polegająca na wyznaczeniu wartości przybliżonych, a następnie estymacji parametrów orientacji zewnętrznej kamery w ramach jednego procesu dla całego bloku zdjęć, jest podejściem globalnym. Alternatywnie, stosowana jest również strategia przyrostowa, która uruchamia proces dopasowania wiązek na etapie formowania bloku, po każdym dołączeniu nowego zdjęcia lub grupy zdjęć (Pyka, 2023).

W metodzie SfM często stosowana jest samokalibracja, gdzie równania kolinearności są rozszerzone o parametry orientacji zewnętrznej kamery oraz dystorsji. Równania te przedstawiają następujące wzory:

$$\begin{aligned} x &= x_o - c \frac{r_{11}(X - X_o) + r_{21}(Y - Y_o) + r_{31}(Z - Z_o)}{r_{13}(X - X_o) + r_{23}(Y - Y_o) + r_{33}(Z - Z_o)} + \Delta x_d \\ y &= y_o - c \frac{r_{12}(X - X_o) + r_{22}(Y - Y_o) + r_{32}(Z - Z_o)}{r_{13}(X - X_o) + r_{23}(Y - Y_o) + r_{33}(Z - Z_o)} + \Delta y_d \end{aligned} \quad (4.1)$$

gdzie:

x, y – współrzędne punktu odniesienia (np. punktu wiążącego lub fotopunktu) na zdjęciu w układzie scentrowanym;

x_o, y_o – współrzędne punktu głównego;

$\Delta x_d, \Delta y_d$ – składowe dystorsji w modelu Brown’a;
 X, Y, Z – współrzędne punktu w układzie terenowym;
 X_o, Y_o, Z_o – współrzędne środka rzutów (położenie kamery);
 c – ogniskowa kamery;
 r_{ij} – elementy macierzy rotacji.

Jakość estymacji parametrów orientacji zewnętrznej i orientacji wewnętrznej oraz dystorsji ocenia się na podstawie średniego błędu reprojektacji (RE) wszystkich punktów osnowy, gdzie dominującą grupą są punkty wiążące. Błąd reprojektacji oblicza się według wzoru:

$$RE = \frac{1}{n} \sum \sqrt{v_x^2 + v_y^2} \quad (4.2)$$

gdzie:

v_x, v_y - poprawki losowe uzyskane dla wszystkich obserwacji współrzędnych x i y punktów osnowy na zdjęciach;

n - liczba wszystkich pomiarów punktów osnowy na zdjęciach (obserwowana para współrzędnych x, y jest traktowana jako jeden pomiar).

Błąd reprojektacji jest również wykorzystywany do filtracji punktów wiążących po procesie aerotriangulacji. W takim przypadku RE oblicza się tylko na podstawie obserwacji danego punktu osnowy. Punkty wiążące, dla których błąd reprojektacji jest uznawany za zbyt duży (zwykle gdy RE jest poniżej 1 piksela), są usuwane, a następnie przeprowadza się ponowną estymację parametrów.

Znajomość parametrów orientacji zewnętrznej zdjęć umożliwia wyszukiwanie punktów homologicznych przy wykorzystaniu zależności punkt a linia epipolarna. Proces ten, nazywany gęstym dopasowaniem zdjęć (ang. *dense image matching*) i odbywa się z nominalną gęstością jednego piksela. W rzeczywistości gęstość ta bywa mniejsza, co wynika z różnych przyczyn, takich jak różnice w perspektywie zdjęć, obszary widoczne tylko na jednym z obrazów w parze czy brak odpowiedniej tekstury na zdjęciach (np. materiały odbijające światło, słabe oświetlenie, wysoki poziom szumu). Za produkt w postaci gęstej chmury punktów odpowiada algorytm Multi-View-Stereo.

Na rysunku 4.3 przedstawiono schemat działania algorytmu SfM-MVS (Luhmann i in., 2023) gdzie:

- 1 – zastosowanie detektora wykrywania cech (ang. *feature detector*) do identyfikacji punktów charakterystycznych na obrazach, które mogą zostać wykorzystane do dalszego procesu generowania modelu 3D. Na tym etapie przeprowadzana jest analiza każdego z obrazów wejściowych w celu wykrycia regionów o unikalnych cechach (punktów charakterystycznych), które umożliwiają odnalezienie tych samych elementów obiektów na zdjęciach wykonanych z różnych kątów. Najczęściej używanym detektorem punktów jest algorytm SIFT lub SURF;
- 2 – po wykryciu cech, tworzone są ich deskryptory, czyli unikalne opisy, które umożliwiają ich rozpoznanie na innych obrazach;
- 3 – w tym kroku następuje odnalezienie wykrytych punktów charakterystycznych na odpowiadających sobie zdjęciach celem wyznaczenia grup widoków przedstawiających wspólny obraz zarejestrowanego obiektu tzw. dopasowywanie cech (ang. *feature matching*);
- 4 – weryfikacja geometryczna poprawności dopasowania punktów homologicznych metodą RANSAC (ang. *RANdom SAMple Consensus*);
- 5 – na tym etapie przetwarzania obrazów poprzez względną orientację (ang. *relative orientation*), dane dotyczące punktów charakterystycznych oraz pokrycia obserwowanego obiektu są wykorzystywane do oszacowania parametrów wewnętrznych (ogniskowa, punkt główny, parametry dystorsji) oraz elementów orientacji zewnętrznej zdjęć;
- 6 – optymalizacja dokładności lokalizacji cech i orientacji kamery poprzez dostosowanie metodą niezależnych wiązek (ang. *bundle adjustment*) tzw. minimalizacja błędu reprojektacji;
- 7 – za pomocą triangulacji, wyznaczone są oszacowane punkty w przestrzeni 3D odpowiadające wcześniej zidentyfikowanym punktom charakterystycznym. Końcowym wynikiem tego procesu dla wszystkich zdjęć jest częściowa rekonstrukcja geometrii analizowanego obiektu w formie tzw. rzadkiej chmury punktów (ang. *sparse point cloud*);
- 8 – obliczenie głębi na podstawie punktów homologicznych na obrazach tzw. dopasowanie stereo (para zdjęć) (ang. *stereo matching*);
- 9 – zastosowanie algorytmu „zagęszczania” chmur punktów określonych algorytmami MVS (ang. *Multi-View-Stereo*), charakteryzujących się różnorodnym podejściem (np. tensory 3D (T.-P. Wu i in., 2010), głębokie sieci neuronowe (Kuhn i in., 2020)). Zgodnie z literaturą algorytmy „zagęszczania” można podzielić na cztery grupy w oparciu o bazową metodykę interpolowania informacji (Seitz i in., 2006; Shuhan Shen, 2013):
 - metody oparte na wokselach (ang. *Voxel based methods*), które polegają na podziale trójwymiarowej przestrzeni na woksele (podstawowe jednostki przestrzeni 3D, odpowiedniki pikseli w przestrzeni 2D) o różnej wielkości, w zależności od wymaganej rozdzielczości i dokładności modelu. Następnie woksele są klasyfikowane na podstawie


obrazu z kamer jako część obiektu lub tła. Metody te są głównie stosowane do małych obiektów o niewielkiej objętości przestrzennej (Vogiatzis i in., 2007);

- metody oparte na rozroście punktów charakterystycznych (ang. *Feature Point Growing Methods*), które bazują na analizie najbliższego otoczenia punktów w rzadkiej chmurze punktów, wyznaczonej na podstawie wykrytych punktów charakterystycznych w obrazach. W przeciwieństwie do innych metod, nie wymagają one zdefiniowania objętości w przestrzeni 3D. Niemniej, w zależności od zastosowanego algorytmu rozszerzania i filtracji nowych punktów, mogą być obliczeniowo wymagające, a także pozostawiać luki w końcowym modelu (Furukawa & Ponce, 2010; T.-P. Wu i in., 2010);
- metody oparte na ewolucji powierzchni (ang. *Surface Evolution based methods*), które opierają się na zamknięciu przewidywanej objętości modelu w siatce, a następnie odkształcaniu jej powierzchni na podstawie analizy obserwacji, w celu zminimalizowania odległości między siatką a rzeczywistą powierzchnią obiektu. Ostateczny efekt zależy od oszacowania objętości otaczającej przestrzeni, co sprawia, że metoda ta jest trudna do zastosowania w przypadku obiektów o większych rozmiarach (Faugeras & Keriven, 1998; Hernández Esteban & Schmitt, 2004);
- metody łączenia map głębi (ang. *Depth Map Merging Methods*) oparte są na wykorzystaniu zasady paralaksy, aby za pomocą pary zdjęć stworzyć mapy głębi, czyli obrazy, na których wartość piksela reprezentuje oszacowaną odległość punktu od kamery. Następnie, mapy głębi z różnych par zdjęć są łączone, a wynikowe odległości pikseli są wykorzystywane do triangulacji nowych punktów w przestrzeni 3D. Metoda ta nie wymaga ograniczeń objętości obiektu, dzięki czemu nadaje się do rekonstrukcji dużych obiektów, choć często kosztem dokładności i kompletności wygenerowanego modelu (J. Li i in., 2010);

10 – gęsta chmura punktów (ang. *dense point cloud*);

11 – tworzenie modelu powierzchniowego (ang. *surface model*) na podstawie gęstej chmury punktów (4.2.2. *Parametryczne modelowanie powierzchniowe*);

12 – wizualizacja modelu 3D (4.2.3. *Wizualizacja modelu 3D*).



Rysunek 4.3. Schemat działania algorytmu SfM-MVS: proces generowania modelu 3D na podstawie zdjęć, obejmujący detekcję cech (SIFT, SURF), dopasowywanie punktów homologicznych (RANSAC), optymalizację orientacji kamer (*bundle adjustment*), triangulację do utworzenia rzadkiej chmury punktów, obliczenie głębokości i zagęszczenie chmury punktów, aż po końcową wizualizację modelu 3D (źródło: opracowanie własne)

4.2.2. Parametryczne modelowanie powierzchniowe


Posiadając rozproszoną, przestrzenną chmurę punktów (x, y, z) uzyskaną w wyniku automatycznego dopasowania obrazów cyfrowych, kolejnym krokiem jest przeprowadzenie rekonstrukcji. Tworzenie modeli wielokątnych, które spełniają wysokie standardy w zakresie modelowania i wizualizacji, jest wymagane w wielu dziedzinach. Metoda oparta na wielokątach zazwyczaj stanowi najlepsze podejście do dokładnego odwzorowania wyników pomiarów oraz optymalnego opisu powierzchni (Zawieska, 2013). Analizując dostępne algorytmy rekonstrukcji powierzchni, można wymienić:

- metodę pojemnościową (VCG);
- algorytm Alpha Shape;
- algorytm Ball-Pivoting;
- algorytm Poissona.

Większość algorytmów rekonstrukcji wymaga znajomości wektorów normalnych dla punktów, dlatego konieczne jest ich wcześniejsze obliczenie. Wektory te szacuje się na podstawie punktów zlokalizowanych w bliskim sąsiedztwie analizowanego punktu, a następnie przeprowadza się wygładzanie wektorów dla całego modelu (Zawieska, 2013).

Metoda pojemnościowa

Algorytm opracowany przez Curless B. w 1997 roku (Curless, 1997), opiera się na kierunkowej funkcji odległości, ważonej przyrostowo (rysunek 4.4).




Rysunek 4.4. Schemat działania metody pojemnościowej opracowanej przez Curless B. (1997): obliczanie wagi w i odległości d niezbędnych do aktualizacji woksela poprzez rzutowanie promienia z sensora przez woksel na powierzchnię zasięgu. Waga w jest wyznaczana metodą liniowej interpolacji wag w_a , w_b i w_c , które są przechowywane w sąsiednich wierzchołkach powierzchni zasięgu (źródło: (Curless, 1997))

Metoda pojemnościowa działa poprzez analizę wycinka obrazu, obliczając odległości jego powierzchni od sensora, a zebrane dane są łączone z już istniejącymi. Algorytm ten używa siatki objętościowej, analizując osobno każdą komórkę, a następnie wygładza wyniki na ich stykach. Metoda ta jest przeznaczona głównie do skanowania laserowego z równomiernym rozkładem punktów pomiarowych. Jednakże w przypadku chmur punktów metoda ta prowadzi do powstawania artefaktów poza obszarem modelowanego obiektu, co również spowodowało rezygnację z jej stosowania (Curless, 1997; Zawieska, 2013).

Algorytm Alpha Shape

Metoda ta jest stosowana w geometrii obliczeniowej do odtwarzania kształtów na podstawie zbioru punktów w przestrzeni. Mając zbiór punktów, które tworzą chmurę danych w 2D lub 3D Alpha Shape pozwala na stworzenie "szkicu" kształtu, który najlepiej opisuje strukturę tych punktów, biorąc pod uwagę różne poziomy szczegółowości. Proces ten polega na łączeniu sąsiadujących punktów i tworzeniu wielokątów (dla 2D) lub wielościanów (dla 3D), a wszystko to kontrolowane jest przez parametr alpha. Zmienianie tego parametru wpływa na dokładność odtworzenia – dla małych wartości alpha wynik jest bardziej szczegółowy, a dla większych kształt staje się bardziej uproszczony. Alpha Shape jest szczególnie przydatne, gdy próbujemy zrekonstruować kształty, które mogą mieć otwory, wklęsłości lub nieregularności, które klasyczne metody, takie jak np. Ball-Pivoting, nie potrafią uchwycić. W rezultacie Alpha Shape


daje elastyczny sposób na uzyskanie przybliżenia oryginalnego kształtu z wybranego zbioru punktów, dostosowując stopień szczegółowości w zależności od potrzeb (Edelsbrunner i in., 1983) (rysunek 4.5).



Rysunek 4.5. Schemat działania metody Alpha Shape: a) chmura punktów, b) rekonstrukcja kształtu ze współczynnikiem $\alpha = 0.030$, c) rekonstrukcja kształtu ze współczynnikiem $\alpha = 0.037$, d) rekonstrukcja kształtu z zastosowaniem współczynnika $\alpha = 0.010$ (źródło: (Q.-Y. Zhou i in., 2018))

Algorytm Ball-Pivoting

Algorytm Ball-Pivoting (Bernardini i in., 1999) łączy sąsiadujące punkty na powierzchni, jeśli kolejny punkt znajduje się na okręgu o zadanym promieniu. Stały promień działania algorytmu sprawia, że najlepiej nadaje się on do modeli z regularną siatką punktów. Zbyt duży promień powoduje utratę szczegółów modelu, natomiast zbyt mały promień prowadzi do powstawania dziur (rysunek 4.6) (Zawieska, 2013).



Rysunek 4.6. Zasada działania algorytmu Ball-Pivoting poprzez łączenie kolejnych punktów na powierzchni za pomocą okręgu o określonej średnicy: a) łączenie kolejnych punktów na powierzchni za pomocą okręgu o zadanym promieniu, b) zbyt mały promień prowadzi do powstawania niepożądanych otworów w modelu, c) natomiast, zbyt duży promień powoduje deformację i utratę szczegółów modelu (źródło: (Bernardini i in., 1999))

Algorytm Poissona

Algorytm Poissona (Kazhdan i in., 2006) do rekonstrukcji modeli (rysunek 4.7) opiera się na funkcji charakterystycznej zbioru χ , która przyjmuje wartość 1 dla punktów wewnątrz modelu i 0 dla punktów zewnętrznych. Istnieje zależność między wektorami normalnymi a funkcją charakterystyczną modelu, gdzie gradient tej funkcji stanowi pole wektorowe. W szczególności, w pobliżu powierzchni modelu gradient funkcji odpowiada wektorom normalnym. Problem wyznaczenia funkcji charakterystycznej sprowadza się do znalezienia skalarnej funkcji χ , której gradient najlepiej przybliża dane pole wektorowe $\vec{V}$ (Zawieska, 2013):


$$\min_{\chi} \|\nabla \chi - \vec{V}\| \quad (4.8)$$

Kiedy zastosujemy operator dywergencji, problem zostaje przekształcony w taki, który można opisać równaniem różniczkowym Poissona. Celem jest znalezienie skalarnej funkcji χ , której laplasjan (dywergencja gradientu) odpowiada dywergencji pola wektorowego $\vec{V}$ (Zawieska, 2013):

$$\Delta \chi \stackrel{\text{def}}{=} \nabla \nabla \chi = \nabla \vec{V} \quad (4.9)$$

Podejście to w rekonstrukcji powierzchni charakteryzuje się następującymi cechami (Zawieska, 2013):


- rozwiązanie ma charakter globalny, jest bezpośrednio obliczane na podstawie wszystkich punktów, bez potrzeby etapowego wyznaczania rozwiązań lokalnych i tworzenia z nich spójnego modelu;
- umożliwia uzyskiwanie gładkich powierzchni nawet w przypadku danych z zakłóceniami, eliminując lokalne anomalie spowodowane przez pojedyncze punkty odstające od powierzchni;
- algorytm jest odporny na lokalne nieciągłości w powierzchni;
- dostępne są wydajne algorytmy do rozwiązywania równania Poissona.



Rysunek 4.7. Proces odtwarzania powierzchni metodą Poissona: a) zbiór wektorów normalnych $\vec{V}$, b) gradient charakterystyczny $\nabla\chi_m$, c) funkcja charakterystyczna χ_m , d) powierzchnia ∂M (źródło: (Kazhdan i in., 2006))

Wyznaczanie wartości wektorów normalnych dla poszczególnych punktów odbywa się poprzez lokalne przybliżenie powierzchni. Dla każdego analizowanego punktu P_0 określa się zbiór n najbliższych sąsiadów, które tworzą lokalną siatkę, taką jak siatka Voronoi. W tym otoczeniu sąsiednie punkty są wykorzystywane do stworzenia podstaw trójkątów, które definiują lokalną strukturę powierzchni w przestrzeni 3D. Na podstawie tej siatki wyliczany jest wektor normalny n , będący kluczowym elementem charakteryzującym geometrię punktu P_0 . Proces obliczania wektora normalnego wykorzystuje lokalne dopasowanie powierzchni kwadratowej do danych punktów. Dopasowanie to pozwala na wyznaczenie lokalnego pola wektorowego, które najlepiej przybliży orientację powierzchni w otoczeniu P_0 . Co istotne, metoda ta wymaga minimalnej liczby trzech sąsiednich punktów, co czyni ją bardziej efektywną niż tradycyjne podejścia, takie jak dopasowanie powierzchni kwadratowych, które wymaga co najmniej dziewięciu sąsiednich punktów. Dzięki temu algorytm zachowuje lokalny charakter geometryczny wyliczanych wektorów, unikając degradacji dokładności, jaka może wystąpić przy uwzględnieniu bardziej oddalonych punktów (rysunek 4.8).

Metoda ta jest bardzo podatna na zmiany wartości wektorów normalnych. Jeśli parametry zostaną niewłaściwie dobrane, na modelu mogą pojawić się artefakty w postaci narośli. Natomiast przy prawidłowym obliczeniu wektorów normalnych, metoda ta przynosi dobre rezultaty (Zawieska, 2013). Z tego powodu metoda Poissona, zaimplementowana w oprogramowaniu Agisoft Metashape Professional, została wykorzystana w przeprowadzonych eksperymentach jako odpowiednia do tworzenia i wizualizacji modeli opartych na chmurze punktów.



Rysunek 4.8. Wyznaczanie wektora normalnego n w punkcie P_0 poprzez lokalne przybliżenie powierzchni. Analizowany punkt P_0 otaczają sąsiednie punkty P_1, P_2, P_3, P_4 , które tworzą lokalną siatkę Voronoi. Wektor normalny n wyznaczany jest na podstawie dopasowania krzywej kwadratowej oraz wektorów v_1, v_2, v_3, v_4 , co pozwala na precyzyjne określenie lokalnych właściwości geometrycznych punktu P_0 . Metoda wymaga minimalnej liczby trzech sąsiednich punktów, w przeciwieństwie do bardziej złożonych metod dopasowania powierzchni kwadratowych, które wymagają co najmniej dziewięciu punktów (źródło: (OuYang & Feng, 2005))

4.2.3. Wizualizacja modelu 3D

Prezentacja modelu 3D często stanowi jedyny rezultat, który jest istotny dla odbiorców spoza środowiska technicznego (w tym co istotne, dla lekarzy medycyny sądowej) i jest główną formą interakcji z modelem. W dziedzinie fotogrametrii, pierwsze próby wizualizacji modeli 3D rozpoczęto w latach 90. XX wieku. Małe obiekty, takie jak modele architektoniczne, samochody czy twarze, były przedstawiane za pomocą siatkowej formy wizualizacji (ang. *wireframe*) (Gruen & Baltsavias, 1989) lub przy użyciu oprogramowania CAD. Dzięki rosnącym możliwościom pamięci komputerowej, obecne możliwości szczegółowości powstających wizualizacji stają się coraz bardziej powszechne. W zależności od wymagań dotyczących dokładności modelu 3D oraz użytego oprogramowania, istnieje kilka metod ich wizualizacji (Zawieska, 2013):

- tryb siatkowy jest najstarszą metodą prezentowania modeli 3D, gdzie model jest przedstawiany za pomocą punktów, linii i krzywych, ukazując jedynie krawędzie bez uwzględnienia cieni czy tekstur. Technika ta jest głównie wykorzystywana w programach CAD (ang. *Computer-Aided Design*);
- tryb cieniowania oparty jest o zasady optyki, a szczególnie na prawie cosinusów Lamberta, które mówi, że jasność powierzchni wzrasta wraz z cosinusem kąta padania światła. Stosowane są różne algorytmy cieniowania, z których najpopularniejsze to cieniowanie płaskie (ang. *flat shading*) i cieniowanie gładkie (ang. *smooth shading*).

Kluczowa różnica między nimi polega na wykorzystaniu wektorów normalnych: w cieniowaniu płaskim jednolity kolor przypisuje się całym obszarom, podczas gdy w cieniowaniu gładkim wektory normalne są uśredniane, co daje bardziej realistyczny efekt. Cieniowanie płaskie sprawdza się przy małych obiektach, gdzie źródła światła i obserwator są oddalone. Bardziej szczegółowe modele wymagają większej liczby poligonów, co jednak może obniżać realizm obrazu. Cieniowanie gładkie można realizować za pomocą różnych algorytmów;

- tryb teksturowania jest metodą polegającą na nakładaniu tekstury (np. z obrazu cyfrowego) na powierzchnię modelu 3D. Każdy piksel modelu przyjmuje kolor odpowiadający określonemu fragmentowi tekstury. W porównaniu z cieniowaniem płaskim, teksturowanie może zmniejszyć liczbę potrzebnych poligonów, ale zwiększa złożoność modelu.

4.3. Podsumowanie

Jako, że większość zmian patologicznych na powierzchni ciała i związanych z nimi parametrów geometrycznych ewoluuje w przestrzeni trójwymiarowej opisano proces generowania fotorealistycznych modeli 3D. Rozdział rozpoczął od wskazania detektorów wykrywających cechy charakterystyczne na obrazach, ze szczególnym uwzględnieniem detektora SIFT, ASIFT, PCA-SIFT, SURF, FAST oraz Harrisa. Następnie opisano najpowszechniej wykorzystywany algorytm w modelowaniu 3D - SfM-MVS. Modelowanie 3D, z wykorzystaniem algorytmów jak Structure-from-Motion (SfM) i Multi-View-Stereo (MVS), umożliwia tworzenie dokładnych modeli 3D z obrazów 2D. Te metody, oparte na dopasowaniu punktów charakterystycznych i triangulacji, pozwalają na rekonstrukcję przestrzenną obiektów. Metoda SfM-MVS jest bardzo skuteczna, jeżeli posiadamy dobrej jakości obrazy o odpowiednio gęstym pokryciu z wstępnie skalibrowaną kamerą, albo przynajmniej stabilną mechanicznie podczas akwizycji obrazu, oraz założoną osnowę fotogrametryczną o znanych wielkościach odcinków. Zazwyczaj osiągalna dokładność mieści się w zakresie 0,5-2 pikseli (Luhmann i in., 2023).

W rozdziale przedstawiono również szczegółową analizę różnych podejść do parametrycznego modelowania powierzchniowego, w tym metodę pojemnościową (VCG), algorytm Ball-Pivoting, algorytm Poissona oraz algorytm Alpha Shape, które stanowią podstawowe narzędzia w procesie rekonstrukcji powierzchni 3D. Rozdział zamyka omówienie metod wizualizacji modeli 3D, prezentując tryby siatkowy, cieniowania oraz teksturowania,

które znajdują zastosowanie w zależności od wymagań dotyczących dokładności modelu i wykorzystywanego oprogramowania. Opisane metody zostały zaimplementowane w szeregu profesjonalnych narzędzi, takich jak Agisoft Metashape Professional, RealityCapture, Pix4Dmapper, Meshroom czy COLMAP.

5. Głębokie sieci neuronowe w klasyfikacji obrazów medyczny

Jak wspomniano we wcześniejszych rozdziałach, obrazowanie medyczne jest istotnym źródłem informacji nie tylko w medycynie sądowej, ale również w wielu innych dziedzinach medycyny. Obecne metody obrazowania dostarczają ogromnych ilości danych, które można przekształcić w użyteczne informacje tylko wtedy, gdy są poddane odpowiedniemu przetworzeniu. Kluczowe znaczenie w rozwoju tej dziedziny ma proces pozyskiwania danych oraz automatyzacja procesów wydobycia i zrozumienia informacji (tzw. interpretacja obrazu) (Patias, 2002; Talevi i in., 2023).

W ostatnich latach dziedziny sztucznej inteligencji oraz automatycznego wykrywania wzorców poczyniły znaczne postępy. Uczenie maszynowe, a konkretniej jego zaawansowana forma - uczenie głębokie, stały się powszechnie stosowanymi narzędziami do rozwiązywania skomplikowanych problemów, które wcześniej wymagały tradycyjnych rozwiązań.

W niniejszym rozdziale skoncentrowano się na omówieniu zagadnień związanych z uczeniem głębokim oraz sieciami neuronowymi. Ze względu na szeroki i złożony charakter tego tematu, przedstawiono jedynie opis zagadnień niezbędnych do zrozumienia eksperymentów przeprowadzonych w niniejszej rozprawie doktorskiej.

5.1. Analiza aktualnego stanu wiedzy w badaniu obrazów zewnętrznych

W rozdziałach 2.1.1. *Dokumentacja obrazów występujących na powłokach ciała*; 2.3. *Stosowane metody wymiarowania obrazów* oraz 3. *Pośmiertne kryminalistyczne metody obrazowania 3D* szczegółowo opisano proces dokumentowania obrazów znajdujących się na powłokach ciała metodami tradycyjnymi (wykorzystującymi diagram ciała i pomiary manualne). Wskazano również na wykorzystanie poszczególnych sensorów oraz ich integrację w procesie tworzenia cyfrowej dokumentacji medycznej 3D mogącej służyć nie tylko jako zapis zebranych danych ale również jako pomoc w analizie obrazów oraz ich narzędzi sprawczych. Jednak, aby uzyskać pełne zrozumienie oraz wszechstronne ujęcie zagadnienia będącego tematem niniejszej rozprawy doktorskiej, konieczne jest również uwzględnienie aktualnych badań związanych wyłącznie z analizą obrazów zewnętrznych.

W 2021 roku, autorka przeprowadziła badanie literatury, które wykazało wiele istotnych artykułów naukowych poruszających zagadnienie klasyfikacji obrazów występujących na ciele człowieka. Badanie to stanowiło podstawę do wyznaczenia celu i zadań badawczych, których

wyniki omówiono w dalszej części rozprawy. W ramach tego etapu, przeszukano cztery bazy danych pod kątem artykułów opublikowanych w latach 2016-2021 (Scopus, PubMed, Web Of Science i IEEE Xplore). Przegląd ograniczony został do artykułów opublikowanych od 2016 roku, ponieważ to w tym okresie nastąpił wzrost dostępności i jakości medycznych zbiorów danych zapoczątkowany przez ISIC Archive (*The International Skin Imaging Collaboration (ISIC)*, 2016) i Camelyon16 (Challenge., 2016), a także pojawienie się sieci U-Net (Ronneberger i in., 2015) zaprojektowanej pod segmentację obrazów medycznych. Rozpoczęcie przeglądu literatury od 2016 roku pozwoliło skupić się na najbardziej aktualnych i zaawansowanych rozwiązaniach w tym zakresie.

Strategia wyszukiwania oparta została o wytyczne *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA-ScR) (Tricco i in., 2018). Na rysunku 5.1(a) przedstawiono cztery klastry słów kluczowych i haseł przedmiotowych, tj. przedmiot badania, zadanie, metoda i rodzaj danych, gdzie:

- jako przedmiot badań określono rany (ang. *injuries*) z dodatkowym uwzględnieniem ang. *wounds*, które stanowią specyficzny rodzaj ran charakteryzujących się przerwaniem ciągłości skóry lub tkanki. Jak zauważyła autorka, w literaturze anglojęzycznej autorzy często stosują określenia *injuries* i *wounds* (również zamiennie), co stanowiło podstawę rozszerzenia słów kluczowych do dwóch pozycji;
- jako zadanie określono identyfikację (ang. *identification*), wykrywanie (ang. *detection*), klasyfikację (ang. *classification*) i rozpoznawanie (ang. *recognition*);
- jako metodę wyszukano określenia takie jak sztuczna inteligencja (ang. *artificial intelligence*), uczenie maszynowe (ang. *machine learning*), uczenie głębokie (ang. *deep learning*) oraz widzenie komputerowe (ang. *Computer Vision*);
- jako zestaw danych wybrano obrazy cyfrowe 2D.


Wszystkie wyniki wyszukiwania zostały zaimportowane do oprogramowania zarządzającego bibliografią Mendeley Desktop. Następnie jak pokazano na rysunku 5.1(b) usunięto duplikaty publikacji i spośród dostępnych wyników przejrano tytuły oraz abstrakty pod kątem ich dalszego uwzględnienia w przeglądzie, a następnie na tej podstawie dokonano kolejnej selekcji. Dodatkowo, zakwalifikowane artykuły naukowe musiały spełniać warunek publikacji w języku angielskim (z uwagi na brak dostępnych artykułów z wybranego zakresu w języku polskim), być co najmniej recenzowanymi artykułami naukowymi oraz korzystając z licencji Politechniki Warszawskiej na dostęp sieciowy do baz elektronicznych autorka musiała posiadać pełny dostęp do tekstu. W sumie wykluczono 455 artykułów, które nie były zgodne z

określonym zakresie poszukiwania. Ponadto do przeglądu włączono jeden artykuł z literatury cytowanej, opublikowany przed 2016 rokiem, oraz jeden artykuł z 2022 roku dołączony już po zakończeniu przeglądu i udostępniony autorce przez osobę ze środowiska naukowego. Ostatecznie, do szczegółowej analizy pełnych tekstów włączono 19 artykułów. Wybrane artykuły podzielone zostały na kategorie obrażeń:

- oparzenia (Abubakar i in., 2019; Abubakar, Ugail, & Bukar, 2020a, 2020b; Abubakar, Ugail, Smith, i in., 2020; Abubakar & Ugail, 2019; Badea i in., 2016; Chauhan i in., 2019; Chauhan & Goyal, 2020; Cirillo i in., 2019; Jiao i in., 2019; Kuan i in., 2017; Rostami, Niezgoda, i in., 2021; Suvarna i in., 2017; Yadav i in., 2019b);
- rany szarpane (rany postrzałowe są specyficzną formą ran szarpanych) (Oura i in., 2021);
- tkanka z obrażeniem (bez klasyfikacji według rodzaju obrażenia) (Anisuzzaman i in., 2022a; F. Li i in., 2018; Privalov i in., 2021; Song & Sacan, 2012)

W tabeli 5.1 przedstawiono podsumowanie istniejących rozwiązań podając wskaźnik Accuracy (%) jako metrykę porównawczą, ponieważ w większości omawianych artykułów była to jedyna wykazana metryka. W przypadku brak parametru Accuracy (%) podawano wynik dla innego parametru. Z dokonanego przeglądu wynikało, że tylko niektóre badania oparte zostały o metodę end-to-end CNN lub FCN do klasyfikacji obrażeń, a w większości zamiast tego stosowano inne podejścia np. SVM (ang. *Support-Vector Machines*) i dopiero na ostatnim etapie, używano typowych narzędzi uczenia maszynowego jako klasyfikatorów. Ponadto większość badaczy dysponowała małą liczbą obrazów co zdaniem autorki znacząco mogło wpływać na uzyskiwane wyniki. Należy jednak zauważyć, że dostępność medycznych zbiorów danych jest znacząco ograniczona z uwagi na wrażliwość zawartych tam informacji czy kwestie prawne.

Przeprowadzona analiza pozwoliła na zidentyfikowanie obszaru wartego szczególnej uwagi. Przegląd literatury wykazał, że istniejące badania dotyczące analizy obrażeń w dużej mierze koncentrowały się na analizie oparzeń oraz obrażeń w kontekście ich występowania, jednak proces klasyfikacji różnych typów obrażeń nie był szeroko badany. Wnioski te skłoniły autorkę do podjęcia badań mających na celu implementację metodologii uczenia głębokiego, w szczególności sieci w pełni konwolucyjnych (FCN), w celu stworzenia bardziej niezawodnego podejścia do detekcji i klasyfikacji obrazów przedstawiających różne rodzaje obrażeń. Celem badań przedstawionych w niniejszej rozprawie doktorskiej jest opracowanie systemu, który nie tylko zidentyfikuje obecność obrażeń, ale również precyzyjnie sklasyfikuje ich rodzaj, co może znacząco usprawnić proces diagnostyczny.



b)

Rysunek 5.1. Strategia i proces przeprowadzonego przeglądu literatury: (a) cztery klastry słów kluczowych i haseł przedmiotowych obejmujące przedmiot badań, zadanie, metodę oraz rodzaj danych, (b) diagram PRISMA ilustrujący etapy selekcji artykułów (źródło: opracowanie własne)

Tabela 5.1. Podsumowanie metod wykrywania obrażeń na obrazach 2D na podstawie przeprowadzonego przeglądu literatury


Ref.	Tematyka badania	Wykorzystany model	Zbiór danych	Liczba zdjęć w zbiorze	Accuracy (%)
(Abubakar, Ugail, Smith, i in., 2020)	Głębokość oparzenia	ResNet50, VGG16	obrazy z Internetu i szpitala	743	ResFeat50: 95.43, VggFeat16: 85.67
(Jiao i in., 2019)	Głębokość oparzenia	Mask R-CNN	obrazy ze szpitala Wuhan Hospital No. 3 i Tongren Hospital of Wuhan University	1150	R101A CNN: 82.04, IV2RA CNN: 83.02, R101FA CNN: 84.51
(Chauhan & Goyal, 2020)	Głębokość oparzenia	ResNet50, VGG16, VGG19	Zbiór danych Burn Images (B.I.) i Unseen Burn Images (UBI)	B.I.: 141, UBI: 63	91.53
(Abubakar i in., 2019)	Detekcja i klasyfikacja oparzenia	VGG16, VGG19, VGG-Face	obrazy ze szpitala Bradford, United Kingdom i Federal Teaching Hospital Gombe (FTHG) w Nigerii	brak danych	VGG-16: 98.750, VGG19: 97.560, VGG-Face: 95.208
(Abubakar, Ugail, & Bukar, 2020a)	Rozróżnienie oparzenia od zdrowej skóry dla różnych etnicznych przypadków	ResNet50	obrazy ze szpitala Bradford, United Kingdom i Federal Teaching Hospital Gombe (FTHG) w Nigerii	1360 obrazy dla rasy kaukaskiej (680 oparzenia, 680 skóra nieuszkodzona), 540 obrazy dla rasy afrykańskiej (270 oparzenia, 270 skóra nieuszkodzona)	Dla zbioru rasy afr.: 97.1, Dla zbioru rasy kauk.: 99.3
(Abubakar & Ugail, 2019)	Detekcja i klasyfikacja oparzenia	ResNet101	obrazy ze szpitala Bradford, United Kingdom	1360	99.5
(Oura i in., 2021)	Predykcja odległości postrzału	AIDeveloper open-source software	Symulowany zbiór danych na 19 ciałach świni	204	98
(Badea i in., 2016)	Klasyfikacja ciężkości oparzenia	ResNet	obrazy z oddziału chirurgii plastycznej kliniki pediatrycznej	611	65
(Kuan i in., 2017)	Klasyfikacja ciężkości oparzenia	CNN (brak szczegółów)	Własny zbiór danych	164	73.2
(Anisuzzaman i in., 2022b)	Rozpoznanie obrażenia	multimodality-based CNN	Zbiór danych AZH, Medetec wound database i AZHMT	AZH: 730, Medetec: 358, AZHMT: 1088	od 72.95 do 100 dla różnych eksperymentów i klas
(Cirillo i in., 2019)	Głębokość oparzenia	VGG16, GoogleNet, ResNet50, ResNet10	brak danych	23	90.54
(Chauhan i in., 2019)	Detekcja i klasyfikacja części ciała na której występuje oparzenie	ResNet50	obrazy z Internetu i innych dostępnych baz	109 oparzenia, 4981 skóra nieuszkodzona	93.58
(Abubakar, Ugail, & Bukar, 2020b)	Detekcja i klasyfikacja oparzenia i wrzodów	CNN (brak szczegółów)	obrazy z Internetu i szpitala	29 wrzody, 31 oparzenia	99.9

(Rostami, Niezgoda, i in., 2021)	Detekcja i klasyfikacja oparzenia	AlexNet	zbiór danych BIP_US (<i>Burns BIP_US Database</i> , 2018)	94	90.5
(Suvarna i in., 2017)	Klasyfikacja oparzenia	SVM, KNN DNN	obrazy z dostępów otwartych i szpitala Sri. Devaraju Arasu, Kollar, Karnataka, India	150 950	SVM: 85.0% - 92.5% KNN: 70% - 82.5% mIoU: 80.97% - 85.88%
(Song & Sacan, 2012)	Detekcja i klasyfikacja obrażenia		obrazy z Internetu i szpitala		MaxIoU: 81.32% - 86.40% Precision: 90.88% - 94.94%
(F. Li i in., 2018)	Detekcja i pomiar obrażeń	Mask R-CNN	brak danych	330	DC: 79.1% SEM: 0.042
(Privalov i in., 2021)	Detekcja i analiza obrażeń	CNN (with ReLU), SVM	baza danych New York University	650 (do segmentacji obrażeń); 3400 (do detekcji infekcji obrażeń)	95.3% -95.6%
(Yadav i in., 2019a)	Detekcja i klasyfikacja obrażenia	SVM, feature selection	zbiór danych BIP_US (<i>Burns BIP_US Database</i> , 2018)	74	82.43
Oznaczenia:			SEM - Standard Error of Mean,		
SVM – Support Vector Machine,			CNN - Convolutional Neural Networks,		
KNN – K-Nearest Neighbors algorithm,			ReLU - Rectified Linear Unit		
DNN – Deep Neural Network,			TL – Transfer Learning		
R-CNN - Region-based Convolutional Neural Network,			DCNN – Deep Convolutional Neural Network.		

Źródło: opracowanie własne

5.2. Uczenie głębokie w zadaniach segmentacji obrazów

Rozpoznawanie obiektów (ang. *object recognition*) opisuje zbiór powiązanych działań obejmujących identyfikację obiektów na obrazach cyfrowych. Jest to jedno z kluczowych zadań uczenia głębokiego (ang. *deep learning*) będącego działem informatyki zwanym sztuczną inteligencją (ang. *artificial intelligence*) (rysunek 5.2). Wyróżnia się trzy główne typy zadań związanych z rozpoznawaniem obiektów: klasyfikację (ang. *classification*), wykrywanie obiektów (ang. *object detection*) oraz segmentację (ang. *segmentation*) (rysunek 5.3).




Rysunek 5.2. Schemat przedstawiający hierarchię sztucznej inteligencji (źródło: opracowanie własne)



Rysunek 5.3. Rozpoznawanie obiektów – podział (źródło: opracowanie własne)

Klasyfikacja ma na celu przypisanie obrazu do jednej z predefiniowanych klas, takich jak człowiek, narzędzie, obrażenie, czy bardziej szczegółowe kategorie jak kobieta/mężczyzna/dziecko, broń biała/palna, podbiegnięcie krwawe/otarcie naskórka (rysunek 5.4(a)). Wykrywanie obiektów, znane również jako klasyfikacja z lokalizacją, jest bardziej zaawansowaną formą klasyfikacji. W tym przypadku algorytm nie tylko klasyfikuje obiekty,

ale również lokalizuje je na obrazie, rysując ramki ograniczające (ang. *bounding boxes*) wokół każdego obiektu (rysunek 5.4(b)). Kolejnym wyzwaniem pod względem złożoności jest segmentacja. Wyróżnia się dwa rodzaje segmentacji: segmentację semantyczną (ang. *semantic segmentation*) i segmentację instancji (ang. *instance segmentation*). Segmentacja semantyczna polega na przypisywaniu każdego piksela na obrazie do określonej klasy, tzw. klasyfikacja pikselowa (rysunek 5.4(c)). Segmentacja instancji obiektów ma na celu rozróżnienie różnych instancji tej samej klasy. Oznacza to, że na obrazie przedstawiającym grupę dzieci, każde dziecko, pomimo że należy do tej samej klasy, otrzyma oddzielną maskę (rysunek 5.4(d)) (Liu i in., 2020).



Rysunek 5.4. Przykłady zadań związanych z rozpoznawaniem obiektów: (a) klasyfikacja obiektów, (b) wykrywanie obiektów z lokalizacją (bounding boxes), (c) segmentacja semantyczna – klasyfikacja pikselowa, (d) segmentacja instancji – rozróżnienie poszczególnych instancji tej samej klasy (źródło: (Liu i in., 2020))

Należy zauważyć, że obraz cyfrowy reprezentowany jest przez dwuwymiarową macierz. Liczba wierszy i kolumn macierzy definiuje rozdzielczość obrazu w pionie i w poziomie. Natomiast każdy z jej elementów opisuje wartość pojedynczego punktu obrazu określanego jako piksel składający się z pewnej liczby bitów. W zależności od liczby bitów przypadających na piksel możemy wyróżnić cztery podstawowe typy obrazów: obraz binarny, obraz w skali szarości, obraz kolorowy RGB i grafika komputerowa (Sundararajan, 2017). Rozważając obraz cyfrowy w zadaniach analizy i rozpoznawania obiektów istotne są jego cechy (ang. *features*). Występująca konfiguracja pikseli dla danej cechy układa się w określone struktury takie jak krawędzie (ang. *edges*), kontury (ang. *contours*), narożniki (ang. *corners*) czy skupiska (ang. *blobs*). Do jej wykrycia (ang. *feature detection*) stosuje się odpowiednie detektory, przy

czym wykorzystując deskryptor można ją opisać¹⁰. Wyniki odpowiednio zastosowanego detektora powinny wskazywać (Russell & Norvig, 2020):

- wysokie prawdopodobieństwo dla pikseli należących do szukanych struktur;
- niskie prawdopodobieństwo dla pikseli nienależących do szukanych struktur.

Krawędzie (ang. *edges*) należą do najczęściej wykrywanej cechy. Są to linie proste lub krzywe pojawiające się na płaszczyźnie obrazu, gdzie występuje duża różnica w intensywności pikseli położonych blisko siebie. Wspomniane zmiany jasności pikseli mogą być spowodowane zmianami koloru, skali szarości lub tekstury obrazu. Wysoka dokładność wykrywania krawędzi oznacza, że detektor posiada zdolność do wykrywania konturów zbliżonych do rzeczywistych tym samym zmniejszając wykrywanie fałszywych. Najczęściej detekcja krawędzi wykorzystywana jest do ustalania relacji między różnymi obszarami cech np. segmentacji i rozpoznawania obrazu. Dlatego też precyzyjne detektory krawędzi powinny charakteryzować się wysoką odpornością w różnych warunkach obrazowania (np. różne pozycje kamery i różne rozdzielczości obrazowania kamery) oraz odpornością na różne rodzaje szumów (Jing i in., 2022).

Kontury (ang. *contours*) to linie lub krzywe reprezentujące lub ograniczające kształt lub formę obiektu widocznego w kadrze obrazu. Różnica pomiędzy krawędzią a konturem jest taka, że kontury zwykle dążą do zamknięcia i połączenia wszystkich ciągłych punktów wzdłuż granic o tym samym kolorze lub intensywności (Gong i in., 2018).

Narożniki (ang. *corners*) można zdefiniować jako środek obszaru zainteresowania (ang. *Region Of Interest*, ROI) o wysokiej średniej krzywiznie dużej i symetrycznej względem swojego środka. Innym, znacznie prostszym do zrozumienia jest określenie, że narożnikiem określa się przecięcie dwóch lub większej liczby krawędzi. Narożniki na obrazach reprezentują istotne informacje w opisie cech obiektu, które odgrywają kluczową i niezastąpioną rolę w zadaniach opierających się na ich skutecznym wykrywaniu m.in. rekonstrukcji 3D, dopasowania stereo, rozpoznania obiektów czy ich śledzenia (J. Wang & Zhang, 2018).

Skupiska (ang. *blobs*) to dowolny, inny wzór obrazu, który nie jest narożnikiem ani krawędzią, a jego piksele znacznie różnią się od swoich sąsiadów (np. połączony obszar pikseli o podobnym kolorze lub intensywności). Jednym z głównych powodów analizy skupisk jest dostarczenie dodatkowych informacji o regionach, które nie są uzyskiwane z detektorów

¹⁰ Temat ten poruszono również w rozdziale 4.1. *Detektory wykrywania cech charakterystycznych w zadaniu rekonstrukcji 3D powierzchni* w którym opisano wybrane detektory w kontekście modelowania 3D obiektów.


krawędzi lub detektorów narożników, jak również uzyskanie regionów zainteresowania do dalszego przetwarzania (Han & Uyyanonvara, 2016).

W przetwarzaniu obrazów, kluczową rolę odgrywa wyodrębnianie i analiza struktur celem reprezentacji wizualnej obrazu. W erze przed rozwojem głębokiego uczenia, cechy te były identyfikowane za pomocą zestawu filtrów górnoprzepustowych, takich jak np. filtry Gaussa i Sobela, które pomagają w identyfikacji konturów czy krawędzi. Rozwój głębokiego uczenia, przyniósł techniki, w których sztuczne sieci neuronowe uczą się samodzielnie rozpoznawać cechy na podstawie dużych zbiorów danych (O'Mahony i in., 2020). Tworzenie odpowiedniego zbioru w przypadku braku istniejącego jest oddzielnym problemem badawczym, który wymaga dużych nakładów pracy (Liu i in., 2020). Przykładem istniejących już zbiorów danych jest ImageNet zawierający ponad milion poetykietowanych obrazów (Deng i in., 2009). W kontekście segmentacji, jednym z często stosowanych podejść są sieci w pełni konwolucyjne zaprojektowane do segmentacji obrazów na poziomie pikseli. Dzięki FCN możliwe jest uzyskanie szczegółowych map segmentacji, które są wykorzystywane w różnych aplikacjach, takich jak diagnostyka medyczna (Emek Soylu i in., 2023).

5.2.1. Sieci w pełni konwolucyjne

Sieci w pełni konwolucyjne (ang. *Fully Convolutional Networks*, FCN) (Long i in., 2015) charakteryzują się zdolnością do analizy obrazów o dowolnym rozmiarze i generowania map segmentacji o tych samych wymiarach. Standardowa budowa przyjmuje postać skierowanego acyklicznego grafu warstw z których każda składa się z wielu filtrów (ang. *kernels*) (rysunek 5.5). Każdy filtr przesuwany jest po obrazie wejściowym lub mapie cech z poprzedniej warstwy, tworząc nową mapę cech charakterystycznych. Właśnie te kolejne warstwy konwolucyjne składają się na wielowarstwowy charakter sieci. Bezpośrednio po warstwach konwolucyjnych występuje warstwa aktywacji typu ReLU (ang. *Rectified Linear Unit*), która wprowadza nieliniowość do modelu, umożliwiając rozpoznawanie złożonych wzorców w analizowanych danych. Proces ten jest wspierany przez warstwy łączenia (ang. *pooling*), które redukują wymiarowość map cech poprzez wybór najbardziej znaczących cech w określonym obszarze. Jest to istotne zarówno dla zwiększenia efektywności obliczeniowej, jak i ograniczenia ryzyka przeuczenia się modelu. Aby odwrócić efekt redukcji wymiarowości spowodowany przez warstwy pooling, stosuje się warstwy dekonwolucyjne, które działają jako funkcje odwrotne do konwolucji, przekształcając zredukowane mapy cech z powrotem do rozmiaru przestrzennego obrazu wejściowego. Jest to niezbędne dla dokładnego odwzorowania

granic i segmentów obiektów. Ważnym elementem architektury sieci FCN są połączenia omijające (ang. *skip connections*), które przesyłają mapy cech z wcześniejszych warstw konwolucyjnych bezpośrednio do głębszych warstw poprzez próbkowanie w górę (ang. *upsampling*). Pozwala to na kombinację informacji lokalnej i globalnej, co poprawia precyzję lokalizacji i klasyfikacji obiektów. Ostateczna segmentacja obrazu jest realizowana w warstwie wyjściowej, która stosuje ostatnią warstwę konwolucyjną celem zredukowania liczby kanałów map cech do liczby klas segmentacji. Mapa wynikowa przechodzi przez warstwę softmax, która przypisuje każdemu pikselowi prawdopodobieństwo przynależności do jednej z klas (S. Khan i in., 2018; O'Mahony i in., 2020).




Rysunek 5.5. Architektura sieci w pełni konwolucyjnej (ang. *Fully Convolutional Networks*, FCN) określana jako metoda enkoder-dekoder. Enkoder zbiera informacje na temat obrazu wejściowego, a dekoder generuje maskę predykcji na podstawie cech zebranych w enkoderze (źródło: (<https://github.com/FisherShi/semantic-segmentation>))

Warstwy splotowe (konwolucji)

Głównym elementem sieci FCN jest wspomniana warstwa konwolucyjna (rysunek 5.6), która odpowiada za większość obciążenia obliczeniowego sieci. Warstwa ta składa się z trzech wymiarów: wysokości (h), szerokości (w) i głębokości (d). Głębokość, w tym przypadku, to liczba kanałów warstwy wejściowej, dla obrazu RGB jest to $h \times w \times 3$. Każda warstwa konwolucyjna tworzy siatkę o identycznych wymiarach co dane wejściowe, lecz z mniejszą wielkością każdego wymiaru. Zbudowana jest z neuronów wyposażonych w zestaw wag określanych mianem kernela (filtru). Wstępnie wyuczone filtry są zdolne do detekcji różnorodnych cech, takich jak krawędzie, tekstury czy kształty, co pozwala na rozróżnianie

różnych obiektów na obrazie. Podczas procesu konwolucji neurony wykonują operację mnożenia wartości pikseli przez odpowiednie wagi, a następnie sumują wyniki, tworząc mapy cech (ang. *feature map*), które są następnie wykorzystywane do dalszego przetwarzania w głębszych warstwach sieci. Mapa cech zwykle przybiera kształt prostokątny i określana jest jako pole recepcyjne. Niewielkie pole recepcyjne pozwala uzyskać dużą ilość informacji z danych wejściowych, zawierając wysoce lokalne funkcje, co umożliwia utworzenie głębszej architektury. W celu uzyskania bardziej uniwersalnych cech (większej ich liczby) obrazu dopuszczalne jest użycie wielu map cech neuronów w ramach jednej warstwy (S. Khan i in., 2018).

FCN składa się z wielu warstw konwolucyjnych. Pierwsza warstwa odpowiedzialna jest za tworzenie cech niskiego poziomu, takich jak krawędzie. W kolejnych warstwach sieć stopniowo rozpoznaje coraz bardziej złożone cechy. Taki sposób wyłaniania cech określany jest jako ekstrakcja cech (Omiotek, 2021).



Rysunek 5.6. Budowa warstwy konwolucyjnej dla obrazu RGB. Warstwa ta wykorzystuje filtry (kernels) do detekcji cech, takich jak krawędzie, tekstury czy kształty, tworząc mapy cech (ang. *feature maps*), które są następnie przetwarzane w głębszych warstwach sieci (źródło: (Omiotek, 2021))

Warstwa normalizacji

Warstwa normalizacji pełni kluczową rolę w procesie przetwarzania danych wejściowych i przygotowania ich do dalszej analizy. Zasadniczo odnosi się do procesu skalowania danych wejściowych do określonego zakresu w celu poprawy stabilności i wydajności procesu uczenia sieci. Istnieją różne metody normalizacji, a jedną z nich jest normalizacja wsadowa (ang. *batch*

normalisation). Oparta jest o normalizację średniej i wariancję aktywacji warstwy, aby przestrzegać rozkładu jednostkowego Gaussa, pomagając w zwalczaniu problemu zwanego *internal covariance shift*, który odnosi się do zmiany rozkładu aktywacji każdej warstwy w trakcie trenowania sieci, gdy parametry są aktualizowane. Jeżeli rozkład aktywacji się zmienia, może to spowolnić proces uczenia i uczynić go mniej stabilnym. Normalizacja batchowa przyspiesza uczenie sieci, zapobiegając zanikaniu gradientów i nasyceniu aktywacji. W ten sposób proces uczenia staje się bardziej stabilny i możliwy do przeprowadzenia przy wyższych współczynnikach uczenia (Szeliski, 2022)

Funkcja aktywacji

Wygenerowana mapa cech jest przetwarzana przez funkcję aktywacji ReLU (ang. *Rectified Linear Unit*), która wprowadza nieliniowość do procesu uczenia. Zasada działania ReLU oparta jest o prostą zasadę, gdzie, jeżeli wartość wejściowa jest dodatnia, funkcja przepuszcza ją bez zmian, natomiast jeżeli jest ujemna, zastępuje ją zerem (S. Khan i in., 2018):

$$f(x) = x^+ = \max(0, x) \quad (5.1)$$

gdzie:


x – oznacza wejście neuronu.

To proste podejście umożliwia sieci naukę złożonych wzorców danych, ponieważ aktywacje nie są ograniczone do liniowej przestrzeni. ReLU pomaga również w rozwiązaniu problemu zanikającego gradientu, który może wystąpić podczas uczenia głębokich sieci neuronowych, ponieważ pochodna funkcji dla dodatnich wartości wejściowych jest stała (i równa 1), co sprzyja szybszej i bardziej efektywnej konwergencji podczas treningu (S. Khan i in., 2018).

Warstwy łączące (pooling)

Na obrazie cyfrowym piksele występujące w swoim bliskim sąsiedztwie oscylują w podobnych wartościach przez co warstwy konwolucyjne również generują podobne wartości w wyjściach. Rezultatem jest uzyskanie wielu informacji o niewielkim wpływie. W przypadku operacji łączenia (ang. *pooling*) poprzez redukcję wymiarów pola recepcyjnego mapy cech zmniejszana jest również liczba parametrów do trenowania sieci. W efekcie znacząco skracany jest czas działania sieci, model zostaje uproszczony oraz w niektórych przypadkach *pooling* pomaga walczyć z przeuczeniem (ang. *overfittingiem*). Zasadniczo wyróżniamy dwa rodzaje warstw łączenia: warstwę maksymalizującego łączenia (ang. *max pooling layer*) oraz warstwę uśredniającego łączenia (ang. *average pooling layer*). W przypadku funkcji maksymalizującego łączenia, wartość maksymalna wybierana jest z wartości pikseli w obrębie

poła recepcyjnego, natomiast w przypadku funkcji uśredniającego łączenia obliczana jest średnia ze wszystkich wartości pikseli w danym połu (rysunek 5.7) (S. Khan i in., 2018; Szeliski, 2022).



Rysunek 5.7. Redukcja wymiarów pola recepcyjnego mapy cech: (a) funkcja wybiera największą wartość z macierzy 2×2 w mapie danych wejściowych, następnie zmniejsza rozmiar macierzy dwukrotnie przypisując jej tę wartość, (b) liczona jest średnia wartość z macierzy 2×2 , następnie dla zmniejszonego rozmiaru przypisywana jest obliczona wartość średnia (źródło: opracowanie własne)


Warstwy dekonwolucyjne

W tradycyjnych sieciach konwolucyjnych (CNN), warstwa w pełni połączona (ang. *fully connected layer*) jest zwykle umieszczana na końcu sieci po kilku warstwach splotowych i łączących. Ta warstwa łączy całą objętość wejściową z poprzednich warstw splotu i łączenia, lub wszystkie neurony z poprzedniej w pełni połączonej warstwy, z każdym pojedynczym neuronem w swojej warstwie. Ze względu na to, że w pełni połączona warstwa zawiera większość parametrów sieci, często prowadzi to do przeuczenia (ang. *overfitting*). Ponadto, jednym z głównych problemów w pełni połączonych warstw jest utrata informacji przestrzennej, kiedy sieć przechodzi przez te warstwy. Wszystkie neurony otrzymują aktywację od wszystkich neuronów wejściowych, co znacznie utrudnia efektywne uczenie się sieci dla zadań takich jak segmentacja semantyczna. W przypadku sieci FCN warstwę w pełni połączoną zastąpiła warstwa dekonwolucyjna (ang. *deconvolutional layer*). Głównym celem warstwy dekonwolucyjnej jest przywrócenie utraconych informacji przestrzennych i zwiększenie rozmiaru danych wyjściowych do wymiarów odpowiadających oryginalnemu obrazowi wejściowemu. To umożliwia dokładne lokalizowanie i klasyfikowanie obiektów na obrazach w zadaniach segmentacji semantycznej. Warstwy dekonwolucyjne wykonują próbkowanie map cech z poprzedniej warstwy (tzw. *upsampling*). Jedną z metod próbkowania mapy cech jest interpolacja danych wejściowych, gdzie wprowadzane są dodatkowe piksele pomiędzy istniejące piksele na mapie cech. Techniki interpolacji mogą obejmować najbliższe sąsiedztwo,

interpolację liniową lub inne zaawansowane metody interpolacji, takie jak interpolacja sześcienna (Maggiori i in., 2016).

Transfer learning

Z uwagi na złożoność konwolucyjnych sieci neuronowych i potrzebę dużej ilości danych uczących, stosuje się transfer learning (rysunek 5.8) celem uniknięcia trenowania ich od samego początku. Ponieważ posiadanie wystarczająco dużej ilości danych jest rzadkością, zwłaszcza w dziedzinie medycyny, powszechną praktyką jest ponowne wykorzystanie wag z modeli wstępnie wytrenowanych na dużych zbiorach danych, takich jak wspomniany wcześniej ImageNet. W czasie uczenia sieci FCN, następuje implementacja wag enkodera tzw. *backbone* (np. ResNet50, EfficientNetB3). Wstępnie wytrenowany *backbone* zapewnia solidny fundament, który można dostosować do nowego zadania, często poprzez trening tylko końcowych warstw sieci tzw. *fine-tuning*. Enkoder można dostosować do danego zadania, np. zmieniając wymiary neuronów wyjściowych (aby zaspokoić inną liczbę klas), modyfikację funkcji straty (softmax) i uczenie się końcowych kilku warstw od początku. Jednak w większości przypadków, zwykle wystarcza uczenie się końcowych 2-3 warstw (Azizpour i in., 2016; S. Khan i in., 2018).



Rysunek 5.8. Przykład transfer learningu do zadania segmentacji semantycznej gdzie z nauczonego modelu CNN z obliczonymi parametrami (obrazek górny) przekazywane są wagi do modelu FCN (obrazek dolny) (źródło: (Imad i in., 2021))

5.2.2. Przykładowe architektury sieci


Jak wspomniano wcześniej metody głębokiego uczenia do przetwarzania obrazów przyczyniły się do znaczących osiągnięć w dziedzinie widzenia komputerowego. W szczególności sieci neuronowe wyznaczają najnowocześniejsze rozwiązania w zadaniach segmentacji semantycznej. Najskuteczniejsze architektury przeznaczone do rozwiązywania zadań tego typu są oparte na enkoderze i dekodерze. Enkoder stanowi zwykle wstępnie wytrenowana sieć klasyfikacyjna, natomiast dekodер ma semantycznie rzutować cechy dyskryminacyjne z enkodera na przestrzeń pikseli, aby uzyskać gęstą klasyfikację każdego piksela na obrazie wyjściowym. Część z istniejących architektur FCN powstała z myślą o rozwiązywaniu zadań na konkretnych zbiorach danych, w tym na obrazach medycznych (S. Khan i in., 2018). Poniżej omówiono trzy sieci wykorzystane jako dekodер (U-Net, FPN, LinkNet) oraz dwa przykłady sieci bazowych stanowiących enkoder (ResNet50, EfficientNetB3), których zastosowanie przebadano w ramach niniejszej pracy.

U-Net


Sieć U-Net (rysunek 5.9) opublikowana została w 2015 roku (Ronneberger i in., 2015) i stała się jedną z najbardziej wpływowych architektur w dziedzinie segmentacji semantycznej. Początkowo została przedstawiona jako architektura sieci konwolucyjnej do segmentacji obrazów biomedycznych jednak z czasem jej zastosowanie zostało rozszerzone na inne dziedziny. Z punktu widzenia pracy na obrazach medycznych należy zauważyć, że sieć ta jest efektywna w uczeniu się nawet na stosunkowo małych zbiorach danych. Z punktu widzenia zadań z dziedziny medycyny jest to istotne z uwagi na ograniczony dostęp do dużych zbiorów danych.

Architektura U-Net charakteryzuje się unikalną strukturą enkodera-dekodera w kształcie litery U, która jest podzielona na dwie główne fazy: kontrakcji tzw. enkodera i ekspansji tzw. dekodera. Ścieżka kontrakcji (rysunek 5.10(a)) budowę przypomina tradycyjną architekturę sieci CNN. Zawiera ona wielokrotność dwóch operacji konwolucji z których każda stosuje filtr konwolucyjny, zaczynając od oryginalnego obrazu poddanego funkcji aktywacji ReLU. Obraz jest następnie czterokrotnie próbkowany w dół (ang. *downsampling*) za pomocą funkcji *max pooling*, co ma na celu podwojenie liczby map cech na każdym etapie. To przetwarzanie wstępne pozwala na ekstrakcję istotnych cech na różnych poziomach złożoności. W ścieżce ekspansji (rysunek 5.10(b)) następuje odwrócenie procesu z fazy pierwszej, gdzie obraz jest stopniowo powiększany do oryginalnych wymiarów (ang. *upsampling*), a cechy z fazy kodera są łączone z aktualnymi cechami przez połączenia określone jako przeskakujące lub pomijające

(ang. *skip connections*). Te połączenia są kluczowe, ponieważ umożliwiają bezpośrednie przekazywanie informacji z wyższych poziomów szczegółowości do warstw dekodujących pomagając w odzyskiwaniu lokalnych informacji podczas procesu segmentacji. Dzięki połączeniom przeskakującym, sieć U-Net jest w stanie zachować detale na poziomie pikseli, co jest kluczowe w precyzyjnej segmentacji obrazów (Rostami, Anisuzzaman, i in., 2021). Finalnie, warstwa końcowa sieci, zwykle splot 1×1 , mapuje zgromadzone cechy na obraz segmentacji, co pozwala na precyzyjne określenie granic obiektów w obrazie.




Rysunek 5.9. Przykład architektury sieci U-Net, podzielonej na część enkodera (po lewej) i dekodera (po prawej). Niebieskie prostokąty odpowiadają wielokanałowej mapie cech, gdzie liczba kanałów oznaczona jest nad polem, natomiast rozmiar x-y jest podany w dolnym lewym rogu. Białe pola reprezentują skopiowane mapy cech (źródło: (Ronneberger i in., 2015))



Rysunek 5.10. Fragmenty architektury sieci U-Net: (a) ścieżka enkodera zbudowana jest z czterech bloków w skład których wchodzi: dwie operacje konwolucji 3×3 i funkcja aktywacji ReLU (oznaczone niebieskimi strzałkami) i operacja max pooling 2×2 (oznaczona czerwoną strzałką), (b) pomiędzy ścieżką enkodera i dekodera umieszczony jest blok analogiczny do bloku ze ścieżki enkodera z tą różnicą, że nie występuje tu operacja max pooling, (c) ścieżka dekodera zbudowana jest z czterech bloków w skład których wchodzi operacje: dekonwolucji 2×2 (oznaczone zielonymi strzałkami), zwiększającej wymiary mapy cech. Mapy cech ze ścieżki enkodera są kopiowane i przycinane, a następnie łączone z odpowiadającymi im mapami w ścieżce dekodera (oznaczone szarymi strzałkami). Po każdym łączeniu następuje seria dwóch konwolucji 3×3 z aktywacją ReLU (oznaczone niebieskimi strzałkami) (źródło: (Ronneberger i in., 2015))

Feature Pyramid Network (FPN)


FPN to zaawansowana architektura sieci neuronowej do semantycznej segmentacji obrazów z 2017 roku (Lin i in., 2017), która zainspirowana została przez budowę sieci U-Net. FPN (rysunek 5.11) rozpoczyna się od ścieżki określanej jako „od ogółu do szczegółu” tzw. *bottom-up*, przetwarzającej i zmniejszającej rozmiary obrazu wejściowego za pomocą warstw konwolucyjnych i łączących. Wyniki z ostatniej warstwy każdego etapu są następnie kierowane do odpowiedniego poziomu piramidy. Następnie w ścieżce określanej jako „od szczegółu do ogółu” tzw. *top-down* rozpoczynającej się od najgłębszej warstwy (o najniższej rozdzielczości i najwyższym poziomie semantyki) cechy są stopniowo interpolowane do wyższych rozdzielczości, przy czym każdy poziom cech jest łączony z odpowiednim poziomem ze ścieżki *bottom-up* za pomocą operacji sumowania. Dzięki wykorzystaniu *lateral connections*, które integrują cechy ze ścieżki *bottom-up* i *top-down* cechy na każdym poziomie mają informacje zarówno o wysokim poziomie semantyki, jak i wysokiej rozdzielczości (Lin i in., 2017).



Rysunek 5.11. Przykład architektury sieci FPN, gdzie po lewej stronie (ścieżka *bottom-up*) widoczne są cztery poziomy map cech odpowiadające kolejnym etapom sieci. Wraz z każdym poziomem następuje przeskalowanie o 2 w kolejnych blokach w stosunku do obrazu wejściowego. Końcowa warstwa, mająca najwięcej cech, przekazywana jest do ścieżki *top-down* i zostaje poddana konwolucji 1 x 1, w celu redukcji wymiarów kanałów (źródło: (Lin i in., 2017))

LinkNet

Inna popularna architektura do semantycznej segmentacji obrazów oparta na U-Net to sieć LinkNet z 2017 roku (Chaurasia & Culurciello, 2017) (rysunek 5.12). Podobnie jak U-Net, LinkNet posiada strukturę w kształcie litery U, lecz wprowadza znaczące modyfikacje poprzez zastąpienie standardowych operacji konwolucyjnych blokami rezydualnymi (ang. *residual blocks*) na każdym etapie enkodera i dekodera. Takie podejście nie tylko ułatwia uczenie głębszych sieci dzięki redukcji problemu zanikającego gradientu, ale także poprawia propagację cech, co może skutkować bardziej precyzyjnym odwzorowaniem cech w procesie dekodowania. W kontekście połączeń przeskakujących lub pomijających (ang. *skip connections*), LinkNet rezygnuje z tradycyjnej konkatenacji na rzecz operacji dodawania, co pozwala na lepsze zachowanie informacji przestrzennych zgubionych podczas licznych operacji *downsamplingu* w enkoderze. Innowacja LinkNetu polega również na bezpośrednim przekazywaniu wejść każdej warstwy enkodera do odpowiedniego dekodera, umożliwiając efektywne odzyskiwanie utraconych informacji przestrzennych. Współdzielenie wiedzy między enkoderem a dekodern na każdym etapie pozwala na redukcję liczby parametrów w dekodernie, co przekłada się na ogólnie bardziej wydajną sieć. Dzięki tym unikalnym cechom, LinkNet przewyższa inne zaawansowane technologie segmentacji, oferując szybsze przetwarzanie oraz działanie w czasie rzeczywistym, co czyni ją idealnym rozwiązaniem dla aplikacji wymagających natychmiastowej odpowiedzi, takich jak systemy wizyjne pojazdów autonomicznych czy zastosowania w rzeczywistości rozszerzonej (Chaurasia & Culurciello, 2017).




Rysunek 5.12. Przykład architektury sieci LinkNet, gdzie *conv* oznacza operację splotu, a *full – conv* pełny splot. Symbol /2 wskazuje na operację redukcji rozmiaru o współczynnik 2, realizowaną przez splot z wartością *stride* równą 2, co oznacza przesunięcie jądra o dwa piksele po każdym jego zastosowaniu. Analogicznie, * 2 oznacza operację zwiększania rozmiaru o ten sam współczynnik. Między warstwami konwolucyjnymi stosowana jest normalizacja i funkcja aktywacji ReLU. Lewa strona schematu to koder, zaczynający się od bloku początkowego z operacją splotu o jądrze 7×7 i przesunięciu 2, oraz przestrzennym max poolingiem na obszarze 3×3 , także z przesunięciem 2. Koder zawiera kolejne bloki rezydualne. Prawa część schematu prezentuje dekoder (źródło: (Chaurasia & Culurciello, 2017))

ResNet50

Sieć rezydualna ResNet została przedstawiona w 2015 roku i opublikowana w 2016 (He i in., 2016) mając na celu ulepszenie procesu trenowania bardzo głębokich sieci neuronowych poprzez wprowadzenie koncepcji reformulowania warstw jako uczenia się funkcji rezydualnych (resztkowych), a nie funkcji niereferencyjnych. W tradycyjnych sieciach CNN każda warstwa próbuje bezpośrednio nauczyć się docelowej reprezentacji danych. Natomiast w sieciach rezydualnych, każda warstwa zamiast tego, uczy się pewnej różnicy (rezydium) między wejściem a docelową reprezentacją. Oznacza to, że zamiast próbować nauczyć się bezpośrednio docelowego wyniku, sieć uczy się, jak ta różnica powinna zostać zastosowana do danych wejściowych w taki sposób, aby zbliżyć je do pożądanego wyniku. Dzięki takiemu podejściu, sieci rezydualne mogą efektywniej trenować bardzo głębokie modele, ponieważ znacznie łatwiej i szybciej jest optymalizować rezydua niż bezpośrednio całą funkcję (Tang i in., 2021).

ResNet50 stanowi 50-warstwowy wariant sieci ResNet wytrenowany na podstawie ponad 1 miliona obrazów z ogólnodostępnej bazy ImageNet. W literaturze, sieć ResNet50 wielokrotnie zestawiana była w połączeniu z siecią U-Net uzyskując wysokie wyniki w zadaniu segmentacji obrazu (Tang i in., 2021). Schemat działania wielowarstwowej sieci pokazano na rysunku 5.13. Sieć zbudowana jest z 4 bloków z czego pierwszą warstwę sieci stanowi obraz wejściowy, który konwertowany jest do odpowiednich rozmiarów. Każdy z bloków, poza ostatnim, składa się z warstw konwolucyjnych (łącznie 48 z 50 warstw z których zbudowana jest sieć stanowią warstwy konwolucyjne). Po każdej konwolucji następuje normalizacja (ang. *batch normalisation*), a następnie funkcja aktywacji. Z kolei pomiędzy poszczególnymi blokami występują połączenia przeskakujące (ang. *skip connections*), które umożliwiają przyspieszenie procesu uczenia oraz rozwiązują problem znikającego gradientu (He i in., 2016).



Rysunek 5.13. Architektura sieci ResNet50 (źródło: (He i in., 2016))

EfficientNetB3

Sieć EfficientNet przedstawiona została w 2019 (Tan & Le, 2019) roku jako innowacyjne podejście stosujące prostą jednak skuteczną metodę skalowania w trzech wymiarach (ang. *compound scaling*). W tradycyjnych sieciach CNN skalowany jest tylko jeden wymiar sieci, natomiast EfficientNet stosując złożony współczynnik jednolicie skaluje wszystkie trzy wymiary obrazu: głębokość (oznaczającą ilość warstw w sieci), szerokość (odnoszącą się do liczby kanałów w warstwach) i rozdzielczość (dotyczącą rozmiaru obrazu wejściowego) (Tan & Le, 2019):

$$\begin{aligned} d &= \alpha^\varphi \\ w &= \beta^\varphi \end{aligned} \tag{5.2}$$

$$r = \gamma^\varphi$$

$$\alpha \times \beta^2 \times \gamma^2 \approx 2$$

$$\alpha \geq 1, \beta \geq 1, \gamma \geq 1$$

gdzie:

α – skalowanie głębokości;


β – skalowanie szerokości;

γ – skalowanie rozdzielczości;

φ – globalny współczynnik skalowania (zmienny w zależności od wariantu sieci EfficientNetB0 do EfficientNetB7).

Każdy z rodzajów sieci EfficientNet (B1 do B7) jest wariantem stopniowo zwiększającym swój rozmiar, w zależności od ustalonych wymagań i określonych ograniczeń obliczeniowych. Jednak, architektura i sposób działania każdego z modeli jest podobny. W pierwszej kolejności następuje przetworzenie obrazów wejściowych przez początkowe warstwy konwolucyjne. Kolejno, próbki przepływają przez ciąg bloków *MBConv*, które są wyposażone w moduł *SE* (rysunek 5.14). Na końcu tego etapu, dane przechodzą przez dodatkową warstwę konwolucyjną, po której następuje zastosowanie globalnej warstwy uśredniającej. W tej warstwie dla każdego kanału dokonuje się redukcji przestrzennych wymiarów do jednej wartości średniej. Następnie, ta średnia jest kierowana do warstwy w pełni połączonej, która odpowiada za ostateczną klasyfikację obrazu (Tan & Le, 2019).

W przypadku sieci ResNet wyższą dokładność uzyskuje się poprzez zwiększenie głębokości sieci, natomiast EfficientNet poprzez potrzebę stałego, manualnego dostosowywania parametrów (wymiarów) pozwala na uzyskanie wyższej dokładności (Yin i in., 2022; T. Zhou i in., 2021).



Rysunek 5.14. Architektura sieci EfficientNetB3 (źródło: (Kashevnik & Ali, 2022))

5.3. Podsumowanie

W rozdziale przedstawiono wykorzystanie głębokich sieci neuronowych w zadaniu segmentacji obrazów medycznych, ze szczególnym uwzględnieniem analizy obrazów zewnętrznych. Jako kluczowe narzędzie wskazano sieci w pełni konwolucyjne (FCN), które umożliwiają efektywną segmentację semantyczną poprzez przypisanie każdego piksela obrazu do odpowiedniej klasy.

Przeprowadzony w 2021 roku systematyczny przegląd literatury, obejmujący lata 2016-2021 i zgodny z wytycznymi PRISMA-ScR, pozwolił zidentyfikować główne trendy badawcze oraz istniejące luki w obszarze automatycznej klasyfikacji obrazów. Analiza wykazała, że dotychczasowe badania koncentrowały się głównie na oparzeniach, podczas gdy kompleksowa klasyfikacja różnych typów obrazów pozostawała obszarem wymagającym dalszych badań. Ten przegląd stanowił podstawę do wyznaczenia kierunku badań przedstawionych w rozprawie oraz selekcji odpowiednich architektur sieci do przeprowadzenia eksperymentów.

W rozdziale szczegółowo omówiono ogólną budowę architektury sieci FCN, przedstawiając jej fundamentalne komponenty: warstwy splotowe, funkcje aktywacji, warstwy łączące (pooling) oraz warstwy dekonwolucyjne. Szczególną uwagę poświęcono koncepcji transfer learningu, podkreślając jej kluczowe znaczenie w kontekście ograniczonej dostępności medycznych zbiorów danych, co stanowi powszechny problem w zastosowaniach medycznych.

Ostatnia część rozdziału zawiera szczegółowy opis wybranych architektur sieci, w tym dekodérów (U-Net, FPN, LinkNet) oraz enkoderów (ResNet50, EfficientNetB3), których praktyczne zastosowanie zostało przedstawione w części eksperymentalnej rozprawy. Każda z tych architektur została przeanalizowana pod kątem swojej budowy, zasady działania oraz specyficznych cech wyróżniających, co stanowi teoretyczną podstawę do dalszych badań eksperymentalnych.

6. Struktura i sekwencja przeprowadzonych badań

Jak wspomniano we wcześniejszych rozdziałach, medycyna sądowa skoncentrowana jest głównie na kompleksowej analizie pacjentów, u których nie stwierdza się funkcji życiowych. Jedną z przeprowadzanych analiz jest analiza obrażeń ujawnionych na powłokach ciała człowieka. Diagnostykę obejmującą rozpoznanie typu obrażenia, jego umiejscowienia na ciele, barwy i wymiarów przeprowadza się zwykle w czasie rzeczywistym podczas sekcji zewnętrznej zwłok. Badanie, niejednokrotnie przeprowadza się w ograniczonym zasobie czasowym, a analiza poddana jest subiektywnej ocenie oraz doświadczeniu lekarza medycyny sądowej. Czynniki te stwarzają ryzyko wystąpienia błędu, pominięcia istotnych informacji czy też zapisu ich niewystarczającej ilości. Ponadto, praktyka wskazuje na potrzebę posiadania cyfrowej dokumentacji możliwej do analizy nawet w przypadkach wznowienia postępowania, gdyż dostęp do zwłok wymagałby ekshumacji. Na gruncie rozważań przeprowadzonych w niniejszej rozprawie, autorka zauważa potencjał *wykorzystania wybranych algorytmów uczenia głębokiego umożliwiając automatyczną detekcję i klasyfikację obrażeń ciała na podstawie zdjęć post-mortem a opracowana metodyka ich zapisu na wirtualnych modelach 3D ciała automatyzuje proces badania obrażeń w diagnostyce sądowej* (jak zostało określone w tezie rozprawy).

6.1. Informacje o kwestiach etycznych

Planowane badania nie stanowią eksperymentu medycznego w rozumieniu art. 21 ust. 1 ustawy o zawodach lekarza i lekarza dentysty (Ustawa z dnia 5 grudnia 1996 r.) i nie wymagają uzyskania opinii Komisji Bioetycznej przy Warszawskim Uniwersytecie Medycznym, o której mowa w art. 29 ust. 1 ww. ustawy. Ponadto utworzone zbiory danych nie zostały dotychczas opublikowane z uwagi na trwające postępowania sądowe, a selektywnie opublikowane materiały zostały w pełni zanonimizowane.

6.2. Koncepcja wykorzystania multimodalnych metod do analizy obrażeń na obrazach post-mortem

W niniejszej rozprawie doktorskiej przyjęta koncepcja badań podzielona została na pięć części zmierzających do udowodnienia, postawionej w pracy tezy. Zamiarem autorki było

przedstawienie możliwości wykorzystania nowoczesnych technologii cyfrowych w procesie interpretacji obrazów znajdujących się na powłokach ciała ofiary, zidentyfikowania krytycznych priorytetów w zakresie zaproponowanych podejść oraz zbadaniu ich wpływu na praktyczny wymiar pracy lekarza medycyny-sądowej. W przyszłości zaplanowano integrację rozpoczętych badań zmierzającą do utworzenia spójnego systemu TIPPI (ang. *Targeted Injury Post-mortem Perception and Identification system*). Plan badań przedstawiono na rysunku 6.1.


Pierwszą część badań przeprowadzonych w ramach niniejszej rozprawy rozpoczyna etap pozyskania danych. Analiza literatury wykazała, że obecnie nie istnieje upubliczniony zbiór danych zawierający obrazy post-mortem potrzebne do realizacji zaplanowanego zagadnienia badawczego. Brak adekwatnego zbioru danych stworzył konieczność jego opracowania w celu spełnienia zaplanowanych eksperymentów i specyficznych wymagań badawczo-aplikacyjnych.

Druga część badań stanowi zbadanie możliwości automatycznego modelowania 3D w procesie pozyskiwania cyfrowej dokumentacji ofiary. Z założenia eksperyment przeprowadzony został z wykorzystaniem algorytmu SfM-MVS zaimplementowanego w komercyjnym oprogramowaniu Agisoft Metashape Professional. W ten sposób uzyskując cyfrowy model 3D ciała ludzkiego na podstawie obrazów post-mortem.

Trzecia część badań obejmuje wykorzystanie sieci w pełni konwolucyjnych (FCN) w zadaniu segmentacji semantycznej obrazów. W ramach zaplanowanego działania skupiono się na dwóch rodzajach obrazów zewnętrznych: otarciach naskórka i podbiegnięciach krwawych. Celem jaki planowano osiągnąć było wykazanie, że wykorzystanie pewnych modeli uczenia głębokiego może doprowadzić do detekcji i klasyfikacji obrazów stanowiąc przykład nieinwazyjnej diagnostyki pośmiertnej.

Czwarta część badań poświęcona została integracji wyników uzyskanych we wcześniejszych etapach. W tej części eksperymentu dokonano próby integracji wyników z części drugiej (II) z częścią trzecią (III) poprzez wskazanie lokalizacji rozpoznanych obrazów przez sieci w pełni konwolucyjne do segmentacji semantycznej na fotogrametrycznym modelu 3D stanowiącym cyfrową dokumentację medyczną ofiary.

Piąta część badań swym zakresem objęła analizy morfometryczne i morfologiczne obrazów, zarówno w przestrzeni 2D jak i 3D. Do tego celu wykorzystano eksperymenty na macierzach konwolucji oraz przetworzenia na modelach 3D.



Rysunek 6.1. Schemat planowanych badań zawartych w rozprawie doktorskiej (źródło: opracowanie własne)

7. Charakterystyka danych źródłowych – CZĘŚĆ I badań

Badania prowadzone w ramach niniejszej rozprawy doktorskiej wymagały dostępu do dwóch kluczowych rodzajów danych, niezbędnych do realizacji założonych celów badawczych. Pozyskanie danych stanowiło pierwszą część badań, która zajęła autorce około roku, a jej efektem było powstanie unikatowej, autorskiej bazy danych z której następnie wydzielono dwa podzbiory:

Zbiór danych 3D-TIP (ang. *3D-Tissue-Injuries of Post-mortem*)

Zbiór stanowiący sieć obrazów post-mortem przeznaczoną do wygenerowania modeli 3D w pozycji ułożenia ciała *prone* (twarzą skierowaną do dołu) i *supine* (twarzą skierowaną do góry). Celem zapewnienia wysokiej dokładności w odwzorowaniu modeli 3D, zastosowano osnowę fotogrametryczną w postaci czterech odcinków skalujących. Dzięki niej możliwe stało się ustanowienie odniesienia dla wszystkich zdjęć, co zapewniło spójność i skalowalność modeli, a ponadto osnowa pozwoliła na precyzyjne odwzorowanie wymiarów i proporcji ciała.

Zbiór danych 2D-TIP (ang. *2D-Tissue-Injuries of Post-mortem*)

Zbiór obejmujący obrazy przedstawiające dwa rodzaje obrażeń: podbiegnięcia krwawe oraz otarcia naskórka. Te dwa typy obrażeń zostały wybrane ze względu na ich częstość występowania oraz znaczenie w kontekście medycyny sądowej. Celem wydzielenia takiego podzbioru była konieczność poetykietowania występujących obrażeń, co umożliwiło ich wykorzystanie w procesie uczenia maszynowego.

7.1. Protokół pozyskania danych

Dane zebrane do utworzenia zbioru danych pozyskane zostały na terenie Zakładu Medycyny Sądowej Warszawskiego Uniwersytetu Medycznego w okresie od 05/07/2021 r. do 29/08/2022 r. Dane pozyskano przy wykorzystaniu kamery niemetrycznej Canon EOS 5D Mark II (Tokio, Japonia) z obiektywem stałogniskowym Canon Lens EF 24 mm i Canon Lens EF 35 mm. Rysunek 7.1 przedstawia wykorzystany sensor oraz akcesoria, a także wskazuje specyfikację kamery i dobrane parametry do przeprowadzenia pomiarów.




Model kamery niemetrycznej	Canon EOS 5D Mark II	
Typ sensora	36 × 24 mm CMOS	
Rozdzielczość obrazu	5616 × 3744 pikseli	
Format obrazu	JPG i RAW (.cr2)	
Rozmiar piksela obrazowego	0.006 mm / pix	
Obiektyw	Canon Lens EF 24 mm	Canon Lens EF 35 mm
ISO	200	200
Przysłona	f3.5	f4
Czas ekspozycji	1/60	1/60

Rysunek 7.1. Aparatura badawcza wykorzystana do utworzenia bazy danych: sensor, akcesoria oraz specyfikacja kamery i dobrane parametry do przeprowadzenia pomiarów (źródło: opracowanie własne)

Rysunek 7.2. przedstawia szczegółowy schemat stanowiska pomiarowego na którym przeprowadzono zebranie danych, gdzie:

- 1 – na każdym stole sekcyjnym utworzona została osnowa fotogrametryczna w postaci czterech odcinków stanowiąca system odniesienia przestrzennego umożliwiające precyzyjne pomiarowe określenie położenia punktów na powierzchni stołów sekcyjnych;
- 2 – osnowa fotogrametryczna utworzona została z wykorzystaniem elementów stałych stołów sekcyjnych, którymi były bolce przytwierdzone do blatów. Wybór tych punktów miał na celu skonstruowanie stałego, jednolitego punktu odniesienia, eliminując potrzebę codziennego powtarzania procedur pomiarowych;
- 3 – każdorazowo przed wykonaniem zdjęć na stole sekcyjnym zakładana była dodatkowa osnowa w postaci czterech kodowanych punktów umieszczonych w rogach stołu sekcyjnego. Punkty wykorzystane zostały w procesie orientacji wzajemnej obrazów oraz jako dodatkowe punkty kontrolne. Z uwagi na charakter ludzkiej skóry trudny do uchwycenia (słaby kontrast, jednolita struktura) oraz panujące warunki w miejscu pomiarowym (ciało często było lekko mokre po myciu lub jeszcze nie zostało umyte przez co widoczne były zabrudzenia i inne artefakty) zdecydowano, że założenie dodatkowej osnowy zminimalizuje ryzyko błędów i zniekształceń w procesie fotogrametrycznym;
- 4 – obok ciała układano wzornik kolorów;
- 5 – na każdym stole sekcyjnym sekcyjnym wzdłuż najdłuższych (bocznych) krawędzi znajdowała się podziałka miernicza będąca stałym elementem stołu sekcyjnego. Podziałka służyła jako dodatkowa (zabezpieczająca) skala odniesienia;

6 – osnowa fotogrametryczna założona została na trzech stołach sekcyjnych. Pomiedzy punktami osnowy pomierzone zostały odcinki skalujące. Pomiaru dokonano z wykorzystaniem geodezyjnej taśmy mierniczej z dokładnością do 1 milimetra.



Rysunek 7.2. Schemat stanowiska pomiarowego utworzonego w Zakładzie Medycyny Sądowej Warszawskiego Uniwersytetu Medycznego. Odcinki 1_2, 1_4, 4_3 wybrane zostały jako odcinki referencyjne, natomiast odcinek 3_2 stanowił odcinek kontrolny (źródło: opracowanie własne)


Ponadto, poza zaprojektowaniem stanowiska pomiarowego należało opracować protokół ułożenia ciała, a następnie rejestracji obrazów. Schemat pozyskania zdjęć do bazy 3D-TIP przedstawiony został na rysunku 7.3, gdzie:

1 – zdjęcia starano się wykonywać z pokryciem co najmniej 70%;
 2 – do rejestracji obrazów całego ciała wykorzystano obiektyw 24 mm. W pierwszej kolejności zdjęcia rejestrowano w pozycji *supine*, czyli twarzą skierowaną do góry. Średnia odległość fotografowania wynosiła 50-60 cm¹¹. Pomiaru dokonywano w trzech seriach:

- seria I pod kątem 0° (tzw. na wprost ciała);
- seria II pod kątem 45°. Dla ułatwienia serie zdjęć wykonywano z drabinki na wysokości 45 cm względem wysokości blatu stołu sekcyjnego;
- seria III pod kątem 90°. Dla ułatwienia serie zdjęć wykonywano z drabinki na wysokości 70 cm względem wysokości blatu stołu sekcyjnego;

¹¹ Wielkość piksela terenowego GSD (ang. Ground Sampling Distance), przy wybranej odległości od obiektu (50-60 cm) wyniosła od 1.25×10^{-2} cm do 1.5×10^{-2} cm.

3 – po wykonaniu zdjęć dla całego ciała w pozycji *supine* obracano ciało do pozycji *prone*.
W przypadku naruszenia któregoś z punktów dodatkowej osnowy, punkt usuwano;
2 – powtórzenie kroku 2 dla ciała znajdującego się w pozycji *prone*, czyli twarzą skierowaną do blatu stołu sekcyjnego.




Rysunek 7.3. Schemat procedury pozyskania zdjęć do zbioru danych 3D-TIP (źródło: opracowanie własne)

Z uwagi na charakter i organizację prac w Zakładzie Medycyny Sądowej, a także na czasochłonność procesu pozyskiwania danych, procedura rejestracji obrazów do bazy 3D-TIP była ograniczona do godzin porannych, przed rozpoczęciem sekcji zwłok. Tego rodzaju ograniczenie czasowe wynikało z konieczności dostosowania się do harmonogramu przeprowadzanych sekcji. Z kolei proces gromadzenia danych do bazy 2D-TIP mógł odbywać się w trakcie przeprowadzania zewnętrznych sekcji zwłok, co dawało większą elastyczność w kwestii czasu, ale także wymagało dodatkowej organizacji pracy, aby nie kolidowało z procedurami diagnostycznymi.

Wszystkie zdjęcia obrazujące obrażenia, takie jak podbiegnięcia krwawe oraz otarcia naskórka, były wykonywane z użyciem obiektywu o ogniskowej 35 mm, natomiast średnia odległość fotografowania mieściła się w przedziale 25-40 cm¹² (rysunek 7.4).

Ponadto, celem zapewnienia odpowiednich i w miarę możliwości powtarzalnych warunków pomiarowych, opracowano przekrojowy protokół w formie schematu warunków fotografowania (rysunek 7.5). Protokół ten zawiera wytyczne m.in. dotyczące zapewnienia właściwego źródła światła, konieczność zapewnienia odpowiedniego stanu ‘czystości’ ciała poprzez usunięcie zabrudzeń, płynów i innych zanieczyszczeń, eliminacja lampy błyskowej.



Rysunek 7.4. Schemat procedury pozyskania zdjęć do zbioru danych 2D-TIP (źródło: opracowanie własne)

¹² Wielkość piksela terenowego GSD (ang. *Ground Sampling Distance*), przy wybranej odległości od obiektu (25-40 cm) wyniosła od 4.3×10^{-3} cm do 6.9×10^{-3} cm.

	WYMÓG	UZASADNIENIE
1	Zapewnienie właściwego źródła światła.	Warunki laboratoryjne zapewniające światło białe, jasne i wolne od odbłasków i efektów stroboskopowych.
2	Zapewnienie odpowiedniego stanu czystości ciała.	Obrazy muszą być wystarczająco jasne, aby przedstawić granice obrażeń, ale jednocześnie nie powinny być prześwieczone, aby nie utracić szczegółów ani nie zmieniać barw na obrazie. Preferowane jest źródło światła jak najbardziej zbliżone do białego i wolne od odbłasków.
3	Maksymalna rozdzielczość zdjęć.	Tło i otoczenie mogą wpływać na odcienie czerwieni na zdjęciu, zmieniając pigment skóry i prawdziwy kolor obrażenia. Ponadto usunięcie rozpraszających elementów, poprawia jakość odwzorowania.
4	Brak lampy błyskowej.	Dla odległości fotografowania od 50 cm do 60 cm GSD wynosi od 1.25×10^{-2} cm do 1.5×10^{-2} cm. Natomiast dla odległości fotografowania od 25 cm do 40 cm GSD wynosi od 4.3×10^{-3} cm do 6.9×10^{-3} cm. Model FPN przypisuje etykietę do każdego takiego piksela, klasyfikując co znajduje się na tym fragmencie terenu o podanych wymiarach piksela terenowego.
5	Odpowiednia liczba zdjęć.	Lampa błyskowa może powodować odbłaski, prześwieczenie, zmianę barw i może powodować powstawanie cieni.
		1) Dla pojedynczego obrażenia: wykonanie co najmniej 4 zdjęć (pod różnymi kątami). 2) Dla sieci zdjęć: wykonanie zdjęć z zachowaniem pokrycia obrazów co najmniej 70%.
		1) Zapewnienie większej ilości informacji o obiekcie oraz przyczynienie się do sztucznego powiększenia zbioru danych dla celów segmentacji semantycznej. 2) Zwiększenie prawdopodobieństwa odnalezienia punktów wiążących w procesie pozyskiwania produktu 3D.

Rysunek 7.5. Schemat przedstawiający ustalone warunki fotografowania zapewniając odpowiednie i powtarzalne warunki pomiarowe (źródło: opracowanie własne)

7.2. Struktura danych wejściowych

Pozyskane dane utworzyły dwa zbiory: (1) 3D-TIP (ang. *3D-Tissue-Injuries of Post-mortem*) oraz (2) 2D-TIP (ang. *2D-Tissue-Injuries of Post-mortem*). Zebrane dane składały się łącznie z 7169 obrazów cyfrowych, z czego 3645 obrazy wydzielono do zbioru 3D-TIP, natomiast 3524 obrazy zostały przydzielone do zbioru 2D-TIP.

7.2.1. Obrazy ze zbioru danych 3D-TIP

Dane wejściowe z podzbioru 3D-TIP obejmowały obrazy post-mortem ofiar zdarzeń o charakterze kryminalnym w wieku 18-59 lat, zarówno mężczyzn, jak i kobiet rasy kaukaskiej, w stadium rozkładu 1-3 dni (wczesne stadium rozkładu). W ramach prac zmierzających do utworzenia tego zbioru wykonano ponad 5 tys. zdjęć, jednak w procesie selekcji część z nich została odrzucona m.in. uwagi na występujące artefakty czy niekompletność danych. Pozyskane obrazy skatalogowane zostały wg. danego przypadku (np. xx/yy, gdzie xx oznacza dzień, a yy miesiąc, w którym wykonano zdjęcia), a następnie rozróżniono obrazy z pozycji *supine* i *prone*. Łącznie, wyselekcjonowano 12 przypadków ofiar zdarzeń o charakterze kryminalnym przeznaczonych do badań nad tworzeniem dokumentacji cyfrowej 3D.

Należy zaznaczyć, że ciała, na których przeprowadzono badanie charakteryzowały się dużą różnorodnością zarówno pod względem kształtu sylwetki, jak i płci. Ponadto, podczas akwizycji danych ciała ułożone zostały w podobnych pozycjach z ramionami ułożonymi wzdłuż tułowia (ale nie przyciśniętymi bezpośrednio do ciała): w pozycji leżącej na plecach (*supine*) lub na brzuchu (*prone*). W przypadku niektórych przypadków, z powodu *rigor mortis*, dłonie pozostawiono w pozycji przypominającej zaciśniętą pięść, co stanowiło naturalną konsekwencję stężenia pośmiertnego. Istotnym czynnikiem wpływającym na proces akwizycji danych było pochodzenie ciał. Część z nich trafiała na stół sekcyjny bezpośrednio z chłodni, co powodowało kondensację wody na powierzchni skóry. Inne wymagały przygotowania, polegającego na usunięciu zanieczyszczeń, takich jak brud, pozostałości po działaniach zespołu ratunkowego (np. opatrunki, elektrody CPR) czy płyny ustrojowe. Takie przygotowanie było niezbędne do uzyskania jak najlepszej jakości danych i minimalizacji wpływu artefaktów na proces analizy. Tabela 7.1 przedstawia szczegółową strukturę zbioru, uwzględniając charakterystykę badanych obiektów, ich somatotypy (ektomorfik, mezomorfik, endomorfik), liczbę wykonanych zdjęć oraz występowanie potencjalnych artefaktów, takich jak płyny, brud czy odpady medyczne.

Tabela 7.1. Struktura zbioru danych 3D-TIP

Zbiór danych 3D-TIP					
Nazwa ^a	Płeć	Somatotyp ^b	Artefakty ^c	Pozycja	Liczba zdjęć
21/07	Mężczyzna	mezomorfik	-	supine	181
				prone	182
04/08	mężczyzna	mezomorfik	p, m	supine	168
				prone	172
05/08	mężczyzna	mezomorfik	o	supine	190
				prone	175
26/07/a	mężczyzna	endomorfik	m	supine	78
				prone	82
26/07/b	mężczyzna	endomorfik	p, b	supine	104
				prone	77
11/08	kobieta	endomorfik	p	supine	114
				prone	82
23/07	mężczyzna	ektomorfik	-	supine	170
				prone	165
20/07	mężczyzna	mezomorfik	p	supine	192
				prone	158
14/09	kobieta	endomorfik	p, m	supine	142
				prone	138
15/09	mężczyzna	mezomorfik	p	supine	140
				prone	142
16/07	mężczyzna	mezomorfik	-	supine	237
				prone	221
14/07	kobieta	endomorfik	m	supine	178
				prone	157
Podsumowanie	kobieta n = 3 mężczyzna n = 9	ektomorfik n = 1 mezomorfik n = 6 endomorfik n = 5			n = 3645 supine n = 1894 prone n = 1751

^a ofiary zdarzeń o charakterze kryminalnym zostały nazwane xx/yy, gdzie xx oznacza dzień, a yy miesiąc, w którym wykonano zdjęcia. Dodatkowe oznaczenie a, b itd., zastosowano celem rozróżnienia ofiar z tego samego dnia;

^b somatotyp to charakterystyka uwarunkowania budowy sylwetki według trzech podstawowych typów:

- ektomorfik - szczupła budowa ciała o drobnych kościach,
- mezomorfik - muskularna budowa ciała,
- endomorfik - krągłe, miękkie ciało;

^c cechy/elementy widoczne na ciele, które mogą wpłynąć na pomiar np.:

- p - płyny (woda, krew itp.),
- b - brud,
- m - odpady medyczne (gaza, elektrody CPR itp.),
- o - ciała obce).

Źródło: opracowanie własne

7.2.2. Obrazy ze zbioru danych 2D-TIP

Obrazy przydzielone do zbioru 2D-TIP przedstawiały obrażenia (otarcia naskórka i podbiegnięcia krwawe). Jednak, aby zastosować obrazy do segmentacji semantycznej i nauczyć model automatycznej identyfikacji i podjęcia w tym kierunku wiarygodnej decyzji, należało odpowiednio przygotować zbiór danych. Na rysunku 7.6 przedstawiono schemat procesu etykietowania danych przez autorkę, gdzie:

- 1 – w celu ochrony wrażliwych danych zdecydowano się na open-sourcowe oprogramowanie CVAT (ang. *Computer Vision Annotation Tool*) postawione na serwerze lokalnym wykorzystując konteneryzację Docker Desktop;
- 2 – zbiór wyselekcjonowanych 3524 obrazów poddany został analizie w kierunku rozpoznania obrażenia;
- 3 – następnie spośród dostępnych narzędzi wybrano narzędzie poligonu pozwalające na precyzyjne utworzenie wielokąta wykorzystując wybrane punkty. Należy zauważyć, że z pomocą tego narzędzia etykietowanie danych przeprowadzono na poziomie pikseli, gdzie każdy piksel, który nie został oznaczony jako któreś z obrażeń traktowany był jako tło;
- 4 – przystąpiono do manualnego etykietowania danych poprzez precyzyjne zaznaczenie poligonów odpowiadających poszczególnym klasom. W badaniach prowadzonych w niniejszej rozprawie doktorskiej na obrazach wskazywane były dwa rodzaje etykiet obrażeń: 1) podbiegnięcia krwawe, 2) otarcia naskórka, występujące w czterech konfiguracjach:
 - otarcie naskórka widoczne jako jedyny rodzaj obrażenia na obrazie;
 - podbiegnięcie krwawe widoczne jako jedyny rodzaj obrażenia na obrazie;
 - otarcie naskórka i podbiegnięcie krwawe widoczne jako dwa rodzaje obrażeń widocznych na obrazie, jednak nie wchodzących ze sobą w żadną korelację;
 - otarcie naskórka i podbiegnięcie krwawe widoczne jako dwa rodzaje obrażeń widocznych na obrazie, graniczące ze sobą (np. otarcie naskórka otoczone podbiegnięciem krwawym);
- 5 – wynikiem procesu etykietowania danych do segmentacji semantycznej była klasyfikacja obrażeń dla każdej pre-zdefiniowanej klasy. Na jednym obrazie mogło znajdować się wiele etykiet obrażeń w zależności od ich występującej konfiguracji;
- 6 – aplikacja CVAT umożliwia również wyświetlenie bitmap segmentacji (tzw. masek segmentacji);
- 7 – plikiem wyjściowym jest .xml zawierający informacje o przypisaniu pikseli obrazów do pre-zdefiniowanych klas;
- 8 – ze względu na złożoność zadania, w końcowym etapie poetykietowane obrazy zostały zweryfikowane i w miarę potrzeby poprawione.

W tabeli 7.2 opisano strukturę zbioru poetykietowanych danych. Zestaw danych zawierał 3524 obrazy, które zostały podzielone na trzy grupy: 80% dane testowe ($n = 2818$), 10% dane walidacyjne ($n = 353$) i 10% dane testowe ($n = 353$) przy użyciu losowego podziału danych, przy czym każdy z zestawów zawierał innego pacjenta. Ponadto w tabeli wskazano na charakter danych pod względem płci oraz wieku ofiary. Obrażenia zostały sklasyfikowane jako podbiegnięcia krwawe, otarcia naskórka oraz ich kombinacje, z różną liczbą wystąpień w poszczególnych zbiorach. Łącznie wskazano 18 762 etykiet obrażeń na obrazach.

Tabela 7.2. Struktura zbioru danych 2D-TIP

Zbiór danych 2D-TIP			
	<i>n - liczba obrazów cyfrowych</i>		
	Zbiór Treningowy (n = 2818)	Zbiór Testowy (n = 353)	Zbiór Walidacyjny (n = 353)
Ofiary zdarzeń kryminalnych [n (%)]	237 (25.13)	353 (37.43)	353 (37.43)
Płeć [n (%)]			
Kobieta	111 (46.83)	176 (49.86)	176 (49.86)
Mężczyzna	126 (53.16)	177 (50.14)	177 (50.14)
Wiek [średnia (SD)]	46.45 (10.18)	46.96 (9.56)	46.95 (10.13)
Obrażenie			
Podbiegnięcie krwawe ^a [n (%)]	679 (24.09)	132 (37.39)	132 (37.39)
Otarcie Naskórka ^b [n (%)]	549 (19.48)	53 (15.01)	53 (15.01)
Podbiegnięcie i otarcie ^c [n, (%)]	1590 (56.42)	168 (47.59)	168 (47.59)
Łączna liczba poetykietowanych obrazów	n = 3524		
Łączna liczba etykiet obrażeń	n = 18 762		

^a obrazy zawierające wyłącznie podbiegnięcia krwawe (zbliżenia obrażenia, ale także szerokie kadry z większym fragmentem ciała pokrytym wieloma podbiegnięciami);

^b obrazy zawierające wyłącznie otarcia naskórka (zbliżenia obrażenia, ale także szerokie kadry z większym fragmentem ciała pokrytym wieloma otarciami/płaszczyznowym otarciem);

^c obrazy dla podbiegnięć krwawych i otarć w różnych kombinacjach (zbliżenia, szerokie kadry, pojedyncze obrażenia tj. podbiegnięcie i otarcie na tych samych zdjęciach, ale nie połączone razem oraz połączone itp.)

Źródło: opracowanie własne

W analizie obrazów przedstawiających obrażenia takie jak otarcia naskórka i podbiegnięcia krwawe należy również wskazać kilka cech mogących wpłynąć na wynik segmentacji, a także przyczyniających się do wyboru skutecznego klasyfikatora:

- niektóre obrażenia mogą charakteryzować się niskim kontrastem, zmiennością barwy, niejednorodnymi granicami itp.;
- stosunkowo niewielki zbiór danych: pomimo zwiększenia ilości danych poprzez augmentację zbioru danych w kontekście standardów uczenia sieci FCN wciąż jest niewystarczający (9.1 Augmentacja danych ze zbioru 2D-TIP). Niemniej jednak, pomimo

niewielkiej liczby obrazów, istnieje znaczna liczba etykiet obrażeń (około 18 762 etykiety), co odzwierciedla wysoką złożoność adnotacji tego zbioru danych;

- relatywnie niewielki obszar zajmowany przez obrażenie w stosunku do całego kadru obrazu, co skutkowało przewagą pikseli traktowanych jako tło, a przypisanych do klasy (tabela 7.3);
- charakter danych wymagający wiedzy specjalistycznej.

Tabela 7.3. Statystyka zbioru danych TIP w kontekście występowania etykiety obrażenia

Szczegółowa statystyka zbioru danych TIP				
Parametry obrazu	Minimum	Maksimum	Średnia	Odchylenie standardowe
Rozmiar (mln pix)	21.03	21.03	21.03	0
Szerokość (pix)	5616.00	5616.00	5616.00	0
Wysokość (pix)	3744.00	3744.00	3744.00	0
Powierzchnia obrażenia (pix)	19.38	3168618.89	41948.68	159438.81
Obszar zajmowany przez obrażenie na obrazie (%)	0.00	38.68	1.08	2.81

Źródło: opracowanie własne

8. Automatyczne modelowanie w procesie tworzenia cyfrowej dokumentacji medycznej 3D sylwetki człowieka – CZĘŚĆ II badań

Niniejszy rozdział omawia część II przeprowadzonych eksperymentów w ramach niniejszej rozprawy doktorskiej. W badaniu wykorzystano autorski zbiór danych (7.2.1. *Obrazy ze zbioru danych 3D-TIP*) pozyskany na terenie Zakładu Medycyny Sądowej Warszawskiego Uniwersytetu Medycznego. Z uwagi na uwarunkowania antropologiczne terytorium na którym prowadzono badania przyjęto założenie badawcze o ograniczeniu się w tym studium wyłącznie do analiz obrazów na rasie kaukaskiej. Ponadto, badanie ograniczono wyłącznie do osób w przedziale wiekowym 18-59 lat z uwagi na pigmentację skóry istotną w badaniach nad częścią III (9. *Sieci w pełni konwolucyjne w zadaniu rozpoznania i klasyfikacji obrazów – CZĘŚĆ III badań*).

W niniejszym rozdziale autorka ukazuje proces tworzenia dokumentacji cyfrowej ciała ludzkiego, proponowane parametry, dla których osiągane wyniki powinny spełniać wymogi Zakładu Medycyny Sądowej i minimalne wskaźniki jakie powinny zostać spełnione, aby móc rozpocząć dokumentowanie ciała ludzkiego w praktyce medyczno-sądowej w postaci cyfrowego modelu 3D. Rozdział ten stanowić może pewnego rodzaju przewodnik protokołu pozyskiwania zdjęć (7.1. *Protokół pozyskania danych*) i podejścia automatycznego modelowania do tworzenia cyfrowych dokumentacji 3D bezwładnego ciała ludzkiego. Badania przeprowadzone zostały poprzez połączone podejście SfM-MVS do rekonstrukcji kształtu i tekstury obiektu na podstawie obrazów cyfrowych bez wcześniejszej znajomości położenia, elementów orientacji wewnętrznej i zewnętrznej kamery.

8.1. Platforma badawcza: hardware i software


Rozważając spełnienie minimalnych kryteriów technicznych umożliwiających wygenerowanie w krótkim czasie fotorealistycznego modelu 3D jako środowisko implementacji SfM-MVS zdecydowano się na oprogramowanie komercyjne proponowane przez firmę Agisoft. Agisoft Metashape Professional jako zaawansowane oprogramowanie służące do fotogrametrii i modelowania 3D, umożliwia przetwarzanie zdjęć cyfrowych w wysokiej jakości produkty fotogrametryczne. Ponadto oprogramowanie udostępnia API w języku Python, które stwarza możliwości zautomatyzowania wielu procesów i integracje oprogramowania z innymi narzędziami. Ponadto dzięki temu dodatkowi, w przyszłości pojawia się możliwość tworzenia niestandardowych funkcji i operacji, które mogą być dodatkowo

zintegrowane z zagadnieniem związanym z medycyną sądową, np. analizy morfologiczne i morfometryczne.


Dane przetworzone zostały z wykorzystaniem sprzętowej konfiguracji, w skład której wchodził procesor AMD Ryzen 9 5900X 12-Core, 3.70 GHz, karta graficzna NVIDIA GeForce GTX 960, pamięć RAM: 32.0 GB i system operacyjny Windows 10 Pro (64-bitowy system operacyjny, procesor x64). Dostępne środowisko programistyczne to Python 3.10.

8.2. Weryfikacja wygenerowanych modeli

Akwizycja danych metodą pasywną, której wynikiem są obrazy cyfrowe wymaga odpowiedniego przetworzenia danych w celu uzyskania chmur punktów i możliwości dalszego wygenerowania widoku 3D ciała. Zaimplementowana metoda SfM-MVS w oprogramowaniu Agisoft Metashape Professional składa się z kilku etapów (szczegółowy opis w rozdziale 4.2.1.1. *SfM-MVS*). W pierwszym kroku zaimportowano obrazy oraz przeprowadzono ich wyrównanie. Następnie w procesie dopasowania cech (ang. *feature matching*) odnaleziono punkty charakterystyczne na odpowiadających sobie zdjęciach, wynik tego etapu ukazano na rysunku 8.1. Z kolei na rysunku 8.2 przedstawiono wynik określania wzajemnego położenia i orientacji kamery dla wykrytych par obrazów.




Rysunek 8.1. Dopasowanie cech na etapie zastosowania algorytmu SfM, gdzie niebieskie linie łączą wykorzystane punkty dopasowania między wybraną parą obrazów, a czerwone linie pokazują niewykorzystane punkty (źródło: opracowanie własne)



Rysunek 8.2. Przykład pozycji kamer dla jednego z ciał pokazanego w położeniu *prone* i *supine* (źródło: opracowanie własne)

W celu optymalizacji dokładności lokalizacji cech i orientacji kamery (tzw. wyrównanie obserwacji) zastosowano metodę niezależnych wiązek (*ang. bundle adjustment*). Efektem było uzyskanie chmury punktów wiążących, zwanej również rzadką chmurą punktów (*ang. sparse point cloud*), która stanowi podstawę do dalszych etapów generowania modelu w postaci dyskretnej (rysunek 8.3).




Rysunek 8.3. Rzadka chmura punktów wygenerowana w procesie SfM dla jednego z badanych ciał (źródło: opracowanie własne)

Kolejnym etapem w procesie generowania modelu 3D stanowiło obliczenie na podstawie odpowiadających sobie punktów na parach obrazów. W ostatecznym wyniku na podstawie algorytmu MVS (ang. *Multi-View-Stereo*) uzyskano końcową mapę głębi. Efektem tego etapu było stworzenie gęstej chmury punktów (ang. *dense point cloud*) (rysunek 8.4), która charakteryzuje się dużą liczbą punktów dokładnie odwzorowujących powierzchnię badanego obiektu.

Po etapie generowania gęstych chmur punktów, kolejny krok związany był z generowaniem siatek trójkątów, gdzie chmura punktów przekształcana jest w rzeczywistą powierzchnię 3D poprzez połączenie wierzchołków punktów tworząc trójkąty. Na ostateczną dokładność i kompletność tego procesu wpływ ma kilka następujących parametrów:

- dokładność orientacji obrazów na podstawie wartości błędu reprojekcji;
- dokładność skalowania modelu na podstawie wartości RMSE na odcinkach referencyjnych (używanych do określania skali) i odcinkach kontrolnych (do niezależnej kontroli);
- gęstość chmury punktów na centymetr kwadratowy w celu oceny liczby punktów pozwalających na dokładną rekonstrukcję kształtu;
- liczba trójkątów definiujących szczegóły ostatecznego modelu 3D.


Ostatnim krokiem w procesie tworzenia pełnowymiarowej cyfrowej dokumentacji 3D w postaci fotorealistycznego modelu 3D ciała ludzkiego było nałożenie tekstury na wygenerowane modele siatkowe (ang. *mesh*). Tekstura pozyskana została ze zdjęć cyfrowych.



Rysunek 8.4. Gęsta chmura punktów będąca wynikiem procesu MVS wygenerowana dla jednego z badanych ciał (źródło: opracowanie własne)

8.3. Ocena otrzymanych wyników

W pierwszym etapie przetwarzania danych obrazy zostały podzielone na dane wejściowe dwóch kategorii: (1) w pozycji *prone* gdzie pacjent jest ułożony twarzą w dół na stole sekcyjnym, oraz (2) w pozycji *supine* gdzie pacjent ułożony jest plecami stykającymi się ze stołem sekcyjnym. W procesie wyrównania przyjęto model samokalibracji. Rysunek 8.5 przedstawia rozkład residuów obrazów dla najlepszych, średnich i najgorszych uzyskanych wyników. Należy zauważyć, że obiekt znajduje się w centralnej części kadru, natomiast największe residua zlokalizowane są na krawędziach obrazu.



Rysunek 8.5. Rozkład residuów obrazów w procesie samokalibracji, przedstawiający różnice dla (a) najlepszych, (b) średnich i (c) najgorszych wyników. Największe residua zlokalizowane są na krawędziach obrazu (kolor czerwony), podczas gdy obiekt znajduje się w centralnej części kadru (źródło: opracowanie własne)

Zaimplementowany algorytm Structure-from-Motion z podejściem Multi-View-Stereo w oprogramowaniu Agisoft Metashape wygenerował gęste chmury punktów. Tabela 8.1 przedstawia wyniki etapu Structure-from-Motion (SfM). Jednym z wyników jest wartość Średniego Błędu Reprojektacji, która odpowiada za jakość względnej orientacji obrazów. Wartości Średniego Błędu Reprojektacji (pix) dla ciała w pozycji *supine* mieszczą się w zakresie od 1,3 do 1,9 pikseli (średnia 1,6 pikseli), a dla ciała w pozycji *prone* w zakresie od 1,4 do 2,1 pikseli (średnia 1,8 pikseli). Biorąc pod uwagę użycie kamery niemetrycznej oraz trudny obiekt pomiarowy jest to dokładność wystarczająca dla diagnostyki medycznej.

Tabela 8.1. Parametry i wyniki dla etapu Structure-from-Motion (pozyskanie rzadkiej chmury punktów)

Nazwa	Liczba zdjęć	Średni błąd kwadratowy na odcinkach [cm] (ang. RMSE - Root Mean Square Error)			
		Średni błąd reprojekcji [cm] (ang. <i>Mean Reprojection Error</i>)	odcinki referencyjne (ang. <i>control points</i>)	odcinki kontrolne (ang. <i>check points</i>)	Liczba punktów wiążących
Pacjent 1 - supine	181	0.025 (1.7 pix)	0.52	0.31	96.729
Pacjent 1 - prone	182	0.023 (1.9 pix)	0.50	0.03	135.121
Pacjent 2 - supine	168	0.022 (1.7 pix)	0.55	0.21	122.932
Pacjent 2 - prone	172	0.023 (1.9 pix)	0.53	0.17	119.318
Pacjent 3 - supine	190	0.023 (1.8 pix)	0.56	0.21	116.445
Pacjent 3 - prone	175	0.025 (2.1 pix)	0.50	0.10	113.074
Pacjent 4 - supine	78	0.019 (1.5 pix)	0.54	0.14	59.582
Pacjent 4 - prone	82	0.023 (1.9 pix)	0.46	0.15	58.053
Pacjent 5 - supine	104	0.021 (1.6 pix)	0.16	0.61	89.806
Pacjent 5 - prone	77	0.022 (2.0 pix)	0.11	0.65	59.401
Pacjent 6 - supine	114	0.022 (1.6 pix)	0.53	0.35	76.733
Pacjent 6 - prone	82	0.021 (1.4 pix)	0.51	0.18	46.161
Pacjent 7 - supine	170	0.022 (1.6 pix)	0.50	0.25	112.41
Pacjent 7 - prone	165	0.022 (1.8 pix)	0.54	0.23	105.804
Pacjent 8 - supine	192	0.020 (1.5 pix)	0.51	0.28	110.073
Pacjent 8 - prone	158	0.023 (1.9 pix)	0.54	0.29	100.245
Pacjent 9 - supine	142	0.020 (1.3 pix)	0.47	0.24	88.114
Pacjent 9 - prone	138	0.020 (1.4 pix)	0.47	0.18	97.126
Pacjent 10 - supine	140	0.022 (1.5 pix)	0.12	0.05	86.82
Pacjent 10 - prone	142	0.022 (1.6 pix)	0.14	0.05	89.698
Pacjent 11 - supine	237	0.022 (1.6 pix)	0.50	0.28	149.768
Pacjent 11 - prone	221	0.025 (2.0 pix)	0.50	0.28	135.501
Pacjent 12 - supine	178	0.024 (1.9 pix)	0.16	0.61	97.061
Pacjent 12 - prone	157	0.023 (1.8 pix)	0.13	0.62	86.223
ŚREDNIA	152	0.022 (1.6 pix)	0.42	0.27	98.008

Źródło: opracowanie własne

Tabela 8.2 przedstawia wyniki etapu Multi-View-Stereo (MVS). Po przeanalizowaniu kształtu powierzchni, osiągnięta gęstość dokładnie odwzorowuje anatomiczną powierzchnię ciała ludzkiego. Na chmurze brak jest zauważalnych martwych pól, co potwierdza gęstość pozyskanej chmury w zakresie od 130,57 do 1027,16 punktów na cm (średnia 425,66 pkt/cm³). Ostateczny etap budowania modelu 3D obejmował generowanie trójkątnej siatki 3D, gdzie liczba trójkątów wahała się od 1 446 990 do 10 401 187 (średnia 6 172 888) (jak pokazano w tabeli 8.3).

Tabela 8.2. Parametry i wyniki dla etapu Multi-View-Stereo (pozyskanie gęstej chmury punktów)

Nazwa	Parametr jakości (rozdzielczość obrazu) ¹	Głębokość filtracji danych ²	Gęstość (pkt/cm3)
Pacjent 1 - supine	high	mild	221.91
Pacjent 1 - prone	high	mild	262.32
Pacjent 2 - supine	high	mild	316.97
Pacjent 2 - prone	high	mild	292.29
Pacjent 3 - supine	high	aggressive	792.51
Pacjent 3 - prone	high	moderate	874.51
Pacjent 4 - supine	high	moderate	895.03
Pacjent 4 - prone	high	moderate	1027.16
Pacjent 5 - supine	high	mild	891.63
Pacjent 5 - prone	high	mild	948.49
Pacjent 6 - supine	high	mild	722.21
Pacjent 6 - prone	high	mild	502.33
Pacjent 7 - supine	high	mild	239.66
Pacjent 7 - prone	high	mild	248.64
Pacjent 8 - supine	high	mild	174.99
Pacjent 8 - prone	high	mild	206.26
Pacjent 9 - supine	high	mild	230.48
Pacjent 9 - prone	high	mild	251.40
Pacjent 10 - supine	high	mild	221.97
Pacjent 10 - prone	high	mild	225.36
Pacjent 11 - supine	high	mild	198.45
Pacjent 11 - prone	high	mild	206.74
Pacjent 12 - supine	high	mild	130.57
Pacjent 12 - prone	high	mild	134.07

¹ parametr high warunkuje przetwarzanie obrazów w oryginalnym rozmiarze (bez ich zmniejszania);

² głębokość filtracji pomaga w usuwaniu szumów z obrazów. Ze względu na znaczną ilość drobnych szczegółów, większość modeli używała trybu łagodnego (mild) filtrowania, jednak ze względu na specyfikę obiektu, jeden model używał trybu agresywnego (aggressive) filtrowania głębokości, a trzy używały trybu umiarkowanego (moderate).

Źródło: opracowanie własne

Tabela 8.3. Parametry i wyniki dla otrzymania modelu 3D

Nazwa	Liczba trójkątów	Typ interpolacji
Pacjent 1 - supine	1,446,990	Enabled
Pacjent 1 - prone	1,817,430	Enabled
Pacjent 2 - supine	1,636,269	Enabled
Pacjent 2 - prone	2,129,375	Enabled
Pacjent 3 - supine	6,270,636	Enabled
Pacjent 3 - prone	7,347,684	Enabled
Pacjent 4 - supine	6,876,856	Enabled
Pacjent 4 - prone	8,528,693	Enabled
Pacjent 5 - supine	7,434,557	Enabled
Pacjent 5 - prone	7,810,848	Enabled
Pacjent 6 - supine	5,668,921	Enabled
Pacjent 6 - prone	4,720,975	Enabled
Pacjent 7 - supine	7,144,707	Enabled
Pacjent 7 - prone	6,903,806	Enabled
Pacjent 8 - supine	5,346,549	Enabled
Pacjent 8 - prone	5,330,441	Enabled
Pacjent 9 - supine	7,537,105	Enabled
Pacjent 9 - prone	6,779,668	Enabled
Pacjent 10 - supine	7,114,722	Enabled
Pacjent 10 - prone	7,149,805	Enabled
Pacjent 11 - supine	6,156,447	Enabled
Pacjent 11 - prone	7,255,777	Enabled
Pacjent 12 - supine	9,339,873	Enabled
Pacjent 12 - prone	10,401,187	Enabled
ŚREDNIA	6,172,888	


Źródło: opracowanie własne

W tabeli 8.4 przedstawiono podsumowanie doboru odpowiednich parametrów w generowaniu modeli 3D osiągając wyniki odpowiadające standardom w tworzeniu medycznej cyfrowej dokumentacji 3D. Natomiast na rysunku 8.6 przedstawione zostało zestawienie 6 wygenerowanych produktów prowadzących do utworzenia cyfrowej dokumentacji fotogrametrycznej 3D ciała ludzkiego.

Tabela 8.4. Generalizacja doboru parametrów i ich wpływu na proces otrzymania produktu 3D

Parametr	Wpływ	Dobór	Opis
Liczba zdjęć	Średni błąd reprojekcji	77 - 237	Zakłada się, że średnia liczba zdjęć dla pojedynczego modelu powinna wynosić około 150.
Parametr jakości obrazu	Gęstość chmur punktów	High	Przetwarzanie obrazów w wysokiej jakości (High) prowadzi do uzyskania gęstości chmur punktów w zakresie 130,57 - 1027,16 pkt/cm ³ , co zapewnia szczegółowe odwzorowanie powierzchni obiektu.
Głębokość filtracji danych	Gęstość chmur punktów	Mild, Moderate, Aggressive	Głębokość filtracji jest zależna od obiektu, ale dla większości przykładów z reguły będzie pasowało: Mild do ogólnych analiz, Moderate dla bardziej szczegółowych analiz, a Aggressive dla bardzo szczegółowych obiektów.
Interpolacja	Liczba trójkątów	Enabled	Włączenie interpolacji (Enabled) pozwala na uzyskanie większej liczby trójkątów w zakresie 1 446 990 - 10 401 187, co zapewnia płynne przejścia między wierzchołkami i bardziej szczegółowe modele.
Średnie wyniki, w granicach których istnieje gwarancja utworzenia dobrej jakości cyfrowej dokumentacji 3D ciała ludzkiego			
Błąd	Wpływ na błąd	Zakres	Opis
Średni błąd reprojekcji (pix)	Dokładność orientacji obrazu	1,3 - 2,1 pix	Niski średni błąd reprojekcji oznacza większą dokładność orientacji obrazu, co wpływa na ogólną jakość modelu 3D.
RMSE na odcinkach referencyjnych	Dokładność skalowania modelu	0,11 - 0,61 pix	Niższe wartości RMSE wskazują na wyższą dokładność odwzorowania rzeczywistych wymiarów obiektów, co jest kluczowe dla wiarygodności modeli 3D.

Źródło: opracowanie własne



a) rzadka chmura punktów b) gęsta chmura punktów c) siatka trójkątów d) model solid e) model wysokościowy f) model 3D z nałożoną teksturą

Rysunek 8.6. Przedstawienie sześciu produktów otrzymanych w oprogramowaniu Agisoft: a) rzadka chmura punktów, b) gęsta chmura punktów, c) model siatkowy (ang. *mesh*) tzw. siatka trójkątów, d) model solid będący rezultatem procesu rekonstrukcji 3D na podstawie chmury punktów i siatki trójkątów, e) model wysokościowy, f) model z nałożoną teksturą (źródło: opracowanie własne)


Rysunek 8.7 przedstawia zestawienie tekstury uzyskanej na modelu z teksturą rzeczywistą ze zdjęcia. Przedstawione zestawienie pokazuje, że uzyskane odwzorowanie jest szczegółowe. Tekstura wygenerowana została o wymiarach 8192 x 8192 pikseli przy GSD wynoszącym od 4.3×10^{-3} cm do 6.9×10^{-3} cm, gdzie średnia wielkość modelu (samego ciała) obejmuje obszar około 1.5 m². Oznacza to, że zachowano dobre odwzorowanie detali, jednak w przyszłości autorka zaleca wykorzystanie jednak tekstury o rozdzielczości 16384 x 16384 pikseli z uwagi odwzorowanie struktury widocznej na teksturze.



a) zdjęcie oryginalne



b) fragment model 3D



c) fragment model 3D



d) fragment model 3D

Rysunek 8.7. Porównanie dokładności odwzorowania tekstury na modelu 3D z teksturą rzeczywistą uzyskaną ze zdjęcia RGB (źródło: opracowanie własne)

Warto zwrócić uwagę, że taki model 3D obrażenia pozwala również na przeprowadzenie dodatkowych analiz. Przykładowe z nich opisano zostały w rozdziale *11. Analiza morfometryczna i morfologiczna obrażenia jako cyfrowe wspomaganie obrazowej diagnostyki – CZĘŚĆ V badań*.

9. Sieci w pełni konwolucyjne w zadaniu detekcji i klasyfikacji obrazów – CZĘŚĆ III badań¹³

Posiadając dokumentację ciała w postaci 3D, na której możliwe jest przeprowadzenie szeregu analiz, kolejnym etapem jest zbadanie możliwości zautomatyzowania procesu wykrycia obrazów. Pierwszym krokiem w tym kierunku jest przeprowadzenie badań nad wykorzystaniem w pełni konwolucyjnych sieci neuronowych (ang. *Fully Convolutional Network*, FCN) do zadania segmentacji semantycznej dwóch typów obrazów: podbiegnięć krwawych i otarć naskórka. W zamyśle autorki wykorzystanie segmentacji semantycznej pozwoli na automatyczną oraz nieinwazyjną detekcję i klasyfikację obrazów na powłokach ciała znajdujących się na obrazach 2D, aby w kolejnym kroku przenieść rozpoznane maski obrazów na model 3D.


Należy zauważyć, że uczenie FCN wymaga podjęcia wielu decyzji przy określaniu architektury modelu np. Number of Layers, Pooling Layers (type, kernel size, stride), Normalisation Layers, Activation Functions (np. ReLU), Output Layer (number of classes), a także innych hiperparametrów związanych z procesem uczenia np. Initial Learning Rate, Batch Size, Number of Epochs, Optimizer Parameters, Dropout, Loss Function, Early Stopping. Z uwagi na długi czas wymagany do pełnego wytrenowania, a następnie dokonania oceny zachowania modelu FCN, wybór najbardziej obiecujących wartości hiperparametrów opiera się zazwyczaj o pewne reguły i heurystykę pomagając szybko zbudować pierwszą wersję modelu. W literaturze opisywane podejście do uczenia opiera się o wykorzystywanie tzw. benchmarków będących dużymi zbiorami danych, na podstawie których dokonuje się oceny skuteczności różnych rozwiązań. Takim przykładem jest zbiór danych ImageNet wykorzystany do wstępnego wytrenowania modelu EfficientNetB3 zawierający ponad 1 mln obrazów podzielonych na 1000 klas, z których każda zawiera ponad 1000 obrazów.

Niniejszy rozdział omawia część III przeprowadzonych eksperymentów w ramach niniejszej rozprawy doktorskiej. W badaniu wykorzystano zbiór danych 2D-TIP (7.2.2. *Obrazy ze zbioru danych 2D-TIP*) oraz przetestowano 6 modeli sieci FCN¹⁴. Badanie ograniczono wyłącznie do

¹³ W ramach prac nad niniejszym rozdziałem zdecydowano się na używanie w większości oryginalnych określeń anglojęzycznych z uwagi na brak ich polskich odpowiedników.

¹⁴ W ramach projektu SzIR-2 nr 1820/18/Z01/POB2/2021 nt. „Opracowanie koncepcji wykorzystania algorytmów SI w badaniu archiwalnych obrazów cyfrowych pochodzących z kryminalistycznego miejsca zdarzenia”, trwającego w okresie 01.2021 r. – 06.2023 r., gdzie autorka była głównym wykonawcą, wstępnie zbadano i wyznaczono parametry dla trzech sieci U-Net, FPN i LinkNet z backbone EfficientNetB3 i ResNet50 (łącznie 6 modeli).

osób w przedziale wiekowym 18-59 lat z uwagi na pigmentację skóry. Jeżeli w badaniu brana byłaby grupa wiekowa z zaawansowaną plamicą starczą to należałoby uwzględnić ryzyko uznania przez model segmentacji, widocznych plam za obrażenie. Oczywiście, wskazując nową klasę pre-zdefiniowaną i ucząc model jak rozróżnić plamice od podbiegnięć byłaby możliwość łatwego ominięcia tego problemu. Natomiast, w przypadku osób poniżej ustalonej, dolnej granicy wiekowej (>18) czynnikiem decyzyjnym stanowiła znacząca dysproporcja w zasobach danych co przełożyło się na podjęcie decyzji o wykluczeniu tej grupy wiekowej. Ostatnim wprowadzonym ograniczeniem było utworzenie zbiorów dla ciał w stadium rozkładu 1-3 dni (wczesne stadium rozkładu) z uwagi na zachodzące zmiany wraz z jego postępowaniem. Występujące przeobrażenia znacząco mogą wpływać na wygląd obrażenia, jak również samą pigmentację skóry. Na rysunku 9.1 przedstawiono schemat działań prowadzący do otrzymania wyniku segmentacji semantycznej.




Rysunek 9.1. Podglądowy schemat procesu segmentacji semantycznej (źródło: opracowanie własne)

9.1. Augmentacja danych ze zbioru 2D-TIP

Wykorzystanie głębokich modeli sieci neuronowych w zadaniu segmentacji semantycznej wymaga dużych ilości danych do treningu i uczenia sieci. Jak wspomniano we wcześniejszych rozdziałach w sektorze nauk medycznych istnieje niewiele publicznie dostępnych zbiorów danych z uwagi na wrażliwość/prywatność zawartej tam informacji. Jednym z narzędzi rozwiązujących ten problem jest augmentacja do tj. sztucznego rozszerzenia posiadanych danych. Każdy obraz w zbiorze 2D-TIP poddany został sześciu następującym przetworzeniom:

1. Odbicie lustrzane (ang. *horizontal flip*): augmentacja ta losowo odwraca wejściowy obraz wzdłuż jego osi pionowej (od lewej do prawej) z określonym prawdopodobieństwem ($p = 0,5$). Z uwagi na charakter danych przedstawiający ciało ludzkie, nie odwracano obrazu wzdłuż osi poziomej (tzw. do góry nogami).
2. Transformacje afiniczne: odbywają się bez deformacji z zachowaniem równoległości linii:
 - a. Transformacja afiniczna – translacja (ang. *affine transforms - translate*): augmentacja translacji przesuwa równolegle wszystkie punkty dziedziny w wejściowym obrazie w kierunku poziomym i pionowym. Translacja odbywa się bez deformacji i obracania.
 - b. Transformacja afiniczna – skalowanie (ang. *affine transforms – scale*): obraz wejściowy został przeskalowany do rozmiaru 640 x 480 pikseli, a następnie losowo przycięty do rozmiaru 480 x 480 pikseli.
 - c. Transformacja afiniczna – obrót (ang. *affine transforms – rotate*): obrót obrazu w każdej z trzech osi (X, Y, Z).
3. Szum gaussowski (ang. *gaussian noise*): jest to proces zakłócenia danych wejściowych przez dodanie szumu do obrazu w wyniku odchylenia wartości pikseli obrazu.
4. Losowa transformacja perspektywiczna po czterech punktach (ang. *random four-point perspective transform*): przekształcenie zmieniające perspektywę obrazu z wykorzystaniem zdefiniowanych czterech punktów kontrolnych. W wyniku tego procesu zasymulowany może być widok obrazu z różnych kątów.

Ponadto, poza wymienionymi przetworzeniami dla każdego z obrazów została zastosowana dodatkowa transformacja w taki sposób, że w pierwszej kolejności wyznaczono 3 grupy, w obrębie których zdefiniowano 3 kolejne przetworzenia. Na rysunku 9.2 przedstawiono schemat zastosowania augmentacji danych wraz z przykładami wstępnie przetworzonych obrazów.



Rysunek 9.2. Schemat zastosowania augmentacji danych w zadaniu segmentacji semantycznej, ilustrujący proces przetwarzania obrazów 2D-TIP za pomocą różnych technik augmentacyjnych, zawierający przykłady wstępnie przetworzonych obrazów (źródło: opracowanie własne)

9.2. Platforma badawcza: hardware i software

Pierwsze prace nad modelami U-Net/FPN/LinkNet z EfficientNetB3 oraz U-Net/FPN/LinkNet z ResNet50 w ramach zadania segmentacji semantycznej przeprowadzono z wykorzystaniem konfiguracji sprzętowej w skład której wchodził procesor Intel(R) Core(TM) i7-7700HQ CPU @ 2.80GHz, karta graficzna NVIDIA GeForce GTX 1060, pamięć RAM 16 GB, kolejne badania przeprowadzono z następującą konfiguracją: procesor AMD Ryzen 9 5900X 12-Core, 3.70 GHz, karta graficzna NVIDIA GeForce GTX 960, pamięć RAM rozbudowana do 64 GB i system operacyjny Windows 10 Pro (64-bitowy system operacyjny, procesor x64). Ponadto pracowano w środowisku programistycznym Python 3.8 (z uwagi na brak kompatybilności wersji Python 3.10 z biblioteką TensorFlow) z wykorzystaniem edytora kodowania Visual Studio Code z wykorzystaniem bibliotek:

- Biblioteka `os`

Opis: Standardowa biblioteka Pythona do interakcji z systemem operacyjnym. W przypadku opracowanego modelu służyła jako wsparcie do zarządzania zmiennymi środowiskowymi, a mianowicie informowanie biblioteki `segmentation_models`, że ma używać `TensorFlow` jako frameworka.

- Biblioteka `Numpy`

Opis: Biblioteka do obliczeń numerycznych w Pythonie, szczególnie przydatna do pracy z dużymi tablicami wielowymiarowymi. W przypadku opracowanego modelu posłużyła `np.` do ustawienia wag klas w funkcji strat.

- Biblioteka `Segmentation_models`

Opis: Biblioteka oferująca predefiniowany model segmentacji obrazów (U-Net z EfficientNetB3), który współpracuje z się z Keras i TensorFlow. funkcje strat i metryki specyficzne dla segmentacji obrazów.

- Biblioteka `TensorFlow`

Opis: Kompleksowa biblioteka do uczenia maszynowego i głębokiego uczenia. Zawiera narzędzia do budowania i trenowania modeli, przetwarzania danych itp.

- Biblioteka `KERAS`

Opis: API do budowania i trenowania modeli głębokiego uczenia.

Opracowane modele segmentacji semantycznej oparte są o wstępnie przetrenowane modele z odpowiednimi funkcjami strat (`DiceLoss` i `FocalLoss`) oraz metrykami (F1-score - Dice score,

Mean-IoU - Jaccard score, Precision, Sensitivity, Specificity). Modele klasyfikują każdy piksel obrazu do określonej klasy.

9.3. Weryfikacja działania segmentacji semantycznej na obrazach post-mortem

W niniejszym rozwiązaniu zastosowano metodę *transfer learningu* dla modelu EfficientNetB3 oraz ResNet50, gdzie wykorzystano wagi z wstępnie przetrenowanego modelu na zbiorze obrazów ImageNet, następnie sieć została douczona na zbiorze danym 2D-TIP. Uwzględniając występowanie nadmiernego dopasowania oraz długiego czasu potrzebnego na uczenie i tak już wstępnie wyuczonej sieci, zastosowano metodę *dropout* i *early stopping*. Implementacja *dropout* składała się z dwóch etapów: (1) etapu uczenia całej sieci neuronowej i (2) uśredniania wyników całego zbioru. *Dropout* przechodząc przez każdą warstwę, losowo usuwał neurony z prawdopodobieństwem P zachowując inne z prawdopodobieństwem $Q = (1 - P)$, gdzie wartość dla $P = 0,5$. Wynikiem była mniejsza liczba węzłów i mniejsze skale, tym samym obniżając powiązania i ułatwiając trenowanie sieci neuronowej. W przypadku *early stopping* stosowanym jako jedna z technik regularyzacji podczas trenowania, ustawiono wartość na 10, która przerywała uczenie sieci gdy wydajność na zbiorze walidacyjnym przestała się poprawiać po 10 epokach, a następnie przywracała wagi z najlepszej epoki. Optymalizując proces uczenia sieci wykorzystano algorytm ADAM (Kingma & Ba, 2015), którego celem było zoptymalizowanie funkcji strat łącząc DiceLoss i FocalLoss, przyspieszenie uczenia sieci dzięki adaptacyjnemu dostosowaniu tempa uczenia osiągając zbieżność, zwiększenie stabilności uczenia sieci redukując oscylacje gradientów i pomagając w uniknięciu problemów z niestabilnymi gradientami. Dla współczynnika uczenia w optymalizatorze ADAM przyjęto wartość `learning_rate` 0.001 (zapewniając umiarkowane tempo uczenia) i wielkość `batch_size` 2. Gdy proces uczenia zwalniał, współczynnik uczenia był dynamicznie zmniejszany o czynnik 2-10 przy użyciu callbacku `ReduceLROnPlateau`. Callback ten monitorował stratę walidacyjną i redukował współczynnik uczenia o ustalony czynnik (w tym przypadku 0,1), gdy nie było poprawy przez określoną liczbę epok.

Wspomniany wcześniej problem z dużą rozbieżnością dla obszarów zajmowanych przez obrażenie (stosunkowo małe obrażenia na ciele lub zbliżenia wypełniające cały kadr) powodował, że sieć wskazywała na duże odchylenia w kierunku przewidywań tła, pomijała niektóre obrażenia lub wykrywała je częściowo, co utrudniało proces uczenia. Na tym etapie

należało zastosować niestandardową funkcję strat, gdzie najpierw zastosowana została funkcja docelowa oparta na współczynniku Dice (ang. *Dice Coefficient*), który przyjmuje wartość między 0 a 1, a który w zamyśle miał zostać zmaksymalizowany, który można wyrazić jako:

$$D = \sum_{c=1}^C \frac{2 \sum_{n=1}^N p_n(c) g_n(c)}{\sum_{n=1}^N p_n(c)^2 + \sum_{n=1}^N g_n(c)^2} \quad (9.1)$$

gdzie:

C – opisuje całkowitą liczbę klas, w tym tło;

N – opisuje liczbę pikseli;

$p_n(c)$ – przewidywane prawdopodobieństwo dla piksela n przynależnego do klasy c ;

$g_n(c)$ – to *ground truth* dla piksela n przynależnego do klasy c .

Kolejno, zastosowano funkcję straty Focal Loss z parametrem $\gamma = 2$, zdefiniowaną jako:

$$F = \frac{1}{N} \sum_{c=0}^{C-1} \sum_{n=0}^N g_n(c) (1 - p_n(c))^2 \log(p_n(c)) \quad (9.2)$$

Funkcja straty Dice'a uczy rozkładu klas, co pomaga rozwiązać problem niezbalansowanych pikseli, podczas gdy Focal Loss lepiej uczy model, jak klasyfikować słabo kategoryzowane piksele. Mając te dwie części wzoru, możemy zdefiniować całą funkcję straty:

$$L = C - (1 - \lambda)D - \lambda F \quad (9.3)$$

gdzie:

λ – parametr ten łączy się ze stratą Dice'a i Focal Loss równoważąc wpływ obu komponentów. Dostrajany jest podczas optymalizacji parametrów i równy 0.42.

Na rysunku 9.3 przedstawiona została przykładowa zmodyfikowana architektura tradycyjnego modelu enkoder-dekoder U-Net z EfficientNetB3 backbone (dla tego modelu uzyskano najlepsze wyniki). Ścieżki kompresji (enkoder) oraz dekompresji (dekoder) charakteryzują się pewną symetrycznością tworząc architekturę modelu przypominającą literę U (stąd określenie U-Net). EfficientNetB3 jako enkoder wykorzystany został do stworzenia reprezentacji najistotniejszych cech obrazu oryginalnego niezbędnych w procesie generowania

przez dekodery obrazu z maskami segmentacji. Celem uproszczenia, na rysunku 9.3 enkoder przedstawiony został w postaci bloków. W pierwszym etapie, obraz wejściowy RGB w procesie post-processingu zostaje zmniejszony i przycięty do rozmiaru 480x480, a następnie wprowadzany do pierwszego bloku sieci zwanego rdzeniem (na rysunku: *stem*), gdzie wykonywane są operacje takie jak Batch Normalisation, Padding, spłot 2D i funkcja aktywacji ReLU. Następnie pokazanych jest siedem kolejnych bloków (na rysunku: *block*) zawierających wiele warstw konwolucyjnych z rozmiarem spłotu 3x3, przedzielonych warstwami Max Pooling, stopniowo zmniejszając wymiar macierzy i zwiększając liczbę wydobytych cech, aż do osiągnięcia rozmiaru równego 15x15x1536. U-Net jako dekodery skonstruowana jest w podobny sposób z tą różnicą, że zamiast warstw Max Pooling zastosowane są warstwy dekonwolucyjne w celu zwiększenia rozdzielczości wyjściowej obrazu i dodano cztery skip connections. Sieć kończy się klasyfikatorem przypisującym piksele obrazu do odpowiednich kategorii, który złożony jest z trzech warstw w pełni połączonych (ang. *fully connected layers*) i funkcji softmax, która ostatecznie przetwarza przypisane do klas piksele na maski segmentacji dla: background, podbiegnięcie krwawe i otarcie naskórka. Ponadto należy zaznaczyć, że architektura w przeciwieństwie do tradycyjnej budowy wykorzystuje zrównoważoną metodę skalowania w odniesieniu do szerokości sieci, głębokości sieci i rozdzielczości sieci co skutkuje znacznie dokładniejszą reprezentacją niż w tradycyjnym dekodzie U-Net. Dodatkowo, w tabeli 9.1 przedstawione zostały informacje o strukturze modeli i doborze parametrów sieci. Natomiast tabela 9.2 opisuje dodatkowe parametry, wspólne dla wszystkich sieci.

Tabela 9.1. Budowa i parametry dla modeli

Dekoder	Enkoder	Trainable Parameters ¹	Liczba warstw	Średni czas uczenia sieci (w sek.)	Inference Time per Image (ms) ²
U-Net	EfficientNetB3	17,868,123	229	142,29	212
	ResNet50	32,561,404	125	134,42	152
FPN	EfficientNetB3	13,914,027	232	179,24	223
	ResNet50	26,914,124	128	161,02	174
LinkNet	EfficientNetB3	13,761,275	239	141,86	171
	ResNet50	28,783,676	135	169,77	152

¹ wagi i przesunięcia w sieci neuronowej, które są aktualizowane podczas procesu trenowania modelu. Im więcej tzw. trenowalnych parametrów, tym bardziej złożony jest model. Większa liczba parametrów pozwala modelowi lepiej dopasować się do danych treningowych, ale może również prowadzić do przeuczenia (ang. *overfitting*), zwłaszcza jeśli ilość danych treningowych jest niewystarczająca;

² czas, jaki model potrzebuje na przetworzenie pojedynczego obrazu podczas fazy predykcji, podawany w milisekundach.

Źródło: opracowanie własne

Tabela 9.2. Parametry wspólne dla wszystkich modeli

Parametr	Wartość
Maksymalna liczba epok ¹	120
Mini-batch	2
Początkowy współczynnik uczenia (ang. <i>Initial learning rate</i>)	0,001
Czynnik spadku współczynnika uczenia (ang. <i>Drop factor of learning rate</i>) ²	0,1
Okres spadku współczynnika uczenia (ang. <i>Drop period of learning rate</i>) ³	2-10

¹ maksymalna liczba pełnych przeglądów całego zestawu danych treningowych przez algorytm uczenia się podczas procesu trenowania sieci;

² określa, o ile razy współczynnik uczenia ma być zmniejszony, gdy osiągnie się określony warunek jaki jest poprawy w wydajności modelu;

³ okres spadku współczynnika uczenia to liczba epok po których współczynnik uczenia zostanie zmniejszony o określony czynnik.

Źródło: opracowanie własne

Wydajność utworzonego modelu zweryfikowana została przez 5 wskaźników: Dice Coefficient (F1-score), Jaccard score, Precision, Sensitivity and Specificity. Dice Coefficient (F1-score) jest miarą używaną do oceny wydajności algorytmów segmentacji, uwzględniającą zarówno Precision, jak i Sensitivity, obliczaną za pomocą poniższego wzoru:

$$Dice\ Coefficient = \frac{2\ TP}{(2\ TP + FP + FN)} \quad (9.4)$$

gdzie:

TP (*True Positives*) – liczba pikseli poprawnie zaklasyfikowanych jako należących do danej klasy (podbiegnięcia krwawe lub otarcia naskórka);

FP (*False Positives*) – liczba pikseli błędnie zaklasyfikowanych jako należących do danej klasy, które w rzeczywistości są inną klasą lub tłem;

FN (*False Negatives*) – liczba pikseli błędnie zaklasyfikowanych jako tło lub inna klasa, które w rzeczywistości należą do danej klasy.

Jaccard Coefficient służy do oceny podobieństwa między zbiorami, obliczając stosunek wielkości przecięcia do wielkości sumy zbiorów próbek. Współczynnik Jaccard Coefficient jest obliczany za pomocą poniższego wzoru:

$$Jaccard\ score = \frac{TP}{(TP + FP + FN)} \quad (9.5)$$

gdzie:

TP (True Positives) – liczba pikseli poprawnie zaklasyfikowanych jako należących do danej klasy;

FP (False Positives) – liczba pikseli błędnie zaklasyfikowanych jako należących do danej klasy, które w rzeczywistości są inną klasą lub tłem;

FN (False Negatives) – liczba pikseli błędnie zaklasyfikowanych jako tło lub inna klasa, które w rzeczywistości należą do danej klasy.

Kolejnym wskaźnikiem jest Precision, który oblicza procent pikseli jakie sieć zaklasyfikowała we wszystkich przewidzianych klasach. Innymi słowy, mierzy dokładność przewidywań pozytywnych przypadków dla każdej klasy (podbiegnięcia krwawe lub otarcia naskórka) i określa, jaki procent przewidywanych przez model pozytywnych pikseli dla danej klasy jest rzeczywiście prawdziwy:

$$Precision = \frac{TP}{(TP + FP)} \quad (9.6)$$

gdzie:

TP (True Positives) – liczba prawdziwie pozytywnych pikseli dla danej klasy (np. poprawnie wykryte podbiegnięcia krwawe);

FP (False Positives) – liczba fałszywie pozytywnych pikseli dla danej klasy (np. piksele błędnie zaklasyfikowane jako podbiegnięcia krwawe, które w rzeczywistości są otarciami lub tłem).

Sensitivity wskazuje, zdolność modelu do wykrywania wszystkich rzeczywistych pozytywnych pikseli dla danej klasy i określa, jaki procent rzeczywistych pozytywnych pikseli dla danej klasy został poprawnie zidentyfikowany przez model:

$$Sensitivity = \frac{TP}{(TP + FN)} \quad (9.7)$$

gdzie:

TP (True Positives) – liczba prawdziwie pozytywnych pikseli dla danej klasy;

FN (False Negatives) – liczba fałszywie negatywnych pikseli dla danej klasy (np. piksele błędnie zaklasyfikowane jako tło lub inna klasa, które w rzeczywistości są podbiegnięciami krwawymi).


Ostatnim wskaźnikiem jest Specificity, mierzy zdolność modelu do poprawnego identyfikowania negatywnych pikseli (tła). Określa, jaki procent rzeczywistych negatywnych pikseli (tło) został poprawnie zidentyfikowany przez model.

$$Specificity = \frac{TN}{(TN + FN)} \quad (9.8)$$

gdzie:

TN (True Negatives) – liczba prawdziwie negatywnych pikseli (tło);

FP (False Positives) – liczba fałszywie pozytywnych pikseli (piksele błędnie zaklasyfikowane jako podbiegnięcia krwawe lub otarcia naskórka, a które w rzeczywistości są tłem).



Rysunek 9.3. Architektura modelu U-Net z EfficientNetB3 backbone (źródło: opracowanie własne z wykorzystaniem kodu latex do rysowania sieci neuronowych dostępnego open-source na <https://github.com/HarisIqbal88/PlotNeuralNet?tab=readme-ov-file>)

9.4. Ocena otrzymanych wyników

W tabeli 9.3 wskazano wyniki metryk dla wszystkich modeli w czterech różnych scenariuszach:

Scenariusz pierwszy

W pierwszym scenariuszu testy przeprowadzono na obrazach zawierających tylko podbiegnięcia krwawe. Model U-Net z EfficientNetB4 backbone osiągnął najlepsze wyniki z wyjątkiem metryki Sensitivity dla której model U-Net z ResNet50 wypadł lepiej o 0,7 punktu procentowego.

Drugi scenariusz

W drugim scenariuszu testy przeprowadzono na obrazach zawierających tylko otarcia. Podobnie jak w przypadku scenariusza pierwszego, najlepsze wyniki uzyskano dla modelu U-Net z EfficientNetB4, z wyłączeniem metryki Sensitivity gdzie model LinkNet z EfficientNetB3 działał lepiej o 1,3 punktu procentowego. Oczywiście jest, że skuteczność przewidywania w przypadku otarć jest wyższa niż w przypadku podbiegnięć krwawych z uwagi na charakter obrażenia (wyraźniej oznaczone granice, kolor itp.).

Trzeci scenariusz

W ostatnim scenariuszu rozważono połączenie dwóch poprzednich scenariuszy. Testowane obrazy zawierały przypadki podbiegnięć krwawych i otarć w dowolnej kombinacji. Dla tego testu różnica w metryce pomiędzy obiecującym modelem U-Net z EfficientNetB4, wyniosła: (1) dla metryki Precision model FPN z ResNet50 uzyskał wyższą wartość o 1,2 punktu procentowego, (2) dla metryki Sensitivity model FPN z EfficientNetB3 uzyskał wartość wyższą o 1,0 punktu procentowego.

Czwarty scenariusz

Ostatni z rozważanych scenariuszy jest najtrudniejszym testem, co odzwierciedlają wyniki. Jest to spowodowane dwoma czynnikami:

- istnieją dwa różne obrażenia, które należy skategoryzować;
- w wielu sytuacjach oba obrażenia są widoczne równolegle. Bardzo częstym przypadkiem jest otarcie otoczone podbiegnięciem. Ten scenariusz jest najbardziej zbliżony do rzeczywistych przypadków, więc wyniki tego eksperymentu są najbardziej wiarygodne.

Podsumowując przedstawione wyniki ze wszystkich scenariuszy, zauważalne jest, że najlepsze z nich zasadniczo uzyskał model U-Net z EfficientNetB4 backbone. Z tego względu w następnych badaniach autorka rozprawy skupia się jedynie na tym modelu, wskazując jego


potencjał dalszego rozwoju i rozważając jego wykorzystanie w przyszłych badaniach po zakończeniu badań doktorskich.

Tabela 9.3. Wyniki metryk dla wszystkich modeli

Typ obrażenia	F1-score - Dice score	Mean-IoU - Jaccard score	Precision	Sensitivity	Specificity
Podbiegnięcia krwawe, No. (%)					
U-Net + EfficientNetB4	93,70%	88,20%	94,70%	92,70%	99,20%
U-Net + ResNet50	91,10%	83,70%	88,90%	93,40%	96,50%
FPN + EfficientNetB3	90,90%	83,40%	88,80%	93,10%	96,70%
FPN + ResNet50	91,00%	83,60%	94,50%	87,80%	98,00%
LinkNet + EfficientNetB3	87,10%	77,10%	82,80%	91,90%	96,10%
LinkNet + ResNet50	85,00%	73,90%	81,50%	88,80%	95,30%
Otarcia naskórka, No. (%)					
U-Net + EfficientNetB4	94,50%	89,60%	94,80%	94,20%	99,10%
U-Net + ResNet50	89,40%	80,90%	87,90%	91,10%	96,70%
FPN + EfficientNetB3	91,40%	84,20%	88,50%	94,50%	97,90%
FPN + ResNet50	90,50%	82,70%	94,20%	87,10%	97,50%
LinkNet + EfficientNetB3	89,60%	81,20%	84,40%	95,50%	96,60%
LinkNet + ResNet50	86,90%	76,80%	83,00%	91,10%	93,80%
Podbiegnięcia i otarcia, No. (%)					
U-Net + EfficientNetB4	92,20%	85,50%	92,70%	91,70%	98,90%
U-Net + ResNet50	89,00%	80,10%	87,40%	90,60%	93,60%
FPN + EfficientNetB3	90,50%	82,60%	88,40%	92,70%	94,70%
FPN + ResNet50	89,40%	80,90%	93,90%	85,40%	95,80%
LinkNet + EfficientNetB3	86,70%	76,50%	82,20%	91,70%	94,40%
LinkNet + ResNet50	84,60%	73,40%	81,10%	88,50%	93,10%


Źródło: opracowanie własne

Przykład uzyskanych wyników segmentacji przedstawiony został na rysunku 9.4 pokazując jak sprawdzone modele FCN radzą sobie z poprawnym rozpoznaniem obrażeń. Należy zaznaczyć, że jakość predykcji jest dokładniejsza (granice) dla otarć niż dla podbiegnięć krwawych, a powodem mogą być naturalnie bardziej rozmyte krawędzie dla podbiegnięć krwawych.



Rysunek 9.4. Przykładowe wyniki segmentacji obrazów dla powłok ciała przy użyciu proponowanych modeli FCN. Wynik segmentacji na obrazie wejściowym oznaczono kolorem zielonym dla otarć oraz kolorem czerwonym dla podbiegnięć krwawych (źródło: opracowanie własne)


Na rysunku 9.5 przedstawiono wyniki segmentacji dla scenariusza trzeciego odpowiadającego przypadkom podbiegnięć krwawych i otarć występujących w dowolnej kombinacji. Najczęściej spotykanym przypadkiem w praktyce medyczno-sądowej jest występowanie otarcia naskórka w bliskim sąsiedztwie z podbiegnięciem krwawym. Oczywiście, poza poprawnie sklasyfikowanymi obrażeniami, model FCN nie uniknął kilku błędów.



Rysunek 9.5. Przykładowe wyniki segmentacji dla podbiegnięć krwawych i otarć naskórka występujących razem: oryginalny obraz wejściowy (po lewej), wyniki segmentacji architektury (środek po lewej: otarcia, środek po prawej: podbiegnięcia krwawe), zaznaczony wynik segmentacji na obrazach wejściowych (po prawej): czerwony dla podbiegnięć krwawych i zielony dla otarć (źródło: opracowanie własne)

Na rysunku 9.6 wskazano przykłady nie wykrycia obrażenia lub jego częściowego wykrycia lub niepoprawnego sklasyfikowania rodzaju obrażenia. Pierwsze dwa przykłady (rysunek 9.6(a-b)) wskazują na niewykrycie wszystkich obrażeń widocznych na obrazie lub tylko ich częściowe wykrycie. Występujące błędy dotyczą w dużej mierze jedynie podbiegnięć krwawych, ponieważ wartości pikseli są podobne do wartości regionu skóry. Niektóre przypadki dotyczą otarć, gdzie na tym samym przykładzie można również zauważyć

sklasyfikowania obszaru nie będącego podbiegnięciem krwawym, a stanowiącego plamę opadową (rysunek 9.6(c)). W tym przypadku pigmentacja skóry negatywnie wpłynęła na obszar obrażeń przyczyniając się do znacznego utrudnienia w odróżnieniu tych pikseli. W ostatnim przykładzie (rysunek 9.6(d)) następuje klasyfikacja podbiegnięć krwawych jako otarć lub otarć jako podbiegnięć krwawych.



Rysunek 9.6. Przykłady nieprawidłowych wyników klasyfikacji przy użyciu proponowanego modelu DNN: a) obraz wejściowy, kolejno od góry: 1-2 przykłady pokazują niewykrycie wszystkich obrażeń widocznych na obrazie lub wykrycie ich tylko częściowo, 3 przykład przedstawia błędną klasyfikację obszaru, który nie jest ani podbiegnięciem krwawym, ani otarciem, 4 przykład błędna klasyfikacja podbiegnięć krwawych jako otarć i na odwrót, b) maska segmentacji dla otarć, c) maska segmentacji dla podbiegnięć krwawych, d) wynik segmentacji na obrazie wejściowym z otarciami oznaczonymi kolorem zielonym i podbiegnięciami krwawymi oznaczonymi kolorem czerwonym (źródło: opracowanie własne)

Analizując występujące błędy na rysunku 9.6, można wysunąć wniosek iż ich wystąpienie spowodowane mogło być brakiem niewystarczającej liczby próbek zbioru uczącego, dlatego też w przypadku dostarczenia ich większej liczby o podobnej charakterystyce można oczekiwać znacznej poprawy wydajności klasyfikacji.

Dodatkowo, dla pokreślenia uzyskanych wyników, przeprowadzono badanie literatury, które wykazało wiele istotnych artykułów naukowych poruszających zagadnienie klasyfikacji obrażeń na obrazach (tabela 5.1. Podsumowanie metod wykrywania obrażeń na obrazach 2D). Na ich podstawie w tabeli 9.4 porównano otrzymane wyniki dla modelu U-Net z EfficientNetB4 backbone z innymi podobnymi metodami. Należy zaznaczyć, że z uwagi na brak publikacji dotyczących obrażeń badanych w ramach niniejszej rozprawy, porównania dokonano z obrazami dla obrażenia oparzenia. W kontekście badań zawartych w niniejszej rozprawie istnieje zasadnicza różnica: badanie obrażenia będącego oparzeniem nie ma z reguły charakteru kryminalistycznego. Jednak oparzenie stanowi jedno z obrażeń, które również wskazuje i rozpoznaje lekarz medycyny sądowej. Dokonując analizy, autorka zauważyła, że większość autorów posługuje się jedynie wskaźnikiem Accuracy (%), niektóre również F-score (%). Jak wskazuje tabela 9.4, w przypadku omawianym w ramach niniejszej rozprawy doktorskiej, dostosowany model FCN uzyskał najwyższe wyniki w zakresie wskaźnika F-score niż większość innych modeli dla oparzeń, poza modelami ResFeat50 i VggFeat16 (jednak jedynie dla części zestawu danych). W przypadku Accuracy, model osiągnął najwyższy wynik spośród badanych. Z punktu widzenia wielkości bazy danych, baza danych 2D-TIP obejmującej 3524 obrazy zajmuje pierwsze miejsce. Należy zaznaczyć, że zastosowany model FCN łączący kilka rozwiązań prowadzących do regularyzacji sieci i zatrzymania jej przeuczenia (ang. *overfittingu*) poprzez połączenie metody *early stopping* i *dropout*. Dodatkowo *batch normalization* przyspieszył uczenie sieci, tym samym zapobiegając zanikaniu gradientów. Natomiast w celu dodatkowo, sztucznego zwiększenia zbioru danych zastosowano augmentację. Te metody, prawdopodobnie znacząco wpłynęły na uzyskane wyniki, tym samym przewyższając metryki innych podejść publikowanych w literaturze.

Tabela 9.4. Porównanie otrzymanych wyników uzyskanych podczas badań eksperymentalnych z innym metodami

Ref.	Wykorzystany model CNN	Rok publikacji	Zbiór danych	F-score (%)	Accuracy (%)
Podbiegnięcia krwawe i otarcia:					
rozpoznane w ramach niniejszej rozprawy doktorskiej	U-Net z EfficientNetB3	-	3524	92.2	99.90
Oparzenia:					
(Şevik i in., 2019)	DCNN: SegNet	2019	105	80.5	-
(Rehman Butt i in., 2019)	hybrid segmentation method	2019	173	-	74.86
(Yadav i in., 2019a)	SVM-based method	2019	74	85.0	82.43
(Abubakar, Ugail, Smith, i in., 2020)	customised ResNet50	2020	1900	-	99.30
(F. A. Khan i in., 2020)	DCNN	2020	450	-	79.40
(Abubakar, Ugail, Smith, i in., 2020)	CNN: ResFeat50	2020	743	93.0-97.0	95.43
(Abubakar, Ugail, Smith, i in., 2020)	CNN: VggFeat16	2020	743	78.0-93.0	85.67
(Jiao i in., 2019)	R-CNN: R101A	2019	1150	-	82.04
(Jiao i in., 2019)	R-CNN: IV2RA	2019	1150	-	83.02
(Jiao i in., 2019)	R-CNN: R101FA	2019	1150	-	84.51
(Chauhan & Goyal, 2020)	CNN: ResNet50, VGG16, VGG19	2020	141	87.2	91.53
(Abubakar i in., 2019)	CNN: VGG16	2019	-	-	98.75
(Abubakar i in., 2019)	CNN: VGG19	2019	-	-	97.56
(Abubakar i in., 2019)	CNN: VGG-Face	2019	-	-	95.21
(Abubakar, Ugail, & Bukar, 2020a)	CNN: ResNet50	2020	680	-	99.30
(Abubakar & Ugail, 2019)	CNN: ResNet101	2019	1360	-	99.50
(Cirillo i in., 2019)	CNN: VGG16, GoogleNet, ResNet50, ResNet101	2019	23	-	90.54
(Chauhan i in., 2019)	CNN: ResNet50	2019	109	-	93.58
(Rostami, Niezgoda, i in., 2021)	CNN: AlexNet	2021	94	89.2	90.50
R-CNN - Region-based Convolutional Neural Network, SVM – Support Vector Machine, DCNN – Deep Convolutional Neural Network.					

Źródło: opracowanie własne

Ostatnią z analiz jaką przeprowadzono, był wpływ czasu wykrycia obrażenia w porównaniu ze średnim czasem przeprowadzania zewnętrznej sekcji zwłok. Doświadczony lekarz medycyny sądowej potrzebuje średnio 15 minut na ocenę obrażeń na powłokach ciała (pomiar wykonany w zakresie od 03:39 do 27:19 minut na podstawie 100 przykładów sekcji zewnętrznej zwłok). Średni czas detekcji i klasyfikacji obrażenia na obrazie to 0,22 sekundy, przy odchyleniu standardowym (S.D.) równym 0,44 sekundy. Analiza procentowa wykazała, że 16% wyników mieści się w przedziale 0–0,1 sekundy, 55% w przedziale 0,1–0,3 sekundy, a 29% przekracza 0,3 sekundy. Zastosowanie miar takich jak mediana (0,22 sekundy) pozwala na lepsze zrozumienie danych w kontekście asymetrycznego rozkładu. Przeprowadzono również analizę przedstawionego przedziału ufności (95% CI) dla średniej wartości czasu przewidywania (0,22 sekundy). Wartości te mieściły się w zakresie od 0,03 do 0,41 sekundy, co potwierdzono zarówno dla pojedynczych obrażeń, jak i tych występujących w skupiskach.

10. Przeniesienie wyników segmentacji na model 3D – CZĘŚĆ IV badań

W poprzednich rozdziałach przedstawiono dwa podejścia, których potencjał zastosowania w medycynie sądowej jest wyraźnie zauważalny przez autorkę. Każde z przedstawionych rozwiązań to inna metoda, inny otrzymany produkt jednak celem każdego z nich jest pomoc w procesie diagnozy lekarzowi medycyny sądowej. Na tym etapie zrealizowano:

1. Część II – automatyczne modelowanie 3D w zadaniu analizy obrazów post-mortem pomocne w procesie tworzenia dokumentacji cyfrowej ciała ludzkiego. W kontekście tych badań należy ponownie wspomnieć, że przeprowadzana sekcja zwłok jest czynnością niepowtarzalną, mającą duży wpływ na kierunek dalszego postępowania karnego. Cyfrowy zapis w postaci obrazów RGB (należących już do częstej praktyki lekarskiej) ale również pełny model 3D ciała ludzkiego z nałożoną teksturą (zagadnienie jego wykorzystania wciąż będące w fazie badań w różnych ośrodkach) umożliwiają późniejszy wgląd i analizę przez biegłych, co jest nieocenione w kontekście sądowym. Posiadanie takiej dokumentacji zapewnia transparentność, umożliwia weryfikację wyników przez niezależnych ekspertów oraz stanowi trwały zapis, który może być wykorzystany w przyszłości, jeśli zajdzie potrzeba ponownego przeanalizowania przyczyn śmierci lub metodologii przeprowadzonej sekcji.
2. Część III - analiza obrazów post-mortem z wykorzystaniem segmentacji semantycznej pozwalając na automatyczną oraz nieinwazyjną detekcję i klasyfikację obrażeń na powłokach ciała przyspieszając sekcję zwłok, jak również wykluczając czynnik ludzki subiektywnej oceny w ten sposób automatyzując proces dokumentowania obrażeń.

Autorka przedstawionych badań dostrzega potencjał, który poszerza zakres przeprowadzonych badań poza zaplanowane rozwiązania, obejmujące trzy kluczowe komponenty analizy obrazów. Wizja ta skierowana jest na stworzenie miarodajnego, jednolitego systemu, którego efektem będzie nie tylko znaczące przyspieszenie i zwiększenie dokładności procesów diagnozowania i dokumentowania w medycynie sądowej, ale również stworzenie możliwości dla głębszej, wielowymiarowej analizy danych, co może przyczynić się do rozwoju nowych metod badawczych oraz udoskonalenia obecnych praktyk. System ten miałby potencjał do stania się narzędziem transformującym sposób, w jaki specjaliści mogą weryfikować i interpretować dane z różnych scenariuszy medycznych i prawnych, zapewniając tym samym lepszą jakość i wiarygodność dowodów sądowych, co jest nieocenione w kontekście międzynarodowych standardów medycyny sądowej.


W niniejszym rozdziale przedstawiono pierwszy krok zmierzający do integracji przedstawionych badań, którym jest zaprezentowanie rozpoznanych obrazów w procesie segmentacji semantycznej na fotogrametrycznym modelu 3D ciała człowieka.

10.1. Rodzaj wykorzystanych danych

W tej części badania wykorzystany został fotogrametryczny model 3D oraz wyniki segmentacji semantycznej. Rysunek 10.1 przedstawia wyeksportowany model 3D w formacie .obj, odpowiadające mu wyniki segmentacji semantycznej w formacie .png oraz obrazy wejściowe w formacie .jpg. Należy zauważyć, że obrazy z procesu segmentacji semantycznej zostały poddane pre-processingowi w postaci skalowania z rozmiaru 5616 x 3744 do rozmiaru 640 x 640, a następnie przycięciu do rozmiaru 480 x 480. Pre-processing stanowił krok dzięki któremu osiągnięto zgodność z modelem wstępnie przetrenowanym na zbiorze ImageNet (gdzie średnia rozdzielczość obrazu wynosiła 469 x 387), poprawiono wydajność obliczeniową, a także zapewniono spójność danych gdyż zbiór 2D-TIP poddany został koniecznej augmentacji celem jego sztucznego powiększenia. Oznacza to, że uzyskanie wyników na obrazie oryginalnym w tym przypadku nie było możliwe. Aby móc nanieść rozpoznane predykcje na model 3D należało przywrócić oryginalne proporcje obrazu poprzez zastosowanie paddingu, czyli tzw. dopełniania poprzez dodawanie dodatkowych pikseli wokół obrazu (na rysunku 10.1(b) widoczne jako czarne obramowanie po prawej i lewej stronie). Dodanie paddingu pozwala na dopasowanie obrazu do wymaganego rozmiaru bez skalowania, które mogłoby zniekształcić zawartość obrazu w ten sposób zachowując jego oryginalne proporcje.



a) model 3D z nałożoną teksturą



b) obrazy oryginalne

c) wyniki segmentacji semantycznej

Rysunek 10.1. Dane wykorzystane do integracji modelu 3D z wynikami segmentacji semantycznej po paddingu w postaci (a) wyeksportowanego modelu 3D (.obj), (b) oryginalnych obrazów wejściowych (.jpg) oraz (c) obrazów z wynikami segmentacji (.png). Obrazy (c) zostały poddane pre-processingowi, w tym skalowaniu i przycięciu, a następnie zastosowaniu padding w celu zachowania oryginalnych proporcji obrazów (b) przed ich integracją z modelem 3D (źródło: opracowanie własne)

10.2. Platforma badawcza: hardware i software

Obliczenia wykonano przy wykorzystaniu konfiguracji sprzętowej w skład której wchodził procesor AMD Ryzen 9 5900X 12-Core, 3.70 GHz, karta graficzna NVIDIA GeForce GTX 960, pamięć RAM 32 GB i system operacyjny Windows 10 Pro (64-bitowy system operacyjny, procesor x64). Skrypt napisany został w środowisku programistycznym Python 3.10 z wykorzystaniem edytora kodowania Visual Studio Code i przy wykorzystaniu bibliotek:

- Biblioteka `copy`

Opis: Standardowa biblioteka Pythona umożliwiająca wykonywanie operacji kopiowania obiektów w Pythonie. Szczególnie przydatna, gdy chcemy stworzyć kopię obiektu, aby zmodyfikować jego zawartość bez wpływu na oryginalny obiekt. W przypadku omawianej funkcji wykorzystana do `deepcopy` kolorów wierzchołków trójkątów modelu 3D. Dzięki temu można było zmodyfikować kolory niektórych z nich (tj. nanieść kolor maski w miejsce obrażenia) bez wpływu na oryginalne dane.

- Biblioteka `Numpy`

Opis: Biblioteka do obliczeń numerycznych w Pythonie, szczególnie przydatna do pracy z dużymi tablicami wielowymiarowymi. Wykorzystana przede wszystkim do tworzenia nowych tablic kolorów czy przetwarzania współrzędnych wierzchołków.

- Biblioteka `cv2` (OpenCV)

Opis: Standardowa biblioteka open-sourcowa do komputerowego przetwarzania obrazów i wideo. Oferuje ona szeroki zakres funkcji do analizy obrazów, takich jak detekcja krawędzi, znajdowanie konturów, przekształcenia geometryczne i wiele innych. W kontekście omawianej funkcji zastosowana przede wszystkim do przekształceń kolorów (`cv2.cvtColor`), znajdowania konturów (`cv2.findContours`), detekcji krawędzi (`cv2.Canny`) i innych operacji przetwarzania obrazów związanych z wyodrębnieniem masek segmentacji.

- Biblioteka `PILLOW` (Python Imaging Library)

Opis: Biblioteka do pracy z obrazami umożliwiająca otwieranie, manipulowanie i zapisywanie różnych formatów plików graficznych.

- Biblioteka `Trimesh` (Python Imaging Library)

Opis: Biblioteka do pracy z siatkami trójkątów. Umożliwia manipulowanie i analizowanie siatek 3D, w tym operacje takie jak wczytywanie, zapisywanie, transformacje i wizualizacje.

- Biblioteka Open3D (Python Imaging Library)

Opis: Biblioteka do pracy z danymi 3D, w tym chmurami punktów, modelami siatkowymi (ang. *mesh*) i obrazami. Umożliwia przetwarzanie, analizowanie i wizualizowanie danych 3D. Biblioteka ta umożliwiła również projekcję punktów 2D na obraz 3D oraz nakładanie kolorowych masek na model 3D.

10.3. Weryfikacja działania integracji masek segmentacji semantycznej z modelem 3D

W ramach prac eksperymentalnych wstępnie zaprojektowano metodę projekcji rozpoznanych masek klas obrazów na model 3D. Zadanie podzielono na trzy etapy:

Przygotowanie masek segmentacji

Pierwszym krokiem było już wspomniane dostosowanie masek segmentacji, które w wyniku pre-processingu zostały przeskalowane i przycięte. Składało się na to skalowanie, przycinanie i dodawanie paddingu (rysunek 10.1(c)). W szczególności proces obejmował użycie funkcji takich jak `crop_and_resize` oraz `add_padding_to_image`. W tych operacjach kluczowe parametry to:

- `scale_x` i `scale_y`, które odpowiadają za przeskalowanie obrazu wzdłuż osi X i Y;
- `crop_x` i `crop_y`, które określają zakres przycięcia obrazu;
- `offset`, przesunięcie, które pozwala dostosować padding w obrazie, co może być istotne dla prawidłowego wyrównania maski z modelem 3D.

Dzięki tym operacjom maski segmentacji zostały przygotowane w taki sposób, aby mogły być później prawidłowo rzutowane na model 3D.

Rzutowanie wierzchołków modelu 3D na obraz 2D

W drugim etapie wierzchołki modelu 3D były rzutowane na obraz 2D celem określenia, które punkty modelu 3D znajdują się w granicach obrazu. Dodatkowo sprawdzono, które z tych punktów trafiają do regionów z maską segmentacyjną (gdzie maska ma wartość większą niż zero). Chodziło o to, by zidentyfikować, które fragmenty obrazu na których jest maska mają swoje odpowiedniki w przestrzeni 3D. Rzutowanie zostało zrealizowane za pomocą funkcji `cv2.projectPoints`, która wykorzystuje:

- macierz rotacji R oraz wektor translacji t (opisane w równaniu 10.1):

$$T = \begin{bmatrix} R & t \\ 0 & 1 \end{bmatrix} \quad (10.1)$$

$$T = \begin{bmatrix} r_{11} & r_{12} & r_{13} & t_x \\ r_{21} & r_{22} & r_{23} & t_y \\ r_{31} & r_{32} & r_{33} & t_z \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

gdzie:

R – macierz rotacji (3×3);

t – wektor translacji (3×1);

r_{ij} – elementy macierzy rotacji różne dla każdego z obrazów;

t_x, t_y, t_z – elementy wektora translacji różne dla każdego z obrazów.

- macierz kamery K (opisane w równaniu 10.2):

Zmodyfikowana macierz kamery K dla każdego piksela obrazu to macierz 3×3 . W kontekście przetwarzania obrazów i rzutowania punktów, współrzędne c_x, c_y reprezentują środek obrazu w układzie współrzędnych kamery. Te współrzędne są istotne, ponieważ określają punkt główny (ang. *principal point*) na obrazie, czyli punkt, w którym oś optyczna kamery przecina płaszczyznę obrazu:

$$K = \begin{bmatrix} f_x & 0 & c_x \pm offset \\ 0 & f_y & c_y \pm offset \\ 0 & 0 & 1 \end{bmatrix} \quad (10.2)$$

gdzie:

$f_x = f_y = f$ – parametry ogniskowej w pikselach;

c_x, c_y – współrzędne środka obrazu, gdzie $c_x = \frac{\text{szerokość_obrazu}}{2}$ i $c_y = \frac{\text{wysokość_obrazu}}{2}$;

$offset$ – obliczone przesunięcie dla obrazów uwzględniające kalibrację kamery, która dokładniej określa położenie punktu głównego.

- współczynniki zniekształceń optycznych, uwzględniające zniekształcenia radialne i tangencjalne (opisane w równaniu 10.3):

Macierz dystorsji wykorzystana do korekcji zniekształceń radialnych i tangencjalnych występujących na obrazie. W tym przypadku jest zdefiniowana jako:

$$dist = [k_1 \quad k_2 \quad p_1 \quad p_2 \quad k_3] \quad (10.3)$$

gdzie:

k_1, k_2, k_3 – zniekształcenia radialne;

p_1, p_2 – zniekształcenia tangencjalne.

Funkcja `cv2.projectPoints` przekształca punkty 3D na współrzędne 2D w przestrzeni obrazu, przy jednoczesnym uwzględnieniu parametrów kamery oraz zniekształceń optycznych. W procesie rzutowania dodatkowo sprawdzono, które z tych punktów trafiają do regionów z maską segmentacyjną (gdzie maska ma wartość większą niż zero). Chodziło o to, by zidentyfikować, które fragmenty obrazu na których jest maska, mają swoje odpowiedniki w przestrzeni 3D. Równanie 10.4 opisuje pełny proces rzutowania punktów 3D na współrzędne obrazu 2D, uwzględniając zarówno transformację przestrzenną, jak i parametry optyczne kamery:

$$\begin{aligned} \begin{bmatrix} u \\ v \\ 1 \end{bmatrix} &= K \begin{bmatrix} x_{distorted} \\ y_{distorted} \\ 1 \end{bmatrix} \\ \begin{bmatrix} x_{distorted} \\ y_{distorted} \end{bmatrix} &= \begin{bmatrix} \frac{X_{camera}}{Z_{camera}} (1 + k_1 r^2 + k_2 r^4 + k_3 r^6) + 2p_1 \frac{X_{camera}}{Z_{camera}} \frac{Y_{camera}}{Z_{camera}} + p_2 (r^2 + 2 \left(\frac{X_{camera}}{Z_{camera}} \right)^2) \\ \frac{Y_{camera}}{Z_{camera}} (1 + k_1 r^2 + k_2 r^4 + k_3 r^6) + p_1 \left(r^2 + 2 \left(\frac{Y_{camera}}{Z_{camera}} \right)^2 \right) + 2p_2 \frac{X_{camera}}{Z_{camera}} \frac{Y_{camera}}{Z_{camera}} \end{bmatrix} \quad (10.4) \\ \begin{bmatrix} X_{camera} \\ Y_{camera} \\ Z_{camera} \end{bmatrix} &= R \begin{bmatrix} X_{world_point} \\ Y_{world_point} \\ Z_{world_point} \end{bmatrix} + t \end{aligned}$$

gdzie:

ostateczny wzór wyraża współrzędne obrazowe u i v w funkcji współrzędnych w globalnym układzie odniesienia $X_{world_point}, Y_{world_point}, Z_{world_point}$, parametrów kamery oraz współczynników zniekształceń.

Po rzutowaniu punktów na obraz 2D, dla każdego punktu sprawdzano, czy znajduje się on w granicach wymiarów obrazu (np. $0 \leq u < \text{szerokość obrazu}$, $0 \leq v < \text{wysokość obrazu}$). Następnie weryfikowano, czy wartość maski w odpowiadającym miejscu jest większa niż zero, co wskazywało na przynależność punktu do regionu segmentacyjnego.

Przeniesienie masek na model 3D

Trzeci etap stanowił przeniesienie masek na model 3D, co zostało zrealizowane w trzech głównych krokach:

- a. rzutowanie masek na model 3D: po określeniu, które wierzchołki modelu 3D pasują do maski w obrazie 2D (w wyniku rzutowania 3D na 2D), można było wybrać, które wierzchołki w przestrzeni 3D powinny zostać „pokryte” przez maski. Innymi słowy, wierzchołki, które po rzutowaniu na obraz znalazły się w obszarze maski, są uznawane za te, które należą do obszaru reprezentowanego przez maskę w przestrzeni 3D. W utworzonej funkcji maski stanowią obraz w skali szarości zawierający informacje o segmentacji obrazu. Model 3D reprezentowany jest jako zbiór wierzchołków i trójkątów, gdzie każdy wierzchołek ma przypisany kolor.
- b. przypisanie klas segmentacji: w następstwie przeniesienia masek na model 3D, wierzchołki, które znalazły się w obszarze maski, są przypisywane do odpowiednich klas segmentacji;
- c. kolorowanie wierzchołków: na koniec, te same wierzchołki, które zostały przypisane do danej klasy segmentacji w masce, są kolorowane zgodnie z wartościami z maski. Dzięki temu w modelu 3D widać, które obszary odpowiadają poszczególnym klasom segmentacyjnym (podbiegnięcia krwawe, otarcia naskórka).

10.4. Ocena otrzymanych wyników

W ramach eksperymentu przeprowadzono rzutowanie wierzchołków modelu 3D na obraz 2D dla kilku zestawów danych, celem zobaczenia które z nich znajdują się w określonych regionach obrazu maski segmentacji semantycznej. Punkty 3D reprezentują wierzchołki modelu trójwymiarowego, a celem ich odwzorowania na obrazie 2D jest zrozumienie, jak te punkty są widoczne w danej perspektywie kamery. Wyniki przedstawiono w tabeli 10.1, która zawiera:

- liczbę wierzchołków 3D, które zostały poprawnie rzutowane na płaszczyznę obrazu i znajdują się w jego granicach. Oznacza to, że po przekształceniu i rzutowaniu współrzędne u i v mieszczą się w zakresie szerokości i wysokości obrazu;
- liczbę punktów wierzchołków 3D, które zostały poprawnie rzutowane na płaszczyznę obrazu, znajdują się w jego granicach oraz należą do obszaru, gdzie maska ma wartość większą od zera (zgodnie z rysunkiem 10.2). Wierzchołki przypadające na maskę o wartości większej od zera są identyfikowane jako należące do interesującego nas obszaru oznaczonego w masce.

Analizując, można zauważyć, że liczba punktów rzutowanych na obraz jest znacznie większa niż liczba punktów znajdujących się w obszarze maski. Niskie wartości punktów w

masce w porównaniu do liczby punktów rzutowanych mogą wskazywać na mały obszar maski w stosunku do całego obrazu oraz na pewne niedokładności w dopasowaniu maski do rzutowanych punktów. Uzyskane wyniki sugerują niewielkie odchylenia w dopasowaniu masek, jednak nie są one na tyle duże, aby uznać je za błąd. Głównym powodem rozbieżności jest mały obszar maski, co nie stanowi błędu w procesie rzutowania, a jedynie ograniczenie wynikające z charakterystyki danych wejściowych.

Tabela 10.1. Liczba punktów modelu 3D rzutowanych na obraz 2D i znajdujących się w granicach obrazu oraz liczba punktów, które znajdują się w obszarze maski


Numer maski	in_image_cnt ¹	in_mask_cnt ²	Dokładność ³
2612_klatka_size.png	278623	153	≈ 0.055 %
2594_noga_size.png	265115	6147	≈ 2.32 %
2517_ręka_size.png	161000	1286	≈ 0.80 %

¹ liczba punktów wierzchołków 3D poprawnie rzutowanych na płaszczyznę obrazu i znajdujących się w granicach tego obrazu;

² liczba punktów wierzchołków 3D poprawnie rzutowanych na płaszczyznę obrazu, znajdujących się w granicach obrazu oraz znajdujących się w obszarze, gdzie maska ma wartość większą od zera;

³ obliczona jako $D = \frac{\text{in_mask_cnt}}{\text{in_image_cnt}} \times 100\%$

Źródło: opracowanie własne




Rysunek 10.2. Oznaczenie wartości rzutowanych pikseli, które znajdują się w obrębie obrazu oraz w obszarze maski segmentacji semantycznej, gdzie wartość jest większa od zera (źródło: opracowanie własne)

Wierzchołkom 3D, które znajdują się w obszarze maski na obrazie 2D, przypisywane są kolory segmentacji wynikające z masek. Dane te są przechowywane w strukturze modelu, a następnie zapisywane w pliku wyjściowym modelu 3D. Zaktualizowany model 3D, uwzględniający te kolory, został zapisany i zwizualizowany przy użyciu narzędzia Open3D, co pozwoliło dokładnie zobrazować dopasowanie masek i ich wpływ na segmentację modelu 3D.


Na rysunku 10.3 przedstawiono projekcje masek w postaci punktów na chmurę dla trzech obrazów segmentacji. W tym przypadku wykryte obrażenia należały do otarć naskórka. Natomiast na rysunku 10.4 przedstawiono model 3D z projekcją wykrytych obrażeń. Osiągnięto wizualną zgodność z rzeczywistością wskazując, że wykonana projekcja jest w stanie dokładnie odwzorować kształt i strukturę obiektu, co jest niezwykle ważne w zastosowaniach takich jak medycyna sądowa. Dzięki temu następuje lepsze zrozumienie relacji przestrzennych między różnymi obrażeniami. Należy jednak zauważyć, że w przyszłości należałoby poprawić jakość modelu 3D oraz dokładność rzutowania. W tym celu można podjąć następujące kroki:

- wykonać precyzyjną kalibrację kamery: przeprowadzenie kalibracji kamery z wykorzystaniem pola testowego może poprawić dokładność rzutowania. Proces ten powinien obejmować dokładne pomiary parametrów wewnętrznych uwzględniając również istotne przesunięcie optyczne c_x, c_y ;
- zastosowanie bardziej zaawansowanych metod teksturowania poprzez interpolację kolorów, aby uzyskać płynniejsze przejścia między wierzchołkami lub zastosować mapowania tekstur o wysokiej rozdzielczości, co powinno pozwolić na lepsze odwzorowanie szczegółów.


Analiza wyników projekcji punktów na model 3D oraz ocena wizualna zidentyfikowały obszary wymagające poprawy. Jednakże, mimo pewnych niedokładności, uzyskane wyniki oferują istotne korzyści w wielu zastosowaniach praktycznych. Dokładniejsza segmentacja maski, precyzyjna kalibracja kamery, optymalizacja transformacji przestrzennych oraz zastosowanie zaawansowanych metod teksturowania mogą znacząco poprawić jakość wyników.



a) projekcja na obraz 2594 (kolana)




b) projekcja na obraz 2612 (klatka piersiowa)



c) projekcja na obraz 2517 (ramię)

Rysunek 10.3. Przedstawienie projekcji masek segmentacji 2D na odpowiadające im punkty w przestrzeni 3D, ilustrując rozmieszczenie wykrytych obrażeń (otarć naskórka) na trzech obrazach (źródło: opracowanie własne)



Rysunek 10.4. Przedstawienie modelu 3D z projekcją masek segmentacji, pokazując odwzorowanie wykrytych obrażeń na modelu trójwymiarowym osiągając względnie wizualną zgodność z rzeczywistością (źródło: opracowanie własne)

11. Analiza morfometryczna i morfologiczna obrażenia jako cyfrowe wspomaganie obrazowej diagnostyki – CZĘŚĆ V badań

Posiadając dokumentację medyczną 3D z automatycznym i bezinwazyjnym rozpoznaniem obrażeń, kolejnym krokiem jest zaoferowanie możliwości przeprowadzania analiz morfometrycznych i morfologicznych. Badania tego typu, w praktyce medyczno-sądowej wykorzystane mogą być do szczegółowych analiz przy stawianiu hipotez powstania danego obrażenia. Należy podkreślić, że w standardowej praktyce lekarskiej takie analizy ograniczone są do określania rozmiaru i ewentualnie kształtu obrażenia, natomiast dostarczenie narzędzi uzyskania dokładniejszych informacji o obrażeniu znacząco może wpłynąć na jakość przeprowadzanych sekcji zwłok zewnętrznych.

Badania nad tą częścią podzielone zostały na dwa podzadania. W pierwszym zbadano cechy fizyczne obrażenia w celu zrozumienia jego charakteru, mechanizmu oraz potencjalnych przyczyn powstania (analiza w przestrzeni 2D). W drugim zadaniu dokonano oceny kształtu, wielkości, głębokości, lokalizacji i innych właściwości uszkodzenia tkanek (analiza w przestrzeni 3D).

11.1. Platforma badawcza: hardware i software

Analizy przeprowadzono z wykorzystaniem sprzętowej konfiguracji, w skład której wchodził procesor AMD Ryzen 9 5900X 12-Core, 3.70 GHz, karta graficzna NVIDIA GeForce GTX 960, pamięć RAM: 32.0 GB i system operacyjny Windows 10 Pro (64-bitowy system operacyjny, procesor x64). Analizy przeprowadzono w środowisku programistycznym Python 3.10 bez dodatkowego edytora kodowania (w tzw. wersji RAW Python) przy wykorzystaniu 8 głównych bibliotek:

- Biblioteka `cv2` (OpenCV)

Opis: Standardowa biblioteka open-sourcowa do komputerowego przetwarzania obrazów i wideo. Wykorzystana do analizy obrazów w przestrzeni 2D z wykorzystaniem operacji na macierzach konwolucji np. Canny Edge Detector, Histogram Equalisation, Unsharp Masking, Sobel Operator.

- Biblioteka `numpy`

Opis: Biblioteka do obsługi dużych, wielowymiarowych tablic i macierzy, a także do wykonywania na nich skomplikowanych operacji matematycznych. Biblioteka ta oferuje

szerokie wsparcie dla operacji algebraicznych, statystycznych oraz transformacji danych. Wykorzystana do analizy obrazów w przestrzeni 2D z wykorzystaniem operacji na macierzach konwolucji np. Laplacian of Gaussian, Unsharp Masking, Histogram Stretching, Wiener Filter, Lucy-Richardson Deconvolution. Natomiast w przypadku analizy w przestrzeni 3D wykorzystana do obliczania odległości euklidesowych pomiędzy punktami i wierzchołkami modelu siatkowego (ang. *mesh*), a także do operacji na tablicach wierzchołków w celu optymalizacji procesów obliczeniowych.

- Biblioteka `scipy`

Opis: Biblioteka do zaawansowanych operacji matematycznych, w tym przetwarzania sygnałów i obrazów. Wykorzystana do analizy obrazów w przestrzeni 2D z wykorzystaniem operacji na macierzach konwolucji np. Robert-Cross Operator, Laplacian of Gaussian.

- Biblioteka `skimage`

Opis: Biblioteka do przetwarzania obrazów, oferująca szeroki zakres funkcji, od prostych operacji filtracji po zaawansowane techniki rekonstrukcji obrazów. Wykorzystana do analizy obrazów w przestrzeni 2D z wykorzystaniem operacji na macierzach konwolucji np. Prewitt Operator, Lucy-Richardson Deconvolution.

- Biblioteka `vedo`

Opis: Biblioteka służąca do m.in. wizualizacji danych 3D. Jest szeroko stosowana w analizie danych naukowych, gdzie konieczne jest wizualne przedstawienie skomplikowanych geometrii, siatek trójwymiarowych i wyników symulacji. Wykorzystana do analizy obrazów w przestrzeni 3D w postaci wizualizacji modelu siatkowego (ang. *mesh*) oraz ścieżek (odległości rzeczywistych), w tym interaktywnego renderowania modelu 3D i wyświetlania punktów wybranych przez autorkę.

- Biblioteka `trimesh`

Opis: Biblioteka przeznaczona do obsługi geometrii 3D, ze szczególnym naciskiem na siatki trójkątów (ang. *wireframe*). Pozwala na wczytywanie, manipulowanie oraz analizę siatek, oferując bogaty zestaw narzędzi do pracy z danymi geometrycznymi, jak wierzchołki, krawędzie, powierzchnie i inne elementy modelu siatkowego (ang. *mesh*). Wykorzystana do analizy obrazów w przestrzeni 3D w postaci zastosowania do wczytywania i przetwarzania plików `.obj` z modelami siatkowymi (ang. *mesh*) obiektu oraz do generowania grafów na podstawie ich struktury.

- Biblioteka `pyvista`

Opis: Biblioteka ułatwiająca wizualizację i analizę danych przestrzennych. Zawiera narzędzia do przetwarzania danych 3D, takich jak siatki, chmury punktów i objętości, a także zapewnia interaktywne środowisko do manipulacji obiektami trójwymiarowymi.

Wykorzystana do analizy obrazów w przestrzeni 3D do interaktywnego wybierania punktów na powierzchni modelu siatkowego (ang. *mesh*) oraz do renderowania obiektów 3D.

- Biblioteka `networkx`

Opis: Biblioteka przeznaczona do analizy i manipulacji grafami oraz sieciami. Oferuje funkcje do tworzenia grafów, analizowania ich właściwości oraz wykonywania operacji na sieciach, takich jak znajdowanie najkrótszych ścieżek czy analizowanie połączeń między węzłami. Wykorzystana do analizy obrazów w przestrzeni 3D do tworzenia grafu ważonego na podstawie struktury modelu siatkowego (ang. *mesh*) oraz obliczania najkrótszej ścieżki (odległości rzeczywistej) między wierzchołkami z wykorzystaniem algorytmu Dijkstry.

11.2. Przeprowadzenie analiz morfologicznych w przestrzeni 2D – operacje na macierzach konwolucji

Przykładowe przetworzenie obrazu z wykorzystaniem operacji na macierzach konwolucji pokazane zostało na rysunku 11.1. W analizie obrazu należy przede wszystkim skupić się na wyrazistości, granicach, konturach i cechach charakterystycznych. Autorka przeprowadziła szereg analiz z wykorzystaniem wybranych operacji na macierz konwolucji, dla których wnioski ogólne opisano w tabeli 11.1. Z uwagi na osiągnięte wyniki, zauważono, że najskuteczniejsze zastosowanie w kontekście analizy obrazów będą miały operacje takie jak:

Operator Sobel Edge Detector

Zasadniczo operator Sobel Edge Detector szacuje zmiany w poziomach intensywności obrazu poprzez wyznaczenie gradientu obrazu w dwóch głównych kierunkach: poziomym i pionowym. Wykorzystuje do tego maski konwolucyjne 3×3 , które są antysymetryczne względem kierunku wykrywanej krawędzi.

Operator ten dokonuje analizy zmian intensywności wzdłuż dwóch osi, a gradient obrazu jest obliczany na podstawie wyników konwolucji obrazu z maskami poziomą (S_x) i pionową (S_y) (Abo-Zahhad i in., 2014):

$$S_x = \begin{bmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{bmatrix} \quad S_y = \begin{bmatrix} +1 & +2 & +1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \quad (11.1)$$

gdzie:

S_x – przykład maski dla kąta 0° ;

S_y – przykład maski dla kąta 90° .

Gradient w danym punkcie obrazu jest obliczany jako:

$$G = \sqrt{(S_x^2 + S_y^2)} \quad (11.2)$$

Na obrazie przedstawiającym obrażenie i przetworzonym filtrem Sobela zauważalna jest wyraźna detekcja drobnych krawędzi. Krawędzie otarcia są dobrze zarysowane, podkreślono najdrobniejsze szczegóły i zmiany w teksturze skóry, co potencjalnie mogłoby umożliwić lekarzowi precyzyjne określenie granic obrażenia.

Operator Prewitt'a

Operator Prewitt'a jest bardzo podobny w działaniu do operatora Sobel'a i również służy do wykrywania pionowych i poziomych krawędzi na obrazach. Różnicą są jedynie wagi zastosowanych mask (Prewitt & Mendelsohn, 2006):

$$P_x = \begin{bmatrix} -1 & 0 & +1 \\ -1 & 0 & +1 \\ -1 & 0 & +1 \end{bmatrix} \quad P_y = \begin{bmatrix} +1 & +1 & +1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix} \quad (11.3)$$

gdzie:

P_x – przykład maski dla kąta 0° ;

P_y – przykład maski dla kąta 90° .

Zastosowanie operatora Prewitta zarówno w pionie, jak i poziomie uwydatnia struktury o określonej orientacji, dzięki lekarz może lepiej zrozumieć rozkład, a także kierunek powstania obrażenia co stanowi ogromną wartość dodaną w kontekście ustalania jego powstania i ewentualnego dopasowania narzędzie/obiektu sprawczego.

Operator Robert-Cross

Operator Robert-Cross'a działa na zasadzie obliczenia różnic intensywności pikseli położonych po przekątnej (dla kierunków 45° i 135°) w swoim sąsiedztwie, a następnie dodaniu

ich wartości bezwzględnych. Operator ten składa się z dwóch macierzy splotu w wymiarach 2×2 (Abo-Zahhad i in., 2014):

$$R_x = \begin{bmatrix} +1 & 0 \\ 0 & -1 \end{bmatrix} \quad R_y = \begin{bmatrix} 0 & +1 \\ -1 & 0 \end{bmatrix} \quad (11.4)$$

gdzie:

R_x – maska dla kierunku 135° ;

R_y – maska dla kierunku 45° .

W kontekście analizy obrażenia na obrazie, filtr Rober-Cross zapewnia podobne efekty jak Sobel Edge Detector, lecz z nieco większą intensywnością całego rozkładu obrażenia (w przeciwieństwie do Sobela, który skupia się na krawędziach). Umożliwia to wyraźną identyfikację, w tym przypadku, powierzchni tarcia.

Laplacian of Gaussian (LoG)

Laplacian jest operatorem różniczkowym drugiego rzędu. W przeciwieństwie do detektorów krawędzi omówionych powyżej wykorzystuje tylko jedną maskę. Z uwagi na dużą wrażliwość LoG'a na szum poprzedza się go wygładzeniem filtrem Gaussa. Dwie powszechnie stosowane małe maski to (Sotak & Boyer, 1989):

$$LoG = \begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix} \quad LoG = \begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix} \quad (11.5)$$

Analizując obrażenie, technika Laplacian of Gaussian łączy wygładzanie z wykrywaniem krawędzi, co skutkuje bardziej jednorodnym obrazem z wyraźnymi konturami obrażenia, uwydatniając je. Ta metoda sprawdzi się również w lepszym uwidocznieniu subtelnych zmian w strukturze skóry wokół obrażenia.


Algorytm Canny Edge Detection

Algorytm Canny'ego podobnie jak poprzednie należy do popularnych metod wykrywania krawędzi. W pierwszej kolejności Canny redukuje szum za pomocą filtru gaussowskiego (maska dobierana jest z uwzględnieniem intensywności szumu na obrazie), następnie stosując operator Sobel'a wyznaczany jest gradient obrazu. Kolejnym krokiem jest zmniejszenie szerokości wykrytych krawędzi do jednego piksela bez utraty ich ciągłości, natomiast progowanie z histerezą łączy krawędzie, które wcześniej zostały podzielone ze względu na lokalnie mniejszy kontrast. Algorytm Canny'ego należy do częściej stosowanych niż

poprzednio wymienione detektory z uwagi na jego duże możliwości dostosowania do konkretnego zadania za pomocą parametrów, wariancji filtru gaussa czy wartości progów. Idea opracowania algorytmu Canny'ego oparta została o (Abo-Zahhad i in., 2014; Canny, 1986):

- zminimalizowanie liczby błędów wykrycia nieistniejących krawędzi;
- zminimalizowanie liczby błędów przy niewykrywaniu istniejących krawędzi;
- zwiększenie dokładności wyznaczania krawędzi.

Detekcja krawędzi metodą Canniego oferuje bardzo precyzyjne i drobne linie krawędzi. Ta technika jest niezwykle skuteczna w identyfikacji dokładnych granic otarcia, co jest kluczowe dla oceny głębokości i rozległości obrażeń.



Rysunek 11.1. Przedstawienie wyników przetworzenia obrazu w przestrzeni 2D za pomocą operacji na macierzach konwolucji, które pomagają w analizie wyrazistości, granic, konturów i cech charakterystycznych, istotnych w kontekście badania obrażeń (źródło: opracowanie własne)

Tabela 11.1. Operacje na macierzach konwolucji i ich zastosowanie analizie obrazów

Operacja na macierzy konwolucji	Zastosowanie
Operator Sobel Edge Detector	Wykrywanie drobnych krawędzi obrazów: umożliwia dokładne zarysowanie granic obrazów, co jest kluczowe dla precyzyjnej oceny obrazów przez lekarza medycyny sądowej. Pomaga w identyfikacji małych, subtelnych zmian w strukturze skóry.
Operator Prewitta	Analiza kierunku powstania obrażenia: uwydatnianie pionowych i poziomych struktur obrazów pomaga w zrozumieniu kierunku i rozkładu siły, która spowodowała obrażenie, co może być istotne w rekonstrukcji przebiegu zdarzenia.
Filtr Rober-Cross	Identyfikacja powierzchni tarcia: intensywniejsza detekcja krawędzi pozwala na wyraźniejsze zobrazowanie powierzchni otarć i tarcia, co może wskazywać na rodzaj narzędzia lub powierzchni, z którą doszło do kontaktu.
Laplacian of Gaussian (LoG)	Wykrywanie subtelnych zmian w strukturze skóry: uwydatnianie konturów i subtelnych zmian w teksturze skóry wokół obrażeń może pomóc w identyfikacji mniej widocznych uszkodzeń, takich jak mikrouszkodzenia lub wczesne stadia podbiegnięć krwawych.
Canny Edge Detection	Precyzyjna identyfikacja granic obrazów: metoda ta pozwala na bardzo dokładne wykrywanie krawędzi, co jest kluczowe dla oceny rozmiaru i rozległości obrażeń, szczególnie w przypadku skomplikowanych i nieregularnych kształtów obrażeń. Z wykorzystaniem tego filtru najczęściej można przeprowadzić pomiar obrażenia w przestrzeni 2D.
Histogram Equalisation*	Ujawnianie wewnętrznych szczegółów obrazów: poprawa kontrastu pozwala na lepsze rozróżnienie między zdrową skórą a obszarem obrażenia, co ułatwia identyfikację wewnętrznych struktur i szczegółów uszkodzenia.
Histogram Stretching*	Wizualizacja różnic tonalnych w obrażeniach: lepsza wizualizacja różnic tonalnych między różnymi obszarami obrażenia pomaga w ocenie intensywności uszkodzeń oraz w identyfikacji różnych faz gojenia lub stopnia podbiegnięcia krwawego.
Unsharp Masking*	Podkreślanie detali obrazów: poprawa wyrazistości obrazu umożliwia dokładniejsze zobrazowanie detali i cech charakterystycznych obrazów, co jest pomocne w ich identyfikacji i klasyfikacji.
Filtr Wienera*	Poprawa jakości obrazów niskiej jakości: zredukowanie szumów pozwala na bardziej precyzyjną ocenę obrazów, nawet w przypadku obrazów o niższej jakości, co jest istotne w sytuacjach, gdy dostępne są jedynie słabej jakości obrazy.
Lucy-Richardson Deconvolution*	Dokładna analiza granic i struktury obrazów: usunięcie rozmycia pozwala na precyzyjniejszą analizę krawędzi i struktury obrazów, co jest kluczowe dla pomiarów i dokładnej oceny rozmiaru oraz kształtu obrażeń.


* W przyszłych badaniach operacje te nie będą uwzględniane w analizie obrazów z uwagi na ich niewielki wpływ

Źródło: opracowanie własne

Na kolejnym rysunku 11.2 skupiono się na przedstawieniu fragmentu otarcia w zbliżeniu wykonując trzy dodatkowe analizy przy użyciu: detekcji krawędzi metodą CANNIEGO, operatora Sobel Edge Detector i operatora Rober-Cross. Obraz przetworzony metodą CANNIEGO ukazuje bardzo precyzyjne i cienkie linie krawędzi. W wyniku tego przetworzenia można zauważyć, że krawędzie otarcia są wyraźnie zarysowane, co sugeruje, że granice obrażenia są ostre i dobrze zdefiniowane. W obrębie obrażenia widoczne są liczne drobne szczegóły, co może wskazywać na nierówną powierzchnię z wieloma małymi nierównościami i zagłębieniami. Konkludując tak wyraźne krawędzie mogą sugerować, że obrażenie powstało w wyniku bezpośredniego kontaktu z ostrym lub szorstkim przedmiotem, który pozostawił dokładnie zarysowane ślady. Obraz przetworzony operatorem Sobela również ukazuje wyraźne krawędzie, ale z mniejszą precyzją niż metoda CANNIEGO. Krawędzie są bardziej miękkie i mniej zdefiniowane niż w przypadku CANNIEGO, co może sugerować, że granice obrażenia są bardziej rozmyte. Jednak, operator Sobela ujawnia większe struktury w obrębie obrażenia, co może wskazywać na obecność większych, bardziej jednorodnych obszarów. Konkludując miękkie krawędzie mogą sugerować, że obrażenie powstało w wyniku działania bardziej rozproszonej siły, na przykład tarcia o chropowatą powierzchnię, która nie pozostawiła ostrych śladów. Zastosowanie innego operatora np. Rober-Cross pokazuje efekty zbliżone do Sobela, ale z pewnymi różnicami. Przykładem są wyraźne krawędzie jednak z nieco inną charakterystyką intensywności niż w przypadku Sobela. Robert-Cross ukazuje szczegóły w nieco innym świetle, podkreślając różnice w teksturze obrażenia. Widoczne są zarówno większe struktury, jak i drobniejsze detale. Podobnie jak w przypadku Sobela, można wysunąć wniosek, że powierzchnia obrażenia jest niejednolita, z obszarami o różnym stopniu uszkodzenia.

Na podstawie analizy przetworzonych obrazów obrażenia z rysunku 11.1 i rysunku 11.2 można wyciągnąć jeden, spójny wniosek dotyczący charakterystyki obrażenia:

- Kontury i granice: obrażenie ma ostre i dobrze zdefiniowane granice, co sugeruje, że mogło powstać w wyniku bezpośredniego kontaktu z ostrym/szorstkim przedmiotem. Jednakże, metody Sobela i Rober-Cross wskazują również na obecność bardziej rozmytych obszarów, co może sugerować działanie dodatkowej siły tarcia.
- Charakterystyka powierzchni: powierzchnia obrażenia jest nierówna, z wieloma małymi nierównościami i zagłębieniami, co widoczne jest szczególnie w detekcji krawędzi metodą CANNIEGO. Obrazy przetworzone operatorami Sobela i Rober-Cross wskazują na obecność zarówno większych, jak i drobniejszych struktur. Rozmycie niektórych granic obrażenia potwierdza możliwość działania siły tarcia, która mogła pogłębić obrażenie.



Rysunek 11.2. Przedstawienie fragmentu otarcia w zbliżeniu, ukazując wyniki trzech analiz przeprowadzonych za pomocą detekcji krawędzi metodą Canniego, operatora Sobela i operatora Robert-Cross. Analiza ta pozwala na szczegółowe uchwycenie konturów, granic i cech charakterystycznych obrażenia, pomagając w identyfikacji typu uszkodzenia oraz sił, które mogły wpłynąć na jego powstanie (źródło: opracowanie własne)

Przeprowadzając analizę obrażenia przy użyciu różnych technik przetwarzania obrazów można uzyskać dokładniejszą ocenę jego charakterystyki pozwalającą na wyciągnięcie wniosków na temat jego powstania. W tym przykładzie ukazane zostało obrażenie określone z natury do *prostych* w analizie (będącym dużym i wyraźnie zarysowanym). W zamyśle autorki przedstawienie takiego przykładu pomaga w lepszym zrozumieniu zagadnienia osobom spoza dziedziny medycyny, pokazując, jak techniki przetwarzania obrazu mogą ujawniać różne aspekty i szczegóły uszkodzenia (np. wskazując, jakie cechy mogą sugerować powstanie obrażenia w wyniku kontaktu z szorstką powierzchnią i wystąpienia tarcia o tę powierzchnię).

11.3. Przeprowadzenie analiz morfometrycznych w przestrzeni 3D

Posiadając obrażenie w przestrzeni 3D, możemy szczegółowo zbadać jego ukształtowanie oraz charakterystykę morfometryczną. Analiza ta pozwala na ocenę stopnia uszkodzenia tkanek, ich rozkładu przestrzennego oraz ewentualnych deformacji. Geometria obrażenia może obejmować lokalne cechy, takie jak np. stopień krzywizny w danym punkcie, który opisuje, jak bardzo powierzchnia odchyła się od płaszczyzny stycznej. Dzięki tej analizie możemy określić np. stopień wklęsłości lub wypukłości tkanek w okolicy obrażenia, co jest istotne w diagnostyce

i ocenie stopnia uszkodzeń. Dzięki zastosowaniu grafów ważonych możliwa jest także analiza przestrzennej relacji pomiędzy różnymi punktami obrażenia, co pozwala na precyzyjne określenie rzeczywistych odległości – najkrótszych ścieżek na powierzchni uszkodzonych tkanek. Użycie algorytmów, takich jak algorytm Dijkstry, umożliwia obliczanie najkrótszych ścieżek na powierzchni ciała, co pozwala lepiej zrozumieć charakter obrażenia.

W niniejszym podrozdziale przedstawiono metodykę analizy obrażenia w przestrzeni trójwymiarowej, ze szczególnym uwzględnieniem wpływu gęstości siatki na dokładność pomiarów. Badania przeprowadzono na modelach o różnej rozdzielczości (od 252 do 17569 elementów), wykazując, że nawet znacząca redukcja gęstości siatki (redukcja do około 7% elementów gęstej siatki w przypadku rzadszej siatki) pozwala zachować dobrą dokładność pomiarową. Dla większego obrażenia różnica w pomiarze odległości rzeczywistych między siatką gęstą a rzadką wyniosła 4,503 mm (różnica rzędu 2,77%), natomiast dla mniejszego obrażenia różnica ta wyniosła 0,456 mm. Wyniki te potwierdzają skuteczność opracowanej metodyki w kontekście zastosowań sądowo-lekarskich, oferując kompromis między dokładnością a efektywnością obliczeniową.


Zaproponowana metodyka, wykorzystująca algorytm PCA do orientacji modelu oraz interpolację *cubic spline*, umożliwia precyzyjne wyznaczanie map głębokości i profili poprzecznych obrażenia. Opracowane narzędzia analityczne zapewniają obiektywny i powtarzalny opis morfometryczny obrażeń, stanowiąc istotny krok w kierunku standaryzacji procedur pomiarowych w medycynie sądowej.

11.3.1. Topologia ukształtowania obrażenia z wykorzystaniem krzywizn głównych

Krzywizny główne stanowią podstawowe narzędzie w analizie kształtu powierzchni, zarówno gładkich, jak i nieregularnych. W kontekście geometrii różniczkowej, krzywizna powierzchni odnosi się do stopnia zakrzywienia w danym punkcie. Na powierzchniach gładkich, takich jak krzywe i powierzchnie różniczkowalne, pojęcia te są precyzyjnie zdefiniowane i dobrze znane w literaturze. Krzywizny są również szeroko stosowane w grafice komputerowej, gdzie złożone powierzchnie są często aproksymowane m.in. za pomocą siatek trójkątów (ang. *wireframe*). Istnieje wiele metod estymacji krzywizn, w tym konstrukcja dyskretnych operatorów krzywizny opartych wyłącznie na geometrii siatki, jak również podejścia polegające na aproksymacji wartości krzywizny na bazie powierzchni przybliżonej


przez siatkę (Makovník & Chalmoviansky, 2023). Dla powierzchni nieregularnych, takich jak powierzchnie opisujące obrażenia na ciele człowieka, zastosowanie krzywizn głównych umożliwia dokładną analizę deformacji tkanek oraz kształtu powierzchni obrażenia. W takich przypadkach, krzywizna powierzchni może być różna w zależności od kierunku wokół danego punktu, co prowadzi do dwóch wartości: krzywizny maksymalnej i krzywizny minimalnej. Główne krzywizny, określane odpowiednio jako κ_1 i κ_2 , pozwalają na identyfikację kierunków, w których powierzchnia odchyła się najmocniej i najslabiej od płaszczyzny stycznej. Zastosowanie estymacji krzywizn, takich jak krzywizna średnia (ang. *mean curvature*) oraz krzywizna Gaussa (ang. *gaussian curvature*), pozwala na szczegółową klasyfikację powierzchni w kontekście wypukłości, wklęsłości czy płaskości. Krzywizna średnia jest uśrednieniem wartości krzywizny maksymalnej i minimalnej, podczas gdy krzywizna Gaussa jest ich iloczynem. Wartości te umożliwiają szczegółową charakterystykę punktów na powierzchni, co jest szczególnie przydatne przy analizie zmian w strukturze uszkodzonych tkanek.

Na rysunku 11.3 przedstawiono wizualizację głównych kierunków krzywizn głównych dla nieregularnej powierzchni obrażenia złożonego z siatki o różnej liczbie trójkątów. Dla obrażenia o mniejszej gęstości siatki (rysunek 11.3(a)) ukazującego uproszczoną reprezentację powierzchni zauważalna jest mniejsza dokładność wyznaczania krzywizn głównych z uwagi na subtelne zakrzywienia powierzchni związane z niewielką powierzchnią obrażenia (17,67 cm²). Krzywizna główna maksymalna (kolor czerwony) wskazuje na miejsce występowania najbardziej zakrzywionej powierzchni typowej dla obrzęków lub zgrubień. Kierunki linii wskazują, w którym kierunku powierzchnia jest najbardziej zakrzywiona. Linie te reprezentują lokalne odchylenia od płaszczyzny stycznej – długie strzałki mogą wskazywać na rozległe, łagodniejsze zakrzywienia, natomiast krótkie strzałki mogą sugerować gwałtowne zmiany krzywizny. Krzywizna główna minimalna odnosi się do najmniejszego zakrzywienia w danym punkcie, często w kierunku prostopadłym do krzywizny maksymalnej (kolor zielony) wskazując stan powierzchni płaski lub minimalnie zakrzywiony. Kierunki strzałek dla krzywizny minimalnej również pokazują, w jakim kierunku powierzchnia zmienia się najłagodniej. Dla obrażenia o większej gęstości siatki (rysunek 11.3(b)) widoczne stają się już subtelne zmiany rzędu nawet dziesiątych milimetra.




Rysunek 11.3. Przedstawienie wizualizacji krzywizn głównych powierzchni obrazienia złożonego z siatek o różnej liczbie trójkątów. Dla (a) mniejszej gęstości siatki obserwuje się mniejszą gęstość wyznaczenia krzywizn, natomiast dla (b) większej gęstości siatki, liczba krzywizn głównych wyraźnie się zwiększa pozwalając na dokładniejsze uchwycenie subtelnych zmian powierzchni obrazienia (źródło: opracowanie własne)

Na rysunku 11.4 przedstawiono kierunki rozkładu krzywizn głównych z różnej perspektywy. Na wskazanym obrazieniu zauważalne jest skupisko rozchodzących się krzywizn sugerujące wklęsłość obrazienia. Oznaczać by ono mogło punkt początkowy powstania obrazienia w wyniku np. upadku i działającej siły tarcia (rysunek 11.5).



Rysunek 11.4. Przedstawienie rozkładu krzywizn głównych na powierzchni obrazienia z różnych perspektyw, ukazując skupisko rozchodzących się krzywizn (oznaczone czerwonymi strzałkami) (źródło: opracowanie własne)



Rysunek 11.5. Przykładowa ilustracja możliwego mechanizmu powstania obrażenia, sugerująca wpływ siły tarcia i kontaktu ciała z powierzchnią (źródło: opracowanie własne)

Poza wskazaniem krzywizn głównych autorka obliczyła kluczowe wartości skalarne bezpośrednio z nimi związane (rysunek 11.6):

- krzywizna średnia (ang. *mean curvature*) definiowana jako średnia wartość krzywizn maksymalnej i minimalnej. Pozwala ona na klasyfikację wierzchołka jako wypukłego, jeśli krzywizna średnia jest większa niż zero ($H > 0$); wklęsłego, jeśli krzywizna średnia jest mniejsza niż zero ($H < 0$), prawie płaskiego, gdy krzywizna średnia zbliża się do zera ($H \approx 0$).
- krzywizna gaussa (ang. *gaussian curvature*) obliczana jako iloczyn krzywizny maksymalnej i minimalnej. Wartość krzywizny Gaussa informuje o globalnym charakterze danego punktu powierzchni: eliptyczny ($K > 0$), hiperboliczny ($K < 0$), paraboliczny ($K \approx 0$), gdy powierzchnia jest płaska w dowolnej orientacji.


	$K < 0$	$K = 0$	$K > 0$
$H < 0$	Saddle ridge 	Ridge 	Peak
$H = 0$	Minimal surface 	Plane 	Not possible
$H > 0$	Saddle valley 	Valley 	Pit

Rysunek 11.6. Podstawowe kształty zdefiniowane dla *mean* (ozn. H) i *gaussian curvature* (ozn. K). Dla H będącego powierzchnią wypukłą ($H > 0$), wklęsłą ($H < 0$), płaską ($H \approx 0$), oraz dla K będącego powierzchnią eliptyczną ($K > 0$), hiperboliczną ($K < 0$), paraboliczną ($K \approx 0$) (źródło: (Clouchoux i in., 2012))

Analizując różne algorytmy do analizy krzywizn powierzchni siatki można wyróżnić *Principal Component Analysis (PCA)* oraz *Quadratic Fitting*, których zasadniczą różnicą jest podejście do analizy danych, zwłaszcza geometrii powierzchni siatki 3D. PCA jest metodą analizy statystycznej, której głównym celem jest redukcja wymiarowości oraz wyodrębnienie głównych kierunków zmienności (tzw. *principal components*). PCA analizuje lokalną geometrię siatki, szukając kierunków maksymalnych i minimalnych krzywizn na podstawie rozmieszczenia punktów w sąsiedztwie wybranego wierzchołka. Metoda ta jest szczególnie skuteczna w identyfikacji globalnych wzorców deformacji i głównych trendów zmienności w danych. PCA stanowi jednak uproszczoną metodę analizy, której wyniki dla złożonych i nieregularnych powierzchni mogą nie posiadać odpowiedniej dokładności z powodu nie brania pod uwagę pełnego modelu matematycznego opisującego powierzchnię. Dla bardziej zaawansowanych struktur odpowiedniejszym algorytmem może być *Quadratic Fitting* polegający na dopasowaniu funkcji kwadratowej do lokalnej powierzchni w sąsiedztwie punktu. Jest to bardziej precyzyjna metoda, ponieważ opisuje lokalne krzywizny za pomocą równań kwadratowych. Algorytm ten stara się dopasować powierzchnię drugiego stopnia (np. elipsoidę lub hiperboloidę) do punktów wokół wierzchołka. Na podstawie tej dopasowanej powierzchni obliczane są kierunki głównych krzywizn.

Rysunek 11.7 przedstawia szczegółową analizę morfometryczną obrażenia z wykorzystaniem map *gaussian* i *mean curvature* metodą *Quadratic Fitting*, które wykorzystać można do uzyskania informacji o charakterze i mechanizmie powstania obrażenia. Badanie przeprowadzono w dwóch rozdzielczościach siatki trójkątów (252 oraz 3633 elementów), co pozwoliło na wielopoziomową ocenę deformacji powierzchni. Analiza mapy krzywizny średniej ujawniła wyraźnie zaznaczony obszar centralny o wartościach dodatnich (kolor czerwony), który wskazuje na deformację skierowaną na zewnątrz. Ten wzorec sugeruje działanie siły od wewnątrz na zewnątrz, charakterystyczne dla uderzenia tępym narzędziem lub upadku i powstałego tarcia w jednym kierunku. Wokół centrum obrażenia zaobserwowano strefy o wartościach ujemnych (kolor niebieski), reprezentujące zagłębienia, typowe dla urazów powstałych w wyniku działania siły o średnim natężeniu. Natomiast, analiza krzywizny gaussa wykazała obecność obszarów siodłowych (wartości ujemne, oznaczone kolorem niebieskim), które świadczą o złożonym charakterze odkształcenia tkanki. Taki wzorec deformacji wskazuje na skośny kierunek działania siły, niezachowujący prostopadłości względem powierzchni, z prawdopodobnym komponentem siły skręcającej. Szczegółowa interpretacja mechanizmu urazu, bazująca na kombinacji obu krzywizn, pozwala wnioskować, że pierwotny punkt uderzenia zlokalizowany był w centrum obszaru o dodatniej krzywiznie średniej, a siła


działała pod kątem około 30-45 stopni względem powierzchni. Szczegółowa analiza wzorców deformacji pozwala na wnioskowanie o potencjalnych mechanizmach powstania obrażenia takich jak uderzenia narzędziem tęnym czy upadek (co również potwierdzają analizy w przestrzeni 2D). W przypadku uderzenia narzędziem tęnym charakterystyczny jest wyraźnie ograniczony obszar deformacji pierwotnej o regularnym kształcie, koncentryczny rozkład krzywizny średniej wokół punktu uderzenia oraz względnie symetryczny wzorec deformacji kompensacyjnej. Natomiast uraz powstały w mechanizmie upadku cechuje się bardziej rozległą strefą deformacji pierwotnej, asymetrycznym rozkładem krzywizny średniej oraz obecnością śladów tarcia manifestujących się wydłużonym wzorcem deformacji. W analizowanym przypadku obserwuje się wyraźną obecność składowej stycznej siły urazu (powierzchni ślizgu), manifestującej się wydłużonym kształtem deformacji oraz asymetrycznym rozkładem krzywizn. Ta charakterystyczna cecha jest typowa dla urazów powstałych podczas upadków, gdzie oprócz prostopadłego uderzenia o podłoże występuje również poślizg ciała po powierzchni. Obecność powierzchni poślizgu znajduje odzwierciedlenie w mapach krzywizny gaussa poprzez wydłużony wzorec deformacji oraz stopniową zmianę wartości krzywizny wzdłuż kierunku działania siły. Jest to istotny element różnicujący ten typ urazu od prostego uderzenia narzędziem tęnym, gdzie dominuje siła prostopadła. Chronologiczna sekwencja powstania obrażenia rozpoczyna się od pierwotnego kontaktu z podłożem pod kątem około 30-45 stopni, następnie obserwuje się fazę poślizgu z redystrybucją energii w kierunku górnobocznym, a kończy wtórnymi odkształceniami kompensacyjnymi w tkankach otaczających. Mapy krzywizny w wysokiej rozdzielczości ujawniają również drobne zaburzenia powierzchni, odpowiadające otarciom naskórka charakterystycznym dla urazów powstałych w mechanizmie tarcia o podłoże. Ostre granice między obszarami o różnych wartościach krzywizny, bez cech wyrównania czy remodelingu, wskazują na świeży charakter obrażenia. Asymetryczny rozkład krzywizn oraz obecność wyraźnych stref deformacji kompensacyjnej potwierdzają dynamiczny charakter urazu, typowy dla upadków.




Rysunek 11.7. Przedstawienie analizy morfometrycznej obrazienia z użyciem algorytmu *Quadratic Fitting*, obliczając krzywizny *mean* i *gaussian curvature*. W dwóch rozdzielczościach siatki trójkątów zidentyfikowano obszary deformacji wskazujące na działanie siły z wewnątrz na zewnątrz, charakterystyczne dla uderzeń tępym narzędziem lub upadków (źródło: opracowanie własne)

W ramach pogłębionej analizy morfometrycznej obrazienia przeprowadzono dodatkowe badanie metodą *Principal Component Analysis (PCA)* wykorzystujące analizę w różnych skalach krzywizny (5%, 10% i 45%) (rysunek 11.8). Badanie również wykonano dla dwóch rozdzielczości siatki trójkątów (252 oraz 3633 elementów), co pozwoliło na wielopoziomową ocenę deformacji powierzchni i walidację wcześniej zaobserwowanych cech charakterystycznych dla urazu. Analiza wieloskalowa ujawniła istotne różnice w obrazie deformacji w zależności od przyjętej skali krzywizny. Przy małej skali (5%) widoczne są drobne lokalne deformacje, które mogą odpowiadać mikrourazom powstałym podczas kontaktu z podłożem. Średnia skala (10%) pozwala na identyfikację głównych obszarów deformacji, podczas gdy duża skala (45%) uwypukla globalną strukturę urazu, potwierdzając wcześniejszą hipotezę o mechanizmie powstania obrażenia w wyniku upadku. Szczególnie interesujące

obserwacje pochodzą z analizy map w skali 45%, gdzie widoczny jest wyraźny, koncentryczny wzorec deformacji z dominującym obszarem dodatniej krzywizny średniej w centrum (kolor czerwony) oraz otaczającą go strefą krzywizny ujemnej (kolor niebieski). Ten wzorec jest spójny z mechanizmem upadku, gdzie występuje pierwotny punkt kontaktu z podłożem oraz strefa deformacji wtórnej powstała w wyniku poślizgu. Porównanie map krzywizny średniej i gaussa w różnych skalach dostarcza dodatkowych informacji o złożoności urazu. W małej skali (5%) widoczna jest znaczna heterogenność deformacji, szczególnie w siatce 3633 trójkątów, co może odpowiadać powierzchniowym otarciom naskórka charakterystycznym dla powierzchni poślizgu. W skali średniej (10%) uwidacznia się asymetryczny rozkład deformacji, natomiast w dużej skali (45%) dominuje główny wzorec odkształcenia charakterystyczny dla upadku. Analiza składowych głównych (PCA) w połączeniu z różnymi skalami krzywizny pozwoliła na lepsze zrozumienie hierarchicznej struktury deformacji. W wysokiej rozdzielczości (3633 trójkątów) obserwuje się bardziej złożony wzorec krzywizny Gaussa w małej skali, co potwierdza obecność wielokierunkowych sił działających podczas upadku. Jednocześnie analiza w dużej skali (45%) wykazuje spójny wzorec globalnej deformacji, charakterystyczny dla dynamicznego kontaktu z podłożem (poślizg). Obserwacje te są szczególnie istotne w kontekście różnicowania mechanizmu powstania obrażenia. Wieloskalowa analiza potwierdza, że wzorec deformacji jest bardziej charakterystyczny dla upadku niż dla prostego uderzenia narzędziem tępym. Świadczy o tym przede wszystkim: progresywna zmiana wzorca deformacji w różnych skalach, asymetryczny rozkład krzywizn oraz obecność drobnych deformacji w małej skali, odpowiadających otarciom naskórka. Zastosowanie analizy PCA w połączeniu z różnymi skalami krzywizny stanowi istotne rozszerzenie standardowej metodologii oceny obrażeń, pozwalając na bardziej precyzyjną charakterystykę mechanizmu urazu. Metoda ta może być szczególnie przydatna w przypadkach, gdy klasyczna analiza morfometryczna nie dostarcza jednoznacznych wyników. Wyniki tej rozszerzonej analizy nie tylko potwierdzają wcześniejsze wnioski dotyczące mechanizmu powstania obrażenia, ale również dostarczają dodatkowych, obiektywnych danych wspierających hipotezę o urazie powstałym w mechanizmie upadku.



a) dla obrazienia w siatce trójkątów 252



b) dla obrazienia w siatce trójkątów 3633

Rysunek 11.8. Algorytm *Principal Component Analysis (PCA)* w analizie *mean* i *gaussian curvature* z zastosowaniem różnych skali (wielkością/zasięgiem obszaru, na którym krzywizna jest obliczana wokół każdego punktu siatki 3D) (źródło: opracowanie własne)

Przedstawiona w niniejszym podrozdziale metodologia analizy krzywizn dostarcza obiektywnych danych metrycznych, umożliwiających precyzyjną rekonstrukcję mechanizmu powstania obrażenia oraz dokumentację jego morfometrii. Możliwość różnicowania między urazami i okolicznościami ich powstania ma kluczowe znaczenie zarówno w kontekście klinicznym, jak i w medycynie sądowej, gdzie obiektywizacja oceny obrażeń odgrywa kluczową rolę w procesie opiniowania. Wyniki przeprowadzonej analizy wskazują na znaczący potencjał metody w obiektywnej ocenie obrażeń, szczególnie w kontekście rekonstrukcji mechanizmu ich powstania. Dalsze badania w tym kierunku powinny koncentrować się na tworzeniu biblioteki wzorców krzywizn charakterystycznych dla różnych mechanizmów urazowych, co umożliwiłoby bardziej precyzyjną klasyfikację i rekonstrukcję mechanizmów powstania obrażeń w praktyce medyczno-sądowej.

11.3.2. Obliczenie odległości rzeczywistej obrażenia z wykorzystaniem grafów ważonych

Podstawą przeprowadzonych badań jest reprezentacja powierzchni badanego obiektu w postaci modelu siatkowego (ang. *mesh*) tzw. siatki trójkątów $M = (V, E, F)$ gdzie V reprezentuje zbiór wierzchołków, E zbiór krawędzi, a F zbiór ścian (trójkątów). Każdy wierzchołek $v \in V$ jest zdefiniowany przez wektor położenia $r = (x, y, z)$ w trójwymiarowej przestrzeni euklidesowej $\mathbb{R}^3$, co zapewnia dokładne odwzorowanie geometrii powierzchni.

Analizę przeprowadzono na trzech różnych reprezentacjach tej samej powierzchni:

- model siatkowy z nałożoną teksturą T : $M_t = (V, E, F, T)$ umożliwiający weryfikację wizualną przebiegu ścieżki (odległości rzeczywistej) względem rzeczywistej topografii powierzchni;
- model siatkowy rzadki: $M_s = (V_s, E_s, F_s)$, gdzie liczba elementów $|F_s| = 252$, reprezentujący uproszczoną geometrię z mniejszą dokładnością, ale zredukowaną złożonością obliczeniową;
- model siatkowy gęsty: $M_d = (V_d, E_d, F_d)$, gdzie liczba elementów $|F_d| = 3633$, zapewniający dokładniejsze odwzorowanie krzywizn i geometrii powierzchni.

Proces pomiarowy rozpoczyna się od interaktywnego wyboru punktów pomiarowych przy użyciu biblioteki `PyVista`, co umożliwia precyzyjne wskazanie punktów zainteresowania na modelu 3D. Dla wybranych punktów $p_1, p_2 \in \mathbb{R}^3$, proces lokalizacji najbliższych

wierzchołków modelu siatkowego $v_1^*, v_2^* \in V$, realizowany jest poprzez minimalizację odległości euklidesowej:

$$v_i^* = \arg \min_{v \in V} \|v - p_i\|_2 \quad (11.6)$$

gdzie:

$\|\cdot\|_2$ oznacza normę euklidesową w $\mathbb{R}^3$.

Na podstawie struktury modelu siatkowego utworzono graf nieskierowany $G = (V_G, E_G, w)$, gdzie:

- $V_G = V$ (wierzchołki grafu odpowiadają wierzchołkom modelu siatkowego);
- $E_G = E$ (krawędzie grafu odpowiadają krawędziom modelu siatkowego);
- $w: E_G \rightarrow \mathbb{R}^+$ – funkcja wag definiowana jest jako:

$$w(e) = \|v_i - v_j\|_2 \quad \text{dla } e = (v_i, v_j) \in E_G \quad (11.7)$$

Implementacja grafu wykorzystuje bibliotekę `NetworkX`, która zapewnia efektywne struktury danych i algorytmy do operacji na grafach. Każdej krawędzi przypisano wagę równą odległości euklidesowej między połączonymi wierzchołkami, co pozwoliło na wierne odwzorowanie geometrii powierzchni w strukturze grafowej.

Do wyznaczenia najkrótszej ścieżki (odległości rzeczywistej) zastosowano algorytm `Dijkstra`, który dla grafu G minimalizuje sumę wag. Algorytm iteracyjnie analizuje wszystkie możliwe ścieżki, aktualizując odległości do kolejnych wierzchołków i zachowując informację o optymalnej trasie (rysunek 11.9).

$$d(v_1^*, v_2^*) = \min_P \sum_{e \in P} w(e) \quad (11.8)$$

gdzie:

P reprezentuje ścieżkę między wierzchołkami v_1^* i v_2^* .

Obrażenie o siatce 3633 elementów wygenerowane zgodnie z opracowanymi procedurami tworzenia modeli 3D, opisanymi szczegółowo w rozdziale 8. *Automatyczne modelowania 3D w procesie tworzenia dokumentacji medycznej 3D – CZĘŚĆ II badań* oraz obrażenie o siatce 252 elementów otrzymane w wyniku procesu zmniejszania rozdzielczości siatki podstawowej


z wykorzystaniem adaptacyjnych algorytmów podziału powierzchni, zostało porównane. Przeprowadzone badania wykazały pewne różnice w dokładności odwzorowania geometrii powierzchni w zależności od gęstości siatki:

- model siatkowy rzadki (252 elementy, stanowiący około 7% wielkości siatki gęstej) dla którego długość otrzymanej odległości rzeczywistej wyniosła 5,8263 cm. Odległość składała się z segmentów, precyzyjnie śledzących topografię powierzchni modelu siatkowego. Odległość geodezyjna reprezentuje rzeczywistą długość najkrótszej ścieżki między wybranymi punktami, biegnącej po powierzchni modelu siatkowego.
- model siatkowy gęsty (3633 elementy) dla którego długość otrzymanej ścieżki geodezyjnej wyniosła 5,8719 cm. Większa dokładność odwzorowania krzywizn prowadzi do nieco większej wartości odległości geodezyjnej. Ścieżka lepiej dopasowuje się do lokalnej geometrii powierzchni, uwzględniając jej drobne zakrzywienia.

Analiza charakterystyki wyznaczonych odległości rzeczywistych wykazała szereg wspólnych cech geometrycznych, niezależnych od gęstości zastosowanej siatki. Podstawową właściwością jest zachowanie ciągłości na całej długości, co zapewnia spójne odwzorowanie mierzonej odległości. Obie ścieżki wykazują zdolność lokalnej adaptacji do krzywizny powierzchni, dostosowując swój przebieg do topografii badanego obszaru. Szczególnie istotnym elementem są punkty węzłowe, widoczne na wizualizacji jako czerwone znaczniki, które występują w miejscach znaczących zmian kierunku gradientu powierzchni. Te charakterystyczne punkty reprezentują kluczowe miejsca transformacji geometrycznej ścieżki.

Przeprowadzone badania wykazały, że dokładność wyznaczenia ścieżki geodezyjnej (odległości rzeczywistej) jest skorelowana z gęstością trójkątów w modelu siatkowym. Model siatkowy zawierający 3633 elementy zapewnia lepsze odwzorowanie rzeczywistej geometrii powierzchni w porównaniu z reprezentacją zawierającą 252 elementy, co przekłada się na dokładniejsze wyznaczenie odległości. W omawianym przypadku należy jednak zauważyć, że oba obrazy są niewielkich rozmiarów dlatego różnice w pomiarze również stanowią niewielką odchyłkę. Zwiększenie gęstości modelu siatkowego pozwala na uwzględnienie drobniejszych szczegółów geometrii powierzchni. Otrzymane wartości odległości rzeczywistych wskazują na stosunkowo niewielką odległość między punktami pomiarowymi, co może świadczyć o lokalnym charakterze badanego obszaru. Precyzja pomiaru na poziomie centymetrów pozwala na dokładną analizę topografii powierzchni i może być wykorzystana w dalszych badaniach morfometrycznych. Wizualizacja wyników w postaci kolorowych ścieżek na tle szarego modelu siatkowego z nałożoną teksturą pozwala na intuicyjną interpretację przebiegu najkrótszych dróg między punktami, uwzględniających naturalne ukształtowanie powierzchni.

Precyzyjne oznaczenie punktów węzłowych umożliwia szczegółową analizę zmian kierunku ścieżki w odpowiedzi na lokalne właściwości geometryczne powierzchni. Tego typu specjalistyczna analiza może być przeprowadzana przez doświadczonego biegłego, który na jej podstawie może stawiać hipotezy powstania obrażenia.




Rysunek 11.9. Wyznaczenie i pomiar ścieżki geodezyjnej (odległości rzeczywistej) z wykorzystaniem grafów ważonych dla przykładu obrażenia o mniejszych rozmiarach (źródło: opracowanie własne)

Dla zastosowań medycyny sądowej autorka opracowania zalecałaby wykorzystanie siatki gęstszej, która umożliwia precyzyjne określenie odległości rzeczywistej nieporównywalne do metod tradycyjnych. Choć w niektórych przypadkach tak wysoka precyzja pomiarowa może wykraczać poza praktyczne wymogi proceduralne, reprezentuje ona istotny postęp technologiczny w dziedzinie pomiarów antropometrycznych. Współczesne metody digitalizacji i analizy komputerowej oferują bezprecedensową dokładność rzędu dziesiątych milimetra, co stanowi znaczący przeskok jakościowy w stosunku do tradycyjnych metod pomiarowych. Ta zwiększona precyzja nie tylko podnosi wartość dowodową uzyskanych wyników, ale również stwarza możliwość zastosowania zaawansowanych metod analizy statystycznej. Technologia ta, mimo że w niektórych zastosowaniach może oferować dokładność wykraczającą poza bieżące potrzeby praktyczne, wyznacza nowe standardy w dziedzinie pomiarów antropometrycznych i medycyny sądowej. Stanowi również solidną podstawę dla przyszłych

zastosowań, gdzie wymagania dotyczące precyzji pomiarów mogą wzrosnąć wraz z rozwojem innych dziedzin nauki i techniki.

Na rysunku 11.10 przedstawiono różnice w uzyskanej odległości rzeczywistej dla obrazienia o wymiarach znacznie większych niż przedstawione na rysunku 11.9. Przeprowadzone pomiary dla dwóch różnych gęstości siatki wykazały interesującą zależność. Dla siatki gęstej, składającej się z 17569 elementów, uzyskano odległość geodezyjną wynoszącą 16,2460 cm, podczas gdy pomiar na siatce rzadkiej, zawierającej 1306 elementów (około 7% siatki gęstej), wykazał odległość 15,7957 cm. Różnica w pomiarach wyniosła 0,4503 cm (4,503 mm), co stanowi około 2,77% wartości całkowitej. Jest to wynik szczególnie znaczący, biorąc pod uwagę, że ponad 13-krotna redukcja liczby elementów siatki spowodowała stosunkowo niewielką zmianę w dokładności pomiaru. Obserwacja ta sugeruje, że dla większych obrazień wpływ gęstości siatki na precyzję pomiaru nie jest krytyczny (dla porównania - w przypadku niewielkiej powierzchni obrazienia otrzymano różnicę rzędu 0,456 mm)¹⁵. Pozwala to na optymalizację procesu pomiarowego poprzez standaryzację gęstości siatki bez względu na rozważany przypadek. Ma to istotne znaczenie praktyczne, szczególnie w rutynowej praktyce medycyny sądowej, gdzie szybkość i efektywność procesu pomiarowego mogą być równie istotne jak jego precyzja.



Rysunek 11.10. Wyznaczenie i pomiar ścieżki geodezyjnej (odległości rzeczywistej) z wykorzystaniem grafów ważonych dla przykładu obrazienia o większych rozmiarach (źródło: opracowanie własne)

¹⁵ Standardowe pomiary obrazienia przeprowadzone z wykorzystaniem linijki lub prostej taśmy mierniczej podawane są z dokładnością do ± 1 mm. Uzyskana różnica w dokładności wynosząca poniżej 0,5 mm jest zatem o 50% mniejsza od standardowej tolerancji pomiarowej, co wskazuje na wyższą precyzję zastosowanej metody w porównaniu do metod konwencjonalnych.

11.3.3. Metodyka analizy ilościowej obrażenia z wykorzystaniem PCA i interpolacji *cubic spline* w przestrzeni 3D

W poniższym podrozdziale przedstawiono analizę opartą na metodach numerycznych. Pierwszym etapem analizy jest automatyczna orientacja przestrzenna modelu, realizowana poprzez identyfikację głównych osi bezwładności z wykorzystaniem algorytmu *Principal Component Analysis (PCA)*. W rozdziale 11.3.1. *Topologia ukształtowania obrażenia z wykorzystaniem krzywizn głównych* opisano lokalną analizę krzywizn powierzchni, natomiast na tym etapie algorytm wykorzystano do globalnej orientacji modelu obrażenia w przestrzeni. W pierwszym etapie PCA pozycjonuje cały model 3D względem układu współrzędnych. Algorytm analizuje całosciowy rozkład punktów modelu, identyfikując główne osie bezwładności całej struktury. W tym przypadku trzecia składowa główna (odpowiadająca najmniejszej wartości własnej) definiuje kierunek normalny do płaszczyzny referencyjnej, względem której prowadzone są dalsze obliczenia głębokości i objętości obrażenia. Jest to globalne zastosowanie PCA, gdzie analizowany jest cały zbiór punktów jednocześnie, a celem jest standaryzacja orientacji przestrzennej modelu. Macierz kowariancji dla chmury punktów $P = \{(x_1, y_1, z_1), \dots, (x_n, y_n, z_n)\}$ jest obliczana według wzoru:

$$C = \frac{1}{n} \sum_{i=1}^n (p_i - \bar{p})(p_i - \bar{p})^T \quad (11.9)$$

Gdzie:

$\bar{p}$ – średnia pozycja punktów;

p_i – punkt w przestrzeni 3D.

Wektory własne tej macierzy reprezentują główne osie układu współrzędnych modelu, a wektor własny odpowiadający najmniejszej wartości własnej wskazuje kierunek normalny do powierzchni referencyjnej.

Kluczowym elementem analizy jest wyznaczenie mapy głębokości uszkodzenia. Dla każdego punktu p_i powierzchni, jego wysokość h_i względem płaszczyzny referencyjnej o wektorze normalnym n i punkcie na tej płaszczyźnie p_0 jest obliczana jako:

$$h_i = (p_i - p_0) \cdot n \quad (11.10)$$

Objętość uszkodzenia jest obliczana poprzez sumowanie objętości elementarnych graniastosłupów utworzonych przez trójkąty siatki i ich wysokości. Dla każdego trójkąta o wierzchołkach (p_1, p_2, p_3) , jego wkład do całkowitej objętości wynosi:

$$V = \frac{1}{3} A (h_1 + h_2 + h_3) \quad (11.11)$$

gdzie A jest polem powierzchni trójkąta obliczanym jako:

$$A = \frac{1}{2} \|(p_2 - p_1) \times (p_3 - p_1)\| \quad (11.12)$$

gdzie:

h_1, h_2, h_3 – wysokości w wierzchołkach trójkąta.

Charakterystyka statystyczna głębokości uszkodzenia obejmuje obliczenie podstawowych parametrów, takich jak wartość średnia (μ), odchylenie standardowe (σ), oraz parametry kształtu rozkładu: skośność (γ_1) i kurtozę (κ). Kurtoza jest często definiowana z odjęciem 3, aby uzyskać tzw. kurtozę nadmiarową. Implementacja wykorzystuje funkcje z biblioteki `scipy.stats` do obliczenia skośności i kurtozy, które automatycznie stosują standardowe definicje tych parametrów:

$$\begin{aligned} \gamma &= \frac{1}{n} \sum_{i=1}^n \left(\frac{h_i - \mu}{\sigma} \right)^3 \\ \kappa &= \frac{1}{n} \sum_{i=1}^n \left(\left(\frac{h_i - \mu}{\sigma} \right)^4 - 3 \right) \end{aligned} \quad (11.13)$$

Profile poprzeczne są generowane wzdłuż zadanych kierunków $\theta = \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$. Dla każdego kierunku θ , punkty profilu są wyznaczone według parametrycznego równania linii:

$$\begin{aligned} x(t) &= x_0 + t \cdot \cos(\theta) \\ y(t) &= y_0 + t \cdot \sin(\theta) \end{aligned} \quad (11.14)$$

gdzie:

x_0, y_0 – punkt początkowy profilu;

t – parametr.

Długość profili jest normalizowana względem przekątnej obwiedni modelu (diagonal), a profile są rozmieszczane równomiernie w poprzek obszaru obrażenia. Dla każdego kierunku generowanych jest kilka równoległych profili, których liczba jest parametrem analizy.

Wysokości w punktach profilu są interpolowane z wykorzystaniem dwuwymiarowej interpolacji powierzchniowej. Wykorzystano funkcję `griddata` z biblioteki `SciPy` z metodą *cubic*, która opiera się na interpolacji C1 ciągłej¹⁶ w przestrzeni 2D. Metoda ta pozwala na oszacowanie wartości wysokości w dowolnym punkcie profilu na podstawie znanych wartości w węzłach siatki:

$$h(x, y) = \text{griddata}((x_{\text{mesh}}, y_{\text{mesh}}), h_{\text{mesh}}, (x, y), \text{method} = 'cubic') \quad (11.15)$$

gdzie:

$(x_{\text{mesh}}, y_{\text{mesh}})$ – współrzędne punktów siatki,

h_{mesh} – odpowiadające im wysokości;

(x, y) – współrzędne punktu profilu, dla którego interpolujemy wysokość.

Rzeczywista długość profilu jest obliczana jako suma długości segmentów między kolejnymi punktami próbkowania:

$$L = \sum_{i=1}^{n-1} \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2} \quad (11.16)$$

gdzie:

L – reprezentuje rzeczywistą długość profilu wzdłuż powierzchni;

n – liczba punktów próbkowania.

Przeprowadzona analiza statystyczna obrażenia ujawniła szereg istotnych charakterystyk dotyczących jego morfometrii (tabela 11.2). Maksymalna głębokość obrażenia wynosi 0.76 cm, przy czym średnia głębokość kształtuje się na poziomie 0.47 cm, a mediana 0.49 cm. Zbliżone wartości średniej i mediany wskazują na względnie symetryczny rozkład głębokości w

¹⁶ Oznacza to, że wysokości między znanymi punktami obliczana jest w sposób zachowujący płynność i naturalność przejść (rysowanie linii przez punkty tak aby przejścia między nimi nie były kanciaste czy postrzępione).


analizowanym obszarze. Odchylenie standardowe na poziomie 0.12 cm, stanowiące około 26% średniej głębokości, świadczy o stosunkowo małym rozproszeniu wartości, co sugeruje jednorodny charakter obrażenia. Analiza kształtu rozkładu, wyrażona przez współczynnik skośności wynoszący -0.76, wskazuje na asymetrię lewostronną, co oznacza koncentrację wartości w obszarze większych głębokości, z "ogonem" rozkładu wyciągniętym w kierunku mniejszych wartości. Innymi słowy, w badanym obrażeniu dominują obszary o większej głębokości. Kurtoza o wartości 0.68 jest dodatnia, ale stosunkowo bliska zeru, co świadczy o rozkładzie zbliżonym do normalnego, z nieznacznie większą koncentracją wartości wokół średniej i umiarkowaną liczbą wartości odstających. Całkowita objętość obrażenia wynosi 8.18 cm³, co w połączeniu ze średnią głębokością 0.47 cm wskazuje na znaczną rozległość uszkodzenia w płaszczyźnie poziomej. Taki układ parametrów morfometrycznych sugeruje, że analizowane obrażenie powstało najprawdopodobniej w wyniku działania tępego narzędzia o relatywnie płaskiej powierzchni, przy równomiernym przyłożeniu siły lub upadku i działania siły tarcia.

Tabela 11.2. Wyniki dla analizy ilościowej obrażenia

Parametr	obrażenie w siatce		różnica [cm]
	252	3633	
Maksymalna głębokość [cm]	0.755274	0.755384	1.1×10^{-4}
Średnia głębokość [cm]	0.468296	0.468346	5.0×10^{-5}
Mediana [cm]	0.487461	0.487709	2.48×10^{-4}
Odchylenie standardowe [cm]	0.124603	0.123304	-1.299×10^{-3}
Współczynnik skośności	-0.731825	-0.759791	-2.7966×10^{-2}
Współczynnik kurtozy	0.601327	0.675726	7.4399×10^{-2}
Objętość [cm ³]	8.166057	8.179543	1.3486×10^{-2}

Źródło: opracowanie własne

Na rysunku 11.11 przedstawiono otrzymane wyniki dla dwóch rozdzielczości siatki trójkątów: 252 trójkąty (rysunek 11.11(a)) oraz 3633 trójkąty (rysunek 11.11(b)). Dla każdego wariantu przedstawiono widok z trzech różnych perspektyw, co pozwala na pełniejszą ocenę morfometrii obrażenia. Analizując różnice między obiema siatkami można zauważyć, że została zachowana ogólna morfometria obrażenia dla której w obu przypadkach widoczny jest ten sam charakter rozkładu głębokości, z wyraźnie zaznaczonymi obszarami najgłębszymi (kolor fioletowy) w podobnych lokalizacjach. Siatka 252 trójkątów pokazuje jednak bardziej zgeneralizowany, wygładzony obraz obrażenia, natomiast siatka 3633 trójkątów oferuje znacznie dokładniejsze odwzorowanie szczegółów ukształtowania powierzchni, gdzie krawędzie są bardziej kanciaste, a przejścia między obszarami mniej płynne.




a) obrazienie w siatce trójkątów 252

b) obrazienie w siatce trójkątów 3633

Rysunek 11.11. Rozkład głębokości obrazienia dla dwóch rozdzielczości siatki trójkątów: (a) 252 trójkąty i (b) 3633 trójkąty, z widokami z trzech perspektyw, ukazującymi ogólną morfometrię i szczegóły powierzchni (źródło: opracowanie własne)

Przeprowadzona analiza profili głębokości obrazienia objęła cztery główne kierunki pomiarowe (0° , 45° , 90° i 135°). Rozmieszczenie profili pomiarowych zostało zoptymalizowane względem morfometrii obrazienia, zapewniając reprezentatywne próbkowanie w kluczowych obszarach zmiennej głębokości. Zastosowany protokół pomiarowy umożliwił uzyskanie dziesięciu charakterystycznych profili, których przebieg odzwierciedla lokalną zmienność ukształtowania powierzchni obrazienia (rysunek 11.12).




Rysunek 11.12. Przykład wyznaczenie profili głębokości w czterech głównych kierunkach (0° , 45° , 90° , 135°) dla obrażenia o powierzchni mniejszej (źródło: opracowanie własne)

Uzyskane charakterystyki profilowe korelują z wcześniejszą analizą statystyczną, potwierdzając maksymalną głębokość około 0.75 cm oraz dominację zakresu głębokości 0.4-0.6 cm. Obserwowana płynność przejść między strefami o różnej głębokości, przy braku gwałtownych zmian wartości, sugeruje powstanie obrażenia w wyniku działania narzędzia o względnie jednorodnej powierzchni kontaktu. Zaobserwowana asymetria rozkładu głębokości, z dominacją w kierunku 45° oraz zróżnicowaniem charakterystyk w poszczególnych orientacjach, może stanowić istotną przesłankę w procesie rekonstrukcji mechanizmu powstania obrażenia.


Porównawcza analiza profili obrażenia w dwóch wariantach, dla rozdzielczości siatki 252 trójkątów (rysunek 11.13) oraz siatki 3633 trójkątów (rysunek 11.14), pomimo niewielkości obrażenia, ujawnia pewne różnice w charakterystyce odwzorowania morfometrii powierzchni. Podstawowa geometria i wartości ekstremalne profili pozostają zachowane w obu przypadkach, jednak wyższa rozdzielczość siatki (3633 trójkątów) zapewnia dokładniejszą reprezentację subtelnych zmian ukształtowania powierzchni. Najbardziej znaczące różnice obserwuje się w profilach charakteryzujących się złożoną morfometrią, szczególnie w profilach 2, 4, 7 oraz 9, gdzie większa gęstość siatki pozwala na precyzyjniejsze odwzorowanie lokalnych fluktuacji głębokości. W profilu 2 (0°) widoczne jest wyraźniejsze zdefiniowanie maksimum lokalnego oraz bardziej płynne przejście w strefie spadku głębokości dla siatki 3633 trójkątów. Profil 4 (45°) w wyższej rozdzielczości prezentuje subtelniejsze zmiany w środkowej części przebiegu,

podczas gdy w niższej rozdzielczości te same obszary są reprezentowane przez bardziej uproszczoną krzywą. Szczególnie interesujące różnice występują w profilu 10 (135°), gdzie zwiększenie rozdzielczości siatki pozwoliło na uchwycenie drobnych wahań głębokości w zakresie 0.48-0.49 cm, które w przypadku siatki 252 trójkątów zostały zgeneralizowane. Podobnie w profilu 7 (90°), wyższa rozdzielczość umożliwiła dokładniejsze odwzorowanie przejścia między strefą wzrostu a spadku głębokości w okolicy maksimum lokalnego.

W profilach o prostszej charakterystyce (np. profil 1, 3, 6) różnice między obiema rozdzielczościami są mniej wyraźne, co sugeruje, że przy niewielkich obrażeniach nawet niższa rozdzielczość siatki jest wystarczająca do wiarygodnego odwzorowania podstawowych cech morfometrycznych w obszarach o mniejszej złożoności geometrycznej.



Rysunek 11.13. Wykresy przedstawiające rozkład głębokości dla profili w siatce 252 trójkątów (źródło: opracowanie własne)




Rysunek 11.14. Wykresy przedstawiające rozkład głębokości dla profili w siatce 3633 trójkątów (źródło: opracowanie własne)

W przypadku mniejszego obrażenia, gdzie porównywano siatki o rozdzielczościach 252 i 3633 trójkątów, zwiększenie gęstości próbkowania miało umiarkowany wpływ na dokładność reprezentacji profili, zachowując podstawowe parametry geometryczne, takie jak długości profili oraz wartości maksymalne głębokości. Dla większego obrażenia o podobnym rozkładzie profili (rysunek 11.15) przeprowadzono analizę z wykorzystaniem siatek o rozdzielczościach 1306 (rysunek 11.16) i 17569 (rysunek 11.17) trójkątów. W tym przypadku wpływ zwiększenia gęstości próbkowania był bardziej wyraźny, szczególnie w obszarach o złożonej geometrii. Analiza profili dla większego obrażenia wykazała, że przy zastosowaniu gęstszej siatki (17569 trójkątów) uzyskano dokładniejsze odwzorowanie lokalnych zmian głębokości, szczególnie widoczne w profilach o złożonej charakterystyce, takich jak profil 3 (45°) czy profil 8 (135°).


Jednocześnie główne cechy morfometryczne, w tym położenie ekstremów i ogólny trend zmian głębokości, pozostały spójne dla obu rozdzielczości. Na przykład, w profilu 1 (0°) o długości około 10.8 cm, różnica między rozdzielczościami manifestuje się głównie w dokładniejszym odwzorowaniu drobnych fluktuacji w górnej części profilu.

Porównanie wyników dla obu obrazów prowadzi do wniosku, że wpływ gęstości siatki na dokładność odwzorowania morfometrycznego jest silniej zaznaczony w przypadku większych obrazów, charakteryzujących się bardziej złożoną geometrią i większymi wymiarami charakterystycznymi. Niemniej jednak, w obu przypadkach niższa rozdzielczość siatki okazała się wystarczająca do wiarygodnego uchwycenia podstawowych cech morfometrycznych obrazu. Obserwacja ta ma istotne znaczenie praktyczne, sugerując możliwość stosowania mniej gęstych siatek w przypadku analiz wstępnych lub gdy priorytetem jest optymalizacja czasu obliczeniowego, bez istotnej utraty kluczowych informacji o geometrii obrazu.

Zaobserwowano również, że różnice między profilami w obu rozdzielczościach są bardziej widoczne w obszarach o większej krzywiznie powierzchni oraz w strefach przejściowych między obszarami o różnej głębokości. Potwierdza to, że wybór optymalnej gęstości siatki powinien uwzględniać nie tylko globalne wymiary obrazu, ale również lokalną złożoność jego morfometrii. Niemniej jednak, autorka rekomenduje wykorzystanie siatki o wyższej rozdzielczości w końcowej analizie ilościowej obrazów, szczególnie w kontekście badań sądowo-lekarskich, gdzie precyzja odwzorowania może mieć kluczowe znaczenie dla prawidłowej interpretacji mechanizmu powstania obrazu. Siatka o niższej rozdzielczości może służyć do wstępnej oceny i szybkiej analizy geometrii obrazu, natomiast finalne wyniki powinny być oparte na modelach o większej gęstości próbkowania, zapewniających najdokładniejsze odwzorowanie morfometrii powierzchni. Takie podejście, choć bardziej wymagające obliczeniowo, gwarantuje zachowanie wszystkich istotnych cech geometrycznych obrazu i minimalizuje ryzyko pominięcia potencjalnie ważnych szczegółów morfometrycznych.




Rysunek 11.15. Przykład wyznaczenie profili głębokości w czterech głównych kierunkach (0° , 45° , 90° , 135°) dla obrazienia o powierzchni większej (źródło: opracowanie własne)



a) obrazienie w siatce trójkątów 1306

Rysunek 11.16. Wykresy przedstawiające rozkład głębokości dla profili w siatce 1306 trójkątów (źródło: opracowanie własne)



a) obrazy w siatce trójkątów 17569

Rysunek 11.17. Wykresy przedstawiające rozkład głębokości dla profili w siatce 17569 trójkątów (źródło: opracowanie własne)

11.4. Ocena otrzymanych wyników analiz morfometrycznych i morfologicznych

Przeprowadzone badania nad metodami analizy ilościowej obrazów z wykorzystaniem modelu 3D obrazowania i następczej analizy numerycznej pozwoliły na opracowanie kompleksowej metodyki pomiarowej oraz ocenę jej skuteczności w kontekście zastosowań sądowo-lekarskich. Kluczowym elementem badań była analiza wpływu gęstości siatki triangulacyjnej na dokładność odwzorowania morfometrycznego obrazów o różnej skali i złożoności geometrycznej.

Wykazano, że zastosowanie algorytmu PCA do globalnej orientacji modelu 3D zapewnia stabilną i powtarzalną podstawę do dalszych analiz ilościowych. Metoda ta, w połączeniu z interpolacją *cubic spline* w przestrzeni 3D, umożliwia precyzyjne wyznaczenie map głębokości oraz profili poprzecznych obrazów. Badania przeprowadzone na obrazach o różnej

wielkości (od kilku do kilkunastu centymetrów) potwierdziły uniwersalność opracowanej metodyki.

Szczegółowa analiza porównawcza różnych gęstości siatki triangulacyjnej ujawniła interesujące zależności. Dla mniejszego obrażenia siatka o niższej rozdzielczości (252 trójkąty) stanowiła około 7% siatki o wysokiej rozdzielczości (3633 trójkąty), podczas gdy dla większego obrażenia proporcja ta wynosiła 7.4% (1306 vs 17569 trójkątów). Mimo znacznych różnic w gęstości siatki, podstawowe parametry geometryczne, w tym długości profili oraz wartości ekstremalne głębokości, wykazały wysoką stabilność dla obu wariantów rozdzielczości. W przypadku większego obrażenia różnica w pomiarze odległości geodezyjnej wyniosła 0,4503 cm (2,77%), natomiast dla mniejszego obrażenia różnica ta była rzędu 0,0456 cm, co potwierdza rzetelność opracowanej metodyki pomiarowej.

Z perspektywy analizy sądowo-lekarskiej, modele o wyższej rozdzielczości dostarczają dokładniejszych danych do analizy morfometrycznej, zapewniając precyzyjniejsze odwzorowanie charakterystycznych cech obrażenia. Siatki o niższej rozdzielczości, choć zachowują główne cechy morfometryczne, mogą być wykorzystywane w przypadkach wymagających szybkiej, wstępnej analizy. Szczególnie istotna jest obserwacja, że zwiększenie gęstości siatki prowadzi do lepszego odwzorowania ciągłości powierzchni obrażenia, co manifestuje się większą gładkością krzywych profili i dokładniejszym odwzorowaniem lokalnych zmian geometrii.

Przeprowadzone analizy statystyczne i profilowe potwierdziły skuteczność metodyki w ocenie mechanizmu powstania obrażenia. W badanych przypadkach zaobserwowano regularny charakter obrażeń, z płynnym przejściem od obszarów płytszych do głębszych, bez gwałtownych zmian głębokości, sugerujący powstanie obrażeń w wyniku działania narzędzi o względnie równomiernej powierzchni kontaktu.

Opracowana metodyka stanowi istotny krok w kierunku standaryzacji analizy ilościowej obrażeń w medycynie sądowej, oferując zestaw narzędzi analitycznych pozwalających na obiektywny i powtarzalny opis morfometrycznych obrażeń. Technologia ta wyznacza nowe standardy w dziedzinie pomiarów antropometrycznych i medycyny sądowej, stanowiąc solidną podstawę dla przyszłych zastosowań. Dalsze badania powinny koncentrować się na automatyzacji procesu doboru optymalnej gęstości siatki w zależności od charakterystyki.

12. Podsumowanie i wnioski

Na podstawie przeprowadzonych badań i eksperymentów w niniejszej rozprawie, została udowodniona postawiona teza, że: *wykorzystanie wybranych algorytmów uczenia głębokiego umożliwi automatyczną detekcję i klasyfikację obrażeń ciała na podstawie zdjęć post-mortem a opracowana metodyka ich zapisu na wirtualnych modelach 3D badanych ciał zautomatyzuje proces badania obrażeń w diagnostyce sądowej*. W opracowaniu skupiono się na różnych metodach wykorzystania sztucznej inteligencji celem udowodnienia postawionej w pracy tezy mając na uwadze pilotażowe wykorzystanie tych algorytmów w omawianej dziedzinie. Oznacza to, że w przyjętym podejściu należało wziąć pod uwagę wysoki czynnik niepewności zachowania wykorzystanych funkcji na dość specyficznym zbiorze danych. Osiągnięcie tego zamiaru, określone zostało jak główny cel rozprawy i nastąpiło poprzez realizację zaplanowanych zadań badawczych (rozdział 1.2. *Cel i zakres rozprawy*).

W niniejszej pracy przyjęta koncepcja badań podzielona została na pięć części. W zamyśle autorki wielokierunkowe badania, stanowić mają fundament do przyszłych prac rozwojowych. Ich celem będzie pełna integracja zaproponowanych rozwiązań z uwzględnieniem zidentyfikowanych obszarów nieefektywnych i alternatywnych rozwiązań w celu zwiększenia dokładności, wydajności oraz praktycznego zastosowania planowanego systemu TIPPI (ang. *Targeted Injury Post-mortem Perception and Identification system*). W dłuższej perspektywie ostatecznym celem jest opracowanie spójnego, niezawodnego narzędzia wspomagającego medycynę sądową, które minimalizuje ryzyko błędów i maksymalizuje korzyści wynikające z zaawansowanych technologii cyfrowych.

Pierwszą część badań rozpoczęły prace nad przygotowaniem unikatowego zbioru danych (CZĘŚĆ I), następnie przeprowadzono eksperymenty nad wykorzystaniem możliwości automatycznego modelowania 3D w procesie pozyskiwania cyfrowej dokumentacji 3D ofiary (CZĘŚĆ II). Z założenia eksperyment przeprowadzony został z wykorzystaniem algorytmu SfM-MVS zaimplementowanego w komercyjnym oprogramowaniu Agisoft Metashape Professional. Zasadniczym efektem, jaki planowano uzyskać, była możliwość doboru parametrów dających optymalne wyniki i stanowiących fundament do kolejnych badań, gdzie implementacja algorytmu SfM-MVS, miałaby odbyć się w niekomercyjnym, autorskim oprogramowaniu TIPPI. W toku badań nad tym etapem zidentyfikowano kluczowy czynnik związany z kalibracją kamery, który odgrywa istotną rolę w procesie przenoszenia rozpoznanych obrażeń na model 3D ciała (CZĘŚĆ IV). Dotychczasowe podejście opierające się na samokalibracji okazało się niewystarczające dla zapewnienia wymaganej precyzji, co

wskazuje na konieczność wdrożenia bardziej zaawansowanych metod kalibracji. Dalsze prace rozwojowe będą wymagały szczególnego uwzględnienia tego aspektu.

W kolejnej części badań skupiono się nad wykorzystaniem w pełni konwolucyjnych sieci neuronowych (FCN) w segmentacji semantycznej obrazów (CZĘŚĆ III). W ramach zaplanowanego działania wybrano dwa rodzaje obrazów zewnętrznych: otarcia naskórka i podbiegnięcia krwawe. Wpływ na dokonany wybór obrazów miała wnikliwa analiza literatury oraz praktyczny wymiar medycyny sądowej, którego autorka miała okazję doświadczyć podczas stażu naukowego. Celem, jaki planowano osiągnąć, było wykazanie, że wykorzystanie pewnych modeli uczenia głębokiego może doprowadzić do detekcji i klasyfikacji obrazów, stanowiąc przykład nieinwazyjnej diagnostyki pośmiertnej. Łącznie przebadano sześć modeli i wskazano model wyjściowy do dalszych badań, który osiągnął najlepsze metryki (U-Net z EfficientNetB3 backbone). Na tym etapie posiadając dokumentację ciała w postaci modelu 3D należało wskazać poprawnie zidentyfikowane obrażenia z wykorzystaniem segmentacji semantycznej. W tym celu dokonano rzutowania pikseli obrazów 2D na korespondujące z nimi piksele na modelu 3D (CZĘŚĆ IV). Posiadając rozpoznane obrażenie, w kolejnym kroku należało rozważyć możliwości jego dalszej analizy. W tym celu przeprowadzono badania, które oparte zostały o przetworzenia na macierzach konwolucji i analizach geometrycznych (CZĘŚĆ V). W wyniku prowadzonych eksperymentów, autorka dostrzegła szeroki wybór zastosowania różnych operatorów i brak możliwości jednoznacznego określenia uniwersalnej operacji mogącej znaleźć zastosowanie do analizy obrażenia na cyfrowym obrazie RGB. Wniosek ten skłonił autorkę do podjęcia decyzji o wyselekcjonowaniu 5 z 10 podstawowych operacji na macierzach konwolucji, stanowiąc wsparcie w analizie obrazu zdegradowanego lub obrazu o niejednoznacznych cechach. Ponadto dokonano dogłębnej analizy topologii i ukształtowania obrażenia.

Uzyskane wyniki i zidentyfikowane obszary poprawy efektywności ich wykorzystania ukształtowały kierunek dalszych badań. Autorka uznaje, że cel i zaplanowane etapy przedstawione w rozdziale 1.2 zostały osiągnięte poprzez:

1. Utworzenie zbiorów danych (2D-TIP i 3D-TIP) obejmujących sieć obrazów post-mortem przedstawiających ofiary przestępstw lub zdarzeń o charakterze kryminalnym (CZĘŚĆ I badań).
2. Utworzenie cyfrowej dokumentacji 3D ciała człowieka (CZĘŚĆ II badań).
3. Zastosowanie segmentacji semantycznej do detekcji i klasyfikacji obrazów (CZĘŚĆ III badań).

4. Przeprowadzenie wstępnej próby integracji rozpoznanych obrazów w procesie segmentacji semantycznej z model 3D ofiary (CZĘŚĆ IV).
5. Przeprowadzenie cyfrowej analizy morfometrycznej i morfologicznej obrazów (CZĘŚĆ V badań).
6. Zidentyfikowanie krytycznych priorytetów w zakresie zaproponowanego podejścia dla jego dalszego rozwoju i wskazanie obszarów wymagających optymalizacji (uwzględnione w podrozdziale ZIDENTYFIKOWANIE KRYTYCZNYCH PRIORYTETÓW).
7. Przeprowadzenie analizy wpływu zaproponowanych metod na praktyczny wymiar przeprowadzania sądowo-lekarskich zewnętrznych oględzin zwłok (každorazowo w rozdziale kończącym daną część badań).

12.1. Kluczowe wyniki pracy

Ocena rozprawy pod kątem wkładu w rozwój dziedziny pozwala na wskazanie następujących głównych osiągnięć autorki:

- utworzenie unikatowego typu zbioru danych 2D-TIP i 3D-TIP. Zgodnie z przeprowadzoną analizą literatury na świecie (analiza przeprowadzona w latach 2019-2021), wg. wiedzy autorskiej jest to jedyna baza danych o podobnej treści;
- zaprezentowanie jednego z pierwszych podejść wykorzystania uczenia głębokiego w detekcji i klasyfikacji dwóch wybranych typów obrazów w sposób automatyczny i nieinwazyjny (badanie przeprowadzone w latach 2019-2022);
- projekcja rozpoznanych obrazów na cyfrowy model 3D ciała ludzkiego jako przykład możliwości tworzenia kompleksowej dokumentacji ciała pod kątem medycyny sądowej (badanie przeprowadzone w roku 2023-2024);
- kompleksowa analiza morfologiczna i morfometryczna obrażeń w przestrzeni 2D oraz 3D (badanie przeprowadzone w roku 2023-2024);
- interdyscyplinarna integracja algorytmów przetwarzania obrazów i analiz w jedno spójne narzędzie umożliwiające analizę ciała w diagnostyce medyczno-sądowej (całokształt badań).

Podjęte przez autorkę badania stanowią inspirację do dalszych badań, ukazując ogromny, wciąż niewykorzystany potencjał nowoczesnych technologii przetwarzania obrazów w dotychczas niezbadanych obszarach medycyny.

12.2. Wnioski szczegółowe

Podsumowanie merytorycznych wniosków wynikających z eksperymentów przedstawionych w rozprawie oraz doświadczeń zdobytych podczas jej tworzenia prowadzi do następujących konkluzji:

- dobranie odpowiednich parametrów w generowaniu modeli 3D pozwala na osiągnięcie wyników odpowiadających standardom w tworzeniu medycznej cyfrowej dokumentacji 3D (tabela 8.4. Generalizacja doboru parametrów i ich wpływu na proces otrzymania produktu 3D);
- szybkość wykrywania obrażenia i jego rejestracja zajmująca średnio 0,22 sekundy zarówno w scenariuszach dla jednego obrażenia czy wielu stanowi nieporównywalnie szybszą metodę niż tradycyjna dokumentacja obrażeń zewnętrznych zajmująca około 15 minut (w zakresie od 03:39 do 27:19 minut na podstawie 100 zbadanych przykładów);
- brak wpływu czynnika subiektywnego, czynnika czasu i doświadczenia lekarza medycyny sądowej w procesie detekcji i klasyfikacji obrażenia;
- zastosowanie łączonych rozwiązań w sieci FPN (takich jak np. połączenie metody *early stopping* i *dropout*) umożliwiło uzyskanie najwyższych wskaźników Accuracy (tabela 9.3);
- należy podkreślić istotność pre-processingu, ich odpowiedniego podziału na podzbiory (uczący, testowy i walidacyjny) oraz syntetycznego powiększania zbioru przez augmentacje co przyczyniło się do uzyskania wysokich wyników;
- jeden z największych zbiorów danych utworzony na potrzeby medycyny w kontekście rozpoznania obrażenia (tabela 9.4);
- cechy/elementy widoczne na ciele bez uprzedniego przygotowania ciała do sekcji (np. płyny, zabrudzenia, odpady medyczne, ciała obce) nie wpływają znacząco na uzyskiwanie wyniki w postaci cyfrowej dokumentacji ciała 3D i segmentacji semantycznej;
- przeprowadzone eksperymenty w zakresie projekcji obrażeń na model 3D potwierdzają kluczową rolę precyzyjnej kalibracji kamery. Uzyskanie wyników z wykorzystaniem samokalibracji jest wprowadzić możliwe, jednak wpływa na błąd integracji tych danych;
- odpowiednie zastosowanie operacji na macierzy konwolucji umożliwia poprawę wyrazistości, granic, konturów i cech charakterystycznych. Szczególne znaczenie w procesie analizy zauważono dla operacji na macierzach z wykorzystaniem Operatora Sobel

Edge Detector, Operator Prewitta, Filtr Rober-Cross, Laplacian of Gaussian (LoG) i Canny Edge Detection.

12.3. Zidentyfikowanie krytycznych priorytetów

Niniejsza praca wykazała, że zastosowanie nowoczesnych technologii cyfrowych i algorytmów uczenia głębokiego w analizie obrazów post-mortem może znacznie usprawnić proces identyfikacji i dokumentowania obrazów. Wykorzystanie w pełni konwolucyjnych sieci neuronowych, algorytmów widzenia maszynowego oraz zaawansowanych technik przetwarzania obrazów pozwala na uzyskanie precyzyjnych wyników, które mogą być nieocenione w pracy lekarza medycyny sądowej. Badania autorki opracowania mają charakter otwarty i ciągły, nad którym wciąż trwają prace rozwojowe. W związku z tym, niemożliwe jest zakończenie analizy bez uwzględnienia refleksji dotyczących jej słabszych stron oraz pytań, na które nie udało się odpowiedzieć.

Planując prace doktorskie autorka wprowadziła ograniczenia wynikające z konieczności zawężenia zakresu prowadzonych badań do kluczowych czynników oraz kategorii danych. Ze względu na ograniczenia czasowe i logistyczne, nie było możliwe uwzględnienie pełnego spektrum potencjalnych zmiennych oraz przeprowadzenie badań w szerszym niż przyjętym zakresie. Należy zauważyć, że autorka po wnikliwej analizie literatury i poznaniu praktyki lekarskiej lekarza medycyny sądowej uznaje, że badania zostały skoncentrowane na najistotniejszych aspektach mających bezpośredni wpływ na analizowane zagadnienie. Ponadto, wybrane zmienne (dwie klasy obrazów, charakterystyka zbiorów danych) w literaturze przedmiotu oraz wstępnych badaniach okazały się najbardziej reprezentatywne dla analizowanego problemu. Ograniczenia te, choć mogą wpływać na ogólność wyników, pozwoliły na bardziej skoncentrowaną i efektywną analizę kluczowych aspektów analizowanego zagadnienia, umożliwiając tym samym dokładniejsze i bardziej precyzyjne wnioski w kontekście postawionej tezy badawczej. Należy jednak zauważyć, że budowa większej bazy danych z bardziej zróżnicowaną charakterystyką obrazów znacząco mogłaby przyczynić się do uzyskania większych dokładności.

Projekcja wykrytych obrazów na model 3D wymaga wykonania precyzyjnej kalibracji kamery, która celem uproszczenia etapu generowania produktów 3D została zastąpiona samokalibracją. Na tym etapie autorka zauważa, że przeprowadzenie kalibracji w kontekście dalszego przetwarzania danych jest koniecznym elementem, którego nie należy pomijać. Wykonana projekcja obrazów na model wymagała wykorzystania zmodyfikowanej macierzy

kalibracji kamery K z dodatkowym obliczeniem przesunięcia tzw. *offsetu* dla każdego z obrazów.

12.4. Kierunek dalszych badań

Z biegiem lat i rozwojem technologii, podejście do sekcji zwłok i analiz medycznych uległo znacznym zmianom. Tradycyjne metody, opierające się głównie na wizualnej ocenie przez patologa, są coraz częściej wspomagane przez zaawansowane technologie cyfrowe i modele komputerowe. Cyfryzacja dokumentacji sekcji zwłok oraz zastosowanie modeli 3D w analizie morfometrycznej i morfologicznej ciała zmarłego pozwala na dokładniejsze i bardziej efektywne przeprowadzanie badań, co jest nieocenione w kontekście sądowym. Jednym z głównych wyzwań w nowoczesnej medycynie sądowej jest zapewnienie wysokiej jakości i precyzji danych. Techniki wizualne, mimo swojej przydatności, mają swoje ograniczenia, zwłaszcza w przypadku zaawansowanego rozkładu ciała. Pomimo istnienia kierunkowych badań zarysowana jest wyraźna potrzeba opracowania nowych systemów medycznych, które zapewnią automatyczną diagnozę.

W planach autorki jest dalsza kontynuacja rozpoczętych badań z zamiarem utworzenia systemu TIPPI o potencjale transformującym sposób, w jaki specjaliści mogą weryfikować i interpretować dane z różnych scenariuszy medycznych i prawnych, zapewniając tym samym lepszą jakość i wiarygodność dowodów sądowych, co jest nieocenione w kontekście międzynarodowych standardów medycyny sądowej. Wstępne założenia projektowe dla systemu oparte są o dotychczasowe doświadczenie i eksperymenty autorki w ramach niniejszej rozprawy doktorskiej.

System **TIPPI (ang. *Targeted Injury Post-mortem Perception and Identification*)** stanowić będzie zaawansowane narzędzie do analizy obrazów post-mortem, które integruje nowoczesne technologie cyfrowe z metodami medycyny sądowej. Tworzenie systemu rozpoczęte zostanie utworzeniem automatycznego stanowiska pomiarowego do zbierania danych, w ten sposób eliminując pracochłonny etap pozyskiwania danych (planowana jest znacząca rozbudowa danych). Stanowisko zaprojektowane zostanie w pomieszczeniu do wykonywania MRI umożliwiając również integrację danych zewnętrznych (obrazowania zewnętrzne) i danych wewnętrznych. Utworzony system dla skalibrowanych, zintegrowanych kamer wyzwalanych w tym samym czasie będzie w stanie wykonywać kilka serii zdjęć, a następnie przekazywać je w czasie rzeczywistym do systemu, gdzie z wykorzystaniem algorytmu SfM-MVS i zakodowanych wcześniej punktów osnowy o znanych odcinkach skalujących utworzony

zostanie fotogrametryczny model 3D. Następnie uruchamiany będzie moduł automatycznej detekcji i klasyfikacji obrazów na modelu 3D w efekcie generując protokół zawierający informacje o rodzaju wykrytych obrazów, ich lokalizacji i cechach morfometrycznych i morfologicznych.

13. Bibliografia

- [1] Abo-Zahhad, M., Gharieb, R. R., Ahmed, S. M., & Donkol, A. A. E.-B. (2014). Edge Detection with a Preprocessing Approach. *Journal of Signal and Information Processing*, 05(04), 123–134. <https://doi.org/10.4236/jsip.2014.54015>
- [2] Abubakar, A., & Ugail, H. (2019). *Discrimination of Human Skin Burns Using Machine Learning* (ss. 641–647). https://doi.org/10.1007/978-3-030-22871-2_43
- [3] Abubakar, A., Ugail, H., & Bukar, A. M. (2019). Noninvasive assessment and classification of human skin burns using images of Caucasian and African patients. *Journal of Electronic Imaging*, 29(04), 1. <https://doi.org/10.1117/1.JEI.29.4.041002>
- [4] Abubakar, A., Ugail, H., & Bukar, A. M. (2020a). Assessment of Human Skin Burns: A Deep Transfer Learning Approach. *Journal of Medical and Biological Engineering*, 40(3), 321–333. <https://doi.org/10.1007/s40846-020-00520-z>
- [5] Abubakar, A., Ugail, H., & Bukar, A. M. (2020b). *Can Machine Learning Be Used to Discriminate Between Burns and Pressure Ulcer?* (ss. 870–880). https://doi.org/10.1007/978-3-030-29513-4_64
- [6] Abubakar, A., Ugail, H., Smith, K. M., Bukar, A. M., & Elmahmudi, A. (2020). Burns Depth Assessment Using Deep Learning Features. *Journal of Medical and Biological Engineering*, 40(6), 923–933. <https://doi.org/10.1007/s40846-020-00574-z>
- [7] Alfsen, G. C., Gulczyński, J., Kholová, I., Latten, B., Martinez, J., Metzger, M., Michaud, K., Pontinha, C. M., Rakislova, N., Rotman, S., Varga, Z., Wassilew, K., & Zinserling, V. (2022). Code of practice for medical autopsies: a minimum standard position paper for pathology departments performing medical (hospital) autopsies in adults. *Virchows Archiv*, 480(3), 509–517. <https://doi.org/10.1007/s00428-021-03242-y>
- [8] Anisuzzaman, D. M., Patel, Y., Rostami, B., Niezgoda, J., Gopalakrishnan, S., & Yu, Z. (2022a). Multi-modal wound classification using wound image and location by deep neural network. *Scientific Reports*, 12(1), 20057. <https://doi.org/10.1038/s41598-022-21813-0>
- [9] Anisuzzaman, D. M., Patel, Y., Rostami, B., Niezgoda, J., Gopalakrishnan, S., & Yu, Z. (2022b). Multi-modal wound classification using wound image and location by deep neural network. *Scientific Reports*, 12(1), 20057. <https://doi.org/10.1038/s41598-022-21813-0>

- [10] Azizpour, H., Razavian, A. S., Sullivan, J., Maki, A., & Carlsson, S. (2016). Factors of Transferability for a Generic ConvNet Representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 38(9), 1790–1802. <https://doi.org/10.1109/TPAMI.2015.2500224>
- [11] Badea, M.-S., Vertan, C., Florea, C., Florea, L., & Badoiu, S. (2016). Severe burns assessment by joint color-thermal imagery and ensemble methods. *2016 IEEE 18th International Conference on e-Health Networking, Applications and Services (Healthcom)*, 1–5. <https://doi.org/10.1109/HealthCom.2016.7749450>
- [12] Bay, H., Ess, A., Tuytelaars, T., & Van Gool, L. (2008). Speeded-Up Robust Features (SURF). *Computer Vision and Image Understanding*, 110(3), 346–359. <https://doi.org/10.1016/j.cviu.2007.09.014>
- [13] Bernardini, F., Mittleman, J., Rushmeier, H., Silva, C., & Taubin, G. (1999). The ball-pivoting algorithm for surface reconstruction. *IEEE Transactions on Visualization and Computer Graphics*, 5(4), 349–359. <https://doi.org/10.1109/2945.817351>
- [14] Black, H. I., Coupaud, S., Daéid, N. N., & Riches, P. E. (2019). On the relationships between applied force, photography technique, and the quantification of bruise appearance. *Forensic Science International*, 305, 109998. <https://doi.org/10.1016/j.forsciint.2019.109998>
- [15] Buck, U., Buße, K., Campana, L., & Schyma, C. (2018). Validation and evaluation of measuring methods for the 3D documentation of external injuries in the field of forensic medicine. *International Journal of Legal Medicine*, 132(2), 551–561. <https://doi.org/10.1007/s00414-017-1756-6>
- [16] Buck, U., Naether, S., Braun, M., Bolliger, S., Friederich, H., Jackowski, C., Aghayev, E., Christe, A., Vock, P., Dirnhofer, R., & Thali, M. J. (2007). Application of 3D documentation and geometric reconstruction methods in traffic accident analysis: With high resolution surface scanning, radiological MSCT/MRI scanning and real data based animation. *Forensic Science International*, 170(1), 20–28. <https://doi.org/10.1016/j.forsciint.2006.08.024>
- [17] Buck, U., Naether, S., Räss, B., Jackowski, C., & Thali, M. J. (2013). Accident or homicide – Virtual crime scene reconstruction using 3D methods. *Forensic Science International*, 225(1–3), 75–84. <https://doi.org/10.1016/j.forsciint.2012.05.015>

- [18] *Burns BIP_US Database*. (2018).
- [19] Campana, L., Breitbeck, R., Bauer-Kreuz, R., & Buck, U. (2016). 3D documentation and visualization of external injury findings by integration of simple photography in CT/MRI data sets (IprojeCT). *International Journal of Legal Medicine*, 130(3), 787–797. <https://doi.org/10.1007/s00414-015-1274-3>
- [20] Canny, J. (1986). A Computational Approach to Edge Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-8(6), 679–698. <https://doi.org/10.1109/TPAMI.1986.4767851>
- [21] Casse, J.-M., Martrille, L., Vignaud, J.-M., & Gauchotte, G. (2016). Skin wounds vitality markers in forensic pathology: An updated review. *Medicine, Science and the Law*, 56(2), 128–137. <https://doi.org/10.1177/0025802415590175>
- [22] Challenge., G. (2016). *CAMELYON16*. <https://camelyon16.grand-challenge.org/>
- [23] Chang, Y.-J. (2024). *How to Get Rid of Bruises (Quickly)*. CosmeTalk by Cosmetic Doctors. <https://www.cosmedocs.com/blog/how-to-get-rid-of-bruises-quickly/>
- [24] Chauhan, J., Goswami, R., & Goyal, P. (2019). *Using Deep Learning to Classify Burnt Body Parts Images for Better Burns Diagnosis* (ss. 25–32). https://doi.org/10.1007/978-3-030-13835-6_4
- [25] Chauhan, J., & Goyal, P. (2020). BPBSAM: Body part-specific burn severity assessment model. *Burns*, 46(6), 1407–1423. <https://doi.org/10.1016/j.burns.2020.03.007>
- [26] Chaurasia, A., & Culurciello, E. (2017). LinkNet: Exploiting encoder representations for efficient semantic segmentation. *2017 IEEE Visual Communications and Image Processing (VCIP)*, 1–4. <https://doi.org/10.1109/VCIP.2017.8305148>
- [27] Cirillo, M. D., Mirdell, R., Sjöberg, F., & Pham, T. D. (2019). Time-Independent Prediction of Burn Depth Using Deep Convolutional Neural Networks. *Journal of Burn Care & Research*, 40(6), 857–863. <https://doi.org/10.1093/jbcr/irz103>
- [28] Clouchoux, C., Kudelski, D., Gholipour, A., Warfield, S. K., Viseur, S., Bouyssi-Kobar, M., Mari, J.-L., Evans, A. C., du Plessis, A. J., & Limperopoulos, C. (2012). Quantitative in vivo MRI measurement of cortical development in the fetus. *Brain Structure and Function*, 217(1), 127–139. <https://doi.org/10.1007/s00429-011-0325-x>
- [29] *Coroners statistics 2021: England and Wales*. (2022).

- [30] Cui, H., Gao, X., Shen, S., & Hu, Z. (2017). HSfM: Hybrid Structure-from-Motion. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2393–2402. <https://doi.org/10.1109/CVPR.2017.257>
- [31] Curless, B. (1997). *New Methods for Surface Reconstruction from Range Images*. Stanford University.
- [32] Curtin, S., & Garnett, M. (2023). *Suicide and Homicide Death Rates Among Youth and Young Adults Aged 10–24: United States, 2001–2021*. <https://doi.org/10.15620/cdc:128423>
- [33] D’Apuzzo, N., & Gruen, A. (2009). Recent advances in 3D full body scanning with applications to fashion and apparel. *Optical 3-D measurement techniques IX*, 2.
- [34] Deng, J., Dong, W., Socher, R., Li, L.-J., Kai Li, & Li Fei-Fei. (2009). ImageNet: A large-scale hierarchical image database. *2009 IEEE Conference on Computer Vision and Pattern Recognition*, 248–255. <https://doi.org/10.1109/CVPR.2009.5206848>
- [35] DiMaio, V., & Molina, K. (2021). *DiMaio’s Forensic Pathology 3rd edn* (3. wyd.). CRC Press Taylor and Francis. <https://www.perlego.com/book/2529770/dimaio-forensic-pathology-pdf>
- [36] Ebert, L. C., Flach, P., Schweitzer, W., Leipner, A., Kottner, S., Gascho, D., Thali, M. J., & Breitbeck, R. (2016). Forensic 3D surface documentation at the Institute of Forensic Medicine in Zurich – Workflow and communication pipeline. *Journal of Forensic Radiology and Imaging*, 5, 1–7. <https://doi.org/10.1016/j.jofri.2015.11.007>
- [37] Ebert, L. C., Ptacek, W., Breitbeck, R., Fürst, M., Kronreif, G., Martinez, R. M., Thali, M., & Flach, P. M. (2014). Virtobot 2.0: the future of automated surface documentation and CT-guided needle placement in forensic medicine. *Forensic Science, Medicine, and Pathology*, 10(2), 179–186. <https://doi.org/10.1007/s12024-013-9520-9>
- [38] Edelsbrunner, H., Kirkpatrick, D., & Seidel, R. (1983). On the shape of a set of points in the plane. *IEEE Transactions on Information Theory*, 29(4), 551–559. <https://doi.org/10.1109/TIT.1983.1056714>
- [39] Emek Soylu, B., Guzel, M. S., Bostanci, G. E., Ekinci, F., Asuroglu, T., & Acici, K. (2023). Deep-Learning-Based Approaches for Semantic Segmentation of Natural Scene Images: A Review. *Electronics*, 12(12), 2730. <https://doi.org/10.3390/electronics12122730>

- [40] Eze, U., & Ojifinni, K. (2022). Trauma forensics in blunt and sharp force injuries. *Journal of West African College of Surgeons*, 12(4), 94. https://doi.org/10.4103/jwas.jwas_190_22
- [41] Faugeras, O., & Keriven, R. (1998). Variational principles, surface evolution, PDEs, level set methods, and the stereo problem. *IEEE Transactions on Image Processing*, 7(3), 336–344. <https://doi.org/10.1109/83.661183>
- [42] Flach, P. M., Gascho, D., Schweitzer, W., Ruder, T. D., Berger, N., Ross, S. G., Thali, M. J., & Ampanozi, G. (2014). Imaging in forensic radiology: an illustrated guide for postmortem computed tomography technique and protocols. *Forensic Science, Medicine, and Pathology*, 10(4), 583–606. <https://doi.org/10.1007/s12024-014-9555-6>
- [43] Flies, M. J., Larsen, P. K., Lynnerup, N., & Villa, C. (2019). Forensic 3D documentation of skin injuries using photogrammetry: photographs vs video and manual vs automatic measurements. *International Journal of Legal Medicine*, 133(3), 963–971. <https://doi.org/10.1007/s00414-018-1982-6>
- [44] Fudalej, M., Fudalej, S., Krajewski, P., Kwiatkowska, M., Olczak, M., & Wiergowski, M. (2023). *Medycyna sądowa dla prawników* (E. Gruza & I. Sołtyszewski (Red.)). Wolters Kluwer.
- [45] Furukawa, Y., & Ponce, J. (2010). Accurate, Dense, and Robust Multiview Stereopsis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32(8), 1362–1376. <https://doi.org/10.1109/TPAMI.2009.161>
- [46] Giorgetti, A., Pascali, J. P., Pelletti, G., Silvestri, A., Giovannini, E., Pelotti, S., & Fais, P. (2023). Routine Photography of Injuries. *American Journal of Forensic Medicine & Pathology*, 44(2), 83–89. <https://doi.org/10.1097/PAF.0000000000000825>
- [47] Gong, X.-Y., Su, H., Xu, D., Zhang, Z.-T., Shen, F., & Yang, H.-B. (2018). An Overview of Contour Detection Approaches. *International Journal of Automation and Computing*, 15(6), 656–672. <https://doi.org/10.1007/s11633-018-1117-z>
- [48] Grabherr, S., Baumann, P., Minoiu, C., Fahrni, S., & Mangin, P. (2016). Post-mortem imaging in forensic investigations: current utility, limitations, and ongoing developments. *Research and Reports in Forensic Medical Science*, 25. <https://doi.org/10.2147/RRFMS.S93974>
- [49] Grabherr, S., Egger, C., Vilarino, R., Campana, L., Jotterand, M., & Dedouit, F. (2017).

- Modern post-mortem imaging: an update on recent developments. *Forensic Sciences Research*, 2(2), 52–64. <https://doi.org/10.1080/20961790.2017.1330738>
- [50] Graduszyńska, A., Augustynowicz, A., Borowicz, J., & Pihowicz, N. (2022). The issue of domestic violence towards women in Poland and Europe. *Medycyna Ogólna i Nauki o Zdrowiu*, 28(1), 78–81. <https://doi.org/10.26444/monz/147410>
- [51] Gruen, A., & Baltsavias, E. (1989). *Automatic 3-D Measurement Of Human Faces With CCD-Cameras* (J. U. Baumann & R. E. Herron (Red.); s. 106). <https://doi.org/10.1117/12.950460>
- [52] Gruza, E., Goc, M., & Moszczyński, J. (2020). *Kryminalistyka. Czyli o współczesnych metodach dowodzenia przestępstw* (1. wyd.). Wolters Kluwer Polska.
- [53] Haghpanah, S., Bogie, K., Wang, X., Banks, P. G., & Ho, C. H. (2006). Reliability of Electronic Versus Manual Wound Measurement Techniques. *Archives of Physical Medicine and Rehabilitation*, 87(10), 1396–1402. <https://doi.org/10.1016/j.apmr.2006.06.014>
- [54] Hainan Cui, Shuhan Shen, Wei Gao, & Zhanyi Hu. (2015). Efficient Large-Scale Structure From Motion by Fusing Auxiliary Imaging Information. *IEEE Transactions on Image Processing*, 24(11), 3561–3573. <https://doi.org/10.1109/TIP.2015.2449557>
- [55] Han, K. T. M., & Uyyanonvara, B. (2016). A Survey of Blob Detection Algorithms for Biomedical Images. *2016 7th International Conference of Information and Communication Technology for Embedded Systems (IC-ICTES)*, 57–60. <https://doi.org/10.1109/ICTEmSys.2016.7467122>
- [56] Harris, C. G., & Stephens, M. J. (1988). A Combined Corner and Edge Detector. *Alvey Vision Conference*. <https://api.semanticscholar.org/CorpusID:1694378>
- [57] Hayakawa, M., Yamamoto, S., Motani, H., Yajima, D., Sato, Y., & Iwase, H. (2006). Does imaging technology overcome problems of conventional postmortem examination? *International Journal of Legal Medicine*, 120(1), 24–26. <https://doi.org/10.1007/s00414-005-0038-x>
- [58] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- [59] Hernández Esteban, C., & Schmitt, F. (2004). Silhouette and stereo fusion for 3D object

- modeling. *Computer Vision and Image Understanding*, 96(3), 367–392.
<https://doi.org/10.1016/j.cviu.2004.03.016>
- [60] <https://github.com/FisherShi/semantic-segmentation>. (b.d.).
<https://github.com/FisherShi/semantic-segmentation>
- [61] Imad, M., Doukhi, O., & Lee, D.-J. (2021). Transfer Learning Based Semantic Segmentation for 3D Object Detection from Point Cloud. *Sensors*, 21(12), 3964.
<https://doi.org/10.3390/s21123964>
- [62] *Increasing the Number, Retention and Quality of Board Certified Forensic Pathologists*. (b.d.). <https://www.justice.gov/archives/ncfs/page/file/641646/download>
- [63] Iwanaga, J., Singh, V., Ohtsuka, A., Hwang, Y., Kim, H., Moryś, J., Ravi, K. S., Ribatti, D., Trainor, P. A., Sañudo, J. R., Apaydin, N., Şengül, G., Albertine, K. H., Walocha, J. A., Loukas, M., Duparc, F., Paulsen, F., Del Sol, M., Adds, P., ... Tubbs, R. S. (2021). Acknowledging the use of human cadaveric tissues in research papers: Recommendations from anatomical journal editors. *Clinical Anatomy*, 34(1), 2–4.
<https://doi.org/10.1002/ca.23671>
- [64] Jiao, C., Su, K., Xie, W., & Ye, Z. (2019). Burn image segmentation based on Mask Regions with Convolutional Neural Network deep learning framework: more accurate and more convenient. *Burns & Trauma*, 7. <https://doi.org/10.1186/s41038-018-0137-9>
- [65] Jing, J., Liu, S., Wang, G., Zhang, W., & Sun, C. (2022). Recent advances on image edge detection: A comprehensive review. *Neurocomputing*, 503, 259–271.
<https://doi.org/10.1016/j.neucom.2022.06.083>
- [66] Kashevnik, A., & Ali, A. (2022). 3D Vehicle Detection and Segmentation Based on EfficientNetB3 and CenterNet Residual Blocks. *Sensors*, 22(20), 7990.
<https://doi.org/10.3390/s22207990>
- [67] Kazhdan, M., Bolitho, M., & Hoppe, H. (2006). Poisson surface reconstruction. W *Proceedings of the Fourth Eurographics Symposium on Geometry Processing* (ss. 61–70). Eurographics Association. <https://doi.org/10.5555/1281957.1281965>
- [68] Khan, F. A., Butt, A. U. R., Asif, M., Ahmad, W., Nawaz, M., Jamjoom, M., & Alabdulkreem, E. (2020). Computer-aided diagnosis for burnt skin images using deep convolutional neural network. *Multimedia Tools and Applications*, 79(45–46), 34545–34568. <https://doi.org/10.1007/S11042-020-08768-Y/FIGURES/12>

- [69] Khan, S., Rahmani, H., Shah, S. A. A., & Bennamoun, M. (2018). *A Guide to Convolutional Neural Networks for Computer Vision*. Springer International Publishing. <https://doi.org/10.1007/978-3-031-01821-3>
- [70] Kim, O., McMurdy, J., Lines, C., Duffy, S., Crawford, G., & Alber, M. (2012). Reflectance spectrometry of normal and bruised human skins: experiments and modeling. *Physiological Measurement*, 33(2), 159–175. <https://doi.org/10.1088/0967-3334/33/2/159>
- [71] Kingma, D. P., & Ba, J. L. (2015). Adam: A method for stochastic optimization. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*.
- [72] Knudsen, P. J. T., Thomsen, J. L., Ampanozi, G., & Thali, M. J. (2014). Autopsy. W *Handbook of Forensic Medicine* (ss. 138–160). Wiley. <https://doi.org/10.1002/9781118570654.ch9>
- [73] Koller, S., Ebert, L. C., Martinez, R. M., & Sieberth, T. (2019). Using virtual reality for forensic examinations of injuries. *Forensic Science International*, 295, 30–35. <https://doi.org/10.1016/j.forsciint.2018.11.006>
- [74] Kondo, T., & Ishida, Y. (2010). Molecular pathology of wound healing. *Forensic Science International*, 203(1–3), 93–98. <https://doi.org/10.1016/j.forsciint.2010.07.004>
- [75] Kottner, S., Ebert, L. C., Ampanozi, G., Braun, M., Thali, M. J., & Gascho, D. (2017). VirtoScan - a mobile, low-cost photogrammetry setup for fast post-mortem 3D full-body documentations in x-ray computed tomography and autopsy suites. *Forensic Science, Medicine, and Pathology*, 13(1), 34–43. <https://doi.org/10.1007/s12024-016-9837-2>
- [76] Kreul, D., Thali, M., & Schweitzer, W. (2019). Case report: Forensic 3D-match of hair brush and scalp abrasions revealing dynamic brush deformation. *Journal of Forensic Radiology and Imaging*, 16, 34–37. <https://doi.org/10.1016/j.jofri.2019.01.003>
- [77] Kuan, P. N., Stephanie Chua, E. B., Safawi, H. H. W., & Tiong, W. H. C. (2017). A Comparative Study of the Classification of Skin Burn Depth in Human. *Journal of Telecommunication, Electronic and Computer Engineering*, 9, 15–23.
- [78] Kuhn, A., Sormann, C., Rossi, M., Erdler, O., & Fraundorfer, F. (2020). DeepC-MVS: Deep Confidence Prediction for Multi-View Stereo Reconstruction. *2020 International Conference on 3D Vision (3DV)*, 404–413.

<https://doi.org/10.1109/3DV50981.2020.00050>

- [79] Kulkarni, A. V., Jagtap, J., & Harpale, V. K. (2013). Object recognition with ORB and its Implementation on FPGA. *International Journal of Advanced Computer Research*, 3(11).
- [80] Laha, M. (2021). An Approach Towards 3D Scene Reconstruction from an Uncalibrated Monocular Video Preceded by an Exhaustive Study of Preprocessing of Images and Feature Detection Algorithms. *International Research Journal of Engineering and Technology (IRJET)*, 08(05).
- [81] Leipner, A., Baumeister, R., Thali, M. J., Braun, M., Dobler, E., & Ebert, L. C. (2016). Multi-camera system for 3D forensic documentation. *Forensic Science International*, 261, 123–128. <https://doi.org/10.1016/j.forsciint.2016.02.003>
- [82] Leth, P. M. (2007). The use of CT scanning in forensic autopsy. *Forensic Science, Medicine, and Pathology*, 3(1), 65–69. <https://doi.org/10.1385/FSMP:3:1:65>
- [83] Li, F., Wang, C., Liu, X., Peng, Y., & Jin, S. (2018). A Composite Model of Wound Segmentation Based on Traditional Methods and Deep Neural Networks. *Computational Intelligence and Neuroscience*, 2018, 1–12. <https://doi.org/10.1155/2018/4149103>
- [84] Li, J., Li, E., Chen, Y., Xu, L., & Zhang, Y. (2010). Bundled depth-map merging for multi-view stereo. *2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2769–2776. <https://doi.org/10.1109/CVPR.2010.5540004>
- [85] Lin, T.-Y., Dollar, P., Girshick, R., He, K., Hariharan, B., & Belongie, S. (2017). Feature Pyramid Networks for Object Detection. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 936–944. <https://doi.org/10.1109/CVPR.2017.106>
- [86] Liu, L., Ouyang, W., Wang, X., Fieguth, P., Chen, J., Liu, X., & Pietikäinen, M. (2020). Deep Learning for Generic Object Detection: A Survey. *International Journal of Computer Vision*, 128(2), 261–318. <https://doi.org/10.1007/s11263-019-01247-4>
- [87] *London teen homicides: Boy's stabbing is record 30th killing.* (2021). BBC. <https://www.bbc.co.uk/news/uk-england-london-59836010>
- [88] Long, J., Shelhamer, E., & Darrell, T. (2015). Fully convolutional networks for semantic segmentation. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 3431–3440. <https://doi.org/10.1109/CVPR.2015.7298965>

- [89] Longuet-Higgins, H. C. (1981). A computer algorithm for reconstructing a scene from two projections. *Nature*, 293(5828), 133–135. <https://doi.org/10.1038/293133a0>
- [90] Lowe, D. G. (1999). Object Recognition from Local Scale-Invariant Features. *Proceedings of the International Conference on Computer Vision*.
- [91] Luhmann, T., Robson, S., Kyle, S., & Boehm, J. (2023). *Close-Range Photogrammetry and 3D Imaging*. De Gruyter. <https://doi.org/10.1515/9783111029672>
- [92] Maeda, H., Zhu, B., Ishikawa, T., & Michiue, T. (2010). Forensic molecular pathology of violent deaths. *Forensic Science International*, 203(1–3), 83–92. <https://doi.org/10.1016/j.forsciint.2010.07.024>
- [93] Maggiori, E., Tarabalka, Y., Charpiat, G., & Alliez, P. (2016). Fully convolutional neural networks for remote sensing image classification. *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 5071–5074. <https://doi.org/10.1109/IGARSS.2016.7730322>
- [94] Makovník, M., & Chalmoviansky, P. (2023). *Curvature estimation for meshes via algebraic quadric fitting*. <http://arxiv.org/abs/2304.08909>
- [95] Marcinkowski, T. (2010). *Medycyna sądowa dla prawników* (5. wyd.). Wyższa Szkoła Policji w Szczytnie.
- [96] McGinnis, J. M., Fineberg, H. V., & Dzau, V. J. (2021). Advancing the Learning Health System. *New England Journal of Medicine*, 385(1), 1–5. <https://doi.org/10.1056/NEJMp2103872>
- [97] Mesli, V., Le Garff, E., Marchand, E., Labreuche, J., Ramdane, N., Maynou, C., Delannoy, Y., & Hédouin, V. (2019). Determination of the age of bruises using a bilirubinometer. *Forensic Science International*, 302, 109831. <https://doi.org/10.1016/j.forsciint.2019.05.047>
- [98] Moulon, P., & Monasse, P. (2016). *OpenMVG Tutorial Colloque: Photogrammétrie Numérique et Perception 3D: les nouvelles conquêtes*. https://www.sfpt.fr/wp-content/uploads/2016/03/20160315_Tutoriel_OpenMVG_SFPT-2016.pdf
- [99] Nuzzolese, E., & Di Vella, G. (2012). The development of a colorimetric scale as a visual aid for the bruise age determination of bite marks and blunt trauma. *The Journal of forensic odonto-stomatology*, 30(2), 1–6.

- [100] O'Mahony, N., Campbell, S., Carvalho, A., Harapanahalli, S., Hernandez, G. V., Krpalkova, L., Riordan, D., & Walsh, J. (2020). *Deep Learning vs. Traditional Computer Vision* (ss. 128–144). https://doi.org/10.1007/978-3-030-17795-9_10
- [101] Oehmichen, M. (2004). Vitality and time course of wounds. *Forensic Science International*, 144(2–3), 221–231. <https://doi.org/10.1016/j.forsciint.2004.04.057>
- [102] Offiah, C. E., & Dean, J. (2016). Post-mortem CT and MRI: appropriate post-mortem imaging appearances and changes related to cardiopulmonary resuscitation. *The British Journal of Radiology*, 89(1058), 20150851. <https://doi.org/10.1259/bjr.20150851>
- [103] Oliver, W. R. (2011). Considerations for Gross Autopsy Photography. *Academic Forensic Pathology*, 1(1), 52–81. <https://doi.org/10.23907/2011.008>
- [104] Omiotek, Z. (2021). *Wybrane problemy modelowania predykcyjnego w diagnostyce technicznej i medycznej*. Wydawnictwo Politechniki Lubelskiej. https://bc.pollub.pl/Content/13580/Wybrane_problemy.pdf
- [105] Oura, P., Junno, A., & Junno, J.-A. (2021). Deep learning in forensic gunshot wound interpretation—a proof-of-concept study. *International Journal of Legal Medicine*, 135(5), 2101–2106. <https://doi.org/10.1007/s00414-021-02566-3>
- [106] OuYang, D., & Feng, H.-Y. (2005). On the normal vector estimation for point cloud data from smooth surfaces. *Computer-Aided Design*, 37(10), 1071–1079. <https://doi.org/10.1016/j.cad.2004.11.005>
- [107] Ozkalipci, O., & Volpellier, M. (2010). Photographic documentation, a practical guide for non professional forensic photography. *Torture : quarterly journal on rehabilitation of torture victims and prevention of torture*, 20(1), 45–52.
- [108] Patias, P. (2002). Medical imaging challenges photogrammetry. *ISPRS Journal of Photogrammetry and Remote Sensing*, 56(5–6), 295–310. [https://doi.org/10.1016/S0924-2716\(02\)00066-7](https://doi.org/10.1016/S0924-2716(02)00066-7)
- [109] Payne-James, J., Crane, J., & Hinchliffe, J. A. (2005). Injury Assessment, Documentation, and Interpretation. W *Clinical Forensic Medicine* (ss. 127–158). Humana Press. <https://doi.org/10.1385/1-59259-913-3:127>
- [110] Prewitt, J. M. S., & Mendelsohn, M. L. (2006). The analysis of cell images. *Annals of the New York Academy of Sciences*, 128(3), 1035–1053. <https://doi.org/10.1111/j.1749-6632.1965.tb11715.x>

- [111] Privalov, M., Beisemann, N., Barbari, J. El, Mandelka, E., Müller, M., Syrek, H., Grützner, P. A., & Vetter, S. Y. (2021). Software-Based Method for Automated Segmentation and Measurement of Wounds on Photographs Using Mask R-CNN: a Validation Study. *Journal of Digital Imaging*, 34(4), 788–797. <https://doi.org/10.1007/s10278-021-00490-x>
- [112] Pyka, K. (2023). Orientacja zdjęć w przestrzeni. W *Podstawy fotogrametrii*. Akademia Górniczo-Hutnicza im. St. Staszica w Krakowie.
- [113] Randeberg, L. L., Haugen, O. A., Haaverstad, R., & Svaasand, L. O. (2006). A novel approach to age determination of traumatic injuries by reflectance spectroscopy. *Lasers in Surgery and Medicine*, 38(4), 277–289. <https://doi.org/10.1002/lsm.20301>
- [114] Rehman Butt, A. U., Ahmad, W., Ashraf, R., Asif, M., & Cheema, S. A. (2019). Computer Aided Diagnosis (CAD) for Segmentation and Classification of Burnt Human skin. *2019 International Conference on Electrical, Communication, and Computer Engineering (ICECCE)*, 1–5. <https://doi.org/10.1109/ICECCE47252.2019.8940758>
- [115] Remondino, F., Nocerino, E., Toschi, I., & Menna, F. (2017). A CRITICAL REVIEW OF AUTOMATED PHOTOGRAMMETRIC PROCESSING OF LARGE DATASETS. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-2/W5, 591–599. <https://doi.org/10.5194/isprs-archives-XLII-2-W5-591-2017>
- [116] Repko, J., Pollefeys, M., & Pollefeys, M. (2005). 3D Models from Extended Uncalibrated Video Sequences: Addressing Key-Frame Selection and Projective Drift. *Fifth International Conference on 3-D Digital Imaging and Modeling (3DIM'05)*, 150–157. <https://doi.org/10.1109/3DIM.2005.4>
- [117] *Report on the human rights situation in Ukraine, 1 December 2023 – 29 February 2024 [EN/UK]*. (2024). <https://ukraine.un.org/en/264355-report-human-rights-situation-ukraine-1-december-2023-29-february-2024>
- [118] Rogers, L. C., Bevilacqua, N. J., Armstrong, D. G., & Andros, G. (2010). Digital Planimetry Results in More Accurate Wound Measurements: A Comparison to Standard Ruler Measurements. *Journal of Diabetes Science and Technology*, 4(4), 799–802. <https://doi.org/10.1177/193229681000400405>
- [119] Ronneberger, O., Fischer, P., & Brox, T. (2015). *U-Net: Convolutional Networks for*

Biomedical Image Segmentation (ss. 234–241). https://doi.org/10.1007/978-3-319-24574-4_28

- [120] Ros, A. C., Bacci, S., Luna, A., & Legaz, I. (2022). Forensic Impact of the Omics Science Involved in the Wound: A Systematic Review. *Frontiers in Medicine*, 8. <https://doi.org/10.3389/fmed.2021.786798>
- [121] Rostami, B., Anisuzzaman, D. M., Wang, C., Gopalakrishnan, S., Niezgoda, J., & Yu, Z. (2021). Multiclass wound image classification using an ensemble deep CNN-based classifier. *Computers in Biology and Medicine*, 134, 104536. <https://doi.org/10.1016/j.compbiomed.2021.104536>
- [122] Rostami, B., Niezgoda, J., Gopalakrishnan, S., & Yu, Z. (2021). *Multiclass Burn Wound Image Classification Using Deep Convolutional Neural Networks*. <https://doi.org/10.48550/arxiv.2103.01361>
- [123] Russell, S., & Norvig, P. (2020). *Artificial Intelligence: A Modern Approach (4th Edition)*. Pearson.
- [124] Rutty, G. N., Morgan, B., O'Donnell, C., Leth, P. M., & Thali, M. (2008). Forensic institutes across the world place CT or MRI scanners or both into their mortuaries. *The Journal of trauma*, 65(2), 493–494. <https://doi.org/10.1097/TA.0b013e31817de420>
- [125] Sasidharan, A., & Al-Kandary, N. M. (2019). A Review of the Techniques and Guidelines in Adult Autopsies. *Saudi Journal of Medicine*, 04(12), 774–790. <https://doi.org/10.36348/sjm.2019.v04i12.006>
- [126] Scafide, K. N., Sheridan, D. J., Downing, N. R., & Hayat, M. J. (2020). Detection of Inflicted Bruises by Alternate Light: Results of a Randomized Controlled Trial. *Journal of Forensic Sciences*, 65(4), 1191–1198. <https://doi.org/10.1111/1556-4029.14294>
- [127] Scafide, K. N., Sheridan, D. J., Taylor, L. A., & Hayat, M. J. (2016). Reliability of tristimulus colourimetry in the assessment of cutaneous bruise colour. *Injury*, 47(6), 1258–1263. <https://doi.org/10.1016/j.injury.2016.01.032>
- [128] Scafide, K. R. N., Sheridan, D. J., Campbell, J., DeLeon, V. B., & Hayat, M. J. (2013). Evaluating change in bruise colorimetry and the effect of subject characteristics over time. *Forensic Science, Medicine, and Pathology*, 9(3), 367–376. <https://doi.org/10.1007/s12024-013-9452-4>
- [129] Seitz, S. M., Curless, B., Diebel, J., Scharstein, D., & Szeliski, R. (2006). A Comparison

- and Evaluation of Multi-View Stereo Reconstruction Algorithms. *2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition - Volume 1 (CVPR'06)*, 1, 519–528. <https://doi.org/10.1109/CVPR.2006.19>
- [130] Ustawa z dnia 6 czerwca 1997 r. - Kodeks postępowania karnego, Pub. L. No. Dz.U. 1997 nr 89 poz. 555 (1997). <https://isap.sejm.gov.pl/isap.nsf/download.xsp/WDU19970890555/U/D19970555Lj.pdf>
- [131] Şevik, U., Karakullukçu, E., Berber, T., Akbaş, Y., & Türkyilmaz, S. (2019). Automatic classification of skin burn colour images using texture-based feature extraction. *IET Image Processing*, 13(11), 2018–2028. <https://doi.org/10.1049/IET-IPR.2018.5899>
- [132] Shamata, A., & Thompson, T. (2018a). Documentation and analysis of traumatic injuries in clinical forensic medicine involving structured light three-dimensional surface scanning versus photography. *Journal of Forensic and Legal Medicine*, 58, 93–100. <https://doi.org/10.1016/j.jflm.2018.05.004>
- [133] Shamata, A., & Thompson, T. (2018b). Using structured light three-dimensional surface scanning on living individuals: Key considerations and best practice for forensic medicine. *Journal of Forensic and Legal Medicine*, 55, 58–64. <https://doi.org/10.1016/j.jflm.2018.02.017>
- [134] Shuhan Shen. (2013). Accurate Multiple View 3D Reconstruction Using Patch-Based Stereo for Large-Scale Scenes. *IEEE Transactions on Image Processing*, 22(5), 1901–1914. <https://doi.org/10.1109/TIP.2013.2237921>
- [135] Sieberth, T., Ebert, L. C., Gentile, S., & Fliss, B. (2020). Clinical forensic height measurements on injured people using a multi camera device for 3D documentation. *Forensic Science, Medicine and Pathology*, 16(4), 586–594. <https://doi.org/10.1007/s12024-020-00282-9>
- [136] Song, B., & Sacan, A. (2012). Automated wound identification system based on image segmentation and Artificial Neural Networks. *2012 IEEE International Conference on Bioinformatics and Biomedicine*, 1–4. <https://doi.org/10.1109/BIBM.2012.6392633>
- [137] Sotak, G. E., & Boyer, K. L. (1989). The laplacian-of-gaussian kernel: A formal analysis and design procedure for fast, accurate convolution and full-frame output. *Computer Vision, Graphics, and Image Processing*, 48(2), 147–189. [https://doi.org/10.1016/S0734-189X\(89\)80036-2](https://doi.org/10.1016/S0734-189X(89)80036-2)

- [138] Spitz, W. U., & Spitz, D. J. (2006). Blunt Force Injury. W *Medicolegal Investigation of Death: Guidelines for the Application of Pathology to Crime Investigation* (4. wyd., ss. 460–531). <https://www.ojp.gov/ncjrs/virtual-library/abstracts/blunt-force-injury-medicolegal-investigation-death-guidelines>
- [139] Struck, R., Cordoni, S., Aliotta, S., Pérez-Pachón, L., & Gröning, F. (2019). *Application of Photogrammetry in Biomedical Science* (ss. 121–130). https://doi.org/10.1007/978-3-030-06070-1_10
- [140] Suvarna, M., Toney, G., & Swastik, G. B. (2017). Classification of scalding burn using image processing methods. *2017 International Conference on Intelligent Computing, Instrumentation and Control Technologies (ICICICT)*, 1312–1315. <https://doi.org/10.1109/ICICICT1.2017.8342759>
- [141] Szeliski, R. (2022). *Computer Vision: Algorithms and Applications*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-34372-9>
- [142] Takahashi, N., Higuchi, T., Shiotani, M., Hirose, Y., Shibuya, H., Yamanouchi, H., Hashidate, H., & Funayama, K. (2012). The effectiveness of postmortem multidetector computed tomography in the detection of fatal findings related to cause of non-traumatic death in the emergency department. *European Radiology*, 22(1), 152–160. <https://doi.org/10.1007/s00330-011-2248-6>
- [143] Talevi, G., Pannone, L., Monaco, C., Bori, E., Cappello, I. A., Candelari, M., Wyns, M., Ramak, R., La Meir, M., Gharaviri, A., Chierchia, G. B., Innocenti, B., & de Asmundis, C. (2023). Evaluation of photogrammetry for medical application in cardiology. *Frontiers in Bioengineering and Biotechnology*, 11. <https://doi.org/10.3389/fbioe.2023.1044647>
- [144] Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *Proceedings of the 36th International Conference on Machine Learning, ICML*, 6105–6114.
- [145] Tang, Y., Zhang, A. A., Luo, L., Wang, G., & Yang, E. (2021). Pixel-level pavement crack segmentation with encoder-decoder network. *Measurement*, 184, 109914. <https://doi.org/10.1016/j.measurement.2021.109914>
- [146] Teresiński, G. (Red.). (2019). *Medycyna sądowa tom 1*. PZWL Wydawnictwo Lekarskie.
- [147] Teresiński, G. (Red.). (2021). *Medycyna sądowa Tom 3* (1. wyd.). PZWL Wydawnictwo Lekarskie.

- [148] Thali, M. J., Braun, M., Brüscheiler, W., & Dirnhofer, R. (2000). Matching tire tracks on the head using forensic photogrammetry. *Forensic Science International*, 113(1–3), 281–287. [https://doi.org/10.1016/S0379-0738\(00\)00234-6](https://doi.org/10.1016/S0379-0738(00)00234-6)
- [149] Thali, M. J., Braun, M., & Dirnhofer, R. (2003). Optical 3D surface digitizing in forensic medicine: 3D documentation of skin and bone injuries. *Forensic Science International*, 137(2–3), 203–208. <https://doi.org/10.1016/j.forsciint.2003.07.009>
- [150] Thali, M. J., Dirnhofer, R., & Vock, P. (2008). *The virtopsy approach: 3D optical and radiological scanning and reconstruction in forensic medicine*. Taylor & Francis.
- [151] Thavarajah, D., Vanezis, P., & Perrett, D. (2012). Assessment of bruise age on dark-skinned individuals using tristimulus colorimetry. *Medicine, Science and the Law*, 52(1), 6–11. <https://doi.org/10.1258/msl.2011.011038>
- [152] *The International Skin Imaging Collaboration (ISIC)*. (2016). <https://www.isic-archive.com>
- [153] Tirado, J., & Mauricio, D. (2021). Bruise dating using deep learning. *Journal of Forensic Sciences*, 66(1), 336–346. <https://doi.org/10.1111/1556-4029.14578>
- [154] Trajković, M., & Hedley, M. (1998). Fast corner detection. *Image and Vision Computing*, 16(2), 75–87. [https://doi.org/10.1016/S0262-8856\(97\)00056-5](https://doi.org/10.1016/S0262-8856(97)00056-5)
- [155] Tricco, A. C., Lillie, E., Zarin, W., O’Brien, K. K., Colquhoun, H., Levac, D., Moher, D., Peters, M. D. J., Horsley, T., Weeks, L., Hempel, S., Akl, E. A., Chang, C., McGowan, J., Stewart, L., Hartling, L., Aldcroft, A., Wilson, M. G., Garritty, C., ... Straus, S. E. (2018). PRISMA Extension for Scoping Reviews (PRISMA-ScR): Checklist and Explanation. *Annals of Internal Medicine*, 169(7), 467–473. <https://doi.org/10.7326/M18-0850>
- [156] Ullman, S. (1979). The interpretation of structure from motion. *Proceedings of the Royal Society of London. Series B. Biological Sciences*, 203(1153), 405–426. <https://doi.org/10.1098/rspb.1979.0006>
- [157] UNOCHA. (2024). *Number of Palestinian and Israeli fatalities and injuries caused by war between Hamas and Israel in since October 7, 2023*. <https://www.statista.com/statistics/1422308/palestinian-territories-israel-number-fatalities-and-injuries-caused-by-the-israel-and-hamas-war/>
- [158] Urbanová, P., Hejna, P., & Jurda, M. (2015). Testing photogrammetry-based techniques

- for three-dimensional surface documentation in forensic pathology. *Forensic Science International*, 250, 77–86. <https://doi.org/10.1016/j.forsciint.2015.03.005>
- [159] Verhoff, M. A., Kettner, M., Lászik, A., & Ramsthaler, F. (2012). Digital Photo Documentation of Forensically Relevant Injuries as Part of the Clinical First Response Protocol. *Deutsches Ärzteblatt international*. <https://doi.org/10.3238/arztebl.2012.0638>
- [160] Villa, C. (2017). Forensic 3D documentation of skin injuries. *International Journal of Legal Medicine*, 131(3), 751–759. <https://doi.org/10.1007/s00414-016-1499-9>
- [161] Villa, C., Flies, M. J., & Jacobsen, C. (2018). Forensic 3D documentation of bodies: Simple and fast procedure for combining CT scanning with external photogrammetry data. *Journal of Forensic Radiology and Imaging*, 12, e2–e7. <https://doi.org/10.1016/j.jofri.2017.11.003>
- [162] Vogiatzis, G., Hernandez Esteban, C., Torr, P. H. S., & Cipolla, R. (2007). Multiview Stereo via Volumetric Graph-Cuts and Occlusion Robust Photo-Consistency. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29(12), 2241–2246. <https://doi.org/10.1109/TPAMI.2007.70712>
- [163] Wan, L., Song, Y. X., Li, Z. D., Liu, N. G., Wang, Y. H., Wang, M. W., Zou, D. H., Huang, P., & Chen, Y. J. (2020). The approach of virtual autopsy (VIRTOPSY) by postmortem multi-slice computed tomography (PMCT) in China for forensic pathology. *Forensic Imaging*, 20, 200361. <https://doi.org/10.1016/j.fri.2020.200361>
- [164] Wang, G., Rister, B., & Cavallaro, J. R. (2013). Workload analysis and efficient OpenCL-based implementation of SIFT algorithm on a smartphone. *2013 IEEE Global Conference on Signal and Information Processing*, 759–762. <https://doi.org/10.1109/GlobalSIP.2013.6737002>
- [165] Wang, J., & Zhang, W. (2018). A Survey of Corner Detection Methods. *Proceedings of the 2018 2nd International Conference on Electrical Engineering and Automation (ICEEA 2018)*. <https://doi.org/10.2991/iceea-18.2018.47>
- [166] Witkowska, K. (2013). *Oględziny. Aspekty procesowe i kryminalistyczne*. Wolters Kluwer.
- [167] Wu, C. (2013). Towards Linear-Time Incremental Structure from Motion. *2013 International Conference on 3D Vision*, 127–134. <https://doi.org/10.1109/3DV.2013.25>
- [168] Wu, J., Cui, Z., Sheng, V. S., Zhao, P., Su, D., & Gong, S. (2013). A Comparative Study

- of SIFT and its Variants. *Measurement Science Review*, 13(3), 122–131.
<https://doi.org/10.2478/msr-2013-0021>
- [169] Wu, T.-P., Yeung, S.-K., Jia, J., & Tang, C.-K. (2010). Quasi-dense 3D reconstruction using tensor-based multiview stereo. *2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1482–1489.
<https://doi.org/10.1109/CVPR.2010.5539796>
- [170] Xu, B., Zhang, L., Liu, Y., Ai, H., Wang, B., Sun, Y., & Fan, Z. (2021). Robust hierarchical structure from motion for large-scale unstructured image sets. *ISPRS Journal of Photogrammetry and Remote Sensing*, 181, 367–384.
<https://doi.org/10.1016/j.isprsjprs.2021.09.019>
- [171] Yadav, D. P., Sharma, A., Singh, M., & Goyal, A. (2019a). Feature extraction based machine learning for human burn diagnosis from burn images. *IEEE Journal of Translational Engineering in Health and Medicine*, 7, 1–7.
<https://doi.org/10.1109/jtehm.2019.2923628>
- [172] Yadav, D. P., Sharma, A., Singh, M., & Goyal, A. (2019b). Feature Extraction Based Machine Learning for Human Burn Diagnosis From Burn Images. *IEEE Journal of Translational Engineering in Health and Medicine*, 7, 1–7.
<https://doi.org/10.1109/JTEHM.2019.2923628>
- [173] Yan Ke, & Sukthankar, R. (2004). PCA-SIFT: a more distinctive representation for local image descriptors. *Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2004. CVPR 2004.*, 2, 506–513.
<https://doi.org/10.1109/CVPR.2004.1315206>
- [174] Yin, H., Yang, C., & Lu, J. (2022). Research on Remote Sensing Image Classification Algorithm Based on EfficientNet. *2022 7th International Conference on Intelligent Computing and Signal Processing (ICSP)*, 1757–1761.
<https://doi.org/10.1109/ICSP54964.2022.9778437>
- [175] Yu, G., & Morel, J.-M. (2011). ASIFT: An Algorithm for Fully Affine Invariant Comparison. *Image Processing On Line*, 1, 11–38. <https://doi.org/10.5201/ipol.2011.my-asift>
- [176] Zawieska, D. (2013). *Wieloobrazowe dopasowanie zdjęć bliskiego zasięgu dla automatycznej rekonstrukcji fotorealistycznych modeli 3D*. Politechnika Warszawska.

- [177] Zelensky: 31,000 Ukrainian soldiers killed in Russia's war. (2024). *The Kyiv Independent news desk*. <https://kyivindependent.com/zelensky-31-000-ukrainian-soldiers-killed-in-action/>
- [178] Zhou, L., Wu, G., Zuo, Y., Chen, X., & Hu, H. (2024). A Comprehensive Review of Vision-Based 3D Reconstruction Methods. *Sensors*, 24(7), 2314. <https://doi.org/10.3390/s24072314>
- [179] Zhou, Q.-Y., Park, J., & Koltun, V. (2018). *Open3D: A Modern Library for 3D Data Processing*. https://www.open3d.org/docs/latest/tutorial/Advanced/surface_reconstruction.html
- [180] Zhou, T., Zhang, J., Su, H., Zou, W., & Zhang, B. (2021). EDDs: A series of Efficient Defect Detectors for fabric quality inspection. *Measurement*, 172, 108885. <https://doi.org/10.1016/j.measurement.2020.108885>

Wykaz ilustracji

- Rysunek 2.1.** Referencyjny schemat sylwetkowy służący do oznaczania ujawnionych obrażeń u kobiet i mężczyzn, wykorzystywany w Zakładzie Medycyny Sądowej Warszawskiego Uniwersytetu Medycznego (źródło: zasoby własne) (źródło: zasoby własne)
- Rysunek 2.2.** Pola anatomiczne ciała ludzkiego (głowa, twarz, szyja) z zaznaczeniem kluczowych obszarów wykorzystywanych do oznaczania obrażeń, zgodnie z klasyfikacją anatomiczną (źródło: (Teresiński, 2021))
- Rysunek 2.3.** Pola anatomiczne ciała ludzkiego: a) płaszczyzna czołowa przednia (ang. anterior), b) płaszczyzna czołowa tylna (ang. posterior) z zaznaczeniem kluczowych obszarów wykorzystywanych do oznaczania obrażeń, zgodnie z klasyfikacją anatomiczną (źródło: (Teresiński, 2021))
- Rysunek 2.4.** Linie, podstawowe płaszczyzny anatomiczne oraz orientacje przestrzenne, wykorzystywane w analizie topologicznej ciała ludzkiego: a) płaszczyzna poprzeczna z osią poprzeczną, b) płaszczyzna strzałkowa z osią strzałkową, c) płaszczyzna czołowa z osią pionową, d) linia topograficzna przedniej powierzchni tułowia, e) linia topograficzna tylnej powierzchni tułowia, f) linia topograficzna bocznej powierzchni tułowia (źródło: (Teresiński, 2021))
- Rysunek 2.5.** Przykład dokumentowania wymiaru obrażenia. Ustalony wymiar należy zapisać w dokumentacji sprawozdawczej, ponadto jak ukazano na ilustracji powyżej jako dodatkową formę dokumentacji można wykorzystać zdjęcie z narzędziem pomiarowym służącym jako skala (źródło: zasoby własne)
- Rysunek 2.6.** Przykład obrażeń o nieregularnym, przypadkowym kształcie (a) oraz o charakterystycznym, regularnym kształcie (b) (źródło: zasoby własne)
- Rysunek 2.7.** Przedstawienie zależności między pojęciami urazu i obrażenia: uraz jako energia przekazana ciału w sposób szkodliwy oraz obrażenie jako wynikające z niego naruszenie ciągłości struktur tkankowych (źródło: opracowanie własne)
- Rysunek 2.8.** Klasyfikacja obrażeń z uwzględnieniem specyfiki wykorzystanego narzędzia (źródło: opracowanie własne)
- Rysunek 2.9.** Skala określania czasu powstania podbiegnięcia krwawego w zależności od jego barwy [liczone w dniach] (źródło: (a) zasoby własne, (b) (Chang, 2024))

- Rysunek 2.10.** Przedstawienie charakterystyki plamy opadowej wraz z zestawieniem miejsca styku ciała z podłożem (źródło: opracowanie własne)
- Rysunek 2.11.** Przykłady rodzajów otarć naskórka (źródło: (a) (Teresiński, 2019), (b-e) zasoby własne))
- Rysunek 2.12.** Przykład reliefu tzw. zwałeczkowania otarcia naskórka (źródło: zasoby własne)
- Rysunek 3.1.** Dokumentacja fotograficzna przypadku wykorzystania fotogrametrii w medycynie sądowej: a) charakterystyczny wzór obrażeń (podbiegnięć krwawych i otarć naskórka) na twarzy ofiary, umożliwiający analizę ich pochodzenia, b) bieżnik opony pojazdu biorącego udział w zdarzeniu, służący do porównania i ustalenia zgodności wzoru obrażeń z oponą pojazdu (źródło: (Thali i in., 2000))
- Rysunek 3.2.** Przedstawienie wyników analizy dopasowania obrażeń do wzoru bieżnika opony w omawianym przypadku: a) widok z boku na model 3D twarzy ofiary oraz bieżnika opony, wskazujący na ich wzajemne relacje, b) widok od strony czaszki na model 3D, podkreślający szczegóły dopasowania, c) wizualizacja dopasowania licznych podbiegnięć krwawych na twarzy ofiary do wzoru bieżnika opony, potwierdzająca, że opona pojazdu powypadkowego przejechała po głowie ofiary w niemal podłużnym (źródło: (Thali et al., 2000))
- Rysunek 3.3.** Otarcia naskórka po lewej stronie czoła, powstałe w wyniku uderzenia szczotką do włosów. Obrażenie zawiera regularnie rozmieszczone i ułożone punktowe, otarte, okrągłe zmiany. Mniej głębokie lub bardziej powierzchowne są liczne czerwone, prążkowane przebarwienia skóry, bezpośrednio przylegające lub połączone z punktowymi, głębszymi zmianami: a) dokumentacja fotograficzna, b) model 3D obrażeń, c) model 3D narzędzia sprawczego ze wskazanym pęknięciem (źródło: (Kreul i in., 2019))
- Rysunek 3.4.** Przedstawienie graficzne obrażenia skóry z nałożonymi elementami narzędzia (końcówek włosia szczotki): a) nałożone włosie (beżowe punkty) pasuje do lokalizacji głębszych i ciemniejszych punktowych otarć, b) przerywane kontury podkreślają otarcia skóry, c) wyraźne ukazanie wzoru odśrodkowego, które zostało dodatkowo podkreślone i zilustrowane dodanymi strzałkami (źródło: (Kreul i in., 2019))
- Rysunek 3.5.** Przedstawienie s Porównanie systemów skanowania powierzchniowego oraz ich wyników: a) zasada działania systemu ATOS opartego na projekcji światła strukturalnego oraz skanera ręcznego Go!Scan 50, b) model 3D fragmentu

podeszwy buta uzyskany przy użyciu obu systemów, c) model powierzchniowy ciała ofiary z uwzględnieniem szczegółowego obrazu pleców, ilustrujący różnice w precyzji i dokładności pomiędzy analizowanymi systemami (źródło: (Buck i in., 2018))

Rysunek 3.6. Przykład integracji danych wewnętrznych i zewnętrznych: a) model 3D fragmentu nogi ofiary wygenerowany na podstawie danych CT, b) wizualizacja struktury kości (CT) oraz mięśni (MRI) w modelu 3D, c) zintegrowany model 3D z nałożoną kolorową teksturą uzyskaną z fotogrametrii, ilustrujący zewnętrzną topologię i charakterystykę powłok ciała (źródło: (Campana i in., 2016))

Rysunek 3.7. Dokumentacja obrażenia prawego podudzia z wykorzystaniem technik integracji danych: a) model 3D powierzchni urazu o wymiarach 91 mm × 17 mm wygenerowany na podstawie danych CT z nałożoną kolorową teksturą uzyskaną z fotogrametrii, b) model 3D urazu stworzony na podstawie danych ze skanowania powierzchniowego z nałożoną teksturą fotogrametryczną, umożliwiający porównanie metod i oceny szczegółowości wizualizacji (źródło: (Campana et al., 2016))

Rysunek 4.1. Schemat działania detektora SIFT w procesie detekcji punktów kluczowych (źródło: (G. Wang i in., 2013))

Rysunek 4.2. Klasyfikacja metod wykrywania cech na obrazie: przedstawienie różnych podejść do detekcji cech z uwzględnieniem analizowanych struktur, takich jak narożniki, krawędzie czy regiony. Najczęściej stosowane detektory zostały podkreślone. Detektory pogrubione zostały szczegółowo opisane i występują również w kontekście rekonstrukcji 3D (źródło: opracowanie własne)

Rysunek 4.3. Schemat działania algorytmu SfM-MVS: proces generowania modelu 3D na podstawie zdjęć, obejmujący detekcję cech (SIFT, SURF), dopasowywanie punktów homologicznych (RANSAC), optymalizację orientacji kamer (bundle adjustment), triangulację do utworzenia rzadkiej chmury punktów, obliczenie głębi i zagęszczenie chmury punktów, aż po końcową wizualizację modelu 3D (źródło: opracowanie własne)

Rysunek 4.4. Schemat działania metody pojemnościowej opracowanej przez Curless B. (1997): obliczanie wagi w i odległości d niezbędnych do aktualizacji woksela poprzez rzutowanie promienia z sensora przez woksel na powierzchnię zasięgu. Waga w jest wyznaczana metodą liniowej interpolacji wag w_a , w_b i

w_c , które są przechowywane w sąsiednich wierzchołkach powierzchni zasięgu (źródło: (Curless, 1997))

Rysunek 4.5. Schemat działania metody Alpha Shape: a) chmura punktów, b) rekonstrukcja kształtu ze współczynnikiem $\alpha = 0.030$, c) rekonstrukcja kształtu ze współczynnikiem $\alpha = 0.037$, d) rekonstrukcja kształtu z zastosowaniem współczynnika $\alpha = 0.010$ (źródło: (Q.-Y. Zhou i in., 2018))

Rysunek 4.6. Zasada działania algorytmu Ball-Pivoting poprzez łączenie kolejnych punktów na powierzchni za pomocą okręgu o określonej średnicy: a) łączenie kolejnych punktów na powierzchni za pomocą okręgu o zadanym promieniu, b) zbyt mały promień prowadzi do powstawania niepożądanych otworów w modelu, c) natomiast, zbyt duży promień powoduje deformację i utratę szczegółów modelu (źródło: (Bernardini i in., 1999))

Rysunek 4.7. Proces odtwarzania powierzchni metodą Poissona: a) zbiór wektorów normalnych $\vec{V}$, b) gradient charakterystyczny $\nabla\chi_m$, c) funkcja charakterystyczna χ_m , d) powierzchnia ∂M (źródło: (Kazhdan i in., 2006))

Rysunek 4.8. Wyznaczanie wektora normalnego n w punkcie P_0 poprzez lokalne przybliżenie powierzchni. Analizowany punkt P_0 otaczają sąsiednie punkty P_1 , P_2 , P_3 , P_4 , które tworzą lokalną siatkę Voronoi. Wektor normalny n wyznaczany jest na podstawie dopasowania krzywej kwadratowej oraz wektorów v_1 , v_2 , v_3 , v_4 , co pozwala na precyzyjne określenie lokalnych właściwości geometrycznych punktu P_0 . Metoda wymaga minimalnej liczby trzech sąsiednich punktów, w przeciwieństwie do bardziej złożonych metod dopasowania powierzchni kwadratowych, które wymagają co najmniej dziewięciu punktów (źródło: (OuYang & Feng, 2005)))

Rysunek 5.1. Strategia i proces przeprowadzonego przeglądu literatury: (a) cztery klastry słów kluczowych i haseł przedmiotowych obejmujące przedmiot badań, zadanie, metodę oraz rodzaj danych, (b) diagram PRISMA ilustrujący etapy selekcji artykułów (źródło: opracowanie własne)

Rysunek 5.2. Schemat przedstawiający hierarchię sztucznej inteligencji (źródło: opracowanie własne)

Rysunek 5.3. Rozpoznawanie obiektów – podział (źródło: opracowanie własne)

Rysunek 5.4. Przykłady zadań związanych z rozpoznawaniem obiektów: (a) klasyfikacja obiektów, (b) wykrywanie obiektów z lokalizacją (*bounding boxes*), (c)

segmentacja semantyczna – klasyfikacja pikselowa, (d) segmentacja instancji – rozróżnienie poszczególnych instancji tej samej klasy (źródło: (L. Liu i in., 2020))

Rysunek 5.5. Architektura sieci w pełni konwolucyjnej (ang. Fully Convolutional Networks, FCN) określana jako metoda enkoder-dekoder. Enkoder zbiera informacje na temat obrazu wejściowego, a dekoder generuje maskę predykcji na podstawie cech zebranych w enkoderze (źródło: (<https://github.com/FisherShi/semantic-segmentation>))

Rysunek 5.6. Budowa warstwy konwolucyjnej dla obrazu RGB. Warstwa ta wykorzystuje filtry (kernels) do detekcji cech, takich jak krawędzie, tekstury czy kształty, tworząc mapy cech (ang. *feature maps*), które są następnie przetwarzane w głębszych warstwach sieci (źródło: (Omiolek, 2021))

Rysunek 5.7. Redukcja wymiarów pola recepcyjnego mapy cech: (a) funkcja wybiera największą wartość z macierzy 2 x 2 w mapie danych wejściowych, następnie zmniejsza rozmiar macierzy dwukrotnie przypisując jej tę wartość, (b) liczona jest średnia wartość z macierzy 2 x 2, następnie dla zmniejszonego rozmiaru przypisywana jest obliczona wartość średnia (źródło: opracowanie własne)

Rysunek 5.8. Przykład transfer learningu do zadania segmentacji semantycznej gdzie z nauczonego modelu CNN z obliczonymi parametrami (obrazek górny) przekazywane są wagi do modelu FCN (obrazek dolny) (źródło: (Imad i in., 2021))

Rysunek 5.9. Przykład architektury sieci U-Net, podzielonej na część enkodera (po lewej) i dekodera (po prawej). Niebieskie prostokąty odpowiadają wielokanałowej mapie cech, gdzie liczba kanałów oznaczona jest nad polem, natomiast rozmiar x-y jest podany w dolnym lewym rogu. Białe pola reprezentują skopiowane mapy cech (źródło: (Ronneberger i in., 2015))

Rysunek 5.10. Fragmenty architektury sieci U-Net: (a) ścieżka enkodera zbudowana jest z czterech bloków w skład których wchodzi: dwie operacje konwolucji 3 x 3 i funkcja aktywacji ReLU (oznaczone niebieskimi strzałkami) i operacja max pooling 2 x 2 (oznaczona czerwoną strzałką), (b) pomiędzy ścieżką enkodera i dekodera umieszczony jest blok analogiczny do bloku ze ścieżki enkodera z tą różnicą, że nie występuje tu operacja max pooling, (c) ścieżka dekodera zbudowana jest z czterech bloków w skład których wchodzi: operacje: dekonwolucji 2 x 2 (oznaczone zielonymi strzałkami), zwiększającej wymiary

mapy cech. Mapy cech ze ścieżki enkodera są kopiowane i przycinane, a następnie łączone z odpowiadającymi im mapami w ścieżce dekodera (oznaczone szarymi strzałkami). Po każdym łączeniu następuje seria dwóch konwolucji 3×3 z aktywacją ReLU (oznaczone niebieskimi strzałkami) (źródło: (Ronneberger i in., 2015))

Rysunek 5.11. Przykład architektury sieci FPN, gdzie po lewej stronie (ścieżka bottom-up) widoczne są cztery poziomy mapy cech odpowiadające kolejnym etapom sieci. Wraz z każdym poziomem następuje przeskalowanie o 2 w kolejnych blokach w stosunku do obrazu wejściowego. Końcowa warstwa, mająca najwięcej cech, przekazywana jest do ścieżki top-down i zostaje poddana konwolucji 1×1 , w celu redukcji wymiarów kanałów (źródło: (Lin i in., 2017))

Rysunek 5.12. Przykład architektury sieci LinkNet, gdzie conv oznacza operację splotu, a *full-conv* pełny spłot. Symbol $/2$ wskazuje na operację redukcji rozmiaru o współczynnik 2, realizowaną przez spłot z wartością *stride* równą 2, co oznacza przesunięcie jądra o dwa piksele po każdym jego zastosowaniu. Analogicznie, $*2$ oznacza operację zwiększania rozmiaru o ten sam współczynnik. Między warstwami konwolucyjnymi stosowana jest normalizacja i funkcja aktywacji ReLU. Lewa strona schematu to koder, zaczynający się od bloku początkowego z operacją splotu o jądrze 7×7 i przesunięciu 2, oraz przestrzennym max poolingiem na obszarze 3×3 , także z przesunięciem 2. Koder zawiera kolejne bloki rezydualne. Prawa część schematu prezentuje dekodery (źródło: (Chaurasia & Culurciello, 2017))

Rysunek 5.13. Architektura sieci ResNet50 (źródło: (He i in., 2016))

Rysunek 5.14. Architektura sieci EfficientNetB3 (źródło: (Kashevnik & Ali, 2022))

Rysunek 6.1. Schemat planowanych badań zawartych w rozprawie doktorskiej (źródło: opracowanie własne)

Rysunek 7.1. Aparatura badawcza wykorzystana do utworzenia bazy danych: sensor, akcesoria oraz specyfikacja kamery i dobrane parametry do przeprowadzenia pomiarów (źródło: opracowanie własne)

Rysunek 7.2. Schemat stanowiska pomiarowego utworzonego w Zakładzie Medycyny Sądowej Warszawskiego Uniwersytetu Medycznego. Odcinki 1_2, 1_4, 4_3 wybrane zostały jako odcinki referencyjne, natomiast odcinek 3_2 stanowił odcinek kontrolny (źródło: opracowanie własne)

- Rysunek 7.3.** Schemat procedury pozyskania zdjęć do zbioru danych 3D-TIP (źródło: opracowanie własne)
- Rysunek 7.4.** Schemat procedury pozyskania zdjęć do zbioru danych 2D-TIP (źródło: opracowanie własne)
- Rysunek 7.5.** Schemat przedstawiający ustalone warunki fotografowania zapewniając odpowiednie i powtarzalne warunki pomiarowe (źródło: opracowanie własne)
- Rysunek 7.6.** Schemat procesu etykietowania danych w bazie 2D-TIP (źródło: opracowanie własne)
- Rysunek 8.1.** Dopasowanie cech na etapie zastosowania algorytmu SfM, gdzie niebieskie linie łączą wykorzystane punkty dopasowania między wybraną parą obrazów, a czerwone linie pokazują niewykorzystane punkty (źródło: opracowanie własne)
- Rysunek 8.2.** Przykład pozycji kamer dla jednego z ciał pokazanego w położeniu *prone* i *supine* (źródło: opracowanie własne)
- Rysunek 8.3.** Rzadka chmura punktów wygenerowana w procesie SfM dla jednego z badanych ciał (źródło: opracowanie własne)
- Rysunek 8.4.** Gęsta chmura punktów będąca wynikiem procesu MVS wygenerowana dla jednego z badanych ciał (źródło: opracowanie własne)
- Rysunek 8.5.** Rozkład residuów obrazów w procesie samokalibracji, przedstawiający różnice dla (a) najlepszych, (b) średnich i (c) najgorszych wyników. Największe residua zlokalizowane są na krawędziach obrazu, podczas gdy obiekt znajduje się w centralnej części kadru (źródło: opracowanie własne)
- Rysunek 8.6.** Przedstawienie sześciu produktów otrzymanych w oprogramowaniu Agisoft: a) rzadka chmura punktów, b) gęsta chmura punktów, c) model siatkowy (ang. *mesh*) tzw. siatka trójkątów, d) model solid będący rezultatem procesu rekonstrukcji 3D na podstawie chmury punktów i siatki trójkątów, e) model wysokościowy, f) model z nałożoną teksturą (źródło: opracowanie własne)
- Rysunek 8.7.** Porównanie dokładności odwzorowania tekstury na modelu 3D z teksturą rzeczywistą uzyskaną ze zdjęcia RGB (źródło: opracowanie własne)
- Rysunek 9.1.** Podglądowy schemat procesu segmentacji semantycznej (źródło: opracowanie własne)
- Rysunek 9.2.** Schemat zastosowania augmentacji danych w zadaniu segmentacji semantycznej, ilustrujący proces przetwarzania obrazów 2D-TIP za pomocą

różnych technik augmentacyjnych, zawierający przykłady wstępnie przetworzonych obrazów (źródło: opracowanie własne)

Rysunek 9.3. Architektura modelu U-Net z EfficientNetB3 backbone (źródło: opracowanie własne z wykorzystaniem kodu latex do rysowania sieci neuronowych dostępnego [open-source na https://github.com/HarisIqbal88/PlotNeuralNet?tab=readme-ov-file](https://github.com/HarisIqbal88/PlotNeuralNet?tab=readme-ov-file))

Rysunek 9.4. Przykładowe wyniki segmentacji obrazów dla powłok ciała przy użyciu proponowanych modeli FCN. Wynik segmentacji na obrazie wejściowym oznaczono kolorem zielonym dla otarć oraz kolorem czerwonym dla podbiegnięć krwawych (źródło: opracowanie własne)

Rysunek 9.5. Przykładowe wyniki segmentacji dla podbiegnięć krwawych i otarć naskórka występujących razem: oryginalny obraz wejściowy (po lewej), wyniki segmentacji architektury (środek po lewej: otarcia, środek po prawej: podbiegnięcia krwawe), zaznaczony wynik segmentacji na obrazach wejściowych (po prawej): czerwony dla podbiegnięć krwawych i zielony dla otarć (źródło: opracowanie własne)

Rysunek 9.6. Przykłady nieprawidłowych wyników klasyfikacji przy użyciu proponowanego modelu DNN: a) obraz wejściowy, kolejno od góry: 1-2 przykłady pokazują niewykrycie wszystkich obrazów widocznych na obrazie lub wykrycie ich tylko częściowo, 3 przykład przedstawia błędną klasyfikację obszaru, który nie jest ani podbiegnięciem krwawym, ani otarciem, 4 przykład błędna klasyfikacja podbiegnięć krwawych jako otarć i na odwrót, b) maska segmentacji dla otarć, c) maska segmentacji dla podbiegnięć krwawych, d) wynik segmentacji na obrazie wejściowym z otarciami oznaczonymi kolorem zielonym i podbiegnięciami krwawymi oznaczonymi kolorem czerwonym (źródło: opracowanie własne)

Rysunek 10.1. Dane wykorzystane do integracji modelu 3D z wynikami segmentacji semantycznej po paddingu w postaci (a) wyeksportowanego modelu 3D (.obj), (b) oryginalnych obrazów wejściowych (.jpg) oraz (c) obrazów z wynikami segmentacji (.png). Obrazy (c) zostały poddane pre-processingowi, w tym skalowaniu i przycięciu, a następnie zastosowaniu padding w celu zachowania oryginalnych proporcji obrazów (b) przed ich integracją z modelem 3D (źródło: opracowanie własne)

- Rysunek 10.2.** Oznaczenie wartości rzutowanych pikseli, które znajdują się w obrębie obrazu oraz w obszarze maski segmentacji semantycznej, gdzie wartość jest większa od zera (źródło: opracowanie własne)
- Rysunek 10.3.** Przedstawienie projekcji masek segmentacji 2D na odpowiadające im punkty w przestrzeni 3D, ilustrując rozmieszczenie wykrytych obrażeń (otarcie naskórka) na trzech obrazach (źródło: opracowanie własne)
- Rysunek 10.4.** Przedstawienie modelu 3D z projekcją masek segmentacji, pokazując odwzorowanie wykrytych obrażeń na modelu trójwymiarowym osiągając względnie wizualną zgodność z rzeczywistością (źródło: opracowanie własne)
- Rysunek 11.1.** Przedstawienie wyników przetworzenia obrazu w przestrzeni 2D za pomocą operacji na macierzach konwolucji, które pomagają w analizie wyrazistości, granic, konturów i cech charakterystycznych, istotnych w kontekście badania obrażeń (źródło: opracowanie własne)
- Rysunek 11.2.** Przedstawienie fragmentu otarcia w zbliżeniu, ukazując wyniki trzech analiz przeprowadzonych za pomocą detekcji krawędzi metodą Cannyego, operatora Sobela i operatora Robert-Cross. Analiza ta pozwala na szczegółowe uchwycenie konturów, granic i cech charakterystycznych obrażenia, pomagając w identyfikacji typu uszkodzenia oraz sił, które mogły wpłynąć na jego powstanie (źródło: opracowanie własne)
- Rysunek 11.3.** Przedstawienie wizualizacji krzywizn głównych powierzchni obrażenia złożonego z siatek o różnej liczbie trójkątów. Dla (a) mniejszej gęstości siatki obserwuje się mniejszą gęstość wyznaczenia krzywizn, natomiast dla (b) większej gęstości siatki, liczba krzywizn głównych wyraźnie się zwiększa pozwalając na dokładniejsze uchwycenie subtelnych zmian powierzchni obrażenia (źródło: opracowanie własne)
- Rysunek 11.4.** Przedstawienie rozkładu krzywizn głównych na powierzchni obrażenia z różnych perspektyw, ukazując skupisko rozchodzących się krzywizn (oznaczone czerwonymi strzałkami) (źródło: opracowanie własne)
- Rysunek 11.5.** Przykładowa ilustracja możliwego mechanizmu powstania obrażenia, sugerująca wpływ siły tarcia i kontaktu ciała z powierzchnią (źródło: opracowanie własne)
- Rysunek 11.6.** Podstawowe kształty zdefiniowane dla mean (ozn. H) i gaussian curvature (ozn. K). Dla H będącego powierzchnią wypukłą ($H > 0$), wklęsłą ($H < 0$),

płaską ($H \approx 0$), oraz dla K będącego powierzchnią eliptyczną ($K > 0$), hiperboliczną ($K < 0$), paraboliczną ($K \approx 0$) (źródło: (Clouchoux i in., 2012))

Rysunek 11.7. Przedstawienie analizy morfometrycznej obrażenia z użyciem algorytmu *Quadratic Fitting*, obliczając krzywizny *mean* i *gaussian curvature*. W dwóch rozdzielczościach siatki trójkątów zidentyfikowano obszary deformacji wskazujące na działanie siły z wewnątrz na zewnątrz, charakterystyczne dla uderzeń tępym narzędziem lub upadków (źródło: opracowanie własne)

Rysunek 11.8. Algorytm *Principal Component Analysis* (PCA) w analizie *mean* i *gaussian curvature* z zastosowaniem różnych skali (wielkością/zasięgiem obszaru, na którym krzywizna jest obliczana wokół każdego punktu siatki 3D) (źródło: opracowanie własne)

Rysunek 11.9. Wyznaczenie i pomiar ścieżki geodezyjnej (odległości rzeczywistej) z wykorzystaniem grafów ważonych dla przykładu obrażenia o mniejszych rozmiarach (źródło: opracowanie własne)

Rysunek 11.10. Wyznaczenie i pomiar ścieżki geodezyjnej (odległości rzeczywistej) z wykorzystaniem grafów ważonych dla przykładu obrażenia o większych rozmiarach (źródło: opracowanie własne)

Rysunek 11.11. Rozkład głębokości obrażenia dla dwóch rozdzielczości siatki trójkątów: (a) 252 trójkąty i (b) 3633 trójkąty, z widokami z trzech perspektyw, ukazującymi ogólną morfologię i szczegóły powierzchni (źródło: opracowanie własne)

Rysunek 11.12. Przykład wyznaczenie profili głębokości w czterech głównych kierunkach (0° , 45° , 90° , 135°) (źródło: opracowanie własne)

Rysunek 11.13. Wykresy przedstawiające rozkład głębokości dla profili w siatce 252 trójkątów (źródło: opracowanie własne)

Rysunek 11.14. Wykresy przedstawiające rozkład głębokości dla profili w siatce 3633 trójkątów (źródło: opracowanie własne)

Rysunek 11.15. Przykład wyznaczenie profili głębokości w czterech głównych kierunkach (0° , 45° , 90° , 135°) dla obrażenia o powierzchni większej (źródło: opracowanie własne)

Wykaz tabel

Tabela 5.1. Podsumowanie metod wykrywania obrazów na obrazach 2D na podstawie przeprowadzonego przeglądu literatury Struktura zbioru danych TIP (źródło: opracowanie własne)

Tabela 7.1. Struktura zbioru danych 3D-TIP

Tabela 7.2. Struktura zbioru danych 2D-TIP

Tabela 7.3. Statystyka zbioru danych TIP w kontekście występowania etykiety obrazienia

Tabela 8.1. Parametry i wyniki dla etapu Structure-from-Motion (pozyskanie rzadkiej chmury punktów)

Tabela 8.2. Parametry i wyniki dla etapu Multi-View-Stereo (pozyskanie gęstej chmury punktów)

Tabela 8.3. Generalizacja doboru parametrów i ich wpływu na proces otrzymania produktu 3D

Tabela 8.4. Parametry i wyniki dla otrzymania modelu 3D

Tabela 9.1. Budowa i parametry dla modeli

Tabela 9.2. Parametry wspólne dla wszystkich modeli

Tabela 9.3. Wyniki metryk dla wszystkich modeli

Tabela 9.4. Porównanie otrzymanych wyników uzyskanych podczas badań eksperymentalnych z innym metodami

Tabela 10.1. Liczba punktów modelu 3D rzutowanych na obraz 2D i znajdujących się w granicach obrazu oraz liczba punktów, które znajdują się w obszarze maski

Tabela 11.1. Operacje na macierzach konwolucji i ich zastosowanie analizie obrazów

Tabela 11.2. Wyniki dla analizy ilościowej obrazienia