



ROZPRAWA DOKTORSKA

mgr Oktawia Specht

**Metoda monitoringu batymetrycznego strefy brzegowej na
bazie fuzji wielomodalnych danych geoprzestrzennych
pozyskanych przy użyciu sensorów pokładowych
bezzałogowych platform pomiarowych**

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

Promotor:
prof. dr hab. inż. Andrzej Stateczny

Gdynia 2025

Spis treści

Wykaz ważniejszych oznaczeń i skrótów	4
Wstęp.....	6
1. Analiza metod integracji danych hydroakustycznych i optoelektronicznych stosowanych w hydrografii.....	10
1.1. Charakterystyka danych pozyskanych przy użyciu urządzeń hydroakustycznych w pomiarach batymetrycznych.....	10
1.1.1. Echosonda jednowiązkowa	10
1.1.2. Echosonda wielowiązkowa	17
1.2. Charakterystyka danych pozyskanych przy użyciu urządzeń optoelektronicznych w pomiarach batymetrycznych.....	22
1.2.1. Kamera fotogrametryczna	22
1.2.2. LiDAR.....	29
1.3. Przegląd i analiza istniejących metod modelowania powierzchni terenu w strefie brzegowej	34
1.3.1. Modelowanie powierzchni terenu	35
1.3.2. Budowa siatki TIN	36
1.3.3. Budowa siatki GRID.....	39
1.4. Metody fuzji wielomodalnych danych geoprzestrzennych w pomiarach batymetrycznych.....	43
1.4.1. Fuzja danych	43
1.4.2. Fuzja zdecentralizowana	45
1.4.3. Fuzja scentralizowana	47
2. Metoda monitoringu batymetrycznego strefy brzegowej na bazie fuzji wielomodalnych danych geoprzestrzennych	50
2.1. Opracowanie i analiza danych geoprzestrzennych pozyskanych przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych	50
2.1.1. Opracowanie danych głębokościowych z echosondy jednowiązkowej i wielowiązkowej.....	50
2.1.2. Wyznaczanie głębokości akwenu na podstawie zdjęć lotniczych	58
2.1.3. Ekstrakcja linii brzegowej na podstawie danych LiDAR z lotniczego skaningu laserowego	71
2.1.4. Ekstrakcja linii brzegowej na podstawie danych LiDAR z mobilnego skaningu laserowego	79
2.1.5. Ekstrakcja linii brzegowej na podstawie ortofotomapy.....	82
2.2. Etapy metody monitoringu batymetrycznego strefy brzegowej	83
2.3. Ustalenie metody monitoringu batymetrycznego strefy brzegowej.....	91
3. Badanie i weryfikacja metody modelowania powierzchni terenu w strefie brzegowej ...	97
3.1. Realizacja i opracowanie pomiarów batymetryczno-fotogrametrycznych w strefie brzegowej wybranych akwenów przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych	97
3.1.1. Miejsca realizacji pomiarów batymetryczno-fotogrametrycznych.....	97

3.1.2. Kampania pomiarowa na akwenu morskim przyległym do plaży miejskiej w Gdyni w dniu 10.06.2022 r.	99
3.1.3. Kampania pomiarowa na akwenu morskim przyległym do plaży miejskiej w Gdyni w dniach 05.09-07.11.2023 r.	103
3.1.4. Kampania pomiarowa na jeziorze Kłodno w dniach 02-03.06.2022 r.	107
3.1.5. Kampania pomiarowa na jeziorze Kłodno w dniach 01.08-02.10.2023 r.	112
3.2. Kompleksowa realizacja pomiarów batymetryczno-fotogrametrycznych w strefie brzegowej dla wybranego akwenu przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych	116
3.2.1. Realizacja pomiarów batymetryczno-fotogrametrycznych	116
3.2.2. Aparatura pomiarowa	118
3.2.3. Opracowanie modeli fuzji danych średnich ważonych	119
3.3. Analiza ilościowa wyników metody	121
3.3.1. Wskaźniki ilościowe	121
3.3.2. Kampania pomiarowa na akwenu morskim przyległym do plaży miejskiej w Gdyni w dniu 10.06.2022 r.	123
3.3.3. Kampania pomiarowa na akwenu morskim przyległym do plaży miejskiej w Gdyni w dniach 05.09-07.11.2023 r.	128
3.3.4. Kampania pomiarowa na jeziorze Kłodno w dniach 02-03.06.2022 r.	131
3.3.5. Kampania pomiarowa na jeziorze Kłodno w dniach 01.08-02.10.2023 r.	134
3.3.6. Kompleksowa kampania pomiarowa na jeziorze Kłodno w dniu 13.08.2024 r.	137
Wnioski końcowe	141
Bibliografia	144
Wykaz rysunków.....	153
Wykaz tabel.....	157
Streszczenie	159
Abstract.....	161

Wykaz ważniejszych oznaczeń i skrótów

a – dokładności pomiaru głębokości/współrzędnych prostokątnych płaskich przy poziomie ufności 95%

ALB – batymetryczny skanowanie laserowe

ALS – lotniczy skanowanie laserowe

CMOS – układ wielu elementów światłoczułych wykonany w technologii CMOS

CTD – sonda oceanograficzna

d – głębokość akwenu

$\bar{d}$ – średnia ważona głębokości

DEM – cyfrowy model wysokościowy

f – ogniskowa obiektywu

GCP – naziemny punkt kontrolny

GIS – system informacji geograficznej

GNSS – globalny system nawigacji satelitarnej

GRID – regularna siatka kwadratów

GSD – terenowy wymiar piksela terenowego

IDW – metoda odwrotnych ważonych odległości

IHO – Międzynarodowa Organizacja Hydrograficzna

IMU – inercyjna jednostka pomiarowa

INS – system nawigacji inercyjnej

IQR – rozstęp ćwiartkowy

LiDAR – metoda pomiaru odległości poprzez oświetlanie celu światłem laserowym i pomiar odbicia za pomocą czujnika

MAE – średni błąd bezwzględny

MBES – echosonda wielowiązkowa

MLS – mobilny skanowanie laserowe

N – liczba punktów

NMT – numeryczny model terenu

p – poziom ufności

R – rozstęp

R^2 – współczynnik determinacji

R68 – wartość w zbiorze danych, która jest większa od 68% obserwacji

R95 – wartość w zbiorze danych, która jest większa od 95% obserwacji

RANSAC – konsensus próby losowej

RMS – średnia kwadratowa

RMSE – pierwiastek błędu średniokwadratowego

RTK – technika pozycjonowania satelitarnego w czasie rzeczywistym

SBES – echosonda jednowiązkowa

SfM – technika pozwalająca na tworzenie modeli trójwymiarowych ze zdjęć

SVP – miernik prędkości dźwięku

SVR – regresja wektora nośnego

TIN – nieregularna siatka trójkątów

TLS – naziemny skanowanie laserowe

TRON – metoda Newtona

$TVU_{\max}(d)$ – maksymalny błąd pomiaru głębokości przy poziomie ufności 95%

u – wykładnik potęgi

UAV – bezzałogowy statek powietrzny

USV – bezzałogowa jednostka pływająca

UTM – odwzorowanie uniwersalne poprzeczne Merkatora

w – waga

x, y – współrzędne prostokątne płaskie

$\bar{x}, \bar{y}$ – średnie ważone współrzędnych prostokątnych płaskich

μ – wartość średnia

σ – odchylenie standardowe

Wstęp

Monitoring batymetryczny to proces badania i monitorowania dna zbiorników wodnych (jezior, rzek, mórz i oceanów) w celu opracowania map batymetrycznych. Mapy te przedstawiają ukształtowanie dna i głębokości zbiorników wodnych, przez co znajdują szerokie zastosowanie w wielu dziedzinach życia, takich jak: żegluga i nawigacja, planowanie i budowa infrastruktury wodnej, badania geofizyczne i geologiczne, czy ochrona środowiska. Dokładność i szczegółowość map batymetrycznych zależy bezpośrednio od jakości, ilości i rozmieszczenia danych głębokościowych, które można uzyskać za pomocą różnych metod i urządzeń pomiarowych. Jakość opracowywanych map batymetrycznych powinna być wysoka, ponieważ w przeciwnym razie może to doprowadzić do niewłaściwego określenia warunków żeglowności torów wodnych, kotwiczowisk i innych akwenów użytkowych oraz nieprawidłowego wyznaczenia parametrów bezpiecznej głębokości akwenów w rejonie portów.


Strefa brzegowa, czyli obszar obejmujący brzeg morski i przyległe do niego części lądu i morza, ma szczególne znaczenie z punktu widzenia polityki ekologicznej i ekonomicznej państw nadbrzeżnych. Wynika to z faktu, że jest ona bogata w zasoby naturalne, przez co ok. 50% światowej populacji zamieszkuje obszary zlokalizowane w odległości 100 km od linii brzegowej (**Li Z. i in., 2018**). Z tego powodu niezbędne jest prowadzenie systematycznego monitoringu batymetrycznego, a także prognozowanie dynamicznie zachodzących zmian ukształtowania strefy brzegowej, które zależą od wielu czynników antropogenicznych i naturalnych, takich jak: aktywność biologiczna, erozja morska, wzrost poziomu wód, falowanie, pływy, prądy morskie, transport rumowiska, intruzja wód morskich, regulacja rzek, trzęsienia ziemi, wzrost temperatury i zakwaszanie oceanów, czy zalewanie obszarów położonych w strefie brzegowej.

Do rejestracji danych batymetrycznych są wykorzystywane urządzenia hydroakustyczne, takie jak: echosonda jednowiązkowa (ang. *Single Beam Echo Sounder* – SBES), echosonda wielowiązkowa (ang. *MultiBeam EchoSounder* – MBES), system GNSS (ang. *Global Navigation Satellite System*), system INS (ang. *Inertial Navigation System*) i miernik prędkości dźwięku (ang. *Sound Velocity Profiler* – SVP), które coraz częściej są montowane na bezzałogowych jednostkach pływających (ang. *Unmanned Surface Vehicle* – USV) oraz urządzenia optoelektroniczne, takie jak: LiDAR (ang. *Light Detection And Ranging*), kamera fotogrametryczna, system GNSS i system INS, które również często są instalowane na bezzałogowych statkach powietrznych (ang. *Unmanned Aerial Vehicle* – UAV) (**Lewicka O. i in., 2021**). Natomiast pomiar linii brzegowej tzw. izobaty 0 m wykonuje się przy użyciu precyzyjnych urządzeń geodezyjnych, takich jak: naziemny skaner laserowy (ang. *Terrestrial Laser Scanner* – TLS), tachimetr czy system GNSS. Dodatkowo, coraz częściej stosuje się kamerę fotogrametryczną i LiDAR, które są umieszczane na bezzałogowych statkach powietrznych (UAV). Co więcej, proces wyznaczania linii brzegowej na podstawie danych LiDAR lub z kamery fotogrametrycznej jest wspierany przez różne algorytmy służące do automatycznego określenia przebiegu linii brzegowej.

Współczesne techniki akwizycji danych batymetrycznych pozwalają na pozyskanie dużej liczby punktów pomiarowych przy jednoczesnym wysokim (często niemal stuprocentowym) pokryciu dna pomiarami batymetrycznymi. Dzięki temu spełniają one minimalne wymagania dokładnościowe przewidziane dla najbardziej rygorystycznych kategorii pomiarów hydrograficznych (szczególnej i specjalnej), które zostały określone w standardzie wydanym przez Międzynarodową Służbę Hydrograficzną (ang. *International Hydrographic Organization* – IHO) o nazwie „*S-44 IHO Standards for Hydrographic Surveys*” (**International Hydrographic Organization, 2022**). Należy jednak zauważyć, że dane geoprzestrzenne pozyskane przy użyciu różnych sensorów pokładowych bezzałogowych platform

pomiarowych różnią się dokładnością pomiaru głębokości, który ma decydujący wpływ na jakość opracowanej mapy batymetrycznej.

Jak już wcześniej wspomniano, punkty pomiarowe zarejestrowane przy użyciu sensorów pokładowych platform pomiarowych cechują się różną dokładnością pomiaru głębokości oraz w niektórych miejscach mogą być one nadmiarowe. W związku z tym, przed hydrografem stoi długotrwały i pracochłonny proces opracowania danych batymetrycznych, którego celem jest przedstawienie w sposób wierny i dokładny ukształtowania strefy brzegowej. Przykładowo, dane geoprzestrzenne na akwenu testowym zostały zarejestrowane za pomocą metod i urządzeń, takich jak: SVR (ang. *Support Vector Regression* – SVR), SBES, MLS i UAV. Należy zaznaczyć, że metoda SVR służy do określenia głębokości w miejscach, gdzie nie można było przeprowadzić pomiarów bezpośrednich przy użyciu odbiornika GNSS RTK (ang. *Real Time Kinematic*). W tym celu wykorzystuje ona chmurę punktów SfM (ang. *Structure from Motion*) i głębokości zmierzone za pomocą odbiornika geodezyjnego. Na **Rys. 0.1** przedstawiono lokalizację danych geoprzestrzennych zarejestrowanych przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych i mapę batymetryczną akwenu testowego.



Rys. 0.1. Lokalizacja danych geoprzestrzennych zarejestrowanych przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych (a) i mapa batymetryczna akwenu testowego (b) (opracowanie własne).

W celu uzyskania dokładnej mapy batymetrycznej należało zredukować liczbę punktów pomiarowych pozyskanych z różnych sensorów pokładowych bezzałogowych platform pomiarowych. Efektywne wykorzystanie wielomodalnych danych geoprzestrzennych stanowi problem w ich przetwarzaniu, analizie oraz udostępnianiu. W celu prawidłowej realizacji wszystkich etapów, należy utworzyć nową metodę monitoringu batymetrycznego strefy brzegowej na bazie fuzji wielomodalnych danych geoprzestrzennych pozyskanych przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych, która pozwoli w sposób optymalny z punktu widzenia dokładności pomiarów opracować mapę batymetryczną strefy brzegowej.

Istniejące metody (fuzji) integracji danych geoprzestrzennych w hydrografii, takie jak: interpolacja metodą najbliższego sąsiada (ang. *nearest neighbor interpolation*), interpolacja metodą naturalnego sąsiada (ang. *natural neighbor interpolation*), interpolacja metodą odwrotnych ważonych odległości (ang. *Inverse Distance Weighting* – IDW), czy interpolacja metodą geostatystyczną, nie uwzględniają dokładności pomiaru poszczególnych urządzeń pomiarowych podczas procesu opracowania mapy batymetrycznej. Może to skutkować tym, że dane geoprzestrzenne, które zostały pozyskane przez

urządzenie o niskiej dokładności pomiaru głębokości, będą prowadziły do pogorszenia dokładności odwzorowania (ukształtowania) strefy brzegowej.

Dotychczasowe metody integracji danych geoprzestrzennych wykorzystują wartości interpolowane, wobec czego istnieje potrzeba poszukiwania nowych rozwiązań. Biorąc pod uwagę bezpieczeństwo nawigacji i dokładność map batymetrycznych należy opracować nową metodę, która pozwoli na zachowanie rzeczywistych wartości danych pomiarowych (pozycji i głębokości). Konieczność przedstawienia głębokości na mapie batymetrycznej występuje niezależnie od użytej skali opracowania, z zachowaniem wymaganej wierności odwzorowania powierzchni, z zachowaniem pozycji oraz wartości głębokości minimalnych, istotnych dla bezpieczeństwa nawigacji.

Modelowanie ukształtowania dna strefy brzegowej na podstawie danych geoprzestrzennych zarejestrowanych przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych sytuje niniejszą rozprawę doktorską w dziedzinie nauk inżynieryjno-technicznych w dyscyplinie inżynieria lądowa, geodezja i transport.

Celem głównym niniejszej rozprawy doktorskiej jest opracowanie metody monitoringu batymetrycznego strefy brzegowej na bazie fuzji wielomodalnych danych geoprzestrzennych pozyskanych przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych.

Teza rozprawy doktorskiej, sformułowana na podstawie problemu badawczego, zakłada, że zaproponowana metoda monitoringu batymetrycznego na bazie fuzji wielomodalnych danych geoprzestrzennych pozyskanych przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych umożliwi uzyskanie jakości danych wymaganej dla kategorii specjalnej Międzynarodowej Organizacji Hydrograficznej (IHO).

W ramach rozprawy doktorskiej wykorzystano następujące metody badawcze: analiza i synteza światowego piśmiennictwa wraz z jego abstrahowaniem, eksperyment, badania statystyczne, analiza i konstrukcja logiczna oraz modelowanie matematyczne.

Aby osiągnąć cel główny rozprawy należy zrealizować następujące cele cząstkowe:

- Charakterystyka danych pozyskanych przy użyciu urządzeń hydroakustycznych i optoelektronicznych w pomiarach batymetrycznych;
- Przegląd i analiza istniejących metod modelowania powierzchni terenu w strefie brzegowej;
- Przegląd metod fuzji wielomodalnych danych geoprzestrzennych w pomiarach batymetrycznych;
- Opracowanie i analiza danych batymetryczno-fotogrametrycznych pozyskanych przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych;
- Ustalenie etapów metody monitoringu batymetrycznego strefy brzegowej;
- Ustalenie autorskiej metody monitoringu batymetrycznego strefy brzegowej;
- Realizacja pomiarów batymetryczno-fotogrametrycznych w strefie brzegowej na wybranych akwenach przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych;
- Kompleksowa realizacja pomiarów batymetryczno-fotogrametrycznych w strefie brzegowej na wybranym akwenie przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych;
- Analiza ilościowa autorskiej metody modelowania powierzchni terenu w strefie brzegowej.

W ramach rozprawy doktorskiej dane geoprzestrzenne opracowano przy wykorzystaniu oprogramowania: ArcGIS Pro, HYPACK i QGIS. Dane pomiarowe zarejestrowano w trakcie pięciu

kampanii pomiarowych, przeprowadzonych przez zespół pod kierownictwem prof. Andrzeja Statecznego, w których autorka niniejszej rozprawy brała udział jako pomiarowiec.

Praca składa się ze wstępu, trzech rozdziałów i wniosków końcowych. Wprowadzenie w problematykę rozprawy oraz ogólna analiza literatury są treścią niniejszego wstępu.

W rozdziale I *„Analiza metod integracji danych hydroakustycznych i optoelektronicznych stosowanych w hydrografii”* dokonano analizy metod integracji danych hydroakustycznych i optoelektronicznych stosowanych w hydrografii. Na początku scharakteryzowano dane pozyskane przy użyciu urządzeń hydroakustycznych i optoelektronicznych w pomiarach batymetrycznych. Następnie omówiono istniejące metody modelowania powierzchni terenu w strefie brzegowej. Ponadto opisano metody fuzji wielomodalnych danych geoprzestrzennych stosowane w pomiarach batymetrycznych.

W rozdziale II *„Metoda monitoringu batymetrycznego strefy brzegowej na bazie fuzji wielomodalnych danych geoprzestrzennych”* opisano etapy opracowania i analizy danych geoprzestrzennych pozyskanych przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych. Następnie przedstawiono etapy autorskiej metody monitoringu batymetrycznego strefy brzegowej. W dalszej kolejności zaimplementowano tą metodę w środowisku GIS.

W rozdziale III *„Badanie i weryfikacja metody modelowania powierzchni terenu w strefie brzegowej”* na początku omówiono realizację i opracowanie danych geoprzestrzennych zarejestrowanych podczas czterech kampanii pomiarowych, które przeprowadzono na dwóch akwenach (morskim i śródlądowym) w latach 2022-2023. Warto zaznaczyć, że w trakcie realizacji tych kampanii nie użyto jednocześnie (podczas jednego dnia) wszystkich dostępnych sensorów pokładowych bezzałogowych platform pomiarowych (LiDAR, MBES, MLS, SBES i UAV). Ograniczyło to możliwość dokonania pełnej analizy otrzymanych modeli fuzji danych średnich ważonych. Z tego powodu podjęto decyzję o przeprowadzeniu kompleksowej, jednodniowej kampanii pomiarowej w sierpniu 2024 r. na wybranym akwenie, podczas której zostaną wykorzystane wszystkie dostępne sensory. W drugiej części tego rozdziału została omówiona realizacja i opracowanie danych geoprzestrzennych zarejestrowanych podczas kompleksowej kampanii pomiarowej na jeziorze Kłodno. Wybór tego jeziora był podyktowany możliwością jednoczesnego użycia wszystkich dostępnych sensorów pokładowych bezzałogowych platform pomiarowych (LiDAR, MBES, SBES i UAV). W trzeciej części tego rozdziału została przeprowadzona analiza statystyczna wyników autorskiej metody monitoringu batymetrycznego strefy brzegowej uzyskanych na podstawie modeli fuzji danych średnich ważonych.

Wnioski wynikające z przeprowadzonych w pracy rozważań są treścią jej ostatniej części. Rozprawę uzupełnia wykaz cytowanej literatury, wykaz rysunków i tabel oraz streszczenia w języku polskim i angielskim.

1. Analiza metod integracji danych hydroakustycznych i optoelektronicznych stosowanych w hydrografii

Pomiary hydrograficzne w strefie brzegowej są coraz częściej wykonywane przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych. Zastosowanie zarówno urządzeń hydroakustycznych, jak i optoelektronicznych pozwala na szybkie pozyskiwanie wysokiej jakości danych geoprzestrzennych. Natomiast wykorzystanie wyłącznie jednego urządzenia nie zapewnia pełnego pokrycia badanego obszaru pomiarami. Dlatego też pomiary hydrograficzne przeprowadza się za pomocą urządzeń hydroakustycznych i optoelektronicznych, a następnie dokonuje się integracji danych z tych urządzeń.

W tym rozdziale postanowiono dokonać analizy metod integracji danych hydroakustycznych i optoelektronicznych stosowanych w hydrografii. Na początku scharakteryzowano dane pozyskane przy użyciu urządzeń hydroakustycznych i optoelektronicznych w pomiarach batymetrycznych. Następnie omówiono istniejące metody modelowania powierzchni terenu w strefie brzegowej. Ponadto opisano metody fuzji wielomodalnych danych geoprzestrzennych w pomiarach batymetrycznych.

1.1. Charakterystyka danych pozyskanych przy użyciu urządzeń hydroakustycznych w pomiarach batymetrycznych

Charakterystyka danych odgrywa kluczową rolę podczas ich integracji. W związku z tym, postanowiono szczegółowo opisać dane geoprzestrzenne, które będą wykorzystywane w metodzie monitoringu batymetrycznego strefy brzegowej. W tej części pracy na początku przedstawiono definicje i zastosowanie zarówno echosondy jednowiązkowej, jak i wielowiązkowej. Następnie opisano budowę tych urządzeń oraz omówiono zasadę ich działania. W dalszej kolejności scharakteryzowano dane, które są rejestrowane przez urządzenia hydroakustyczne. Ponadto przedstawiono dokładności pomiaru głębokości przy użyciu echosond.

1.1.1. Echosonda jednowiązkowa

Definicja i zastosowanie

Echosonda jednowiązkowa to urządzenie hydroakustyczne (hydrolokacyjne), które jest przeznaczone do pomiaru odległości (głębokości) między przetwornikiem a powierzchnią dna lub innymi obiektami znajdującymi się w toni wodnej. Jest ono wyposażone w przetwornik nadawczo-odbiorczy, który wytwarza jedną wiązkę akustyczną o pionowej osi (**Makar A., 2011**). System batymetryczny oparty na echosondzie SBES musi również składać się z systemu pozycjonowania, którym najczęściej jest system GNSS RTK. Obszar przeszukiwania przez echosondę (ang. *footprint*) zależy od jej typu. Swoim kształtem przypomina on graniastosłup o przekroju trójkątnym, którego kąt wierzchołkowy jest równy w przybliżeniu szerokościątowej wiązki w płaszczyźnie prostopadłej do kierunku ruchu jednostki pływającej (**International Hydrographic Organization, 2005**):

$$s_o = 2 \cdot d \cdot \tan\left(\frac{\phi}{2}\right) \quad (1.1)$$

gdzie:

s_o – szerokość obszaru przeszukiwania przez echosondę SBES,

d – głębokość akwenu,


ϕ – szerokość wiązki akustycznej emitowana przez echosondę SBES.

W echosondach wykorzystywanych do celów badawczych stosuje się zdecydowanie węższą wiązkę (do 10°), przez co obszar przeszukiwania jest niewielki, a rozdzielczość kątowa jest wysoka (**Salomon R., 2006**).

Echosondy jednowiązkowe znajdują szerokie zastosowanie w wielu dziedzinach nauki. Najpowszechniej wykorzystywaną grupą echosond są echosondy nawigacyjne. Są one przeznaczone głównie do obserwacji dna morza i innych przeszkód nawigacyjnych znajdujących się na dnie (skały, wraki itd.) (**Popielarczyk D., 2011**). Można wyróżnić również echosondy hydrograficzne, które mają za zadanie wizualizację ukształtowania dna i ewentualnie obiektów znajdujących się na nim (**Arseni M. i in., 2019**). Niektóre echosondy hydrograficzne służą również do określania struktury dna i osadów dennych (**Haris K. i in., 2012**). Inna grupa echosond to echosondy rybackie, które są przeznaczone do obserwacji ławic i pojedynczych ryb (**Landero Figueroa M.M. i in., 2021**). Warto zaznaczyć, że echosondy jednowiązkowe znajdują zastosowanie również w monitoringu strefy brzegowej, głównie w celu pomiaru głębokości wzdłuż linii brzegowej oraz na obszarach płytkowodnych.

Budowa i zasada działania

Schemat blokowy typowej echosondy przedstawiono na **Rys. 1.1**. Składa się ona z dwóch głównych kanałów: nadawczego i odbiorczego. Do kanału nadawczego zalicza się: generator impulsów sterujących, wzmacniacz mocy i układ kompensacji. Natomiast do kanału odbiorczego wlicza się: układ filtracji i detekcji, ADC, wzmacniacz selektywny i przedwzmacniacz (**Salomon R., 2006**).



Rys. 1.1. Schemat blokowy typowej echosondy (opracowanie własne na podstawie: (**Salomon R., 2006**)).

Sygnał sondujący jest wytwarzany cyklicznie w generatorze impulsów sondujących. Większość impulsów ma przebieg sinusoidalny. Częstotliwość przebiegu sinusoidalnego (częstotliwość pracy echosondy) zależy od jej zasięgu i rodzaju obserwowanych obiektów. W większości echosond częstotliwość ich pracy mieści się w granicach od ok. 10 kHz do ok. 300 kHz (**Salomon R., 2006**).

Wytworzony w generatorze sygnał sondujący jest następnie wzmacniany we wzmacniaczu mocy. Wyjściowa moc elektryczna tych wzmacniaczy jest zróżnicowana i mieści się w przedziale od

pojedynczych watów w echosondach przeznaczonych dla wędkarzy do kilku kW w echosondach badawczych/rybackich (Salomon R., 2006).

Impuls sondujący o odpowiednio dużej mocy jest podawany na układ kompensacji, którego zadaniem jest eliminacja składowej urojonej impedancji elektrycznej anteny hydroakustycznej i toru kablowego łączącego nadajnik z anteną (Salomon R., 2006).

Jeżeli ta sama antena hydroakustyczna służy do wyzwalania impulsów sondujących i odbioru impulsów echa, to konieczne jest zastosowanie przełącznika nadawanie/odbior (N/O). Ma on za zadanie odcięcie od anteny wyjście przedwzmacniacza w momencie wytwarzania sygnału sondującego i wyjście wzmacniacza mocy w czasie odbioru sygnałów echa (Salomon R., 2006).

Elektryczny impuls sondujący jest przetwarzany na sygnał akustyczny w przetworniku ultradźwiękowym anteny. Następnie ten sygnał jest promieniowany w wąskiej wiązce i po odbiciu od obiektów znajdujących się w wodzie wraca do anteny jako akustyczny sygnał echa. Na wyjściu anteny pojawia się w postaci elektrycznego sygnału echa, który po przejściu przez przełącznik N/O jest podawany do wejścia przedwzmacniacza (Salomon R., 2006).

Pomiar głębokości w echosondzie jednowiązkowej jest realizowany na zasadzie określenia czasu niezbędnego na przejście wypromieniowanego impulsu akustycznego od przetwornika do odbijającego obiektu i z powrotem - do odbiornika odbitych sygnałów (Rys. 1.2) (Bowditch N., 2019):

$$d = d_w + d_r = \frac{c_w \cdot t_w}{2} + d_r \quad (1.2)$$


gdzie:

d_w – głębokość wody pomiędzy przetwornikiem a dnem,

d_r – zanurzenie przetwornika,

c_w – prędkość dźwięku w sondowanym akwenu,

t_w – czas przebiegu impulsu do dna i z powrotem.



Rys. 1.2. Zasada pomiaru głębokości w echosondzie SBES (opracowanie własne na podstawie: (Alevizos E. i in., 2022)).

Zadaniem echosondy SBES jest więc dokładny pomiar czasu od chwili wysłania do chwili powrotu impulsu akustycznego. Aby echo w przetworniku odbiorczym zostało odróżnione od innych ech i mógł

być wykonany pomiar głębokość, moc sygnału akustycznego przychodzącego do przetwornika musi być większa lub co najmniej równa (**Makar A., 2011**):

$$P_s \geq \frac{I_{odb}}{S_r} \quad (1.3)$$

gdzie:

P_s – moc sygnału akustycznego przychodzącego do przetwornika,

I_{odb} – natężenie sygnału akustycznego dochodzącego do przetwornika,

S_r – powierzchnia rdzenia przetwornika odbiorczego.

W dalszej kolejności następuje wzmocnienie i filtracja wąskopasmowa sygnału echa. Filtracja poprawia wyjściowy stosunek sygnału do szumu (ang. *Signal Noise to Radio* – SNR) i ogranicza widmo sygnału, co jest niezbędne, gdy sygnał jest próbkowany i przekształcany na sygnał cyfrowy. Ze względu na dużą dynamikę odbieranych sygnałów i konieczność jej ograniczenia jest stosowana zasięgowa regulacja wzmocnienia (ZRW) (ang. *Time Varied Gain* – TVG). Poza tym, w niektórych echosondach stosuje się ręczną regulację wzmocnienia (RRW), aby operator mógł dokonywać płynnej lub w pewnych granicach skokowej zmiany wzmocnienia echosondy (**Bikonis K., 2007**).

Charakterystyka danych

Dane głębokościowe pozyskane przy użyciu echosondy jednowiązkowej w niewielkim stopniu pokrywają dno pomiarami. Z tego powodu nie spełniają one minimalnych wymagań dotyczących pokrycia dna pomiarami batymetrycznymi (ang. *bathymetric coverage*) dla kategorii pomiarów hydrograficznych IHO: szczególnej, specjalnej i 1a. Kategorie te wymagają co najmniej 100% pokrycia dna pomiarami batymetrycznymi. Natomiast pomiary hydrograficzne wykonywane z wykorzystaniem echosond SBES spełniają wymagania dotyczące pokrycia dna pomiarami batymetrycznymi dla kategorii 1b i 2. W ramach tych kategorii wymagane jest zaledwie 5% pokrycia dna pomiarami batymetrycznymi oraz maksymalna odległość między sąsiednimi profilami sondażowymi, która nie powinna przekraczać 3- lub 4-krotności głębokości sondowanego akwenu (**International Hydrographic Organization, 2022**). W innych międzynarodowych standardach hydrograficznych przyjęto, że odległość między sąsiednimi profilami pomiarowymi jest rzędu 10 m. Niewielkie pokrycie dna pomiarami skutkuje koniecznością realizacji pomiarów batymetrycznych na znacznie większej liczbie profili sondażowych. Należy zaznaczyć, że duża liczba profili pomiarowych przekłada się na znacznie dłuższy czas akwizycji danych batymetrycznych (**Bodus-Olkowska O., Włodarczyk-Sielicka M., 2013**).

Warto podkreślić, że dodatkowo wykonuje się pomiary sonarowe między profilami sondażowymi w celu minimalizacji ryzyka wystąpienia błędów wynikających z niepełnego pokrycia badanego obszaru pomiarami. Aby przeprowadzić badania sonarowe w sposób efektywny, jednostka pływająca powinna przemieszczać się wzdłuż ustalonych profili pomiarowych (**Wojskowe Centrum Normalizacji, Jakości i Kodyfikacji, 2009**).

Ponadto pomiary batymetryczne wykonane przy użyciu echosondy jednowiązkowej są w stanie spełnić wszystkie wymagania dokładnościowe przewidziane dla wszystkich kategorii pomiarów hydrograficznych IHO (**International Hydrographic Organization, 2022**). Oznacza to, że pomiary te są wystarczająco dokładne, aby sprostać najwyższym standardom określonym przez IHO dla różnego rodzaju zadań hydrograficznych.

Dokładność pomiaru głębokości

Współczesne echosondy jednowiązkowe pozwalają na pomiar głębokości z wysoką dokładnością i rozdzielczością rzędu pojedynczych centymetrów na małych głębokościach wynoszących 0.1-0.2 m (**Li Z. i in., 2023**). Jednakże należy pamiętać, że niepewność pomiaru głębokości przy użyciu echosondy SBES zależy od wielu czynników i jest wynikiem przetwarzania informacji pochodzących z różnych źródeł. Zgodnie z „*Manual on Hydrography*” na dokładność pomiaru głębokości mają wpływ (**International Hydrographic Organization, 2005**):

1. Niepewność pomiaru głębokości związana z prędkością rozchodzenia się dźwięku w wodzie (σ_c). Jest to kluczowy i najbardziej zmienny parametr podczas wyznaczania głębokości przy użyciu echosondy SBES. Prędkość dźwięku w wodzie można określić na dwa sposoby. Jednym z nich jest wyznaczenie tego parametru w sposób bezpośredni przy użyciu miernika prędkości dźwięku z dokładnością ± 0.05 m/s (**Li C. i in., 2021**). Dodatkowo w celu dokładniejszego określenia prędkości dźwięku, pomiary temperatury wody są wykonywane z wykorzystaniem sondy temperaturowej, która może zostać umieszczona obok echosondy lub zamontowana na niej. Dane o temperaturze wody są wykorzystywane do korekty prędkości dźwięku, co z kolei wpływa na dokładność pomiarów głębokości prowadzonych za pomocą echosondy SBES. Integracja tych dwóch pomiarów pozwala uzyskać dokładniejsze wyniki pomiarów batymetrycznych.


Innym sposobem wyznaczania prędkości dźwięku w wodzie jest wykorzystanie sondy oceanograficznej (ang. *Conductivity, Temperature, Depth (CTD) sensors*), służącej do pomiarów temperatury i zasolenia wody oraz innych właściwości fizycznych w głębi wody i na jej powierzchni (**Makar A., 2008**). Na podstawie właściwości fizycznych zmierzonych przez sondę CTD wyznaczana jest prędkość rozchodzenia się dźwięku w wodzie. Obliczana jest ona najczęściej przy użyciu wzorów empirycznych: Chen i Millero (**Chen C.T., Millero F.J., 1976, 1977**), Del Grosso (**Del Grosso V.A., 1974**), Mackenziego (**Mackenzie K.V., 1981a, 1981b**), Medwina (**Medwin H., 1975**), czy Wilsona (**Wilson W.D., 1960**).

Najpowszechniejszym i zarazem najdokładniejszym wzorem na obliczenie prędkości rozchodzenia się dźwięku w wodzie morskiej jest wzór empiryczny Wilsona, który zależy od ciśnienia, temperatury i zasolenia. Dokładność wzoru Wilsona szacuje się na ± 0.3 m/s w zakresie ciśnień: 1-1000 kG/cm², temperatur: 4-30°C i zasoleń wody: 0-37‰ (**Wilson W.D., 1960**).

Najbardziej zmiennym i zarazem mającym największy wpływ parametrem na prędkość rozchodzenia się dźwięku w wodzie jest temperatura. Zmiany temperatury wody mogą istotnie wpływać na jej gęstość, a co za tym idzie, na prędkość dźwięku. Prędkość rozchodzenia się dźwięku w wodzie zwiększa się średnio o 4.5 m/s przy wzroście temperatury o 1°C. Drugim czynnikiem wpływającym w umiarkowanym stopniu na prędkość dźwięku w wodzie jest zasolenie. Prędkość rozchodzenia się dźwięku w wodzie rośnie w przybliżeniu o 1.3 m/s przy wzroście zasolenia o 1‰. Trzecim parametrem wpływającym w znikomym stopniu na prędkość dźwięku w wodzie jest ciśnienie hydroakustyczne (głębokość). Prędkość rozchodzenia się dźwięku w wodzie zwiększa się o ok. 1.6 m/s przy wzroście głębokości o 100 m. Zatem można przyjąć, że ciśnienie hydrostatyczne nie ma praktycznie żadnego wpływu na prędkość dźwięku w wodzie podczas realizacji pomiarów batymetrycznych na akwenach płytkowodnych (**Wojskowe Centrum Normalizacji, Jakości i Kodyfikacji, 2009**).

Należy zauważyć, że znaczny wpływ na prędkość rozchodzenia się dźwięku w wodzie mogą mieć krótkookresowe (dobowe) zmiany temperatury powierzchni wody. Zmiany te są wywołane nagrzewaniem się warstwy powierzchniowej wody przez Słońce (efekt popołudniowy) (**Rys. 1.3**).

Zakres zmian prędkości dźwięku o charakterze dobowym może wynosić w sezonie letnim nawet 40 m/s (**Makar A., Naus K., 2003**);



Rys. 1.3. Zakres zmian prędkości rozchodzenia się dźwięku w okresie letnim o charakterze dobowym w Zatoce Gdańskiej (**Makar A., Naus K., 2003**).

2. Niepewność pomiaru głębokości związana z nachyleniem dna (σ_s). Błąd ten zależy od szerokości wiązki akustycznej emitowanej przez echosondę SBES i głębokości akwenu;
3. Niepewność pomiaru głębokości związana z pomiarem czasu (σ_t). W nowoczesnych echosondach SBES błąd ten jest pomijalnie mały i stały. Można go uwzględnić podczas kalibracji urządzenia hydroakustycznego;
4. Niepewność pomiaru głębokości związana z ruchem jednostki pływającej na fali (σ_m): kiwanie (ang. *pitch*), kołysanie (ang. *roll*) i nurzanie (ang. *heave*). Kiwanie i kołysanie mają wpływ na dokładność pomiaru głębokości, jeżeli ich wartość jest większa niż połowa szerokości wiązki akustycznej. Natomiast nurzanie zależy od dokładności pomiaru położenia przetwornika względem czujnika wahań pionowych oraz od dokładności pomiaru kątów kiwania i kołysania bocznego (**Hare R., 1995**);
5. Niepewność pomiaru głębokości związana z zanurzeniem przetwornika echosondy (σ_r). Zanurzenie przetwornika należy każdorazowo zmierzyć przed rozpoczęciem pomiarów batymetrycznych przy użyciu echosondy SBES;
6. Niepewność pomiaru głębokości związana z redukcją głębokością (σ_h). Błąd ten zależy od wysokości pływów, które należy uwzględnić podczas przeliczania zmierzonej przez echosondę SBES głębokości do przyjętego układu wysokościowego.

Znając wyżej wymienione niepewności można wyznaczyć całkowity błąd pomiaru głębokości przy poziomie ufności 95% ($\sigma_{SBES}(p=0.95)$) (**International Hydrographic Organization, 2005**):

$$\sigma_{SBES}(p=0.95) = 2 \cdot \sqrt{(\sigma_c)^2 + (\sigma_s)^2 + (\sigma_t)^2 + (\sigma_m)^2 + (\sigma_r)^2 + (\sigma_h)^2} \quad (1.4)$$

Aby spełnić wymagania dokładnościowe IHO dla kategorii 1b i 2, całkowity błąd pomiaru głębokości przy poziomie ufności 95% ($\sigma_{SBES}(p=0.95)$) nie może być większy od całkowitej niepewności wertykalnej przy poziomie ufności 95% ($TVU_{max}(d)$) (**Ministerstwo Obrony Narodowej, 2018**):

$$TVU_{\max}(d) = \sqrt{a^2 + (b \cdot d)^2} \quad (1.5)$$

$$\sigma_{SBES}(p=0.95) \leq TVU_{\max}(d) \quad (1.6)$$

gdzie:

a – składnik błędu pomiaru niezależny od głębokości,

b – współczynnik reprezentujący składnik błędu pomiaru zależny od głębokości.

W **Tab. 1.1** przedstawiono zależność maksymalnego błędu pomiaru głębokości ($TVU_{\max}(d)$) od głębokości akwenu dla pięciu kategorii pomiarów hydrograficznych IHO: szczególnej, specjalnej, 1a/1b i 2. Analizę przeprowadzono dla głębokości akwenu od 1 m do 20 m z krokiem co 1 m.

Tab. 1.1. Zależność maksymalnego błędu pomiaru głębokości ($TVU_{\max}(d)$) od głębokości akwenu dla pięciu kategorii pomiarów hydrograficznych IHO (opracowanie własne).

Głębokość akwenu (m)	Błąd pomiaru głębokości ($TVU_{\max}(d)$) (m)			
	Szczególna	Specjalna	1a/1b	2
1	0.150	0.250	0.500	1.000
2	0.151	0.250	0.501	1.001
3	0.152	0.251	0.502	1.002
4	0.153	0.252	0.503	1.004
5	0.155	0.253	0.504	1.007
6	0.157	0.254	0.506	1.009
7	0.159	0.255	0.508	1.013
8	0.162	0.257	0.511	1.017
9	0.164	0.259	0.514	1.021
10	0.168	0.261	0.517	1.026
11	0.171	0.263	0.520	1.032
12	0.175	0.266	0.524	1.037
13	0.179	0.268	0.528	1.044
14	0.183	0.271	0.532	1.051
15	0.188	0.274	0.537	1.058
16	0.192	0.277	0.542	1.066
17	0.197	0.281	0.547	1.074
18	0.202	0.284	0.552	1.082
19	0.207	0.288	0.558	1.091
20	0.212	0.292	0.564	1.101

Na podstawie **Tab. 1.1** należy stwierdzić, że błąd pomiaru głębokości ($TVU_{\max}(d)$) rośnie nieznacznie wraz z głębokością akwenu. Różnice pomiędzy maksymalnymi błędami pomiaru głębokości dla kolejnych głębokości akwenu są niewielkie i wynoszą maksymalnie kilka milimetrów, niezależnie od

kategorii pomiarów hydrograficznych. Przykładowo, dla najbardziej rygorystycznej kategorii IHO (szczególnej) błąd $TVU_{max}(d)$ wynosi 0.15 m dla głębokości 1 m. Natomiast wartość tego błędu dla głębokości 5 m jest zaledwie 5 mm większa niż dla głębokości 1 m.

Z **Tab. 1.1** wynika również, że błąd pomiaru głębokości na akwenie płytkowodnym nie może być większy niż 0.15 m ($p=0.95$) dla kategorii szczególnej i 0.25 m ($p=0.95$) dla kategorii specjalnej. Te wymagania dokładnościowe dotyczą akwenów, na których należy zapewnić pełne pokrycia dna pomiarami batymetrycznymi. Warto zauważyć, że dla najbardziej rygorystycznych kategorii pomiarów hydrograficznych IHO nie podano maksymalnej odległości między profilami sondażowymi (**International Hydrographic Organization, 2022**).

W kontekście opracowania metody monitoringu batymetrycznego dane pochodzące z echosondy jednowiązkowej umożliwią pozyskanie informacji o głębokościach na obszarach płytkowodnych, zwłaszcza blisko linii brzegowej. Ponadto zapewniają one wysoką dokładność pomiaru głębokości (0.1-0.2 m), co jest istotne z punktu widzenia wielosensorycznej fuzji danych. Warto jednak pamiętać o różnych parametrach, które mogą wpłynąć na dokładność wyznaczenia głębokości. Zrozumienie budowy i działania echosondy SBES ma kluczowe znaczenie dla identyfikacji tych czynników.

Należy także mieć na uwadze, że dane pozyskane z echosondy jednowiązkowej nie zapewniają pełnego pokrycia badanego obszaru pomiarami. W związku z tym, konieczne może być zastosowanie dodatkowych metod pomiarowych w celu uzyskania pełniejszego obrazu dna akwenu.


1.1.2. Echosonda wielowiązkowa

Definicja i zastosowanie

Echosonda wielowiązkowa to urządzenie hydroakustyczne, które jest przeznaczone do pomiaru głębokości między przetwornikiem a powierzchnią dna lub innymi obiektami znajdującymi się w toni wodnej. Jest ono wyposażone w dwa osobne szyki przetworników nadawczych i odbiorczych. Przetwornik nadawczy wysyła wiele wiązek akustycznych pod różnym kątem, formując tzw. wachlarz wiązek akustycznych (ang. *swath*) (**Rys. 1.4**). Obecnie na rynku są dostępne echosondy MBES generujące maksymalnie do 1024 wiązek akustycznych w sektorze 210° (**NORBIT, 2024**). Dzięki temu możliwe jest pełne pokrycie dna pomiarami (**Grządziel A., 2022**). System batymetryczny oparty na echosondzie MBES musi również składać się z systemu pozycjonowania, którym najczęściej jest system GNSS RTK wspomagany dodatkowo systemem INS (**Stateczny A. i in., 2019**). Poza tym, głowica echosondy wielowiązkowej jest z reguły zintegrowana z czujnikiem ruchu (ang. *Motion Reference Unit* – MRU), który kompensuje błędy spowodowane ruchem jednostki pływającej na wodzie oraz z czujnikiem przypowierzchniowej prędkości dźwięku w wodzie, z uwagi na fakt wysyłania wielu wiązek akustycznych, każdej w innym kierunku (**Bodus-Olkowska I., 2024**).

Od lat pięćdziesiątych XX wieku echosondy wielowiązkowe całkowicie zdominowały współczesne techniki pomiaru głębokości. Należą one do najbardziej efektywnych technik akustycznych badania dna. Dlatego też echosondy MBES, podobnie jak echosondy jednowiązkowe, znalazły zastosowanie w wielu dziedzinach życia. Podstawowym wykorzystaniem echosond wielowiązkowych jest wielopunktowy pomiar głębokości prowadzony zarówno na akwenach płytkowodnych, jak i głębokowodnych (**Gao J., 2009**). Możliwość pomiaru głębokości w kilkuset punktach jednocześnie spowodowała, że urządzenia te znalazły również zastosowanie m.in. do identyfikacji niebezpieczeństw geotechnicznych i wycieków gazów z dna (**Orange D.L. i in., 2002**), klasyfikacji i akustycznego obrazowania dna morskiego (**Mitchell N.C., Hughes Clarke J.E., 1994**), poznawania habitatu morskiego

(Trzcinska K. i in., 2020) i procesów zachodzących w osadach dennych (Todd B.J. i in., 1999), sondaży na potrzeby realizacji inwestycji związanych z układaniem kabli podwodnych i rurociągów, czy też do wykrywania obiektów podwodnych i przeszkód nawigacyjnych (Grządziel A., Wąż M., 2014).



Rys. 1.4. Porównanie obszaru przeszukiwania dna przez echosondę SBES (a) i MBES (b) (opracowanie własne).

Na szczególną uwagę zasługuje rejestracja danych głębokościowych przez echosondę wielowiązkową na obszarach głębokowodnych (powyżej 2 m głębokości). Jest to istotne z punktu widzenia monitoringu batymetrycznego, ponieważ umożliwia pozyskanie szczegółowych danych w miejscach, gdzie przeprowadzenie pomiarów batymetrycznych za pomocą echosondy jednowiązkowej jest niewystarczające.

Budowa i zasada działania

Zasada działania echosondy wielowiązkowej polega na generowaniu wiązek akustycznych prostopadle do kierunku ruchu jednostki pływającej w celu sondażu dna oraz cyfrowym przetwarzaniu sygnałów odbiorczych (United States Army Corps of Engineers, 2013). Echosonda MBES składa się z dwóch osobnych szkieletów przetworników nadawczych i odbiorczych. Przetworniki nadawcze są zazwyczaj rozmieszczone równolegle do wzdłużnej osi symetrii jednostki pływającej. Dzięki temu wiązki akustyczne są generowane prostopadle do kierunku ruchu. W ten sposób „opromieniowują” wąski pas dna. Natomiast przetworniki odbiorcze są zorientowane prostopadle do przetworników nadawczych. Ich zadaniem jest symultaniczne (równoległe) formowanie kilkuset wiązek odbiorczych. Po transmisji sygnałów akustycznych przez przetworniki nadawcze następuje moment ich odbicia od powierzchni dna, a następnie odbiór sygnałów ech przez przetworniki odbiorcze. Echosonda wielowiązkowa odbiera wszystkie sygnały ech, do których przypisany jest określony kąt kierunkowy wiązki i niewielki fragment powierzchni dna (Stepnowski A., 2001). Do formowania wachlarza wiązek akustycznych służą przede wszystkim metody elektronicznego sterowania i techniki cyfrowego przetwarzania sygnału (Grządziel A., Wąż M., 2016).

Pomiar głębokości przy użyciu echosondy wielowiązkowej polega na wyznaczeniu dwóch wielkości: czasu przebiegu impulsu sondującego od przetwornika do dna i z powrotem (t_w) oraz kąta odchylenia wiązki odbiorczej od linii pionu (θ_k) określanego kątem kierunkowym wiązki (Rys. 1.5). Znając obie wyżej wymienione wielkości można określić położenie punktu pomiarowego. Jeżeli rozkład prędkości rozchodzenia się dźwięku w kolumnie wody jest względnie stały, to można przyjąć, że droga pokonywana przez impuls sondujący dla każdej wiązki przypomina linię prostą. Zakładając, że początek

układu współrzędnych znajduje się w pozycji przetwornika, to współrzędne punktu pomiarowego można obliczyć korzystając ze wzorów (Hare R. i in., 1995):

$$y_k = r \cdot \sin(\theta_k) = \frac{c_w \cdot t_w}{2} \cdot \sin(\theta_k) \quad (1.7)$$


$$d_w = \frac{c_w \cdot t_w}{2} \cdot \cos(\theta_k) \quad (1.8)$$

$$d = d_w + d_r = \frac{c_w \cdot t_w}{2} \cdot \cos(\theta_k) + d_r \quad (1.9)$$

gdzie:

y_k – współrzędna poprzeczna punktu pomiaru głębokości,

r – odległość pomiędzy przetwornikiem a punktem padania wiązki na dno.




Rys. 1.5. Pomiar głębokości echosondą MBES (opracowanie własne na podstawie: (Wessex Archeology, 2024)).

W rzeczywistości problem wyznaczenia trójwymiarowych współrzędnych pozycji punktu pomiarowego jest procesem bardziej złożonym. Trajektoria impulsu sondującego jest obliczana na podstawie informacji o powierzchniowej prędkości rozchodzenia się dźwięku w wodzie (ang. *surface sound speed*) i rozkładu tej prędkości w kolumnie wody przy użyciu specjalistycznego oprogramowania hydrograficznego (Grządziel A. i in., 2015). Należy pamiętać, że wszystkie pomiary głębokości są odniesione do przetwornika. Dlatego też podczas wykonywania pomiarów batymetrycznych należy znać dokładne współrzędne pozycji i orientację przestrzenną jednostki pływającej wykonującej pomiar.

Charakterystyka danych

Dane głębokościowe pozyskane przy użyciu echosondy wielowiązkowej pozwalają na pełne pokrycie dna pomiarami, w odróżnieniu do echosondy jednowiązkowej. Z tego powodu pomiary batymetryczne prowadzone z wykorzystaniem echosondy MBES mogą spełniać minimalne wymagania dokładnościowe przewidziane dla najbardziej rygorystycznych kategorii pomiarów hydrograficznych IHO: szczególnej, specjalnej i 1a. Kategorie te wymagają co najmniej 100% pokrycia dna pomiarami batymetrycznymi (International Hydrographic Organization, 2022). W związku z tym, pomiary sonarowe między profilami sondażowymi nie są konieczne.

Na **Rys. 1.6** porównano stopień pokrycia dna pomiarami zarejestrowanymi przy użyciu echosondy jednowiązkowej i wielowiązkowej. Na jego podstawie można stwierdzić, że dane MBES zdecydowanie gęściej pokrywają dno akwenu niż dane SBES.



Rys. 1.6. Porównanie stopnia pokrycia dna pomiarami zarejestrowanymi przy użyciu echosondy SBES (a) i MBES (b) (opracowanie własne).

Poza zdolnością pełnego pokrycia dna pomiarami, dane MBES cechują się również wysoką dokładnością i rozdzielczością (**Stepnowski A., 2001**). Pomiary batymetryczne wykonywane przy użyciu echosond wielowiązkowych zwiększają także wydajność prac sondażowych (**Grządział A., Wąż M., 2014**). Aby zapewnić określony stopień pokrycia dna pomiarami należy zaplanować kształt i odległości między profilami sondażowymi podczas realizacji pomiarów batymetrycznych z wykorzystaniem echosondy MBES. W standardzie pt. „*EM 1110-2-1003 USACE Standards for Hydrographic Surveys*” określono w jaki sposób można obliczyć odległość między profilami sondażowymi przy użyciu echosondy MBES (**United States Army Corps of Engineers, 2013**):

$$L = 2 \cdot d \cdot \tan\left(\frac{\Theta}{2}\right) \cdot (1 - s_p) \quad (1.10)$$

gdzie:

L – odległość między profilami sondażowymi przy użyciu echosondy MBES,

Θ – sektor kątowy promieniowania echosondy MBES,

s_p – strefa przysłonu między sąsiednimi pasami pomiarowymi (ang. *overlap*).

Wspomniana w równaniu (1.10) strefa przysłonu jest definiowana jako pas dna zbadany dwukrotnie lub więcej echosondą wielowiązkową podczas przejścia na sąsiednich profilach sondażowych. Szerokość strefy przysłonu jest wyrażana jako procent całkowitego pasa przeszukiwania lub procent wybranego zakresu pracy echosondy (**Wojskowe Centrum Normalizacji, Jakości i Kodyfikacji, 2009**).

Dokładność pomiaru głębokości

Większość echosond wielowiązkowych umożliwia wykonywanie pomiarów z wysoką dokładnością na stosunkowo niewielkich głębokościach (ok. 1-2 m). Jednakże, aby uzyskać dokładne dane głębokościowe, zaleca się unikanie tak płytkich obszarów. Wynika to z faktu, że w takich miejscach

mogą występować przeszkody podwodne i zaburzenia związane z falami, które wpływają na jakość danych. Należy podkreślić, że na rynku dostępne są echosondy MBES, które pozwalają na realizację pomiarów batymetrycznych z wysoką dokładnością i rozdzielczością rzędu pojedynczych centymetrów na małych głębokościach wynoszących ponad 0.5 m (**Teledyne RESON, 2024**). Trzeba pamiętać również o tym, że dokładność pomiaru głębokości przy użyciu echosondy wielowiązkowej może być zróżnicowana w zależności od modelu i warunków pomiarowych, jednakże jest ona zwykle bardzo wysoka.

Ponadto pomiar głębokości przy użyciu echosondy wielowiązkowej jest procesem nieco bardziej złożonym niż w echosondzie jednowiązkowej. Zgodnie z (**Grządziel A., 2025**) na dokładność pomiaru głębokości mają wpływ:

1. Niepewność pomiaru odległości od przetwornika do powierzchni dna (σ_D). Czynniki wpływającymi na błąd pomiaru odległości od przetwornika do powierzchni dna są: kąt kierunkowy wiązki akustycznej, kąt padania fali akustycznej na powierzchnię dna, prędkość rozchodzenia się dźwięku w wodzie, rodzaj dna i rozdzielczość zakresu próbkowania (ang. *range sampling resolution*);
2. Niepewność pomiaru kąta kierunkowego wiązki akustycznej (σ_θ). Najważniejszymi czynnikami wpływającymi na błąd pomiaru kąta kierunkowego wiązki akustycznej są: prędkość rozchodzenia się dźwięku w wodzie, kąt kołysania bocznego, kąt montażowy przetwornika w płaszczyźnie prostopadłej do kierunku ruchu jednostki pływającej i zastosowany algorytm detekcji dna;
3. Niepewność pomiaru kątów orientacji przestrzennej kadłuba (przetwornika) (σ_p). Błąd ten jest związany z metodą pomiaru przechyłów jednostki pływającej na wodzie, jak i z niedokładnościami instalacji samego przetwornika oraz błędnego pomiaru jego orientacji kątowej w statkowym układzie współrzędnych;
4. Niepewność związana z szerokością wiązki akustycznej (σ_w). Wielokierunkowy pomiar głębokości jest realizowany przede wszystkim przez wiązki ukośne (ang. *oblique beams*), których dokładność i rozdzielczość maleje wraz ze wzrostem kąta odchylenia od linii pionu. Dlatego hydrografa będzie interesowała ta część sektora kątowego wiązek, która pozwoli spełnić minimalne wymagania dokładnościowe w zakresie pomiaru głębokości dla danej kategorii IHO. Jest to tzw. użyteczny sektor promieniowania echosondy MBES;
5. Niepewność pomiaru nurzania (σ_H). Wpływ na dokładność ruchu wertykalnego jednostki pływającej mają falowanie, kiwanie i kołysanie boczne samej jednostki.

Znając wyżej wymienione niepewności można wyznaczyć całkowity błąd pomiaru głębokości przy poziomie ufności 95% ($\sigma_{MBES}(p=0.95)$):

$$\sigma_{MBES}(p=0.95) = 2 \cdot \sqrt{(\sigma_D)^2 + (\sigma_\theta)^2 + (\sigma_p)^2 + (\sigma_w)^2 + (\sigma_H)^2} \quad (1.11)$$

Aby spełnić wymagania dokładnościowe IHO dla kategorii szczególnej, specjalnej i 1a, całkowity błąd pomiaru głębokości przy poziomie ufności 95% ($\sigma_{MBES}(p=0.95)$) nie może być większy od całkowitej niepewności wertykalnej przy poziomie ufności 95% ($TVU_{max}(d)$) (**Ministerstwo Obrony Narodowej, 2018**):

$$\sigma_{MBES}(p=0.95) \leq TVU_{max}(d) \quad (1.12)$$

Zastosowanie echosondy wielowiązkowej w pomiarach batymetrycznych pozwala na pozyskanie danych o wysokiej dokładności i rozdzielczości na obszarach głębokowodnych (**Stepnowski A., 2001**). Co więcej, zapewnia również pełne pokrycie dna pomiarami batymetrycznymi, dzięki czemu mogą zostać spełnione minimalne wymagania dokładnościowe przewidziane dla najbardziej rygorystycznych kategorii pomiarów hydrograficznych IHO: szczególnej, specjalnej i 1a (**International Hydrographic Organization, 2022**). Niemniej jednak należy mieć na uwadze czynniki wpływające na dokładność pomiaru głębokości przy użyciu echosondy MBES.

1.2. Charakterystyka danych pozyskanych przy użyciu urządzeń optoelektronicznych w pomiarach batymetrycznych

Podczas realizacji pomiarów batymetrycznych w strefie brzegowej wykorzystuje się również urządzenia optoelektroniczne. Obecnie stanowią one uzupełnienie pomiarów hydrograficznych realizowanych przy użyciu urządzeń hydroakustycznych. W tej części pracy na początku przedstawiono definicje i zastosowanie kamery fotogrametrycznej i LiDAR-u. Następnie opisano budowę tych urządzeń oraz omówiono zasadę ich działania. W dalszej kolejności scharakteryzowano dane, które są rejestrowane przez urządzenia optoelektroniczne. Ponadto przedstawiono dokładności pomiaru głębokości przy użyciu kamery fotogrametrycznej i LiDAR-u.

1.2.1. Kamera fotogrametryczna

Definicja i zastosowanie

Kamera fotograficzna to urządzenie służące do wykonywania zdjęć fotograficznych. Obecnie powszechnie stosowane są cyfrowe aparaty fotograficzne, których układ optyczny tworzy obraz na przetworniku fotoelektrycznym: matrycy CCD (ang. *Charge-Coupled Device*) lub CMOS (ang. *Complementary Metal Oxide Semiconductor*) (**Neumann K. i in., 2016**). Wśród kamer fotograficznych można wyróżnić kamery topograficzne (zwane inaczej metrycznymi lub fotogrametrycznymi), które są przeznaczone do wykonywania zdjęć na potrzeby opracowań mapowych i innych zadań pomiarowych. Ze względu na wymaganą bardzo wysoką dokładność pomiaru, zdjęcia wykonane przez kamerę metryczną muszą cechować się najwyższą jakością geometryczną i stałością parametrów geometrycznych (**Kurczyński Z., 2006a**). Zadaniem kamery fotogrametrycznej jest uzyskanie obrazu, który ma być rzutem środkowym na płaszczyznę fotografowanego przedmiotu, a promienie rzutujące w przestrzeni obrazowej i przedmiotowej mają być współliniowe (**Tokarczyk R. i in., 2024**).

Kamery fotogrametryczne znajdują zastosowanie w wielu dziedzinach życia, wśród których można wyróżnić:

- Archeologia. Kamery metryczne są stosowane do badania zabytków i dokumentowania stanowisk archeologicznych. Zdjęcia mogą ujawnić ukryte struktury, wzorce terenowe oraz zmiany w krajobrazie, co pozwala archeologom lepiej zrozumieć historię danego obszaru (**Peipe J., Stephani M., 2003**);
- Badania środowiska naturalnego. Kamery fotogrametryczne mogą być używane do monitoringu zanieczyszczeń i zmian zachodzących w pokrywie roślinnej, oceny stanu ekosystemów, a także do planowania i zarządzania obszarami chronionymi;
- Batymetria. Kamery metryczne, które są zamontowane na UAV, umożliwiają pozyskiwanie danych głębokościowych w celu tworzenia trójwymiarowych modeli dna morskiego (**Specht O. i in., 2023**);

- Geodezja i kartografia. Kamery fotogrametryczne są wykorzystywane do tworzenia map topograficznych, w pomiarach geodezyjnych oraz do określania zmian ukształtowania terenu (**Berteška T., Ruzgienė B., 2013**);
- Inżynieria lądowa. Kamery metryczne są stosowane w planowaniu i monitoringu infrastruktury drogowej, kolejowej i lotniskowej. Pozwalają na analizę warunków terenowych, dokładny pomiar trasy oraz symulację różnych scenariuszy projektowych (**Ruzgienė B. i in., 2015**);
- Robotyka. Kamery fotogrametryczne są wykorzystywane do identyfikacji obiektów, i oceny otoczenia oraz nawigacji robotów przemysłowych i usługowych, czy pojazdów autonomicznych (**Liu C. i in., 2023**).

Z punktu widzenia monitoringu batymetrycznego strefy brzegowej istotne jest wykorzystanie kamery fotogrametrycznej do określania głębokości akwenów płytkowodnych na podstawie zdjęć wykonanych przez UAV. Zastosowanie kamery metrycznej w pomiarach batymetrycznych pozwoli na pozyskanie danych głębokościowych na obszarach trudnodostępnych dla innych metod pomiarowych.

Budowa i zasada działania

Najważniejszą częścią kamery fotogrametrycznej jest obiektyw, który w głównej mierze warunkuje właściwości pomiarowe zdjęć oraz ich jakość fotograficzną i geometryczną. Obiektyw fotograficzny to układ optyczny dający rzeczywisty obraz fotografowanego przedmiotu. Aby można było wyznaczyć podstawowe parametry geometryczne obiektywu i przebieg promieni świetlnych, realny obiektyw często zastępuje się wyidealizowanym modelem geometrycznym, w którym przyjęto, że (**Kurczyński Z., 2006a**):


1. Wiązka promieni świetlnych wychodząca z jednego punktu pozostaje wiązką homocentryczną po przejściu przez obiektyw. Oznacza to, że obrazem punktu jest punkt;
2. Obraz płaszczyzny prostopadłej do osi optycznej nadal pozostaje prostopadły do tej osi;
3. Obraz przedmiotu płaskiego prostopadłego do osi optycznej jest w sensie geometrycznym podobny do tego przedmiotu.

Innym niezbędnym wyposażeniem współczesnych kamer fotogrametrycznych jest gimbal. To urządzenie elektroniczne, które umożliwia stabilizację kamery lub innego urządzenia rejestrującego obraz. Gimbal działa w oparciu o żyroskop (najczęściej trójosiowy), który kompensuje drgania i ruchy, zapewniając płynne i stabilne zdjęcia nawet podczas poruszania się kamery lub występujących wibracji (**Hansen J.G., de Figueiredo, R.P., 2024**).

Zdjęcie lotnicze wykonane przez kamerę fotogrametryczną jest rzutem środkowym fotografowanego przedmiotu. Aby można było je wykorzystać do celów pomiarowych, czyli do odtworzenia kształtów i wielkości fotografowanych przedmiotów, należy zapoznać się z teorią rzutu środkowego. Na **Rys. 1.7** przedstawiono zasady rzutu środkowego. Płaszczyzna przedmiotów (powierzchnia terenu) jest odwzorowywana na płaszczyznę zdjęcia. Punkt *O* to środek rzutów, przez który przechodzą promienie świetlne, łączące poszczególne punkty z powierzchni terenu i płaszczyzny zdjęcia. Natomiast punkt *A'* jest obrazem punktu *A*, który powstał w wyniku rzutu prostej *OA* na płaszczyznę zdjęcia. Jeżeli z punktu *O* poprowadzi się prostą prostopadłą do płaszczyzny zdjęcia, to przebija ona tę powierzchnię w punkcie *O'*. W fotogrametrii odcinek *OO'* to ogniskowa obiektywu (*f*) (**Okła K., 2010**).

Szczególnym przypadkiem rzutu środkowego jest takie odwzorowanie, w którym środek rzutów *O* znajduje się w nieskończoności. W takiej sytuacji promienie świetlne są względem siebie równoległe.

Jeżeli dodatkowo promienie świetlne są prostopadłe do płaszczyzny zdjęcia, to mamy do czynienia z rzutem równoległym prostokątnym (ortogonalnym). Przykładem rzutu ortogonalnego jest większość opracowań kartograficznych, takich jak np. mapa topograficzna, ortofotomapa (Okła K., 2010).



Rys. 1.7. Zasady rzutu środkowego i rzutu ortogonalnego (opracowanie własne na podstawie: (Okła K., 2010)).

W celu wykorzystania zdjęcia lotniczego do celów pomiarowych należy wyznaczyć położenie środka rzutów w stosunku do płaszczyzny zdjęcia i fotografowanego terenu oraz położenie płaszczyzny rzutów względem terenu. Parametry te są określane mianem elementów orientacji wewnętrznej (X_o , Y_o , f) i zewnętrznej (ω , φ , κ) zdjęcia lotniczego, dzięki którym możliwe jest odtworzenie wiązki promieni świetlnych i wyznaczenie jej położenia w przestrzeni (Okła K., 2010).

Elementy orientacji wewnętrznej służą do określenia relacji geometrycznych pomiędzy kamerą fotogrametryczną a zdjęciem. Proces ten sprowadza się do wyznaczenia współrzędnych środka rzutów $O(X_o, Y_o)$ względem płaszczyzny zdjęcia na podstawie współrzędnych tłowych punktu głównego zdjęcia (x'_o, y'_o) oraz ogniskowej obiektywu (f). Należy zauważyć, że elementy orientacji wewnętrznej są takie same dla wszystkich zdjęć w trakcie danego lotu fotogrametrycznego (Okła K., 2010).

Natomiast elementy orientacji zewnętrznej służą do określenia relacji pomiędzy lokalizacją obiektów przedstawionych na zdjęciu a ich rzeczywistym położeniem w terenie. Aby można było odtworzyć tę zależność dla każdego zdjęcia należy znać: trójwymiarowe współrzędne środka rzutów (X_o, Y_o, Z_o) oraz kąt nachylenia podłużnego (ω), kąt nachylenia poprzecznego (φ) i kąt skręcenia kamery (κ) (Okła K., 2010).

Charakterystyka danych


Na dokładność metod określania głębokości akwenów na podstawie zdjęć ma wpływ jakość opracowania fotogrametrycznego. Z kolei na jakość opracowania fotogrametrycznego (numerycznego modelu terenu lub ortofotomapy) mają parametry geometryczne zdjęć wykonanych przez UAV. Dlatego podstawą realizacji pomiarów fotogrametrycznych z wykorzystaniem bezzałogowego statku

powietrznego powinien być projekt lotu fotogrametrycznego zawierający wszystkie informacje techniczne o wykonywanym locie (**Suziedelyte Visockiene J. i in., 2016**):

1. Ustalenie rodzaju zdjęć lotniczych i sposobu ich wyzwalania. Ze względu na orientację osi kamery fotogrametrycznej można wyróżnić cztery rodzaje zdjęć: pionowe, prawie pionowe, nachylone i ukośne. Ich wybór zależy od przeznaczenia zdjęć lotniczych oraz ukształtowania terenu. Jeśli chodzi o sposób wyzwalania zdjęć, to powszechnie dzisiaj stosowanym rozwiązaniem jest wyzwalanie migawki kamery z góry zaplanowanych miejscach w przestrzeni. Tak wykonane zdjęcia lotnicze są określane mianem zdjęć celowanych. Dzięki systemowi GNSS/INS możliwe jest wyzwalanie migawki kamery tak, aby środki zdjęć w sąsiednich szeregach oraz odpowiadające im stereogramy i pasy potrójnego pokrycia korespondowały ze sobą (**Kurczyński Z., 2014**);
2. Określenie terenowego wymiaru piksela terenowego (ang. *Ground Sampling Distance – GSD*). Plan lotu fotogrametrycznego jest projektowany w głównej mierze w zależności od terenowego wymiaru piksela terenowego. Na potrzeby wysokorozdzielczych opracowań fotogrametrycznych przyjmuje się, że wielkość GSD powinna wynosić ok. 2-3 cm (**Lewicka O. i in., 2022a**);
3. Wyznaczenie wysokości lotu UAV. Typowe wysokości, na których przeprowadza się pomiary fotogrametryczne przy użyciu bezzałogowych statków powietrznych, wynoszą 70-120 m (**Specht M. i in., 2023**);
4. Wybór pokrycia podłużnego i poprzecznego zdjęć lotniczych. Na potrzeby wysokorozdzielczych opracowań fotogrametrycznych przyjmuje się, że pokrycie podłużne zdjęć powinno wynosić co najmniej 70-90%, natomiast pokrycie poprzeczne zdjęć nie może być mniejsze niż 60-80% (**Jiménez-Jiménez S.I. i in., 2021**);
5. Obliczenie minimalnej odległości między profilami lotu. Znając pokrycie podłużne zdjęć, wysokość fotografowania oraz wybrane parametry techniczne kamery (rozmiar sensora kamery i ogniskową kamery) można obliczyć minimalną odległość między profilami lotu (**Lewicka O. i in., 2022a**);
6. Ustalenie prędkości lotu UAV. Typowe prędkości, z którymi przeprowadza się pomiary fotogrametryczne przy użyciu bezzałogowych statków powietrznych, wynoszą 20-30 km/h (**Lewicka O. i in., 2022a**).

Na **Rys. 1.8** przedstawiono parametry geometryczne zespołu zdjęć wykonanych z niskiego pułapu przez UAV.

Ponadto, na podstawie analizy literatury stwierdzono, że technika Structure from Motion (SfM) stanowi jedną z kluczowych metod określania głębokości akwenów na podstawie zdjęć. Polega ona na dostarczeniu trójwymiarowych scen, wykorzystując serię czasowych obrazów RGB oraz przyporządkowanych do nich informacji georeferencyjnych. Jakość i dokładność danych uzyskanych za pomocą tej techniki zależą głównie od jakości i liczby użytych zdjęć lotniczych oraz precyzji procesu przetwarzania danych.



gdzie:

B_x – odległość między punktami w przestrzeni, z których wykonano sąsiednie zdjęcia w szeregu,

B_y – odległość między osiami sąsiednich szeregów,

l_z – długość boku zdjęcia,

L_z – terenowy zasięg zdjęcia,

P_m – powierzchnia terenu objęta jednym stereogramem (dwa zdjęcia obiektu wykonane z różnych punktów w przestrzeni),

P_n – nowa powierzchnia (przyrost terenu) pokryta przez każde kolejne zdjęcie,

W – wysokość fotografowania.

Rys. 1.8. Parametry geometryczne zespołu zdjęć wykonanych z niskiego pułapu przez UAV (opracowanie własne na podstawie: (Kurczyński Z., 2014)).

Dokładność pomiaru głębokości

Współczesne kamery fotogrametryczne pozwalają odwzorować ukształtowanie terenu z wysokimi dokładnościami wynoszącymi kilka centymetrów (La Salandra M. i in., 2021). Jednakże, aby osiągnąć założoną dokładność pomiaru należy zminimalizować błędy, które mają wpływ na dokładność opracowania fotogrametrycznego stworzonego na podstawie zdjęć lotniczych. Zgodnie z (Dai F. i in., 2014) na dokładność opracowania fotogrametrycznego mają wpływ:

1. Błędy systematyczne związane z kamerą. Są to błędy wynikające z niedoskonałości aparatu fotograficznego, które można podzielić na trzy kategorie: 1) dystorsja obiektywu, 2) przybliżona odległość główna (ang. *principal distance*) i 3) rozdzielczość. Pierwsza z nich to zakrzywienie linii prostych przez układ optyczny (dystorsja), czyli wada optyczna obiektywu, która polega na różnym powiększaniu obrazu w zależności od jego odległości od osi optycznej instrumentu. Im bliżej środka obrazu, tym wyraźniej mogą powstawać zniekształcenia obrazu, w szczególności przy brzegu pola widzenia. Druga z nich to odległość główna kamery (c), czyli odległość między punktem głównym kamery a płaszczyzną obrazu kamery, mierzona wzdłuż prostej prostopadłej do środka rzutów. W procesie rekonstrukcji wiązki promieni świetlnych często podaje się ją w przybliżeniu jako ogniskową obiektywu (f), ponieważ jest to jedna z informacji zapisana dla każdego zdjęcia w formacie EXIF (ang. *Exchangeable Image File Format*). Błędy systematyczne należące do dwóch

pierwszych kategorii można zminimalizować, dostosowując ich parametry w wyniku kalibracji kamery (**Clarke T.A. i in., 1998**). Ostatnia, trzecia kategoria to rozdzielczość ekranu, czyli parametr określający liczbę pikseli obrazu wyświetlanych na ekranie, którego obraz budowany jest z pikseli. Rozdzielczość aparatu można określić na podstawie ogniskowej kamery oraz wysokości, z której zostało wykonane zdjęcie. Im wyższa rozdzielczość ekranu, tym większa możliwość wykonania dokładnego opracowania fotogrametrycznego (**Dai F. i in., 2011**);

2. Błędy systematyczne związane z ustawieniem obrazu. Do czynników wpływających na dokładność opracowania fotogrametrycznego w ramach tej kategorii należą: wysokość fotografowania (im niższa wysokość, tym większa dokładność), odległość między punktami w przestrzeni, z których wykonano sąsiednie zdjęcia lotnicze (im mniejsza odległość, tym większa dokładność), pokrycie podłużne i poprzeczne zdjęć (im większe pokrycie, tym większa dokładność), liczba nakładających się na siebie zdjęć lotniczych (im większa liczba zdjęć, tym większa dokładność), kąt przecięcia się promieni świetlnych kamery (im bliżej 90° , tym większa dokładność) i kąt padania promieni świetlnych na powierzchnię terenu (im bliżej 0° , tym większa dokładność) (**Dai F., Lu M., 2013**).

Dokładność pomiaru głębokości na podstawie zdjęć może znacząco różnić się w zależności od zastosowanego algorytmu. Na potrzeby opracowania metody monitoringu batymetrycznego strefy brzegowej postanowiono przeanalizować powszechnie stosowane metody określania głębokości akwenów, do których można zaliczyć:

- cBathy. Algorytm ten analizuje cechy charakterystyczne fali, takie jak: amplituda, częstotliwość i kształt w długich seriach czasowych w celu wyznaczenia głębokości akwenu. Dane są mierzone za pomocą sensorów np. kamery, która rejestruje fale, a następnie określone są zależności prędkości fali od głębokości. Dokładność pomiaru głębokości dla metody cBathy jest zależna od warunków atmosferycznych, które mogą wpływać na jakość danych zarejestrowanych przez sensory (**Holman R. i in., 2013**);
- Depth Inversion. Metoda ta umożliwia wyznaczanie głębokości akwenów na podstawie propagacji fali powstałej w wyniku połączenia siły wiatru, czasu jego trwania oraz siły grawitacyjnej. Opisane cechy są wykrywane z obrazów wideo poprzez przekształcenie oryginalnych obrazów wideo w obrazy ortogonalne na podstawie fotopunktów oraz w oparciu o analizę korelacji krzyżowej intensywności sygnałów w pikselach. Algorytm Depth Inversion może być wrażliwy na zmienne warunki pogodowe, takie jak wiatr, co może wpłynąć na dokładność odczytów (**Hashimoto K. i in., 2021**);
- Metoda radiometryczna. Polega ona na wyznaczaniu głębokości akwenów płytkowodnych na podstawie koloru piksela zdjęcia lotniczego wykonanego przez kamerę fotogrametryczną. Wpływ na dokładność i zasięg działania (maksymalną głębokość) metody radiometrycznej mają cechy badanego akwenu, takie jak przezroczystość wody czy ukształtowanie dna. W przypadku, gdy jasność koloru dna jest nieznaczną w stosunku do przezroczystości wody, to głębokość akwenu nie jest możliwa do określenia. Przykładem takich akwenów są obszary charakteryzujące się wysokim wskaźnikiem zanieczyszczenia optycznego i o wysokim współczynniku zacielenia. Natomiast najkorzystniejsze warunki działania metody radiometrycznej występują na akwenach o płaskim dnie przy dużej przezroczystości wody (**Pyrchla K. i in., 2018**);
- Metoda regresji wektora nośnego (SVR). Metoda ta wykorzystuje algorytm regresji oparty na koncepcji wektorów nośnych do wyznaczania głębokości akwenów na podstawie danych wejściowych tzn. chmury punktów wygenerowanej przy użyciu techniki SfM i głębokościach

pomierzonych w wybranych miejscach odbiornikiem GNSS RTK. Stosując metodę regresji wektora nośnego można opracować model predykcyjny, który pozwoli na szacowanie głębokości w miejscach niepomierzonych na podstawie dostępnych danych wejściowych. Jednym z głównych ograniczeń metody SVR jest jej złożoność obliczeniowa i wymagana ilość pamięci, szczególnie w przypadku dużych zbiorów danych (**Agrafiotis P. i in., 2019**);

- UAV-Derived Bathymetry (UDB). Metoda ta wykorzystuje algorytmy opierające swoje działanie na obrazach wielospektralnych, które są w stanie zapewnić większą rozdzielczość spektralną niż obrazy RGB poprzez rejestrację danych obrazu w określonych zakresach długości fal widma elektromagnetycznego (**Tonion F. i in., 2020**). Niekorzystne warunki atmosferyczne mogą wpływać na jakość i dokładność zarejestrowanych danych;
- uBathy. Algorytm ten analizuje cechy charakterystyczne fali, podobnie jak w przypadku metody cBathy. Jednakże algorytm uBathy opiera się na analizie głównych składowych (ang. *Principal Component Analysis* – PCA) transformaty Hilberta w dziedzinie czasu. Proces ten wykonuje się na obrazach wideo w celu określenia częstotliwości i liczby falowej poszczególnych składników fali. Dla każdego filmu podrzędnego wykonywana jest analiza głównych składowych czasowej transformacji Hilberta intensywności klatek w skali szarości oraz pobierana jest częstotliwość kątowna fali (ω) i zmienna w przestrzeni liczba falowa (k) dla każdego z głównych trybów dekompozycji i tam, gdzie jest to możliwe. Wartości wyżej wymienionych parametrów należy uzyskać z zarejestrowanych sekwencji obrazów wideo (**Simarro G. i in., 2019**). Należy wiedzieć, że wyniki otrzymane za pomocą metody uBathy mogą być również zależne od warunków hydrometeorologicznych, takich jak: pogoda, prądy morskie, czy stan morza.

Najczęściej stosowaną miarą oceny dokładności metod używanych do określania głębokości akwenów jest pierwiastek błędu średniokwadratowego (ang. *Root Mean Square Error* – RMSE). Dla większości metod, takich jak: cBathy, Depth Inversion, radiometryczna, SVR, uBathy i UDB podano wartości RMSE głębokości. Zostały one zestawione w **Tab. 1.2**.

Na podstawie **Tab. 1.2** można stwierdzić, że wartości RMSE głębokości dla algorytmów: cBathy (0.17-0.34 m), Depth Inversion (0.33-0.52 m), radiometrycznego (0.08-0.25 m), SVR (0.11-0.50 m) i uBathy (0.38-0.73 m) są do siebie zbliżone. W przypadku zastosowania metody UDB uzyskano również wysoką dokładność pomiaru głębokości, jednakże w zakresie głębokości 0-5 m (0.24-0.37 m). Należy zaznaczyć, że algorytmy cBathy, Depth Inversion i uBathy wykorzystują zjawisko dyspersji fali wodnej, która jest modelowana na podstawie zobrażeń wideo.

Z całą pewnością wdrożenie jednego z algorytmów określania głębokości akwenów na podstawie zdjęć do metody monitoringu batymetrycznego strefy brzegowej umożliwi pozyskanie danych głębokościowych na obszarach trudnodostępnych dla innych urządzeń pomiarowych. Jest to szczególnie przydatne w przypadku akwenów o skomplikowanej strukturze dna. Należy wiedzieć, że algorytmy określania głębokości akwenów na podstawie zdjęć różnią się pod względem dokładności i mają pewne ograniczenia, które wynikają głównie z charakterystyki badanego akwenu. Ograniczenia te mogą być spowodowane m.in. jakością zdjęć lotniczych, ukształtowaniem dna, czy też warunkami oświetleniowymi.

Tab. 1.2. Zestawienie wartości RMSE głębokości dla metod: cBathy, Depth Inversion, radiometrycznej, SVR, uBathy i UDB (opracowanie własne).

Metoda określania głębokości akwenu			RMSE (m)
cBathy			0.17-0.34
Depth Inversion			0.33-0.52
Radiometryczna	Zakres głębokości: 0-1.5 m		0.08-0.25
SVR	Zakres głębokości: 0.1-5.57 m		0.11-0.19
	Zakres głębokości: 0.2-14.8 m		0.45-0.50
uBathy	Video 1	$t_f=0$ s	-
		$t_f=5$ s	0.42-0.73
		$t_f=10$ s	0.47-0.59
	Video 2	$t_f=0$ s	0.38-0.44
		$t_f=5$ s	0.38-0.46
		$t_f=10$ s	0.39-0.43
UDB	Zakres głębokości: 0-5 m	Lyzena	0.24
		Stumpf'a	0.37
	Zakres głębokości: 0-11 m	Lyzena	0.89
		Stumpf'a	1.06

1.2.2. LiDAR

Definicja i zastosowanie

Skaner laserowy 3D to urządzenie optoelektroniczne wykorzystujące technologię LiDAR, która umożliwia precyzyjny pomiar odległości oraz tworzenie trójwymiarowych map otoczenia. Pomiar przy użyciu skaningu laserowego polega na wysyłaniu wiązki światła o określonej długości fali i rejestracji sygnału powracającego w przypadku napotkania przez wiązkę na reflektor (obiekt odbijający światło). Na podstawie zmierzonego czasu i znajomości orientacji przestrzennej urządzenia oraz kąta, pod którym została wysłana wiązka światła możliwe jest wyznaczenie położenia reflektora. Wykorzystując te dane skaner laserowy 3D jest w stanie zrekonstruować otoczenie w postaci chmury punktów, co pozwala na dokładne określenie kształtów i odległości obiektów (Royo S., Ballesta-Garcia M., 2019).

Istnieje kilka rodzajów systemów LiDAR, z których każdy ma swoje odrębne zastosowanie i charakterystyki. Do najważniejszych z nich należą:

- Batymetryczny skaning laserowy (ang. *Airborne Laser Bathymetry – ALB*). LiDAR batymetryczny jest montowany na statkach powietrznych. Wykorzystuje on krótkie impulsy laserowe o długości fali z zakresu niebiesko-zielonego do wykonywania pomiarów głębokości akwenów. Batymetryczny skaning laserowy jest przeznaczony do pomiarów hydrograficznych, w szczególności do wyznaczania przebiegu linii brzegowej i ukształtowania dna (Su D. i in., 2020);
- Kosmiczny skaning laserowy. LiDAR kosmiczny jest umieszczany na satelitach i wykorzystywany do badania atmosfery, monitoringu zmian klimatycznych, topografii powierzchni Ziemi itp. (Wu J. i in., 2023);

- Lotniczy skanowanie laserowe (ang. *Airborne Laser Scanning* – ALS). LiDAR lotniczy jest montowany na statkach powietrznych i wykorzystywany do rejestracji danych z powietrza. Jest on powszechnie stosowany w badaniach geologicznych, kartografii, monitoringu środowiska, planowaniu terenów itd. (**Dong W. i in., 2017**);
- Mobilny skanowanie laserowe (ang. *Mobile Laser Scanning* – MLS). LiDAR mobilny jest montowany na poruszających się obiektach, takich jak: jednostki pływające, pociągi czy samochody. Mobilny skanowanie laserowe pozwala na skanowanie dużych obszarów w ruchu, przez co znalazł on zastosowanie w kartografii, systemach bezpieczeństwa drogowego, tworzeniu map 3D miast itd. (**Wang C. i in., 2020**);
- Nasiemny skanowanie laserowe (ang. *Terrestrial Laser Scanning* – TLS). LiDAR nasiemny jest ustawiany na stabilnej podstawie np. na statywie geodezyjnym. Ten rodzaj skanowania laserowego jest wykorzystywany przede wszystkim w architekturze, budownictwie, geodezji, inżynierii i zarządzaniu zasobami naturalnymi (**Morsy S., Shaker A., 2022**);
- Podwodny skanowanie laserowe. LiDAR podwodny jest używany do badania dna morskiego, raf koralowych, mapowania cech geologicznych pod wodą i innych zastosowań morskich (**Chen Y. i in., 2023**).

Pośród przedstawionych wyżej urządzeń, zarówno LiDAR batymetryczny, jak i lotniczy mogą być używane do ekstrakcji linii brzegowej. Batymetryczny skanowanie laserowe został specjalnie zaprojektowany do pomiaru głębokości akwenów z dużą dokładnością, co pozwala na precyzyjne określenie przebiegu linii brzegowej. Natomiast lotniczy skanowanie laserowe może być wykorzystywany do pomiaru ukształtowania terenu części lądowej strefy brzegowej, co umożliwia przeprowadzenie ekstrakcji linii brzegowej. Jednakże należy mieć na uwadze, że koszt zakupu LiDAR-u batymetrycznego jest bardzo wysoki, dlatego rozwijane są metody wyznaczania przebiegu linii brzegowej na podstawie danych LiDAR z ALS.

Budowa i zasada działania

Idea skanowania laserowego sprowadza się do zasady laserowego pomiaru odległości z lecącego statku powietrznego do punktów znajdujących się na powierzchni terenu. Jeżeli gęstość terenowa punktów pomiarowych jest wystarczająca duża (co najmniej kilka punktów na 1 m²), to w efekcie uzyskuje się quasi-ciągłą, przestrzenną reprezentację powierzchni terenu (**Hirata Y., 2004**).

Jak już wcześniej wspomniano, LiDAR lotniczy jest często wykorzystywany do ekstrakcji linii brzegowej ze względu na koszty, które są znacznie niższe niż w przypadku LiDAR-u batymetrycznego. Dlatego w dalszej części rozprawy doktorskiej uwaga zostanie skupiona tylko na lotniczym skanowaniu laserowym. System ALS składa się z trzech podstawowych elementów. Pierwszym z nich jest dalmierz laserowy (ang. *Laser Range Finder* – LRF), który wykorzystuje zakres podczerwieni (ok. 1550 nm) lub rzadziej zakres widzialny. Dalmierz działa impulsowo z częstotliwością od kilkudziesięciu do kilkuset kHz, co pozwala na pomiar odległości od kilkudziesięciu tysięcy do kilkuset tysięcy punktów na sekundę. Na początku promień lasera przechodzi przez optyczny układ skanujący, a następnie jest kierowany prostopadle do kierunku lotu. Dalmierz laserowy rejestruje kąt odchylenia tego promienia od linii pionu. W wyniku ruchu statku powietrznego uzyskuje się w jednym przelocie obraz prostokątnego pasa terenu. Po dotarciu do powierzchni terenu impuls laserowy jest następnie przez nią rozpraszany. Tylko część energii odbija się w stronę statku powietrznego i może zostać zarejestrowana przez optyczny układ odbiorczy, który na jej podstawie określa odległość do reflektora

(Rys. 1.9) (Kurczyński Z., 2006b). LiDAR oblicza odległość między dalmierzem laserowym a obiektem na podstawie pomiaru czasu powrotu odbitego sygnału przy użyciu wzoru (Rohrbach F., 2024):

$$d_l = \frac{c_p \cdot t_p}{2} \quad (1.13)$$


gdzie:

d_l – odległość między dalmierzem laserowym a obiektem, od którego odbił się impuls laserowy,

c_p – prędkość rozchodzenia się dźwięku w powietrzu,

t_p – czas jaki upłynął od momentu wygenerowania do momentu otrzymania impulsu laserowego.

Z dalmierzem laserowym jednocześnie współpracuje system GNSS określający miejsce wysłania impulsu oraz system INS określający przechyły kątowe platformy, na której zamontowano optyczną głowicę skanującą. Dzięki integracji danych zarejestrowanych przez dalmierz laserowy i system GNSS/INS uzyskuje się położenie, z którego wykonano pomiar odległości, samą odległość i jej kierunek w przestrzeni. Pozwala to określić trójwymiarowe współrzędne geodezyjne punktu terenowego, w który w danym momencie był wycelowany laser (Wehr A., Lohr U., 1999).



Rys. 1.9. Idea działania ALS w strefie brzegowej (opracowanie własne na podstawie (Wikimedia Commons, 2024)).

Charakterystyka danych

Dane LiDAR pozyskane przy użyciu lotniczego skaningu laserowego pozwalają na pełne pokrycie terenu pomiarami (Stockdon H.F. i in, 2002). Parametrami, które definiują rozdzielczość przestrzenną pozyskanych danych, są odstęp między punktami i gęstość punktów. Odstępy między punktami to liniowe odstęp punktów w zbiorze danych. Natomiast gęstość punktów to liczba punktów terenowych przypadająca na danym obszarze. Gęstość punktów można oszacować na podstawie rozstawu punktów za pomocą następującego równania (Humboldt State University, 2024):

$$\rho = \frac{1}{d_p^2} \quad (1.14)$$

gdzie:

ρ – gęstość punktów,

d_p – odstęp między punktami.

Zarówno odstęp między punktami, jak i gęstość punktów są podawane jako wartości średnie dla całego zbioru danych. Gęstość terenowa punktów pomiarowych zależy w głównej mierze od zastosowanego skanera laserowego 3D oraz prędkości i wysokości lotu. Wyższe częstotliwości pracy dalmierza laserowego pozwalają na pozyskiwanie większej liczby punktów terenowych na jednostkę powierzchni. Systemy LiDAR zazwyczaj generują od 10 000 do 500 000 impulsów na sekundę (Jo H.C. i in., 2020). Od każdego wygenerowanego impulsu przez skaner laserowy 3D może wrócić od 1 do 5 ech sygnału odbitego. Wpływ na pokrycie terenu pomiarami ma również kąt widzenia (ang. *Field Of View* – FOV), czyli obszar, który jest widoczny przez LiDAR w jednym pomiarze. Im szerszy kąt widzenia, tym większy jest w jednym przelocie obszar przeszukiwania przez skaner laserowy 3D (Humboldt State University, 2024).

Unikalną cechą lotniczego skaningu laserowego jest możliwość przenikania przez warstwę roślinności. Przy dużej gęstości próbkowania jest stosunkowo łatwo odróżnić i wyeliminować odbicia od koron drzew od odbić od gruntu (Kurczyński Z., 2006b). Wykorzystanie LiDAR-u batymetrycznego pozwala również na pokrycie dna akwenów pomiarami. Jednakże należy pamiętać, że dokładność pomiaru głębokości przy użyciu batymetrycznego skaningu laserowego jest w dużym stopniu zależna od współczynnika przejrzystości wody (Kasvi A. i in., 2019). Poza tym, LiDAR batymetryczny ma ograniczony zasięg działania, pozwalający realizować pomiary hydrograficzne do głębokości maksymalnej, która jest uzależniona od współczynnika dyfuzyjnego osłabienia oświetlenia odgórnego $K_d(\lambda)$ (Ficek D., 2013). Błąd pomiaru głębokości z wykorzystaniem batymetrycznego skaningu laserowego może wynosić od kilkunastu centymetrów do niespełna 0.5 m ($p=0.95$) przy zachowaniu odpowiedniej przejrzystości wody (Li S. i in., 2022).

Na etapie przetwarzania danych pomiarowych należy pamiętać o usunięciu bardzo wielu błędnie zarejestrowanych punktów tzw. szumów. Promień laserowy może odbić się wielokrotnie od różnych obiektów lub powierzchni, co w rezultacie powoduje zarejestrowanie fałszywych danych lub dodatkowych odbić. Co więcej, często występuje przygotowanie danych pod dane zastosowanie. W tym celu stosuje się metody komputerowe, które w sposób automatyczny odfiltrowują nieprzydatne punkty. Przykładowo, jeżeli celem jest wygenerowanie Numerycznego Modelu Terenu (NMT), to usunięciu podlegają wszystkie punkty laserowe znajdujące się na budynkach, drzewach i innych „wystających” obiektach ponad powierzchnię terenu (Kurczyński Z., 2006).

Dokładność pomiaru

Wyznaczanie przebiegu linii brzegowej przy użyciu lotniczego skaningu laserowego jest wspierane przez różne metody ekstrakcji linii brzegowej. Poniżej przedstawiono niektóre z nich:

- Metoda autorstwa Lee i in. opiera swoje działanie na średnim przesunięciu segmentu (ang. *mean-shift segmentation*) oraz integracji danych LiDAR, ortofotomap i obrazowań satelitarnych. W pierwszej kolejności metoda ta przyporządkowuje punkty LiDAR do jednej z dwóch klas: lądu lub wody. Do segmentacji chmury punktów LiDAR wykorzystuje się trzy filtry: intensywności odbicia promienia laserowego od powierzchni wody w bliskiej podczerwieni (ang. *Near-InfraRed* – N-IR), wysokości i koloru RGB (Lee I.-C. i in., 2010);

- Metoda autorstwa Liu i in. to automatyczna metoda ekstrakcji linii brzegowej oparta na segmentacji obrazu, która jest przeprowadzana na podstawie danych zarejestrowanych przy użyciu LiDAR-u lotniczego. Na początku metoda ta przekształca cyfrowy model wysokościowy (ang. *Digital Elevation Model* – DEM) wygenerowany w oparciu o dane ALS na obraz binarny. Podczas przetwarzania obrazu na binarny wykorzystuje się następujące algorytmy: grupowania i etykietowania obszarów, określania krawędzi podzielonych obszarów, operacji morfologicznej, śledzenia linii oraz wektoryzacji. Następnie przeprowadza się segmentację obrazu na piksele lądowe i wodne na podstawie DEM oraz ustalonego pływowego układu odniesienia (ang. *tidal datum*) (Liu H. i in., 2007);
- Metoda autorstwa Xu i in. to parametryczna metoda ekstrakcji linii brzegowej na podstawie chmur punktów LiDAR. Pierwsza część algorytmu polega na wykryciu oraz odrzuceniu punktów należących do powierzchni wody. W tym celu wykorzystuje się euklidesową ekstrakcję klastrów, dopasowanie płaszczyzny metodą RANSAC (ang. *RANdom SAmple Consensus*) oraz cechy gęstościowo-odległościowe indywidualnych punktów. Druga część algorytmu polega na wskazaniu potencjalnych punktów granicznych oraz optymalizacji granicy z nich utworzonych. W tym celu autorzy zaproponowali model optymalizacji funkcji kosztu (Xu S. i in., 2019).

Należy mieć na uwadze, że porównanie punktów wygenerowanych przy użyciu wyżej wymienionych metod ekstrakcji linii brzegowej jest niemożliwe (Stateczny A. i in., 2023). Trzeba również pamiętać o tym, że uzyskane dokładności wyznaczenia przebiegu linii brzegowej zostały osiągnięte na różnych zbiorach danych (Tab. 1.3).

Tab. 1.3. Zestawienie osiągniętych poziomów dokładności i liczby wykorzystanych zbiorów danych dla wybranych metod ekstrakcji linii brzegowej na podstawie danych LiDAR z ALS (Stateczny A. i in., 2023).

Autorzy metody ekstrakcji linii brzegowej	Poziom dokładności (m)	Liczba zbiorów danych
Lee i in., 2010	1.5	4
Liu i in., 2007	4.5	1
Xu i in., 2019	1.0	5

Na podstawie Tab. 1.3 można wywnioskować, że przedstawione metody ekstrakcji linii brzegowej spełniają minimalne wymagania dokładnościowe dla pomiarów hydrograficznych, które są realizowane w ramach kategorii szczególnej IHO (błąd pozycji horyzontalnej 5 m ($p=0.95$)) (International Hydrographic Organization, 2022). Warto zaznaczyć, że omawiane metody były testowane na różnej liczbie zbiorów danych. Co więcej, rodzaj akwenu może znacząco wpływać na dokładność danej metody ekstrakcji linii brzegowej.

Jednakże dokładność danych LiDAR ma znaczący wpływ na zastosowanie metod ekstrakcji linii brzegowej. Dokładne dane pozyskane ze skaningu laserowego pozwalają w sposób precyzyjny określić granicę pomiędzy lądem a wodą. Ponadto dane LiDAR zawierające szumy mogą prowadzić do błędów, a w rezultacie wprowadzać nieprawidłowości w analizach. W związku z tym, postanowiono przedstawić czynniki mające wpływ na dokładność pomiaru trójwymiarowych współrzędnych punktów terenowych przy użyciu skanera laserowego 3D (Ren H.C. i in., 2016):

1. Niepewność pomiaru odległości. Błąd ten zależy przede wszystkim od relacji geometrycznych między trzema urządzeniami pomiarowymi: dalmierzem laserowym oraz systemami GNSS i INS. Błąd pomiaru odległości lasera mieści się w przedziale od 2 cm do 4 cm. Po przeprowadzeniu

odpowiedniej kalibracji systemu LiDAR można osiągnąć centymetrową dokładność pomiaru odległości;

2. Niepewność pomiaru kąta kierunkowego wiązki. Błąd ten zależy od wysokości lotu oraz precyzji określenia relacji geometrycznych między systemami GNSS i INS. Należy zauważyć, że niepewność pomiaru kąta kierunkowego wiązki rośnie wraz z wysokością lotu;
3. Niepewność pomiaru kątów orientacji przestrzennej. Błąd ten jest związany z metodą pomiaru przechyłów statku powietrznego, jak i z niedokładnościami instalacji samej jednostki IMU (ang. *Inertial Measurement Unit*) oraz błędnego pomiaru jej orientacji kątowej w statkowym układzie współrzędnych;
4. Niepewność pomiaru współrzędnych pozycji. Na dokładność pomiaru trójwymiarowych współrzędnych punktu terenowego przy użyciu systemu GNSS mają wpływ: błąd orbity satelity, błąd zegara satelity, błąd zegara odbiornika, wielodrogowość sygnału satelitarnego, niestabilność centrum fazowego, geometria konstelacji satelitów, nieoznaczoność pomiaru fazowego itd. Dzięki różnicowym metodom pomiarów GNSS można wyznaczyć trójwymiarowe współrzędne punktu terenowego z dokładnościami centymetrowymi;
5. Błąd synchronizacji czasu. Dalmierz laserowy oraz systemy GNSS i INS rejestrują czas niezależnie od siebie. Aby uzyskać dokładne trójwymiarowe współrzędne punktu terenowego należy sprowadzić czasy tych urządzeń do jednolitego systemu czasu, takiego jak UTC (ang. *Universal Time Coordinated*), czy GPS (ang. *Global Positioning System*);
6. Błąd interpolacji danych. Wynika on z różnych częstotliwości próbkowania danych przez składowe urządzenia systemu LiDAR. Przykładowo, częstotliwość pracy dalmierzy laserowych może wynosić maksymalnie kilkaset kHz. Natomiast systemy GNSS i INS cechują się zdecydowanie mniejszą maksymalną częstotliwością rejestracji danych wynoszącą odpowiednio kilkadziesiąt i kilkaset Hz. Dlatego, aby uzyskać dokładne trójwymiarowe współrzędne punktu terenowego konieczna jest integracja danych zarejestrowanych przez wyżej wymienione urządzenia do jednej epoki pomiarowej. Błąd interpolacji danych mieści się w przedziale od 3 cm do 5 cm.

Sumując wyżej wymienione niepewności pomiaru i błędy, skanowanie laserowe dostarcza danych o dokładności wysokościowej do 0.1 m (Elaksher A. i in., 2023). Dokładność wyznaczenia trójwymiarowych współrzędnych pozycji punktu terenowego jest nieco gorsza i wynosi 0.15-0.25 m (Contreras M.A. i in., 2017).

W celu wyznaczenia przebiegu linii brzegowej stosuje się LiDAR batymetryczny lub LiDAR lotniczy. Ze względu na koszty i fakt, że dokładność pomiaru głębokości przy użyciu batymetrycznego skaningu laserowego jest w dużym stopniu zależna od współczynnika przejrzystości wody coraz częściej stosuje się lotniczy skanowanie laserowe. Dane pochodzące z LiDAR-u lotniczego wspierane metodami ekstrakcji linii brzegowej stanowią alternatywę dla danych pozyskanych przy użyciu LiDAR-u batymetrycznego.


1.3. Przegląd i analiza istniejących metod modelowania powierzchni terenu w strefie brzegowej

Zastosowanie metod modelowania powierzchni terenu w strefie brzegowej umożliwia poznawanie procesów i zjawisk zachodzących w wodzie oraz wzdłuż linii brzegowej. Jednakże stanowi to również problem badawczy, który polega na wyborze najdokładniejszej metody modelowania powierzchni

terenu dla danego zestawu danych. W tym podrozdziale opisano istniejące metody modelowania powierzchni terenu w strefie brzegowej.

1.3.1. Modelowanie powierzchni terenu

Modelowanie powierzchni terenu polega na zbudowaniu regularnej siatki punktów węzłowych z nieregularnej siatki punktów pomiarowych. Na podstawie tej siatki tworzony jest NMT. Wysokości punktów znajdujących się między węzłami wyznacza się w drodze interpolacji. Tak powstały numeryczny model terenu pozwala określić wysokość w każdym punkcie jego powierzchni. NMT to numeryczna reprezentacja powierzchni terenowej, która została utworzona na podstawie zbioru odpowiednio wybranych punktów tej powierzchni oraz zastosowania algorytmów interpolacyjnych umożliwiających odtworzenie ukształtowania terenu. Proces tworzenia numerycznego modelu terenu jest procesem złożonym i wieloetapowym (**Rys. 1.10**) (**Lewicka O., 2023a**).



Rys. 1.10. Schemat przedstawiający etapy tworzenia NMT (opracowanie własne na podstawie: (**Lewicka O., 2023a**)).

Utworzenie NMT wymaga uprzednio zgromadzenia danych pomiarowych. Do najczęściej stosowanych metod rejestracji danych geoprzestrzennych należą:

- Bezpośrednie pomiary terenowe – polegają na geodezyjnym pomiarze położenia lub wysokości obiektów bezpośrednio w terenie. Obecnie najczęściej do pomiaru bezpośredniego wykorzystywane są odbiorniki GNSS i tachimetry elektroniczne. Dane pozyskane metodą bezpośrednią charakteryzują się wysoką dokładnością pomiaru. Jednakże bezpośrednie pomiary terenowe są czasochłonne, co sprawia, że dostarczają małą ilość danych (**Specht C. i in. 2017**);
- Pomiary batymetryczne – polegają na pozyskaniu odpowiednio przetworzonej informacji o rozkładzie głębokości na danym akwenie. Pomiary batymetryczne są zazwyczaj wykonywane za pomocą echosondy jednowiązkowej lub wielowiązkowej (**Nikolakopoulos K.G. i in., 2018**);
- Pomiary fotogrametryczne – metoda pomiaru polegająca na odtworzeniu za pomocą kamery przebiegu promienia biegnącego od obiektywu kamery do szukanego punktu. Pomiary dostarczają informacji o kształcie obiektu i jego położeniu względem innych obiektów w przestrzeni. Do wykonywania zdjęć fotogrametrycznych coraz częściej wykorzystywane są UAV wyposażone w kamery. Ponadto dane fotogrametryczne mogą pochodzić ze zdjęć lotniczych lub satelitarnych (**Burdziakowski P., Bobkowska K., 2021**);
- Pomiary skanowaniem laserowym – pomiar, w który system mierzy kąt między urządzeniem a mierzoną powierzchnią i odległość. Skanowanie laserowe 3D może być realizowane przy użyciu lotniczego, mobilnego lub naziemnego skanera laserowego. Dane pozyskane ze skaningu laserowego charakteryzują się dużą gęstością chmury punktów i wysoką dokładnością pomiaru (**Saylam K. i in, 2017**);
- Wektoryzacja map – polega na rejestracji punktów z mapy analogowej i ich zapisaniu w formie wektorowej. Wektoryzację mapy można przeprowadzić za pomocą oprogramowania GIS (ang. *Geographic Information System*) typu ArcGIS, GeoMedia lub QGIS. Dane pozyskane tą metodą obciążone są błędami związanymi z transformacją współrzędnych (**Wang C. i in., 2022**).

Kolejny etap przy tworzeniu NMT polega na określeniu zakresu danych. Istotnym aspektem przy przygotowywaniu danych jest ich gęstość i rozmieszczenie. W związku z tym należy się spodziewać, że dane rozmieszczone nierównomiernie w wyniku interpolacji utworzą numeryczny model terenu, który nie będzie wiernie odwzorowywał powierzchni terenu (**Lewicka O., 2023a**).

Następnie ustalany jest sposób reprezentacji NMT, czyli struktura modelu. Wyróżnia się następujące sposoby reprezentacji numerycznego modelu terenu (**van Kreveld M., 1997**):

- Nieregularna siatka trójkątów (ang. *Triangulated Irregular Network* – TIN) – forma reprezentacji NMT w postaci nieregularnej siatki trójkątów. Strukturę siatki TIN tworzą przylegające do siebie trójkąty, których wierzchołki znajdują się w punktach pomiarowych. Punkty te powinny być rozmieszczone stosunkowo równomiernie, wówczas powstanie siatka składająca się z trójkątów o zbliżonych kształtach. W przypadku nierównomiernego pokrycia terenu punktami pomiarowymi, powstaną wydłużone trójkąty nieposiadające regularnych kształtów;
- Regularna siatka kwadratów (GRID) – forma reprezentacji NMT w postaci siatki kwadratów pokrywającej równomiernie badany obszar. Modele GRID powstają w wyniku szacowania nieznanego wartości znajdującej się między znanymi wartościami przy użyciu wybranych algorytmów interpolacyjnych. Wówczas powstają węzły siatki GRID, które tworzą strukturę regularnych prostokątów (zazwyczaj kwadratów) o ustalonej rozdzielczości.

Po wyborze struktury NMT należy wybrać metodę interpolacji danych. Jest to najważniejszy etap przy tworzeniu numerycznego modelu terenu. Wśród metod interpolacji można wyróżnić dwie główne grupy modeli przestrzennych (**Lewicka O., 2023a**):


- Modele deterministyczne – wartości są ustalane w oparciu o funkcję odległości lub powierzchni. Do modeli deterministycznych należą m.in. metoda średniej ważonej odległości (**Lu G.Y., Wong D.W., 2008**), funkcje sklepane i funkcje wielomianowe;
- Modele statystyczne – wartości są określane na podstawie teorii prawdopodobieństwa. Do modeli statystycznych należą m.in. kriging (**Fanchi J.R., 2018**) i modele regresyjne.

Ostatni etap prac to wizualizacja NMT. Dodatkowo zaleca się przeprowadzanie oceny dokładności wygenerowanego numerycznego modelu terenu stosując typowe miary dokładności: RMSE (**Pham H., 2019**), średni błąd bezwzględny (ang. *Mean Absolute Error* – MAE) (**Willmott C.J., Matsuura K., 2005**), czy współczynnik determinacji (R^2) (**Genchi S.A. i in., 2020**).

1.3.2. Budowa siatki TIN

Jedną z najczęściej stosowanych form reprezentacji numerycznego modelu terenu jest nieregularna siatka trójkątów (**Stateczny A., 2004**). Siatka TIN pozwala na precyzyjne odwzorowanie zróżnicowanego ukształtowania terenu, mimo pewnych nieregularności jego kształtu.

W celu automatyzacji procesu tworzenia siatki trójkątów opracowano różnego rodzaju algorytmy triangulacji. Najczęściej stosowanym z nich jest algorytm triangulacji Delone (Delaunaya), w którym wykorzystuje się diagramy Woronoja (poligony Thiessena) (**Rys. 1.11**) (**Delaunay B., 1934**). Triangulacja Delaunaya to taka triangulacja zbioru punktów P na płaszczyźnie, że żaden punkt ze zbioru P nie znajduje się wewnątrz okręgu opisanego na trójkącie należącym do triangulacji (**Stateczny A., 2001**).



Rys. 1.11. Proces tworzenia diagramu Woronoja (opracowanie własne na podstawie: **(Angelucci G., Mollaioli F., 2018)**).


Po przeprowadzeniu triangulacji można dokonać interpolacji wysokości dowolnego punktu P powierzchni terenowej, którego rzutem na płaszczyznę poziomą jest punkt P' leżący w trójkącie $A'B'C'$ (**Rys. 1.12**). Aproksymując powierzchnię terenową w trójkącie $A'B'C'$ płaszczyznę przechodzącą przez punkty A, B, C , otrzymuje się wzór na wysokość punktu P postaci (**Stateczny A., 2001**):

$$h_p = \frac{h_A \cdot S_{A'} + h_B \cdot S_{B'} + h_C \cdot S_{C'}}{S_{A'} + S_{B'} + S_{C'}} \quad (1.15)$$

gdzie:

h_A, h_B, h_C – wysokości punktów A, B, C powierzchni terenowej, których rzutem na płaszczyznę poziomą są punkty A', B', C' ,

$S_{A'}, S_{B'}, S_{C'}$ – pola powierzchni przeciwległych trójkątów, powstających przez podział trójkąta $A'B'C'$ odcinkami łączącymi wierzchołki tego trójkąta z punktem P' .




Rys. 1.12. Rzut punktu P powierzchni terenowej na płaszczyznę poziomą (opracowanie własne na podstawie: **(Coxeter H.S.M., 1989)**).

Jednym z najbardziej efektywnych algorytmów do tworzenia wieloboków Woronoja jest metoda oparta na technice zmiatania (ang. *sweep line algorithm*) (**Fortune S., 1986**). Technika zmiatania polega na przesuwaniu prostej (pionowej lub poziomej) przez płaszczyznę, zwykle z lewej strony do prawej lub z góry na dół. Po stronie już „przetworzonej” przez prostą znajdują się obliczone krawędzie diagramu Woronoja, a w miarę przesuwania linii liczba krawędzi rośnie. Aby oddzielić część diagramu, która nie zależy od punktów leżących za prostą zmiatającą, budowana jest krzywa B (ang. *beach line*) składająca się z fragmentów parabol. Krzywa ta określa obszary znajdujące się bliżej punktów niż

prostej zmiatającej. Diagram Woronoja powstaje w wyniku dynamicznego dodawania nowych krawędzi, a jego struktura zmienia się w wyniku tzw. zdarzeń, czyli kluczowych momentów w algorytmie.

Wyróżnia się dwa rodzaje zdarzeń: pojawienie się nowej paraboli i zanikanie łuku paraboli. Nowa parabola powstaje, gdy prosta zmiatająca napotka nowy punkt pomiarowy. Dla tego punktu tworzona jest parabola, która początkowo stykając się z innymi krawędziami tworzy linię, a następnie poszerza się wraz z przesuwaniem prostej zmiatającej. Nowa parabola staje się częścią krzywej B, będącej zbiorem fragmentów parabol, które określają obszary bliższe punktom niż samej prostej. Proces pojawienia się paraboli inicjuje tworzenie nowych krawędzi diagramu Woronoja, które wyznaczają punkty przecięcia fragmentów parabol (**Rys. 1.13a**). Zanikanie łuku paraboli następuje w momencie, gdy prosta zmiatająca styka się z okręgiem opisanym na trójkącie utworzonym w wyniku triangulacji Delaunaya. W takim przypadku fragment krzywej B zanika, a punkt, w którym to następuje, staje się nowym wierzchołkiem diagramu Woronoja (**Rys. 1.13b**). Dzięki tym zdarzeniom struktura diagramu jest dynamicznie modyfikowana i ostatecznie formuje kompletny diagram Woronoja.



Rys. 1.13. Rodzaje zdarzeń przy konstruowaniu siatki TIN na podstawie techniki zmiatania: pojawienie się nowej paraboli podczas przecięcia prostej zmiatającej z punktem pomiarowym (a) i zanikanie łuku paraboli w momencie styczności prostej zmiatającej z okręgiem opisanym na trójkącie (b) (opracowanie własne).

Podsumowując, do zalet stosowania nieregularnej siatki trójkątów można zaliczyć (**Wilson J.P., 2022**):

- Elastyczność w dostosowaniu rozdzielczości siatki. Model TIN pozwala zoptymalizować rozdzielczość siatki poprzez zwiększenie liczby trójkątów na obszarach o zróżnicowanej rzeźbie terenu;
- Łatwość w reprezentacji nieregularnych struktur. Model TIN dokładniej odwzorowuje krzywizny i niestandardowe kształty, takie jak głęboko wcięte rowy wodne, klify czy uskoki niż modele o regularnej siatce.

Natomiast do wad stosowania nieregularnej siatki trójkątów należy zaliczyć (**Wilson J.P., 2022**):


- Nieregularność rozkładu danych. Odległość między węzłami w siatce TIN nie jest stała, przez co dane nie są rozmieszczone równomiernie;
- Trudność analizy danych. Siatka TIN utrudnia analizę danych i wyciąganie na jej podstawie wniosków, ponieważ dane nie są uporządkowane i trudno je porównać;
- Trudność w implementacji. Implementacja modelu TIN może być problematyczna, ponieważ wymaga ona zastosowania bardziej złożonych algorytmów niż w przypadku modeli o regularnej siatce;

- Trudność w interpolacji. Interpolacja nieregularnych danych może być trudniejsza niż danych o regularnej strukturze, co może prowadzić do mniej dokładnych lub mniej wiarygodnych wyników.

Zastosowanie siatki TIN pozwala na interpolację danych głębokościowych w miejscach, gdzie nie zostały wykonane pomiary bezpośrednie. Co więcej, nieregularna siatka trójkątów sprawdzi się doskonale na obszarach o nierównym ukształtowaniu terenu lub nagłych zmianach głębokości.

1.3.3. Budowa siatki GRID

Innym powszechnym sposobem reprezentacji numerycznego modelu terenu jest regularna siatka kwadratów (GRID), która pokrywa równomiernie badany obszar. Ważnym elementem umożliwiającym interpolację NMT przy użyciu modelu GRID jest ustalenie odległości między węzłami, które tworzą siatkę kwadratów (L_{GRID}). W zależności od ukształtowania terenu należy dobrać odległość L_{GRID} w taki sposób, aby regularna siatka kwadratów w możliwie dokładny sposób odwzorowywała ukształtowanie terenu. Na **Rys. 1.14** przedstawiono konstrukcję węzłów siatki GRID.



Rys. 1.14. Konstrukcja węzłów siatki GRID (opracowanie własne na podstawie: (Stateczny A., 2004)).

Przy dużym zagęszczeniu punktów pomiarowych można przyjąć, że wysokości w poszczególnych węzłach będą odpowiadały wysokościami najbliższych do nich punktów. Takie rozwiązanie może prowadzić do nieciągłości powierzchni terenu w miejscach pozbawionych punktów pomiarowych.

Siatka GRID nie jest bezpośrednio oparta na punktach pomiarowych. Dlatego wysokości w poszczególnych węzłach siatki są wyznaczone przy użyciu algorytmów interpolacyjnych. Do najczęściej stosowanych algorytmów interpolacyjnych wykorzystujących NMT w postaci regularnej siatki kwadratów należą:

- Interpolacja funkcjami sklejanymi. Polega ona na znalezieniu funkcji, która jest ciągła, a jednocześnie przechodzi przez punkty danych w sposób jak najbardziej zbliżony do rzeczywistych wartości (Press W.H. i in., 1988);
- Interpolacja metodą najbliższego sąsiada. Polega ona na przypisaniu nowym punktom danych wartości najbliższego punktu danych znanego zbioru;
- Interpolacja metodą naturalnego sąsiada. Polega ona na estymacji wartości w nieznanym punkcie na podstawie wartości sąsiadujących punktów pomiarowych, przy uwzględnieniu obszarów wpływu wyznaczonych przez diagramy Woronoja (Sibson R., 1981);

- Interpolacja metodą odwrotnych ważonych odległości. Polega ona oszacowaniu wartości interpolowanej jako średniej ważonej z wartości znajdujących się w określonej odległości od punktu interpolowanego (**Lu. G.Y., Wong D.W., 2008**).

Jednakże najczęściej stosowanym algorytmem interpolacyjnym wykorzystującym NMT w postaci regularnej siatki kwadratów o wysokiej dokładności jest kriging (**Fanchi J.R., 2018**):

$$z_{kr} = \sum_{i=1}^n w_i \cdot z_i \quad (1.16)$$

gdzie:

z_{kr} – wysokość punktu interpolowanego metodą krigingu,

n – liczba punktów interpolowanych,

w_i – waga dla i -tego punktu,

z_i – wysokość i -tego punktu.

Metoda krigingu składa się z dwóch etapów. Pierwszy etap polega na określeniu zależności przestrzennej między danymi. Do opisu zmienności przestrzennej danych w metodzie krigingu wykorzystuje się najczęściej połowę wartości wariogramu tzw. semiwariogram, który jest wykresem przedstawiającym wartości semiwariancji w funkcji odległości. W związku z tym, przed zbudowaniem semiwariogramu należy obliczyć semiwariancję dla punktów interpolowanych.

Semiwariancja to miara umożliwiająca określenie autokorelacji przestrzennej występujących w danym zbiorze, czyli zależności pomiędzy wartościami jednej cechy zmieniającej się wraz z odległością. Jest to połowa średniej kwadratu różnicy pomiędzy wartościami badanej zmiennej w dwóch lokalizacjach odległych o wektor h (**Mert B.A., Dag A., 2017**):

$$\gamma^*(h) = \frac{1}{2 \cdot N(h)} \cdot \sum_{i=1}^{N(h)} [z(c_i) - z(c_i + h)]^2 \quad (1.17)$$

gdzie:


h – odległość euklidesowa między dwoma punktami interpolowanymi,

$\gamma^*(h)$ – semiwariancja dla odległości h ,

$N(h)$ – liczba par punktów oddalonych o odległość h ,

$z(c_i), z(c_i + h)$ – wysokości w określonych miejscach.

Po obliczeniu semiwariancji można przystąpić do wykreślenia semiwariogramu eksperymentalnego (**Rys. 1.15**), czyli przedstawienia na wykresie semiwariancji danych interpolujących w funkcji odległości (**Wong A.H., Kwon T.J., 2021**).



Rys. 1.15. Wykres przedstawiający semiwariogram eksperymentalny wraz z dopasowanym wariogramem teoretycznym (opracowanie własne na podstawie: **(Wong A.H., Kwon T.J., 2021)**).

Następnie semiwariogram eksperymentalny należy dopasować do semiwariogramu matematycznego (teoretycznego) (**Rys. 1.16**), w taki sposób, aby jak najlepiej odzwierciedlał model empiryczny. Należy jednak mieć na uwadze, że najlepsze wyniki wartości interpolowanych zależą od ustalenia prawidłowego semiwariogramu. Poniżej opisano wybrane modele semiwariogramów teoretycznych.

Model sferyczny ma postać równania (**Montes F. i in., 2005**):

$$\gamma(h) = \begin{cases} C_0 + C_1 \cdot \left[\frac{3}{2} \cdot \left(\frac{h}{g} \right) - \frac{1}{2} \cdot \left(\frac{h}{g} \right)^3 \right] & h \leq g \\ C_0 + C_1 & h > g \end{cases} \quad (1.18)$$

model Gaussa (**Mert B.A., Dag A., 2017**):

$$\gamma(h) = C_0 + C_1 \cdot \left[1 - e^{\left(\frac{-3 \cdot h^2}{g^2} \right)} \right] \quad (1.19)$$

natomiast model liniowy (**Mert B.A., Dag A., 2017**):

$$\gamma(h) = C_0 + C_1 \cdot \left(\frac{h}{g} \right) \quad (1.20)$$

gdzie:

$\gamma(h)$ – semiwariogram teoretyczny dla odległości h ,

C_0 – semiwariancja progowa (ang. *sill*),

C_1 – semiwariancja nuggetowa (ang. *nugget*),

g – zasięg autokorelacji.

Drugi etap prac dotyczy obliczenia wag (w_i) dla punktów interpolowanych. Należy zauważyć, że metoda krigingu, podobnie jak często stosowana podczas interpolacji metoda IDW, przypisuje większe wagi punktom położonym bliżej badanego. Jednakże wagi (nazywane współczynnikami krigingu) bazują nie tylko na odległości pomiędzy punktami, ale także na ich przestrzennym rozmieszczeniu. Są one wyznaczane z układu równań wynikającego z warunku minimalizacji wariancji błędu. Błąd ten

(nazywany wariancją krigingu) jest określony w punktach pomiarowych, jako różnica pomiędzy wartością estymowaną a wynikiem pomiaru (**Journel A.G., Huijbregts Ch.J., 1978**):

$$\begin{bmatrix} \gamma(h_{11}) & \gamma(h_{12}) & \vdots & \gamma(h_{1n}) & 1 \\ \gamma(h_{21}) & \gamma(h_{22}) & \vdots & \gamma(h_{2n}) & 1 \\ \dots & \dots & \vdots & \dots & \dots \\ \gamma(h_{n1}) & \gamma(h_{n2}) & \vdots & \gamma(h_{nn}) & 1 \\ 1 & 1 & \vdots & 1 & 0 \end{bmatrix} \cdot \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \\ \lambda_L \end{bmatrix} = \begin{bmatrix} \gamma(h_1) \\ \gamma(h_2) \\ \vdots \\ \gamma(h_n) \\ 1 \end{bmatrix} \quad (1.21)$$


gdzie:

$\gamma(h_{ij})$ – semiwariancja pomiędzy kolejnymi punktami i oraz j ,

$\gamma(h_i)$ – semiwariancja pomiędzy punktem interpolowanym (nieznany) a i -tym punktem,

λ_L – mnożnik Lagrange’a.

Dopiero po obliczeniu wag (w_i) można przejść do wyznaczenia wysokości dla punktów interpolowanych za pomocą równania (1.16).



Rys. 1.16. Przykłady powszechnie stosowanych teoretycznych modeli semiwariogramów: sferyczny (a), Gaussa (b) i liniowy (c) (opracowanie własne na podstawie: (**Mert B.A., Dag A., 2017**)).

Podsumowując, do zalet stosowania regularnej siatki kwadratów można zaliczyć (**Guo Q. i in., 2023**):

- Efektywność obliczeniową. Wiele algorytmów numerycznych opiera się na siatkach GRID ze względu na ich efektywność obliczeniową;
- Łatwość analizy danych. Siatka GRID ułatwia analizę danych i wyciąganie na jej podstawie wniosków, ponieważ dane są uporządkowane i łatwe do porównania;
- Łatwość w interpolacji. Dzięki siatce GRID interpolacja między punktami jest prosta i efektywna. W tym celu można używać różnego rodzaju algorytmy interpolacyjne, takie jak np. IDW;
- Prostota w implementacji. Model GRID jest łatwy do zrozumienia i zaimplementowania algorytmem. Jego regularna struktura ułatwia operacje geometryczne i obliczenia;
- Regularność rozkładu danych. Odległość między węzłami w siatce GRID jest stała, co zapewnia równomierny rozkład danych.

Natomiast do wad stosowania regularnej siatki kwadratów należy zaliczyć (**Guo Q. i in., 2023**):

- Brak elastyczności w dostosowaniu rozdzielczości siatki. Odległość między węzłami siatki GRID jest stała na całym obszarze, co może prowadzić do utraty istotnych szczegółów terenowych w niektórych miejscach;
- Niewydajność w reprezentacji nieregularnych struktur. W przypadku nieregularnych form terenowych, takich jak tereny góryste, NMT w postaci siatki GRID może w sposób niedokładny odwzorowywać rzeczywiste ukształtowanie terenu.

Zastosowanie siatki GRID pozwala na przedstawienie danych głębokościowych w sposób uporządkowywany i łatwy do analizy. Niemniej jednak dane powinny być równomiernie rozmieszczone ze względu na odległość między węzłami.

1.4. Metody fuzji wielomodalnych danych geoprzestrzennych w pomiarach batymetrycznych

Fuzja wielomodalna w pomiarach batymetrycznych pozwala na dokładne odwzorowanie powierzchni dna akwenu poprzez wykorzystanie bardziej precyzyjnych danych i redukcję błędów pomiarowych. W przypadku pomiarów hydrograficznych może być to łączenie danych pozyskanych z różnych sensorów. Na przykład można integrować dane z echosondy, kamery fotogrametrycznej i LiDAR-u, aby uzyskać ukształtowanie dna akwenu. W tym podrozdziale szczegółowo zdefiniowano pojęcie fuzji danych. Poza tym, opisano dwie podstawowe architektury: zdecentralizowaną i scentralizowaną, które realizują fuzję informacji.

1.4.1. Fuzja danych

Fuzja danych (ang. *data fusion*) to proces łącznego wykorzystania danych pochodzących z różnych źródeł. Proces ten jest również określany jako fuzja informacji (ang. *information fusion*). Inne synonimy procesu fuzji danych to agregacja, amalgamacja, integracja, łączenie i konsolidacja (**Wald L., 1999**).

Fuzja danych obejmuje teorie, metody, techniki i narzędzia, które są wykorzystywane do łączenia danych z wielu źródeł (baz danych, czujników, wiedzy człowieka itp.) w celu uzyskania lepszej pod względem jakościowym (dokładność, odporność itd.) decyzji wynikowej lub podjętych działań. Fuzja informacji to również proces integracji danych, które pochodzą z jednego źródła i zostały

zarejestrowane w różnych momentach czasu lub łączenia zmiennych badanego obiektu, które zostały pozyskane z jednego źródła (**Castanedo F., 2013**).

W podanej wyżej definicji jakość jest pojęciem bardzo ogólnym. Określa ona, że uzyskana informacja końcowa jest bardziej satysfakcjonująca dla odbiorcy danych po przeprowadzeniu procesu fuzji, niż gdyby fuzji nie zrealizowano. Jakość procesu fuzji danych zależy od posiadanej wiedzy dotyczącej badanego obiektu, ilości i jakości pozyskanych informacji, a także od jakości procesu przetwarzania i łączenia danych. Jakość tą można podwyższyć zwiększając dokładność pomiaru lub rejestrując większą liczbę odpowiednio dobranych zmiennych badanego obiektu. Im dokładniejsze i liczniejsze będą dane wejściowe, tym większe będzie prawdopodobieństwo uzyskania zadowalającej jakości danych (**Sroka R., 2008**).

Pojawienie się w ostatnich latach nowych rodzajów sensorów, zaawansowanych technik przetwarzania i łączenia danych (sztuczne sieci neuronowe) oraz zwiększenie możliwości oprogramowania i sprzętu obliczeniowego przyczyniło się do intensywnego rozwoju metod i technik pozwalających na realizację systemów wykorzystujących fuzję danych. Systemy te znalazły zastosowanie w wielu dziedzinach życia, wśród których można wyróżnić (**Hall D., Llinas J., 1997**):

- Batymetria. Fuzja danych może być stosowana do wyznaczania głębokości akwenów w celu określenia miejsc nawigacyjnie niebezpiecznych i przeszkód żeglugowych (**Włodarczyk-Sielicka M. i in., 2023**);
- Geografia fizyczna i geologia. Fuzja informacji jest wykorzystywana w analizie obrazowań powierzchni Ziemi i poszukiwaniu surowców mineralnych oraz w systemach obserwacji i prognozowania warunków pogodowych, a także w systemach identyfikujących, śledzących i prognozujących zjawiska geologiczne (**Jorge O.R. i in., 2022**);
- Lokalizacja i transport. Fuzja danych może być stosowana w systemach radarowych i sterowania oraz do detekcji, lokalizacji i śledzenia obiektów (**Jiang C. i in., 2023**);
- Medycyna. Fuzja informacji jest wykorzystywana w badaniach nad lekami, diagnostyce medycznej, medycynie personalizowanej, monitorowaniu zdrowia i profilowaniu chorób oraz przy modelowaniu i symulacjach biologicznych (**Azam K.S.F. i in., 2022**);
- Zastosowania militarne. Fuzja danych może być stosowana do oceny sytuacji na polu walki i wykrywania min oraz w wielosensorycznych systemach uzbrojenia (**Chmielewski M. i in., 2020**);
- Zastosowania techniczno-inżynierskie. Fuzja informacji jest wykorzystywana do detekcji i przewidywania awarii i uszkodzeń urządzeń technicznych oraz przy nadzorowaniu złożonych procesów i systemów technicznych (**Hakimi O. i in., 2023**).

Należy zauważyć, że każda z wyżej wymienionych aplikacji, w zależności od rodzaju danych (dostępnej wiedzy wstępnej, występujących ograniczeń i zakłóceń, jakości i ilości informacji, podejmowanych decyzji), wymaga zastosowania odrębnej architektury procesu fuzji oraz stosowanych technik (algorytmów). W dalszej części niniejszej rozprawy doktorskiej uwaga zostanie skupiona na architekturze systemów realizujących fuzję danych. Przez architekturę procesu fuzji informacji należy rozumieć zespół elementów tworzących fizyczną strukturę systemu i wzajemne relacje między tymi elementami. Zespół ten jest zdolny do wykonywania ściśle określonych funkcji, których nie mógłby wykonać pojedynczy element systemu. Architektura fuzji danych określa również szczegółowo sposoby wymiany danych między poszczególnymi elementami tego systemu (**Sroka R., 2008**).

Istotnym zagadnieniem wielosensorycznej fuzji danych jest jej umiejscowienie w strukturze procesu. Do podstawowych architektur realizujących fuzję informacji zalicza się: autonomiczną (zdecentralizowaną) i scentralizowaną (Klein L.A., 1999). Wybór architektury systemu fuzji informacji jest podyktowany docelowym zastosowaniem, a także możliwościami obliczeniowymi, sprzętowymi i transmisji danych.

1.4.2. Fuzja zdecentralizowana

Fuzja zdecentralizowana (rozproszona) pozwala na przetwarzanie danych pozyskanych z czujnika w systemie z nim niezależnie związanym. Dla tej struktury niezwykle istotna jest optymalizacja przetwarzania informacji zarejestrowanych przez każdy z sensorów. Optymalizację przetwarzania danych przeprowadza się dla każdego czujnika z osobna, w zależności od jego parametrów i właściwości (czułość, pole widzenia, rozdzielczość, zasięg). Na podstawie tak przygotowanych informacji wykonuje się fuzję danych z wykorzystaniem algorytmów, takich jak:

- Estymacja Bayesowska. Algorytm ten opiera się na zasadach teorii prawdopodobieństwa, zwłaszcza na twierdzeniu Bayesa, pozwalając na aktualizowanie naszych informacji na temat parametrów lub zmiennych losowych po uzyskaniu nowych danych, uwzględniając naszą wiedzę *a priori*. Metoda ta pozwala na określenie wartości danych, które są obciążone niepewnością pomiarową i pochodzą z wielu sensorów. Dzięki estymacji Bayesowskiej możliwe jest uwzględnienie niepewności związanej z każdym z tych sensorów, a także integracja informacji z różnych źródeł w celu uzyskania danych o większej dokładności (Gnyp J.T., 2022).

Wzór na twierdzenie Bayesa można wyrazić w następujący sposób (Stuart A., Ord K., 2010):

$$P(D/E) = \frac{P(E/D) \cdot P(D)}{P(E)} \quad (1.22)$$

gdzie:

D, E – zdarzenia,

$P(D/E)$ – prawdopodobieństwo warunkowe tzn. prawdopodobieństwo zajścia zdarzenia D , o ile zajdzie zdarzenie E ,

$P(E/D)$ – prawdopodobieństwo zajścia zdarzenia E , o ile zajdzie zdarzenie D ,

$P(D)$ – prawdopodobieństwo zajścia zdarzenia D ,

$P(E)$ – prawdopodobieństwo zajścia zdarzenia E przy założeniu, że $P(E) > 0$.

- Metoda średniej ważonej. W tej metodzie wartości pochodzące z różnych źródeł, które się nakładają w jednym punkcie, są standaryzowane poprzez wyznaczenie jednej wartości za pomocą średniej ważonej. Należy zaznaczyć, że każde źródło danych ma przypisaną wagę w ten sposób, że elementy o większej wadze mają większy wpływ na średnią.

Średnia ważoną można wyrazić wzorem (Lu P., Dai F., 2022):

$$\bar{x} = \sum_{i=1}^N w_i \cdot x_i \quad (1.23)$$

gdzie:

$\bar{x}$ – średnia ważona,


N – liczba danych,

w_i – waga dla i -tej danej,

x_i – wartość zmiennej i -tej danej.

- Sztuczne sieci neuronowe (ang. *Artificial Neural Network* – ANN). Są to narzędzia informatyczne, które naśladują pracę ludzkich sieci neuronowych. Sztuczne neurony stanowią jednostki obliczeniowe, które odbierają dane wejściowe i generują dane wyjściowe. Do każdego sztucznego neuronu przypisana jest waga, która określa siłę połączenia z innymi sztucznymi neuronami. Sztuczne neurony są połączone ze sobą w co najmniej trzy warstwy: wejściową, wyjściową i ukrytą, tworząc SSN. Przy czym należy pamiętać, że warstw ukrytych może być wiele. W sztucznej sieci neuronowej dochodzi do procesu uczenia się polegającego na dostosowaniu wag w zależności od błędu między oczekiwanym a rzeczywistym wynikiem sieci (AI, 2024).

Fuzja tego typu jest zwykle prowadzona na poziomie decyzji, ale może być również realizowana na poziomie właściwości (cech). Przykładową architekturę fuzji zdecentralizowanej przedstawiono na Rys. 1.17 (Sroka R., 2008).



Rys. 1.17. Architektura procesu fuzji zdecentralizowanej (opracowanie własne na podstawie: (Sroka R., 2008)).

Architekturę zdecentralizowaną stosuje się, gdy celem procesu fuzji danych jest detekcja lub klasyfikacja obiektów, a informacje pozyskane z czujników uzupełniają się wzajemnie (komplementarność). W szczególności zaleca się stosowanie tej struktury dla danych, które nie są rejestrowane synchronicznie (asynchroniczność).

Podsumowując, do zalet stosowania architektury procesu fuzji zdecentralizowanej można zaliczyć (Sroka R., 2008):

- Brak konieczności posiadania pojemnych i szybkich torów transmisyjnych;
- Możliwość doboru liczby i rodzaju sensorów bez konieczności zmiany algorytmu fuzji danych;
- Możliwość łatwego dodania algorytmu fuzji danych i procesora do istniejącego systemu wielosensorycznego;
- Optymalizację procesu przetwarzania informacji dla każdego czujnika z osobna, w zależności od jego parametrów i właściwości;
- Redukcję obciążenia procesora wykonującego proces fuzji danych dzięki niezależnemu przetwarzaniu informacji i podejmowaniu decyzji wstępnych przez każdy z sensorów;
- Większą zdolność do poprawnej pracy w porównaniu do systemu o architekturze scentralizowanej, gdzie dane docierają do procesora w formie nieprzetworzonej i są następnie analizowane łącznie.

Natomiast do wad stosowania architektury procesu fuzji rozproszonej należy zaliczyć (**Sroka R., 2008**):


- Trudność w określeniu błędów wyników pomiarów oraz wiarygodności sensorów, z których pozyskano dane pomiarowe;
- Zwykle gorszą jakość decyzji wynikowej lub podjętych działań w porównaniu do systemu o architekturze scentralizowanej, gdzie istnieje równoczesny dostęp do wszystkich danych wejściowych.

Powyższe wady wynikają z tego, że systemy o architekturze zdecentralizowanej tracą część informacji na etapie wstępnego przetwarzania danych, przez co nie mogą one dokonać oceny jakości uzyskanego wyniku końcowego przeprowadzonej fuzji. Dlatego systemy o architekturze rozproszonej powinny być projektowane w taki sposób, aby korzystały one z informacji o badanym obiekcie i jakości ich źródła, a nie tylko z samych danych (**Houzelle S., Giraudon G., 1994**).

Fuzja zdecentralizowana pozwala na zachowanie kontroli nad procesem przetwarzania danych na różnych poziomach. Brak nadzoru nad konkretną metodą w różnych rodzajach fuzji może prowadzić do uzyskania zróżnicowanych dokładności danych wyjściowych. Przykładem takiego procesu jest metoda ekstrakcji linii brzegowej zaproponowana przez Xu i in. (**Xu S. i in., 2019**). Metoda ta ma trudności z wygenerowaniem linii brzegowej na akwenach, gdzie występują przeszkody terenowe, takie jak np. pomosty. Aby uzyskać zadowalające wyniki przy użyciu wyżej wymienionej metody, należy wcześniej usunąć obrysy pomostów z danych LiDAR lub wyznaczyć linię brzegową na podstawie ortofotomapy. Jednakże musi to zostać wykonane na etapie przetwarzania danych.

1.4.3. Fuzja scentralizowana

Architektura scentralizowana wykorzystuje dane pierwotne (nieprzetworzone) lub minimalnie przetworzone w systemie związanym ze źródłem informacji. Wstępne przetwarzanie informacji następuje dopiero w procesorze centralnym. Ma ono na celu ujednolicenie struktury danych (operacja porządkowania), czyli sprowadzenie ich do wspólnej miary czasowo-przestrzennej. W dalszej kolejności dochodzi do łączenia informacji, które odpowiadają sobie wzajemnie (kojarzenie danych). Ma ono na celu wybranie reprezentacji danych pozyskanych z różnych sensorów, a następnie ich odpowiednie pogrupowanie. Po przeprowadzeniu operacji porządkowania i kojarzenia danych wykonywana jest fuzja informacji z wykorzystaniem algorytmów, takich jak np. metody grupowania, czy sztuczne sieci neuronowe. Fuzja tego typu jest zwykle prowadzona na poziomie danych, ale może być również realizowana na poziomie właściwości (cech). Taki sposób prowadzenia procesu fuzji danych jest najbardziej dokładny pod warunkiem, że informacje zostały poprawnie przetworzone i odpowiednio przyporządkowane. W procesorze centralnym powinna być również prowadzona ocena jakości wykorzystywanych danych wejściowych. Jest to spowodowane tym, że informacje o złej jakości mogą doprowadzić do niezadowalającego wyniku końcowego lub podjętych działań. Takie źródła danych powinny zostać rozpoznane, a informacje z nich pozyskane powinny być uwzględniane w procesie fuzji lub brane pod uwagę z mniejszą wagą. Przykładową architekturę fuzji scentralizowanej przedstawiono na **Rys. 1.18 (Sroka R., 2008)**.



Rys. 1.18. Architektura procesu fuzji scentralizowanej (opracowanie własne na podstawie: **(Sroka R., 2008)**).

Zadaniem algorytmów stosowanych w systemach o architekturze scentralizowanej jest pozyskiwanie informacji o cechach i właściwościach badanych obiektów z danych pierwotnych w celu ich detekcji, klasyfikacji, identyfikacji lub śledzenia. Ze względu na efektywność procesu fuzji informacji, systemy o architekturze scentralizowanej stosuje się w szczególności do estymacji i predykcji przyszłego położenia obiektu **(Klein L.A., 1999)**.

Podsumowując, do zalet stosowania architektury procesu fuzji scentralizowanej można zaliczyć **(Sroka R., 2008)**:

- Możliwość uzyskania dokładniejszej detekcji i klasyfikacji obiektu w porównaniu do systemu o architekturze autonomicznej pod warunkiem, że dane z systemu wielosensorycznego nie są komplementarne;
- Możliwość uzyskania optymalnego wyniku końcowego lub podjętych działań ze względu na pełną znajomość informacji o badanym obiekcie;
- Redukcję kosztów budowy systemu wieloczujnikowego w porównaniu do systemu o architekturze autonomicznej, gdzie każdy sensor musi posiadać niezależny procesor do przetwarzania pozyskanych przez niego danych;
- Zwiększoną niezawodność systemu wieloczujnikowego w celu zapewnienia redundancji (nadmiarowości) i równoległości przetwarzania informacji.

Natomiast do wad stosowania architektury procesu fuzji scentralizowanej należy zaliczyć **(Sroka R., 2008)**:

- Konieczność transferu dużej ilości danych nieprzetworzonych do procesora centralnego, które są następnie w nim przetwarzane;
- Problem dostępności i przepustowości pasma transmisyjnego ze względu na dużą ilość informacji;
- Zapewnienie dużej mocy obliczeniowej systemu realizującego fuzję danych.

Na podstawie dokonanego przeglądu literatury można przypuszczać, że metoda fuzji scentralizowanej sprawdzi się dobrze na danych dotyczących tego samego akwenu pod warunkiem, że zostały one opracowane zgodnie z przyjętą metodyką. Takie podejście pozwala zachować spójność procesu fuzji informacji oraz zapewnić bardziej jednolite podejście do integracji różnych źródeł danych.

W tej części pracy skupiono się na analizie metod integracji danych hydroakustycznych i optoelektronicznych stosowanych w hydrografii, ze szczególnym naciskiem na dane batymetryczne pozyskiwane w strefie brzegowej. W pierwszej części szczegółowo opisano urządzenia pomiarowe, takie jak: echosonda jednowiązkowa i wielowiązkowa, kamera fotogrametryczna oraz LiDAR, przedstawiając ich konstrukcję, zasadę działania i charakterystykę rejestrowanych danych. Dodatkowo

omówiono czynniki wpływające na dokładność pozyskiwanych danych. Analizie poddano także metody służące do określania głębokości akwenów na podstawie zdjęć lotniczych, w tym metodę regresji wektora nośnego (SVR), a także metody ekstrakcji linii brzegowej, takie jak metoda zaproponowana przez Xu i in. W dalszej kolejności scharakteryzowano siatkę TIN i GRID, które stanowią podstawę do tworzenia modeli powierzchni terenu. Następnie przedstawiono metody fuzji wielomodalnych danych geoprzestrzennych, które w istotny sposób poprawiają jakość modelowania powierzchni terenu.

2. Metoda monitoringu batymetrycznego strefy brzegowej na bazie fuzji wielomodalnych danych geoprzestrzennych

Rozdział poświęcony metodzie monitoringu batymetrycznego strefy brzegowej opartej na bazie fuzji wielomodalnych danych batymetryczno-fotogrametrycznych rozpoczęto od opisanie etapów opracowania i analizy danych geoprzestrzennych pozyskanych przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych. Następnie przedstawiono etapy autorskiej metody monitoringu batymetrycznego strefy brzegowej. W dalszej kolejności zaimplementowano tą metodę w środowisku GIS.


2.1. Opracowanie i analiza danych geoprzestrzennych pozyskanych przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych

Prace nad przygotowaniem metody monitoringu batymetrycznego strefy brzegowej rozpoczęto od opisanie etapów opracowania danych batymetryczno-fotogrametrycznych pozyskanych przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych, takich jak: echosonda jednowiązkowa i wielowiązkowa, kamera fotogrametryczna oraz LiDAR z mobilnego i lotniczego skaningu laserowego. Ponadto dokonano opracowania i analizy danych geoprzestrzennych zarejestrowanych podczas kampanii pomiarowej na akwenie testowym.

2.1.1. Opracowanie danych głębokościowych z echosondy jednowiązkowej i wielowiązkowej

W pomiarach batymetrycznych stosowane są urządzenia hydroakustyczne, których działanie oparte jest na zjawisku echolokacji (**Kang M., 2014**). Należą do nich m.in. echosondy, które wysyłają impuls sondujący w głąb wody, a następnie rejestrują drgania fali dźwiękowej odbitej od dna. Czas i prędkość wysłanego impulsu sondującego pozwala obliczyć głębokość w wybranym punkcie dna (**Lewicka O. i in., 2022c**). Najbardziej znane są echosondy jednowiązkowe i wielowiązkowe. Przedstawiona koncepcja opracowania danych pochodzących z echosondy SBES może być także zastosowana dla danych zarejestrowanych przy użyciu echosondy MBES. Co więcej, zakłada ona, że pomiary batymetryczne będą realizowane z wykorzystaniem bezzałogowej jednostki pływającej, na której zamontowane są echosonda MBES lub SBES i odbiornik GNSS RTK.

Danym batymetrycznym pozyskanym za pomocą echosondy jednowiązkowej lub wielowiązkowej są przypisywane współrzędne prostokątne płaskie z różnicowych pomiarów GNSS RTK oraz głębokości zarejestrowane przez urządzenie hydroakustyczne. Pierwszy etap pracy przy opracowaniu danych batymetrycznych pochodzących z echosondy MBES lub SBES polega na odniesieniu głębokości do obowiązującego w danym państwie układu wysokościowego. Na obszarze Polski, gdzie prowadzono badania w ramach niniejszej rozprawy doktorskiej, głębokości mogą być wyłącznie podawane w układzie PL-EVRF2007-NH, którego poziomem odniesienia ($H=0.000$ m) jest poziom układu wysokości Amsterdam (**Rys. 2.1**) (**Rada Ministrów RP, 2012**).



Rys. 2.1. Schemat blokowy przedstawiający etapy metody wyznaczania głębokości w odniesieniu do ustalonego poziomu odniesienia (opracowanie własne na podstawie: **(Lewicka O. i in., 2022c)**).

Wysokość normalną punktu pomierzonego przez echosondę w układzie PL-EVRF2007-NH oblicza się ze wzoru **(Lewicka O. i in., 2022c)**:

$$H_{PL-EVRF2007-NH} = -(d_w + d_r \pm \Delta d_{PL-EVRF2007-NH}) \quad (2.1)$$

gdzie:

$H_{PL-EVRF2007-NH}$ – wysokość normalna punktu pomierzonego przez echosondę w układzie PL-EVRF2007-NH,

$\Delta d_{PL-EVRF2007-NH}$ – poprawka głębokości odniesiona do zera mapy w układzie PL-EVRF2007-NH, którą należy dodać, jeżeli uśredniony stan wody ($\bar{d}_{SW_{PL-EVRF2007-NH}}$) nie przekracza 500 cm, natomiast w przeciwnym razie trzeba ją odjąć.

Należy jednak pamiętać, że poprawka głębokości jest definiowana następująco **(Lewicka O. i in., 2022c)**:

$$\Delta d_{PL-EVRF2007-NH} = 500 \text{ cm} - \bar{d}_{SW_{PL-EVRF2007-NH}} \quad (2.2)$$


gdzie:

$\bar{d}_{SW_{PL-EVRF2007-NH}}$ – uśredniony poziom morza obserwowany na mareografie pomiędzy kolejnymi pełnymi godzinami w układzie PL-EVRF2007-NH.

Ponadto poprawka głębokościowa zależy od aktualnego poziomu morza, który jest określony w odniesieniu do umownego zera wodowskazu. Przykładowo, na obszarze Polski obowiązuje układ wysokości Amsterdam, którego rzędna wodowskazu wynosi 500 cm **(Rada Ministrów RP, 2019)**. Poziom morza uśrednia się na podstawie obserwacji zarejestrowanych przez mareograf pomiędzy kolejnymi pełnymi godzinami.

Ważnym elementem przy wyznaczaniu poprawki głębokościowej jest odpowiedni wybór stacji hydrometeorologicznej. Stacja powinna być umiejscowiona najbliżej miejsca wykonywania pomiarów

batymetrycznych. Jeżeli w pobliżu realizacji badań nie ma stacji hydrometeorologicznej, to poziom wody należy odczytać z najbliższej położonej łaty wodowskazowej, co zostało zobrazowane na **Rys. 2.2**.




Rys. 2.2. Schemat pomiarów poziomu wody i temperatury wykonywanych przez IMGW dla rzędnej zera wodowskazu w układzie PL-EVRF2007-NH (opracowanie własne na podstawie: (Lewicka O. i in., 2022c)).

W sytuacji, gdy na badanym obszarze lub w jego pobliżu nie ma stacji hydrometeorologicznej oraz nie występuje falowanie podczas realizacji pomiarów batymetrycznych, zmierzone głębokości można odnieść do wysokości zwierciadła wody. W takim przypadku wysokość jest odczytywana na podstawie uśrednionych pomiarów wysokościowych przeprowadzonych wzdłuż izobaty 0 m przy użyciu odbiornika GNSS RTK. Niemniej jednak istnieje także możliwość wyznaczenia przebiegu linii brzegowej z wykorzystaniem innych metod pomiarowych, takich jak np. LiDAR.

Następny etap prac polega na usunięciu błędnie zarejestrowanych głębokości. W przypadku echosond MBES i SBES konieczna jest eliminacja głębokości, których wartość może być kilkakrotnie wyższa niż w rzeczywistości. Jest to spowodowane zjawiskiem wielokrotnego odbicia sygnału hydroakustycznego od dna na obszarze najmniejszych głębokości (mniejszych niż minimalny zakres działania echosondy). Potem usuwane są błędnie zarejestrowane głębokości na wszystkich profilach sondażowych. Eliminację pozostałych błędów pomiarów można wykonać za pomocą metody manualnej.

Pomiary batymetryczne na obszarze płytkowodnym akwenu testowego zostały wykonane dnia 23 sierpnia 2023 r. przy użyciu echosondy jednowiązkowej SonarMite BTX, która była zintegrowana z odbiornikiem GNSS RTK Trimble R10. Zestaw pomiarowy pozwala na rejestrację danych głębokościowych z częstotliwością 1 Hz. Podczas realizacji pomiarów batymetrycznych z wykorzystaniem echosondy SBES wyznaczono 7006 punktów ze średnią dokładnością wynoszącą 0.05 m w płaszczyźnie horyzontalnej i 0.06 m w płaszczyźnie wertykalnej. Po ręcznym oczyszczeniu danych batymetrycznych, liczba danych głębokościowych uległa redukcji o 17%. Błędnie zarejestrowane dane były głównie zlokalizowane blisko linii brzegowej (**Rys. 2.3**).




Rys. 2.3. Oczyszczone dane SBES dla akwenu testowego (opracowanie własne).

W celu przeprowadzenia analizy porównawczej danych głębokościowych zarejestrowanych przez różne sensory, zdecydowano się porównać gęstość tych danych w poszczególnych komórkach siatki GRID. Jako kryterium oceny gęstości danych głębokościowych przyjęto miary R68 i R95, które wynikają z sortowania danych od wartości najmniejszej do największej. Miara R68 oznacza wartość w zbiorze danych, która jest większa od 68% obserwacji. Natomiast miara R95 oznacza wartość w zbiorze danych, która jest większa od 95% obserwacji. Zaletą stosowania miar R68 i R95 jest to, że nie zakładają one żadnego rozkładu statystycznego i charakteryzują się wysokim poziomem ufności. Poza tym, obliczono również inne miary statystyczne, takie jak: średnia arytmetyczna, odchylenie standardowe czy minimalna i maksymalna.

W pierwszej kolejności dla oczyszczonych danych batymetrycznych SBES wygenerowano siatkę GRID z odstępem między komórkami wynoszącym 1 m. Następnie utworzono warstwę poligonową, która obejmowała tylko obszar oczyszczonych danych głębokościowych. Potem przycięto regularną siatkę kwadratów do zasięgu poligonu, aby otrzymać informacje dotyczące liczebności punktów w poszczególnych komórkach siatki GRID.

Z przeprowadzonych analiz statystycznych wynika, że na 1 m² przypada średnio 0.69 punkta, przy odchyleniu standardowym wynoszącym 3.11 punkta. Minimalna liczba punktów w komórce regularnej siatki kwadratów jest równa 0, a maksymalna wartość wynosi 197. Wysoka rozbieżność pomiędzy minimalną a maksymalną liczbą punktów w komórce siatki GRID wynika ze sposobu prowadzenia sondażu hydrograficznego z wykorzystaniem bezzałogowej jednostki pływającej. Na obszarze, gdzie występuje najwięcej danych, rozpoczynano pomiar głębokości na kolejnym profilu sondażowym lub zatrzymywano jednostkę pomiarową. Miary R68 i R95 wynoszą odpowiednio 1 i 2 punkty. Ponadto można stwierdzić, że 5366 komórek regularnej siatki kwadratów (67.16%) nie posiada żadnych danych. Natomiast 2034 komórek siatki GRID (25.46%) ma jedną wartość, a zaledwie 590 komórek (7.38%)

posiada co najmniej dwie wartości. Na podstawie uzyskanych wartości miar statystycznych należy stwierdzić, że dane SBES były pokryte rzadko i nierównomiernie na badanym akwenu (**Rys. 2.4**).




Rys. 2.4. Histogram przedstawiający częstość występowania punktów SBES w komórce siatki GRID dla akwenu testowego (opracowanie własne).

Z kolei proces oczyszczania danych batymetrycznych pochodzących z echosondy wielowiązkowej można przeprowadzić w oparciu o metody wykrywania wartości odstających. Zgodnie z Le Deunf i in. istnieje pięć głównych podejść do wykrywania wartości odstających (**Rys. 2.5**) (**Le Deunf J. i in., 2020**):

- Podejścia oparte na statystyce – umożliwiają identyfikację wartości odstających w danym zbiorze przy wykorzystaniu miar i cech statystycznych. Jeżeli znany jest rozkład danych, to stosuje się metody parametryczne oparte na średniej i odchyleniu standardowym. W przeciwnym razie wykorzystuje się metody nieparametryczne, niewymagające założeń odnośnie do rozkładu populacji, z której losowana jest próba. Popularnymi miarami stosowanymi w metodach nieparametrycznych są mediana i rozstęp ćwiartkowy (ang. *InterQuartile Range* – IQR) (**Lewicka O., 2023b**);
- Podejścia oparte na odległości – odnoszą się do metod, które wykorzystują odległości lub podobieństwa między obiektami w celu analizy zależności w zbiorze danych. Punkty znajdujące się w większej odległości niż pozostałe są identyfikowane jako wartości odstające;
- Podejścia oparte na gęstości – wykorzystują informacje o gęstości punktów w przestrzeni, aby identyfikować klastry lub obszary o większej gęstości;
- Podejścia oparte na klastrowaniu – odnoszą się do metod analizy danych, które skupiają się na grupowaniu podobnych obiektów w tzw. klastry. Obiekty są grupowane na podstawie pewnych cech lub podobieństw między nimi, tak aby obiekty wewnątrz jednego klastra były podobne do siebie nawzajem, a jednocześnie klastry były od siebie różne;
- Podejścia oparte na modelowaniu powierzchni – bazują na konstrukcji modeli matematycznych dna morskiego. W tym kontekście zakłada się, że głębokości pomiarowe, które znacząco różnią się od głębokości modelowanych, są traktowane jako wartości odstające.

Najwięcej metod służących do identyfikacji błędnie zarejestrowanych głębokości przez echosondę wielowiązkową zalicza się do metod o podejściu statystycznym. Co więcej, metoda CUBE (ang. *Combined Uncertainty and Bathymetry Estimator*), należąca do tej grupy metod, jest powszechnie stosowana przez organizacje hydrograficzne, takie jak Kanadyjska Służba Hydrograficzna (ang. *Canadian Hydrographic Service* – CHS) oraz Narodowy Urząd do spraw Badań Oceanów i Atmosfery

(ang. *National Oceanic and Atmospheric Administration* – NOAA). CUBE to metoda automatycznego oczyszczania danych MBES, charakteryzująca się niską wrażliwością na obserwacje odstające. Pierwszym etapem jest utworzenie regularnej siatki z estymowanymi węzłami. Wyznaczanie wartości estymowanych węzłów polega na przypisaniu punktowi pomiarowemu określonej niepewności pomiarowej (ang. *Total Propagated Uncertainty* – TPU) na poziomie ufności 95%. W tej metodzie niepewność pomiarowa jest oznaczana jako tolerancja pionowa. Drugi etap polega na generowaniu hipotez o większym prawdopodobieństwie, zakładających rzeczywiste wartości głębokości w danym punkcie. W trzecim etapie przedstawione są hipotezy alternatywne dotyczące dna morskiego. Wartości oddalone bardziej niż założona tolerancja pionowa są odrzucane.



Rys. 2.5. Klasyfikacja metod wykrywania wartości odstających danych MBES w oparciu o wybrane podejścia (opracowanie własne na podstawie: (Le Deunf J. i in., 2020)).

Kolejną godną uwagi metodą wykorzystującą podejście odległościowe jest ta zaproponowana przez Arge i in. (Arge L. i in., 2010). W ramach tej metody identyfikacja wartości odstających opiera się na triangulacji Delaunaya. Procedura ta jest realizowana we wstępnym etapie, gdzie punkty pomiarowe są traktowane jako wierzchołki trójkątów, które nie nachodzą na siebie. Następnie generowane są przekątne dla utworzonych trójkątów. Po przygotowaniu siatki trójkątów definiuje się tzw. wartość graniczną, powyżej której krawędzie siatki triangulacyjnej zostaną usunięte. W dalszej kolejności identyfikuje się najdłuższe boki siatki trójkątów. Wierzchołki trójkątów, które nie tworzą tych boków, oznaczane są jako wartości odstające i podlegają usunięciu. Metoda oparta na odległości zaproponowana przez Arge i in. może być również stosowana do identyfikacji konstrukcji znajdujących się nad dnem morskim, takich jak rury czy wraki.

Yang i in. opracowali metodę oczyszczania danych MBES opartą na gęstości (Yang F. i in., 2007). W pierwszym etapie dane głębokościowe są umieszczane w tzw. komórkach (ang. *bin*). W drugim etapie prac dokonuje się identyfikacji komórki o największej liczbie danych na obszarze dna akwenu pokrytego danymi. Na jej podstawie wybiera się sąsiadujące z nią komórki o dużej gęstości. Dzięki tak wyselekcjonowanym komórkom o dużej gęstości tworzony jest region. W trzecim etapie wykrywa i usuwa się wartości odstające przy użyciu algorytmów erozji i dylatacji (ang. *erosion and dilation algorithms*). Algorytm erozji służy do identyfikacji komórek krawędziowych (ang. *edge points*), czyli takich, które znacząco różnią się od komórek sąsiadujących. Natomiast algorytm dylatacji ma na celu łączenie ze sobą sąsiednich komórek. Po zastosowaniu obu filtrów otrzymuje się obszar pozbawiony części wartości odstających. W czwartym etapie prac tworzy się nowy region, który jest pozbawiony luk w danych, przy użyciu metody wykrywania krawędzi. W ten sposób usuwa się wartości odstające


znajdujące się poza granicą utworzonego obszaru. W piątym, ostatnim etapie przeprowadza się proces filtracji danych w oparciu o lokalną wariancję i średnią w celu usunięcia pozostałych wartości odstających.

Du i in. opracowali automatyczną metodę oczyszczania danych MBES opartą na klastrowaniu (**Du Z. in., 1996**). Na początku tej metody ustala się kryterium wyodrębniania danych głębokościowych. Na jego podstawie buduje się histogram przedstawiający częstość występowania punktów w określonych przedziałach głębokości. Następnie zbiór danych jest dzielony z uwzględnieniem dominujących głębokości, co umożliwia wyodrębnienie konkretnych struktur lub obszarów o zbliżonych głębokościach. Dodatkowo identyfikowane są obszary, na których głębokości znacząco odbiegają od pozostałych na badanym akwenu. Głębokości te są traktowane jako wartości odstające. Proces wykrywania wartości odstających należy powtarzać stopniowo zmniejszając liczbę analizowanych wiązek akustycznych wygenerowanych przez echosondę wielowiązkową. Metoda oparta na klastrowaniu zaproponowana przez Du i in. kończy się zastosowaniem testu Dixona. Test ten opiera się na porównywaniu różnic między kolejnymi wartościami w zestawie danych. Jeżeli różnica między dwiema sąsiednimi wartościami jest znacząco większa niż oczekiwane różnice w zbiorze danych, to taka wartość jest uznawana za potencjalne odstępstwo lub wartość odstającą.

Jedną z metod reprezentujących podejście oparte o powierzchnię terenu jest metoda zaproponowana przez Arnold i Shaw (**Arnold J., Shaw S., 1993**). W ramach tej metody powierzchnię batymetryczną uzyskuje się poprzez minimalizację funkcji energii (ang. *minimizing an energy function*). W trakcie tego procesu uwzględniane są różne ograniczenia i kryteria, takie jak: gładkość powierzchni, ciągłość czy dopasowanie do odczytów dźwiękowych. Celem jest znalezienie konfiguracji powierzchni, która najlepiej spełnia te kryteria. Wartości głębokości, które znacząco różnią się od głębokości wygenerowanych na podstawie powierzchni batymetrycznej, są uznawane za odstające.

Jak można zauważyć, przytoczone metody z pewnością mogłyby być zastosowane do innych danych o dużej gęstości. Niemniej jednak należy pamiętać, że wykrywanie wartości odstających za pomocą metod automatycznych na obszarach o nieregularnym dnie może okazać się nieskuteczne.


Pomiary batymetryczne na obszarze głębokowodnym akwenu testowego zostały wykonane dnia 1 sierpnia 2023 r. przy użyciu echosondy interferometrycznej PING 3DSS-DX-450. Urządzenie to wysyła impulsy dźwiękowe w postaci 512 oddzielnych wiązek co 10 ms (100 Hz). Dzięki tak wysokiej częstotliwości rejestracji danych można szybko pozyskać gęstą chmurę punktów obrazującą ukształtowanie dna akwenu. Jednakże należy się spodziewać, że część punktów głębokościowych jest obciążona błędami pomiarowymi wynikającymi m.in. z wpływu warunków atmosferycznych, zakłóceń w środowisku wodnym, czy z zanieczyszczeń na powierzchni przetwornika echosondy. W związku z tym, wydaje się konieczne zastosowanie w pierwszym etapie oczyszczania danych MBES filtrów wykrywających wartości odstające. W przypadku danych pozyskanych przy użyciu echosondy wielowiązkowej na akwenu testowym wykorzystano metody wykrywania wartości odstających opartych na odległości: minimalnej (2 m) i maksymalnej (13 m) głębokości. W dalszej części prac nad opracowaniem danych MBES skupiono się nad ręcznym usuwaniem błędów pomiarowych (**Rys. 2.6**).



Rys. 2.6. Oczyszczone dane MBES dla akwenu testowego (opracowanie własne).

Jak można zauważyć na **Rys. 2.6** dane pochodzące z echosondy wielowiązkowej nie dostarczają informacji o głębokościach w bezpośrednim sąsiedztwie linii brzegowej. Obszar wodny w pobliżu linii brzegowej jest zbyt płytki dla echosondy MBES.

W dalszej kolejności na podstawie oczyszczonych danych MBES wygenerowano siatkę GRID o boku długości 1 m. Z przeprowadzonych analiz statystycznych wynika, że na 1 m² przypada średnio 7.71 punkta, przy odchyleniu standardowym wynoszącym 1.82 punkta. Minimalna liczba punktów w komórce regularnej siatki kwadratów jest równa 0, a maksymalna wartość wynosi 10. Miary R68 i R95 wynoszą odpowiednio 8 i 9 punktów. Ponadto należy zauważyć, że zaledwie 418 komórek w siatce GRID (2.84%) nie posiada żadnych danych. Na podstawie uzyskanych wartości miar statystycznych należy stwierdzić, że dane MBES były pokryte gęsto i równomiernie na badanym akwenu (**Rys. 2.7**).



Rys. 2.7. Histogram przedstawiający częstość występowania punktów MBES w komórce siatki GRID dla akwenu testowego (opracowanie własne).

2.1.2. Wyznaczanie głębokości akwenu na podstawie zdjęć lotniczych

Kolejnym sensorem rejestrującym dane batymetryczne jest kamera fotogrametryczna. Dane cyfrowe pozyskane za pomocą kamery są przeznaczone do generowania chmury punktów przy użyciu techniki SfM (**Westoby M.J. i in., 2012**). Następnie na podstawie tych danych tworzony jest model predykcji, który w późniejszym etapie jest wykorzystywany do określania głębokości z wykorzystaniem metody SVR (**Agrafiotis P. i in., 2019**). Z uwagi na złożoność procesów przetwarzania danych fotogrametrycznych, w pierwszej kolejności opisano etap opracowania zdjęć wykonanych przez UAV, ze szczególnym uwzględnieniem ich georeferencji. Następnie szczegółowo omówiono metodę przetwarzania danych przy użyciu metody SVR.

Zanim przystąpiono do opracowania danych pochodzących z bezzałogowego statku powietrznego, konieczne było dokonanie wyboru odpowiedniej metody określania głębokości akwenów płytkowodnych na podstawie zdjęć wykonanych przez UAV. W analizie uwzględniono kilka algorytmów, takich jak: cBathy (**Holman R. i in., 2013**), Depth Inversion (**Hashimoto K. i in., 2021**), metoda radiometryczna (**Pyrchla K. i in., 2018**), SVR (**Agrafiotis P. i in., 2019**), UAV-SfM (**Bagheri O. i in., 2015**), uBathy (**Simarro G. i in., 2019**), czy UDB (**Tonion F. i in., 2020**). Głównymi kryteriami oceny tych metod określania głębokości akwenów płytkowodnych były:


- Dokładność pomiaru głębokości;
- Warunki hydrometeorologiczne występujące podczas realizacji pomiarów fotogrametrycznych;
- Wykorzystana aparatura pomiarowa.

Dokładności pomiaru głębokości wyżej wymienionych metod zostały już przedstawione w podrozdziale 1.2.1. Na podstawie **Tab. 1.2** można stwierdzić, że analizowane metody określania głębokości akwenów płytkowodnych mają zbliżone wartości RMSE głębokości.

W dalszej kolejności uwzględniono pozostałe kryteria oceny metod określania głębokości akwenów płytkowodnych. Ustalono, że algorytmy cBathy, Depth Inversion i uBathy wykorzystują zjawisko dyspersji fali wodnej, która jest modelowana na podstawie zobrażeń wideo. To uwarunkowanie uniemożliwia zastosowanie tych algorytmów, ponieważ zjawisku falowania często towarzyszy silny wiatr. Z kolei pomiary przy użyciu UAV są niemożliwe do wykonania przy silnym wietrze. Ponadto algorytmy te nie znajdują zastosowania na akwenach śródlądowych, gdzie zjawisko falowania praktycznie nie występuje. Algorytm UAV-SfM nie spełnia również założonych kryteriów, ponieważ wymaga on czasochłonnych i manualnych prac w trybie post-processingu. Podobnie jak algorytm SVR opiera swoje działanie na technice SfM, w ramach której generowana jest chmura punktów. Jednakże metoda SVR zakłada selekcję punktów znajdujących się poniżej poziomu zwierciadła wody i korygowanie ich ze względu na zjawisko załamania światła na granicy dwóch ośrodków. Algorytm UDB i metoda radiometryczna nie zostały uwzględnione, ponieważ wymagają one pozyskiwania danych za pomocą kamery wielospektralnej, które są niezbędne do przeprowadzenia operacji matematycznych.

Na potrzeby metody monitoringu batymetrycznego strefy brzegowej postanowiono wybrać algorytm SVR (**Agrafiotis P. i in., 2019**) do określania głębokości akwenów płytkowodnych na podstawie analizy zdjęć wykonanych przez UAV. Algorytm regresji wektora nośnego (**Rys. 2.8**) (**Santos C.E.D.S. i in., 2021**) opiera się na obliczaniu funkcji regresji liniowej w wielowymiarowej przestrzeni cech (**Basak D. i in., 2007**). Dzięki temu zostaje rozwiązany problem refrakcji wiązki świetlnej przy zmianie ośrodka. Ponadto stworzenie matematycznego modelu dna akwenu umożliwia automatyzację

procesu opracowania pomiarów. Algorytm ten dodatkowo wykorzystuje zdjęcia wykonane w korzystnych warunkach hydrometeorologicznych, takich jak bezwietrzna pogoda, co sprzyja skutecznej realizacji pomiarów fotogrametrycznych przy użyciu bezzałogowego statku powietrznego.




Rys. 2.8. Schemat blokowy przedstawiający działanie algorytmu SVR wg (Agrafiotis P. i in., 2019) (opracowanie własne na podstawie: (Lewicka O. i in., 2022b)).

Wybór algorytmu SVR był podyktowany tym, że uzyskał on wysokie dokładności pomiaru głębokości do 1 m na trzech zróżnicowanych obszarach wodnych: akwenie morskim przyległym do plaży miejskiej w Gdyni, jeziorze Kłodno (Specht M. i in., 2023) i jeziorze Raduńskie Górne (Szostak B. i in., 2023). Błąd pomiaru głębokości przy poziomie ufności 95% wyniósł: 0.08 m dla akwenu morskiego przyległego do plaży miejskiej w Gdyni, 0.22-0.24 m dla jeziora Kłodno i 0.08 m dla jeziora Raduńskie Górne. Na podstawie badań przeprowadzonych w ramach eksperymentu wynika, że metoda określania głębokości akwenów płytkowodnych oparta na algorytmie SVR spełnia minimalne wymagania dokładnościowe dla pomiarów hydrograficznych, które są realizowane w ramach kategorii specjalnej IHO (błąd pozycji wertykalnej ≤ 0.25 m ($p=0.95$)).


W późniejszym etapie przystąpiono do opisu etapów metody określania głębokości akwenów płytkowodnych opartej na algorytmie SVR. Po rejestracji danych fotogrametrycznych konieczne jest przeprowadzenie procesu georeferencji zdjęć. Georeferencja jest wykonywana dla obrazów, które nie są osadzone w układzie współrzędnych lub mają słabą dokładność (Hackeloeer A. i in., 2014). Proces georeferencji zdjęć opiera się na wcześniej pomierzonych punktach georeferencyjnych za pomocą odbiornika GNSS RTK. Jednakże dokładność tak przeprowadzonej transformacji współrzędnych zależy od liczby wyznaczonych punktów georeferencyjnych (Oniga V.-E. i in., 2020). Punkty georeferencyjne muszą być rozmieszczone równomiernie, a ich liczba powinna wynosić co najmniej 6. Istotne jest, aby wykonać pomiar współrzędnych punktów georeferencyjnych w docelowym układzie lub aby przeliczyć zarejestrowane współrzędne punktów georeferencyjnych do docelowego układu. Konieczne jest również, aby istniała możliwość określenia współrzędnych punktów georeferencyjnych w obu układach: pierwotnym i wtórnym. Transformację współrzędnych trójwymiarowych można przeprowadzić przy użyciu transformacji 7-parametrowej Bursy-Wolfa. To powszechnie stosowana metoda w geodezji i fotogrametrii, polegająca na transformacji współrzędnych na podstawie wyznaczonych wcześniej parametrów, takich jak: macierze rotacji, wektory translacji i współczynnik skali (Dąbrowski P.S. i in., 2021).

Na **Rys. 2.9** przedstawiono schemat ilustrujący parametry transformacji 7-parametrowej; X, Y, Z to współrzędne punktu, a X', Y', Z' to współrzędne punktu po transformacji. R_x, R_y, R_z opisują trzy macierze rotacji. $\bar{T}_x, \bar{T}_y, \bar{T}_z$ to trzy wektory translacji. P to współczynnik skali.




Rys. 2.9. Schemat parametrów transformacji 7-parametrowej (opracowanie własne na podstawie: **(González-Matesanz J. i in., 2006)**).

Parametry te są obliczane na podstawie zależności pomiędzy punktami zarejestrowanymi w układzie pierwotnym (punktami zarejestrowanymi na zdjęciach) a punktami zarejestrowanymi w układzie docelowym (punktami georeferencyjnymi wyznaczonymi przy użyciu odbiornika GNSS RTK) **(Lewicka O. i in., 2022c) (Rys. 2.10)**.



Rys. 2.10. Schemat blokowy przedstawiający etapy transformacji 7-parametrowej (transformacja Bursy-Wolfa) (opracowanie własne na podstawie: **(Lewicka O. i in., 2022c)**).

Pierwszy etap transformacji 7-parametrowej polega na wyznaczeniu macierzy obrotu, czyli obrotu wektora w przestrzeni euklidesowej **(Slabaugh G.G., 2024)**. Orientację układów współrzędnych najczęściej określa się za pomocą kątów Eulera. Kąty te oznaczają kolejne obroty jakie należy wykonać, aby uzyskać pokrycie osi lokalnego układu współrzędnych z osią wtórnego układu współrzędnych. Do wyznaczenia kątów Eulera można wykorzystać jednostki IMU, które są coraz częściej montowane na UAV **(Elamin A. i in., 2022)**. **Rys. 2.11** przedstawia schemat położenia trzech kątów RPY wokół trzech osi XYZ związanego z układem jednostki IMU.



Rys. 2.11. Schemat położenia trzech kątów RPY wokół trzech osi XYZ związanego z układem jednostki IMU: prawoskrętnym (a) i lewoskrętnym (b) (opracowanie własne na podstawie: (Elmqvist A., Negrut D., 2024)).

Jeżeli urządzenie pomiarowe nie ma możliwości rejestracji kąta rotacji, to należy go obliczyć na podstawie kątów kierunkowych (Feltens J., 2008):

$$\delta_i' = \arctan\left(\frac{y_{k_i}' - y_{p_i}'}{x_{k_i}' - x_{p_i}'}\right) \quad (2.3)$$

$$\delta_i'' = \arctan\left(\frac{y_{k_i}'' - y_{p_i}''}{x_{k_i}'' - x_{p_i}''}\right) \quad (2.4)$$

gdzie:

δ_i' – kąt kierunkowy i -tego odcinka w układzie lokalnym,

δ_i'' – kąt kierunkowy i -tego odcinka w układzie wtórnym,

x_{p_i}', y_{p_i}' – współrzędne punktu początkowego i -tego odcinka w układzie lokalnym,

x_{k_i}', y_{k_i}' – współrzędne punktu końcowego i -tego odcinka w układzie lokalnym,

x_{p_i}'', y_{p_i}'' – współrzędne punktu początkowego i -tego odcinka w układzie wtórnym,

x_{k_i}'', y_{k_i}'' – współrzędne punktu końcowego i -tego odcinka w układzie wtórnym.

Następnie wyznaczone kąty kierunkowe umożliwią obliczenie uśrednionego kąta rotacji (θ) (Lewicka O. i in., 2022c):

$$\theta = \frac{\sum_{i=1}^O (\delta_i'' - \delta_i')}{O} \quad (2.5)$$

gdzie:

O – liczba odcinków.

Zarejestrowane lub obliczone kąty rotacji są niezbędne do wyznaczenia macierzy rotacji. Macierz ta składa się z elementarnych macierzy rotacji. W oryginalnym sformułowaniu modelu transformacji 7-parametrowej trzy elementarne macierze obrotu wokół osi OX, OY i OZ trójwymiarowego układu współrzędnych (R_x, R_y, R_z) mają następującą postać (Bursa M., 1967; Wolf H., 1963, 1967):

$$R_x(\theta) = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \cos(\theta) & \sin(\theta) \\ 0 & -\sin(\theta) & \cos(\theta) \end{pmatrix} \quad (2.6)$$

$$R_y(\theta) = \begin{pmatrix} \cos(\theta) & 0 & -\sin(\theta) \\ 0 & 1 & 0 \\ \sin(\theta) & 0 & \cos(\theta) \end{pmatrix} \quad (2.7)$$

$$R_z(\theta) = \begin{pmatrix} \cos(\theta) & \sin(\theta) & 0 \\ -\sin(\theta) & \cos(\theta) & 0 \\ 0 & 0 & 1 \end{pmatrix} \quad (2.8)$$

Najczęściej do określenia położenia obiektów w przestrzeni stosuje się układ prawoskrętny, dlatego macierze rotacji opisano funkcjami kątów rotacji wokół osi w układzie prawoskrętnym.

Macierz całkowitego obrotu (R) otrzymuje się w wyniku pomnożenia elementarnych macierzy obrotu wokół osi OX, OY i OZ (**Deakin R.E., 2006**):

$$R = R_z(\theta) \cdot R_y(\theta) \cdot R_x(\theta) \quad (2.9)$$

Po przeprowadzeniu rotacji zbioru danych konieczne jest przesunięcie obróconego zbioru danych o wektor translacji ($\vec{T}$) (**Lewicka O. i in., 2022c**):

$$\vec{T}_x = \frac{\sum_{j=1}^I [x_j' - x_j'' \cdot \cos(\theta) + y_j'' \cdot \sin(\theta)]}{I} \quad (2.10)$$

$$\vec{T}_y = \frac{\sum_{j=1}^I [y_j' - x_j'' \cdot \sin(\theta) - y_j'' \cdot \cos(\theta)]}{I} \quad (2.11)$$

$$\vec{T}_z = \frac{\sum_{j=1}^I (z_j' - z_j'')}{I} \quad (2.12)$$

gdzie:

x_j', y_j', z_j' – współrzędne j -tego punktu pomiarowego w lokalnym układzie współrzędnych,

x_j'', y_j'', z_j'' – współrzędne j -tego punktu referencyjnego we wtórnym układzie współrzędnych,

I – liczba punktów pomiarowych i referencyjnych.

Ostatni etap procesu georeferencji zdjęć polega na wyznaczeniu współczynnika skali (S). Współczynnik ten to iloraz odległości pomiędzy dwoma kolejnymi punktami wyrażonymi w lokalnym i wtórnym układzie współrzędnych (**Lewicka O. i in., 2022c**):

$$S = \frac{\sum_{j=1}^{l-1} \left(\frac{d'_j}{d''_j} \right)}{l-1} \quad (2.13)$$

gdzie:

d'_j – odległość pomiędzy dwoma kolejnymi punktami pomiarowymi wyrażonymi w lokalnym układzie współrzędnych,

d''_j – odległość pomiędzy dwoma kolejnymi punktami referencyjnymi wyrażonymi we wtórnym układzie współrzędnych.

Odległość pomiędzy dwoma kolejnymi punktami można wyznaczyć za pomocą następujących zależności:

$$d'_j = \sqrt{(x'_{j+1} - x'_j)^2 + (y'_{j+1} - y'_j)^2} \quad (2.14)$$

$$d''_j = \sqrt{(x''_{j+1} - x''_j)^2 + (y''_{j+1} - y''_j)^2} \quad (2.15)$$

Po wyznaczeniu elementarnych macierzy rotacji, wektorów translacji i współczynnika skali można przystąpić do procesu transformacji współrzędnych. Wzory transformacyjne dla pojedynczego punktu mają postać (**Lewicka O. i in., 2022c**):

$$x_j^d = S \cdot R_x(\theta) \cdot x'_j + \vec{T}_x \quad (2.16)$$

$$y_j^d = S \cdot R_y(\theta) \cdot y'_j + \vec{T}_y \quad (2.17)$$

$$z_j^d = S \cdot R_z(\theta) \cdot z'_j + \vec{T}_z \quad (2.18)$$

gdzie:


x_j^d, y_j^d, z_j^d — współrzędne j -tego punktu wyznaczone według metody 7-parametrowej Bursy-Wolfa we wtórnym układzie współrzędnych.

Wzory transformacyjne (2.16-2.18) stosuje się wówczas, gdy oblicza się jedynie współczynnik skali S . Z kolei cały współczynnik skali M można wyznaczyć za pomocą następującego równania (**Lewicka O. i in., 2022c**):

$$M = 1 + S \quad (2.19)$$

W celu wyznaczenia macierzy rotacji, trzech wektorów translacji i współczynnika skali wymagane jest posiadanie zbioru danych przestrzennych. Wszystkie wyżej wymienione parametry transformacji współrzędnych wyznacza się osobno dla każdego punktu. Następnie oblicza się średnią arytmetyczną dla poszczególnych parametrów. Umożliwia to otrzymanie najlepszego przybliżenia poszukiwanej wartości. Metodę transformacji 7-parametrowej można stosować zarówno w układach lokalnych, jak i w układach odniesienia, które nie są określone. Wadą tej transformacji jest jej złożoność obliczeniowa.

Metoda transformacji 7-parametrowej występuje także w postaci macierzowej. Algorytm transformacji współrzędnych w postaci macierzowej został opracowany o metodę spostrzeżeń pośrednich, określaną również jako metodę parametryczną (**Rys. 2.12**).



Rys. 2.12. Schemat blokowy przedstawiający etapy transformacji 7-parametrowej (transformacja Bursy-Wolfa) w postaci macierzowej (opracowanie własne na podstawie: (**Lewicka O. i in., 2022c**)).

Metoda ta zakłada, że pomiary i wyniki pomiarów nigdy nie prowadzą do poznania prawdziwej wartości, ponieważ każdy pomiar jest obciążony różnego rodzaju błędami wynikającymi z przyjętej metody, zastosowanych systemów i urządzeń pomiarowych. Wykorzystując tę własność można wyznaczyć niewiadome parametry na podstawie wyników pomiarów i związanych z nimi błędami.

Równanie błędów pomiarów (V) można zapisać jako (**Szubrycht T., Wiśniewski Z., 2004**):

$$V = A \cdot X + K \quad (2.20)$$

gdzie:

A – macierz współczynników równań poprawek,

X – macierz niewiadomych parametrów transformacji,

K – macierz wyrazów wolnych.

Z kolei model transformacji dla pojedynczego punktu ma następującą postać (**González-Matesanz J., 2006**):

$$\begin{bmatrix} x'_j \\ y'_j \\ z'_j \end{bmatrix} = \begin{bmatrix} \mu & \gamma & -\beta \\ -\gamma & \mu & \alpha \\ \beta & -\alpha & \mu \end{bmatrix} \cdot \begin{bmatrix} x'_j \\ y'_j \\ z'_j \end{bmatrix} + \begin{bmatrix} x_0 \\ y_0 \\ z_0 \end{bmatrix} \quad (2.21)$$

gdzie:

x'_j, y'_j, z'_j — współrzędne j -tego punktu wyznaczone według modelu transformacji 7-parametrowej we wtórnym układzie współrzędnych,

x'_j, y'_j, z'_j – współrzędne j -tego punktu pomiarowego w lokalnym układzie współrzędnych,

α, β, γ – elementarne macierze obrotu wokół osi: OX, OY i OZ trójwymiarowego układu współrzędnych,

μ – współczynnik skali,

x_0, y_0, z_0 – trzy składowe wektora translacji.

Podstawiając model transformacji dla pojedynczego punktu do równania błędów pomiarów otrzymuje się zależność **(Lewicka O. i in., 2022c)**:

$$\begin{bmatrix} v_x \\ v_y \\ v_z \end{bmatrix} = \begin{bmatrix} \mu & \gamma & -\beta \\ -\gamma & \mu & \alpha \\ \beta & -\alpha & \mu \end{bmatrix} \cdot \begin{bmatrix} x'_j \\ y'_j \\ z'_j \end{bmatrix} + \begin{bmatrix} x_0 \\ y_0 \\ z_0 \end{bmatrix} + \begin{bmatrix} x'_j \\ y'_j \\ z'_j \end{bmatrix} - \begin{bmatrix} x^r_j \\ y^r_j \\ z^r_j \end{bmatrix} \quad (2.22)$$

gdzie:

v_x, v_y, v_z – wektory poprawek współrzędnej x, y i z .

Zapisując parametry transformacji w jednym wektorze uzyskuje się następujące równanie **(Lewicka O. i in., 2022c)**:

$$\begin{bmatrix} v_x \\ v_y \\ v_z \end{bmatrix} = \begin{bmatrix} x'_j & 0 & -z'_j & y'_j & 1 & 0 & 0 \\ y'_j & z'_j & 0 & -x'_j & 0 & 1 & 0 \\ z'_j & -y'_j & x'_j & 0 & 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} \mu \\ \alpha \\ \beta \\ \gamma \\ x_0 \\ y_0 \\ z_0 \end{bmatrix} + \begin{bmatrix} x'_j \\ y'_j \\ z'_j \end{bmatrix} - \begin{bmatrix} x^r_j \\ y^r_j \\ z^r_j \end{bmatrix} \quad (2.23)$$

Jeżeli układ równań poprawek zawiera więcej równań niż poszukiwanych parametrów transformacji, to można je rozwiązać za pomocą równania normalnego **(Lewicka O. i in., 2022c)**:

$$A^T \cdot A \cdot X + A^T \cdot K = 0 \quad (2.24)$$

Wykorzystując zależność (2.24) można obliczyć macierz niewiadomych parametrów transformacji za pomocą metody nieoznaczonej wykorzystującej odwrotność macierzy współczynników równań normalnych **(Lewicka O. i in., 2022c)**:

$$X = -(A^T \cdot A)^{-1} \cdot A^T \cdot K \quad (2.25)$$

Po przeprowadzeniu procesu georeferencji zdjęć przystąpiono do utworzenia gęstej, trójwymiarowej chmury punktów przy użyciu techniki SfM **(Iglhaut J. i in., 2019)**. Algorytm SfM pozwala na obliczenie trójwymiarowych współrzędnych punktów powierzchni na podstawie zdjęć wykonanych z różnych odległości i pod różnymi kątami widzenia. Zasada tworzenia chmury punktów SfM opiera się na łączeniu zdjęć ze sobą na podstawie odwzorowanych, wspólnych cech na różnych obrazach **(Schonberger J.L., Frahm J.-M., 2016)**. Do tej pory algorytm SfM znalazł swoje zastosowanie w mapowaniu raf koralowych **(Casella E. i in., 2017)**, monitorowaniu gleb **(Hänsel P. i in., 2016)**

i obszarów leśnych (**Zahawi R.A., 2015**), a także do oceny zmian zachodzących w korycie rzek (**Marteau B. i in., 2017**).

Jednakże podczas tworzenia scen 3D z wykorzystaniem algorytmu SfM należy uwzględnić zjawisko załamania światła na granicy dwóch ośrodków (**Skarlatos D., Agrafiotis P., 2018**). Zjawisko to opisuje prawo Snella, które określa zmianę kierunku poruszania się wiązki światła przy przechodzeniu przez granicę między dwoma ośrodkami przezroczystymi o różnych współczynnikach załamania. W przypadku akwenu będzie to granica pomiędzy powietrzem a wodą.

Prawo Snella mówi, że promienie padający i załamany oraz prostopadła padania (normalna) leżą w jednej płaszczyźnie, a kąty spełniają zależność (**Born M., Wolf E., 1959**):

$$\frac{\sin(\theta_1)}{\sin(\theta_2)} = \frac{n_2}{n_1} = n_{21} \quad (2.26)$$

gdzie:

θ_1 – kąt padania, kąt między promieniem padającym a normalną do powierzchni granicznej ośrodków,

θ_2 – kąt załamania, kąt między promieniem załamanym a normalną,

n_1 – współczynnik załamania światła ośrodka pierwszego,

n_2 – współczynnik załamania światła ośrodka drugiego,

n_{21} – względny współczynnik załamania światła ośrodka drugiego względem pierwszego.

Prawo Snella ma istotny wpływ na chmurę punktów SfM powodując, że niektóre elementy tej chmury punktów znajdują się wyżej niż w rzeczywistości. Różnice te mogą prowadzić do błędów w późniejszym etapie przetwarzania danych, dlatego konieczne jest ich usunięcie. Można to zrobić za pomocą metody manualnej. Inny sposób polega na naniesieniu niezbędnych poprawek do modelu przy użyciu metody wykorzystującej indeks refrakcji (**Bagheri O. i in., 2015**) lub algorytmów uczenia maszynowego, takich jak np. regresja wektora nośnego (**Agrafiotis, P. i in., 2019**).

Prace nad modelem SVR powinny rozpocząć się od wstępnego przygotowania danych, na podstawie którego zostanie stworzony model predykcji. Na początku należy dokonać filtracji chmury punktów, usuwając punkty znajdujące się poza obszarem zainteresowania, czyli na obszarze lądowym. Następnym krokiem w przygotowaniu danych jest obliczenie głębokości względem wysokości zwierciadła wody. Można ją wyznaczyć metodą geodezyjną przy użyciu odbiornika GNSS RTK. Potem zaleca się usunięcie punktów znajdujących się powyżej powierzchni wody oraz tych, które przekraczają ustalony zakres ze zbioru danych. Na podstawie wcześniejszych badań przeprowadzonych w ramach eksperymentu ustalono, że maksymalna głębokość to 1 m (**Specht M. i in., 2023**).

Kolejnym etapem przygotowania danych jest utworzenie odpowiedników dla profili sondażowych, wzdłuż których wykonywano pomiar głębokości metodą geodezyjną przy użyciu odbiornika GNSS RTK, na podstawie wygenerowanej chmury punktów SfM. Wyznaczono je poprzez uśrednianie głębokości najbliższych elementów chmury punktów (± 10 cm od punktu wyznaczonego z wykorzystaniem odbiornika GNSS RTK).

Ponadto w celu zwiększenia dokładności modelu predykcji powinno się dokonać filtracji danych z ewentualnego szumu pomiarowego. Filtrację można wykonać manualnie lub wykorzystując kryterium statystyczne 2σ , polegające na usunięciu punktów, których odchylenie od wartości średniej

jest większe niż 2σ (95.4% obserwacji). Po odpowiednim przygotowaniu danych możliwe jest obliczenie nowej wartości średniej głębokości w punkcie.

Ostatnim etapem przygotowania danych treningowych jest normalizacja danych pomiarowych. Jest to konieczny proces z uwagi na wrażliwość algorytmu SVR na duże różnice skali pomiędzy poszczególnymi cechami (takimi jak głębokość) danych wejściowych (**Szostak B. i in., 2023**). Do przeprowadzenia normalizacji danych najczęściej stosuje się metodę Z-score (**Patro S.G., Sahu K.K., 2015**):

$$d_i^{norm} = \frac{d_i - \mu_d}{\sigma_d} \quad (2.27)$$

gdzie:

d_i^{norm} – znormalizowana wartość i -tej głębokości,

d_i – zmierzona wartość i -tej głębokości,

μ_d – wartość średnia głębokości,

σ_d – odchylenie standardowe pomiaru głębokości.

Po uprzednim przygotowaniu zbioru treningowego, znormalizowane dane głębokościowe wykorzystuje się do stworzenia modelu matematycznego dna akwenu. W tym celu można zastosować algorytm SVR, który umożliwia określenie takiej funkcji liniowej, aby jak największa liczba pomiarów głębokości znajdowała się nie dalej niż ε od aproksymowanej funkcji. Metoda SVR do aproksymacji funkcji wykorzystuje zależność (2.28), która w literaturze nazywana jest pierwszym problemem optymalizacyjnym (ang. *primal problem*) (**Smola A.J., Schölkopf B., 2004**):

$$\min_w f(w), f(w) \equiv \frac{1}{2} \cdot w^T \cdot w + C \cdot \sum_{i=1}^N \xi_{\varepsilon} (w; d_i, d_{ref_i}) \quad (2.28)$$

gdzie:

$f(w)$ – aproksymowana funkcja predykcji,

w – wektor wag,

C – dodatni hiperparametr określający oddziaływanie funkcji kosztów na wektor wag,

N – liczba danych,

ε – hiperparametr określający maksymalne odchylenie, odległość od aproksymowanej prostej,

ξ_{ε} – odległość od ε dla elementów zbioru treningowego znajdujących się poza założonym maksymalnym odchyleniem ($\xi_{\varepsilon} > 0$),

d_{ref_i} – rzeczywista, znormalizowana wartość i -tej głębokości.

Wspomniany problem optymalizacyjny to problem obliczeniowy, którego rozwiązanie polega na znalezieniu największej bądź najmniejszej wartości pewnego parametru problemu, która spełnia określoną własność. Parametr, którego największej bądź najmniejszej wartości szukamy, nazywa się funkcją kosztu (ang. *loss function*) (**Boyd S., Vandenberghe L., 2004**). W metodzie SVR funkcją kosztów jest ξ_{ε} czyli odległość od ε dla elementów zbioru treningowego znajdujących się poza założonym maksymalnym odchyleniem ($\xi_{\varepsilon} > 0$). Można ją wyznaczyć za pomocą wzoru (**Szostak B. i in., 2023**):

$$\xi_{\varepsilon} = \max \left(\left| \mathbf{w}^T \cdot \mathbf{d}_i - d_{ref_i} \right| - \varepsilon, 0 \right)^2 \quad (2.29)$$

Rozwiązanie pierwszego problemu optymalizacyjnego jest rozwiązaniem rekomendowanym dla zbiorów treningowych, które mają większą liczbę pomiarów niż badanych cech (**Pedregosa F. i in., 2011**). Algorytmem wykorzystywanym do rozwiązania pierwszego problemu optymalizacyjnego jest metoda TRON (ang. *Trust Region Newton Method*) (**Chia-Hua H., Chih-Jen L., 2012**). Jest to dwupoziomowy algorytm iteracyjnym, który odpowiada za: ustalenie wartości wektora wag ($\mathbf{w}^k$), określenie regionu zaufania (Δ_k) oraz sformułowanie modelowego równania kwadratowego (**Szostak B. i in., 2023**):

$$q_k(s) \equiv \nabla f(\mathbf{w}^k)^T \cdot s + \frac{1}{2} \cdot s^T \cdot \nabla^2 f(\mathbf{w}^k) \cdot s \quad (2.30)$$

gdzie:

$f(\mathbf{w}^k + s) - f(\mathbf{w}^k)$ – funkcja, która jest aproksymowana przez modelowe równanie kwadratowe $q_k(s)$,

$\nabla f(\mathbf{w})$ – gradient aproksymowanej funkcji liniowej,

$\nabla^2 f(\mathbf{w})$ – zgeneralizowany hesjan aproksymowanej funkcji,

s – krok optymalizacyjny, który określa kierunek poszukiwania wektora wag,

k – numer iteracji.

Poszukiwanie optymalnego kroku odbywa się za pomocą drugiej warstwy iteracyjnej wykorzystując warunek (**Szostak B. i in., 2023**):

$$\min_s q(s), \text{ dla } \|s\| \leq \Delta_k \quad (2.31)$$

Zakończenie procesu optymalizacyjnego polega na sprawdzeniu gradientu funkcji $\nabla f(\mathbf{w})$ w k -tej iteracji i porównaniu go z gradientem początkowym. Zależność tą można zapisać za pomocą (**Szostak B. i in., 2023**):

$$\|\nabla f(\mathbf{w}_k)\|_2 \leq \varepsilon_s \|\nabla f(\mathbf{w}_0)\|_2 \quad (2.32)$$

gdzie:

$\mathbf{w}_0$ – początkowy wektor wag,

ε_s – kryterium tolerancji określone przez użytkownika.

Drugim kryterium zakończenia procesu optymalizacyjnego jest wykonanie określonej liczby iteracji. Proces ten polega na wielokrotnym powtarzaniu tej samej operacji w pętli, aż spełnione zostaną przyjęte wcześniej kryteria.

Wynikiem implementacji algorytmu SVR jest model regresji liniowej, za pomocą którego korygowane są dane płytkowodne. Należy zwrócić uwagę, że utworzony model korekcji dokonuje przesunięcia poszczególnych elementów chmury punktów, zależnie od zarejestrowanej głębokości. Jak już wspomniano wcześniej, zastosowanie korekty danych jest konieczne dla punktów położonych poniżej zwierciadła wody, które są obciążone błędami wynikającymi z prawa Snella (**Gilbert P., 2021**).

Metoda SVR wykazuje wysoką efektywność w przypadku danych o wysokiej dokładności. Natomiast precyzyjną chmurę punktów SfM można uzyskać, gdy kamera fotogrametryczna pozwala na wykonywanie wysokorozdzielczych zdjęć, warunki oświetleniowe są korzystne, a punkty georeferencyjne zostały właściwie rozmieszczone. Poza tym kluczowe znaczenie ma utrzymanie odpowiedniej prędkości i wysokości lotu UAV, co przyczynia się do pozyskania danych fotogrametrycznych o wysokiej jakości. Dlatego metoda SVR została przetestowana z użyciem danych zarejestrowanych w dniach 2-3 czerwca 2022 r. na akwenu testowym. Podczas realizacji pomiarów fotogrametrycznych wykorzystano bezzałogowy statek powietrzny DJI Phantom 4 RTK, który posiada 1-calowy, 20 megapikselowy sensor CMOS. Zdjęcia lotnicze były wykonywane z niskiego pułapu na wysokości 80 m powyżej powierzchni terenu. Na ich podstawie wygenerowano początkową chmurę punktów UAV składającą się z 13 448 186 punktów (**Rys. 2.13**).



Rys. 2.13. Wygenerowana chmura punktów SfM dla akwenu testowego (opracowanie własne).

Na **Rys. 2.13** można zauważyć, że wygenerowana chmura punktów SfM nie pokrywa całego obszaru wodnego. Jest to spowodowane tym, że w niektórych miejscach nie odnaleziono punktów wiążących (ang. *tie points*). Co więcej, należy oczekiwać, że na akwenach morskich, które nie posiadają cech charakterystycznych, wygenerowany obszar wodny będzie niewielki.

Wygenerowaną chmurę punktów SfM można poddać próbkowaniu (ang. *subsampling*), które polega na zmniejszaniu rozmiaru chmury punktów poprzez usunięcie części punktów z zachowaniem istotnych cech lub właściwości zbioru danych. Proces ten pozwala na zmniejszenie ilości danych w chmurze bez utraty niezbędnych informacji. Dlatego postanowiono przeprowadzić próbkowanie danych zarejestrowanych na akwenu testowym. Po wykonaniu tego procesu chmura punktów UAV liczyła wówczas 5 875 928 punktów.

Następnie wykorzystując metodę SVR skorygowano dane płytkowodne znajdujące się między wysokością zwierciadła wody (160.415 m) a izobatą 1 m (**Rys. 2.14**). Należy zaznaczyć, że wysokość


zwierciadła wody została wyznaczona na podstawie uśrednionych pomiarów wysokościowych wykonanych przy użyciu odbiornika GNSS RTK w układzie PL-EVRF2007-NH.



Rys. 2.14. Chmura punktów wygenerowana za pomocą metody SVR dla akwenu testowego (opracowanie własne).

Na podstawie otrzymanych wyników należy stwierdzić, że chmura punktów wygenerowana za pomocą metody dla akwenu testowego charakteryzuje się wysoką dokładnością pomiaru głębokości do 1 m. Odchylenie standardowe błędów pomiaru głębokości wynosi 0.11 m. Natomiast dokładność pomiaru głębokości przy poziomie ufności 95% wynosi 0.22 m, co oznacza, że utworzony model predykcji pozwala spełnić minimalne wymagania dokładnościowe dla pomiarów hydrograficznych, które są realizowane w ramach kategorii specjalnej IHO.

Z przeprowadzonych analiz statystycznych wynika, że na 1 m² przypada średnio 26.60 punkta, przy odchyleniu standardowym wynoszącym 39.96 punkta. Minimalna liczba punktów w komórce regularnej siatki kwadratów jest równa 0, a maksymalna wartość wynosi 195. Wysoka rozbieżność pomiędzy minimalną a maksymalną liczbą punktów w komórce siatki GRID wynika z własności metody SVR, polegającej na zwracaniu danych batymetrycznych dla określonego zakresu głębokości. Miary R68 i R95 wynoszą odpowiednio 23 i 113 punktów. Ponadto można stwierdzić, że 9322 komórek w regularnej siatce kwadratów (43.72%) nie posiada żadnych danych. Na podstawie uzyskanych wartości miar statystycznych należy stwierdzić, że dane wygenerowane za pomocą metody SVR były pokryte nierównomiernie na badanym akwenu (**Rys. 2.15**).



Rys. 2.15. Histogram przedstawiający częstość występowania punktów wygenerowanych za pomocą metody SVR w komórce siatki GRID dla akwenu testowego (opracowanie własne).

2.1.3. Ekstrakcja linii brzegowej na podstawie danych LiDAR z lotniczego skaningu laserowego

Urządzenia optoelektroniczne są powszechnie stosowane do rejestracji danych batymetryczno-fotogrametrycznych w strefie brzegowej. Jednym z takich urządzeń pomiarowych jest montowany na bezzałogowych statkach powietrznych skaner laserowy LiDAR, który współpracuje z systemami GNSS i INS. System ten rejestruje współrzędne punktu terenowego w wybranych układach współrzędnych (Wehr A., Lohr U., 1999). Zarejestrowane, nieprzetworzone skany należy w pierwszej kolejności połączyć w jedną chmurę punktów. Trzeba pamiętać, że chmury punktów, które były rejestrowane z wykorzystaniem systemów GNSS i INS, posiadają georeferencję. Natomiast jeśli rejestrowano tylko dane LiDAR, to przed rozpoczęciem ich opracowania należy przeprowadzić proces georeferencji w oparciu o punkty georeferencyjne, które zostały pomierzone przy użyciu odbiornika GNSS RTK. Procedura nadania georeferencji chmurze punktów została opisana przy opracowaniu danych z kamery fotogrametrycznej w podrozdziale 2.1.2. Przed rozpoczęciem opracowania chmury punktów LiDAR należy ją oczyścić z ech i szumów występujących podczas rejestracji. LiDAR rejestruje odległość za pomocą wiązki lasera odbitej od różnych powierzchni. Wobec tego można oczekiwać wielokrotnych odbić od jednego celu. Precyzyjne oczyszczenie danych LiDAR obejmuje identyfikację oraz ręczne usunięcie ech i szumów. Istnieją również tradycyjne metody oczyszczania chmur punktów LiDAR opierające się na lokalnym dopasowaniu powierzchni (ang. *Moving Least Squares* – MLS) (Levin D., 1998), uśrednianiu wartości lub na założeniach statystycznych. Ponadto coraz częściej wykorzystuje się techniki uczenia maszynowego do oczyszczania danych LiDAR (Marais P. i in., 2019).


Przed rozpoczęciem opracowania danych LiDAR przystąpiono do wyboru docelowej metody ekstrakcji linii brzegowej. Wybór metody opierał się na ściśle sprecyzowanych kryteriach:

1. Metoda ma służyć wyłącznie do ekstrakcji linii brzegowej z cyfrowego modelu terenu lub z chmury punktów;
2. Dane pomiarowe mają zostać pozyskane za pomocą lotniczego skaningu laserowego;
3. Zaproponowana metoda ma spełniać wymagania dokładnościowe dla pomiarów hydrograficznych, które są realizowane w ramach kategorii specjalnej IHO.

Mając na uwadze powyższe kryteria wybrano trzy metody ekstrakcji linii brzegowej (Lee I.-C. i in., 2010; Liu H. i in., 2007; Xu S., Xu S., 2018). Ich dokładności wyznaczenia przebiegu linii brzegowej

przedstawiono w podrozdziale 1.2.2 (**Tab. 1.3**). Wszystkie trzy metody ekstrakcji linii brzegowej spełniają wymagania dla pomiarów hydrograficznych, które są realizowane w kategorii szczególnej IHO (dokładność horyzontalna 5 m ($p=0.95$)) (**IHO, 2022**). Na podstawie przeprowadzonej analizy porównawczej stwierdzono, że metoda zaproponowana przez Xu i in. wykazuje wyższą dokładność określenia przebiegu linii brzegowej (1 m) w porównaniu do pozostałych dwóch metod (1.5-4.5 m). Warto dodać, że przy wyznaczaniu linii brzegowej stosuje się inne miary dokładności niż podczas realizacji pomiarów batymetrycznych, ponieważ jej precyzyjne określenie może być trudne ze względu na zmienność warunków brzegowych.

Zdecydowano się wybrać metodę parametryczną zaproponowaną przez Xu i in. (**Xu S. i in., 2019**) również dlatego, że metoda ta opiera się na danych pochodzących z chmury punktów. Istotnym atrybutem tej metody jest uwzględnienie wyłącznie geometrycznych właściwości chmury punktów LiDAR do ekstrakcji linii brzegowej. Wybór tej metody był podyktowany również możliwością optymalizacji zmiennych pod konkretny rodzaj zbiornika, charakterystykę linii brzegowej oraz warunki pomiarowe (**Rys. 2.16**).



Rys. 2.16. Schemat blokowy przedstawiający etapy zmodyfikowanej metody ekstrakcji linii brzegowej (**Xu S. i in., 2019**) (opracowanie własne na podstawie: (**Lewicka O. i in., 2022b**)).

Pierwszy etap prac polega na identyfikacji i odrzuceniu punktów należących do obszaru wodnego. W tym celu stosuje się klasteryzację punktów w chmurze LiDAR za pomocą euklidesowej ekstrakcji klastrow (**Rusu R.B., 2009, 2010**). Klastery definiuje się jako zbiór obiektów, takich, że odległość pomiędzy dowolnymi obiektami w klastrze jest mniejsza niż odległość między dowolnym obiektem należącym do klastra a obiektem spoza klastra. Metoda ta jest efektywna dla danych, które nie zawierają wielu odbić od wody, co umożliwia znaczną redukcję punktów wodnych w chmurze. Jednakże należy zauważyć, że dla danych pokrywających akwen płytkowodny, metoda ta może nie spełnić oczekiwań w zakresie usuwania punktów wodnych. Warto również podkreślić, że algorytm

euklidesowej ekstrakcji klastrow wymaga określenia co najmniej trzech parametrów, takich jak minimalna i maksymalna liczba punktów w klastrze oraz tolerancja klastra (Xu S. i in., 2019). Aczkolwiek zmodyfikowana metoda parametryczna zaproponowana przez Halicki i in. wymaga wprowadzenia tylko jednego parametru, jakim jest minimalna liczba punktów w klastrze (Halicki A. i in., 2023).

Drugim z głównych etapów prac jest dopasowanie płaszczyzny przy użyciu metody RANSAC (Fischler M.A., Bolles R.C., 1981). Metoda ta jest inercyjną techniką wykorzystywaną do estymacji parametrów poszukiwanego modelu matematycznego w zbiorze danych, które zawierają znaczną liczbę punktów niepasujących do modelowej powierzchni. Dlatego estymator RANSAC może być używany do przetwarzania chmur punktów obciążonych szumem i błędnymi pomiarami. Co więcej, umożliwia on klasyfikację poszczególnych klastrow jako wodne lub lądowe, bazując na założeniu o płaskości akwenów. Prace nad algorytmem obejmują zasadniczo dwie fazy: inicjalizację i test.

Etap inicjalizacji polega na wyborze w sposób losowy trzech niewspółliniowych punktów. Następnie na podstawie wartości trzech wybranych punktów wyznaczane są parametry równania modelu płaszczyzny. Wynika to z faktu, że w przestrzeni trójwymiarowej płaszczyzna jest definiowana przez cztery parametry, z czego trzy są niezależne. Potem wszystkie pozostałe punkty są porównywane z utworzonym modelem płaszczyzny. Niezbędne jest zatem przyjęcie odpowiedniej wartości tolerancji. Zazwyczaj tolerancja ϵ określana jest jako maksymalna odległość weryfikowanego punktu od teoretycznego modelu. W dalszej kolejności sprawdzane jest, czy punkty, które spełniają kryterium tolerancji, nie przekraczają wcześniej zdefiniowanej wartości progowej δ (Derpanis K.G. i in., 2024). Z kolei określa się liczbę punktów pasującą do znalezionej płaszczyzny.

Algorytm RANSAC ma charakter iteracyjny. Oznacza to, że opisane powyżej etapy są powtarzane, dopóki maksymalna liczba iteracji nie zostanie osiągnięta. Jedynie model z największą liczbą pasujących punktów jest akceptowany jako właściwa płaszczyzna. W celu wykrycia kolejnych płaszczyzn należy usunąć z danych wejściowych punkty, które zostały już dopasowane, a następnie powtórzyć algorytm. Z całą pewnością zaletą algorytmu jest fakt, że potrafi on dopasować płaszczyznę, nawet gdy liczba błędnych pomiarów przekracza połowę obserwacji. Natomiast można przypuszczać, że metoda RANSAC nie sprawdzi się w przypadku małej liczby poprawnie zarejestrowanych punktów.

Po sklasyfikowaniu klastrow na wodne przeprowadza się ich weryfikację w oparciu o wskaźniki gęstościowo-odległościowe obliczone dla poszczególnych punktów (Smeets J. i in., 2013). Ten etap może zostać zastosowany w metodzie ekstrakcji linii brzegowej, ponieważ zakłada on, że odbicia od powierzchni wody, które są zidentyfikowane na podstawie wskaźnika płaskości, mogą pochodzić od płaskich obszarów lądowych. Wobec tego dopuszcza się możliwość reklasyfikacji klastrow lub usunięcia wybranych punktów z chmury LiDAR. W tym celu oblicza się dwie cechy: gęstość punktów (D), która jest liczona dla całego klastra oraz wysokość każdego punktu nad najbliższą płaszczyzną. Klasa obszaru C zostaje zmieniona na lądową, jeżeli gęstość punktów w klastrze D_c jest większa od przyjętej wartości progowej T_D :

$$D_c > T_D \quad (2.33)$$

Ponadto dokonuje się usunięcia wybranych punktów z chmury LiDAR. Punkt zostaje usunięty, jeżeli jego wysokość F będzie większa niż wartość progowa T_e :


$$F > T_e \quad (2.34)$$

W przypadku zmiany klasy obszaru na lądową przeprowadza się korektę rezultatów klasyfikacji wykonanej za pomocą metody RANSAC. Niemniej jednak ten etap nie jest obligatoryjny i może zostać pominięty.

Kolejnym bardzo ważnym etapem jest usunięcie punktów oznaczonych jako wodne i podział pozostałych punktów lądowych na klastry w oparciu o metodę euklidesowej ekstrakcji klastrów (**Rusu R.B., 2009, 2010**).


Powyższe dwa etapy opracowania danych LiDAR odnoszą się do danych, w których występują zarówno punkty lądowe, jak i wodne. Jednakże przy stosowaniu zmodyfikowanej metody ekstrakcji linii brzegowej należy rozważyć sytuację, gdy dane LiDAR pokrywają przede wszystkim część lądową badanego obszaru. Wówczas można pominąć etapy prac dotyczące identyfikacji obszarów wodnych, czyli klasyfikacji klastrów na wodne lub lądowe w oparciu o założenia dotyczące płaskości obszarów wodnych i ich weryfikację w oparciu o wskaźniki gęstościowo-odległościowe (**Halicki A. i in., 2023**).

Dalszy etap prac polega na wyselekcjonowaniu punktów granicznych tworzących linię brzegową dla danego klastra z wykorzystaniem algorytmu testowego (**Xu S. i in., 2019**). W tej metodzie zakłada się, że podczas inicjalizacji wszystkie punkty są traktowane jako nieoznaczone (zaklasyfikowane do klasy „unlabeled”). Co więcej, dla pojedynczego punktu P tworzona jest otoczka wypukła na podstawie wybranych jego k -najbliższych sąsiadów punktu. Punkty, które znajdują się wewnątrz otoczki, zostają oznaczone (zaklasyfikowane do klasy „labeled”). Poza tym, w otoczce wypukłej punkt P nie jest punktem brzegowym zbioru wypukłego S_w , jeżeli leży w trójkącie, którego wierzchołki znajdują się w S_w (**Wang J., Shan J., 2009**). Procedura ta jest powtarzana, dopóki wszystkie możliwe punkty nie zostaną oznaczone. Punkty nieoznaczone w końcowym etapie stanowią punkty graniczne tworzące linię brzegową (**Rys. 2.17**). Ponadto algorytm umożliwia usuwanie punktów, które są położone dalej niż T_d od pozostałych punktów.



Rys. 2.17. Schemat prezentujący zastosowanie algorytmu testowego (**Xu S. i in., 2019**) dla sztucznego zbioru 100 punktów. Początek algorytmu testowego na zbiorze testowym (a), pierwsza otoczka wypukła utworzona w ramach algorytmu testowego (b) i końcowy wynik algorytmu testowego (c) (**Halicki A. i in., 2023**).

Z całą pewnością algorytm testowy jest wart uwagi, ponieważ cechuje go duża odporność na błędne punkty. Natomiast problemem tego algorytmu jest niejednoznaczność wyznaczania przebiegu linii brzegowej na podstawie otrzymanego zbioru punktów. **Rys. 2.18** przedstawia różne sposoby łączenia punktów w celu ekstrakcji linii brzegowej.



Rys. 2.18. Problem niejednoznaczności wyznaczania przebiegu linii brzegowej na podstawie zbioru liczącego 5 punktów (Xu S. i in., 2019).

Po wyznaczeniu punktów granicznych autorzy zmodyfikowanej metody ekstrakcji linii brzegowej zaproponowali filtrację danych w oparciu o tzw. graniczną wysokość (ang. *elevation threshold*). Zastosowanie filtracji wynika z konieczności usunięcia punktów, które nie stanowią linii brzegowej. Takimi punktami mogą być drzewa lub pomosty. Wspominana filtracja polega na odrzuceniu punktów znajdujących się ponad wysokością H_{max} spośród potencjalnych punktów brzegowych. Autorzy zmodyfikowanej metody ekstrakcji linii brzegowej przyjęli wartość graniczną wysokości wynoszącą 2.5 m względem wysokości zwierciadła wody dla akwenu śródlądowego (Halicki A. i in., 2023).

Kolejna filtracja opiera się na krzywej wytyczonej na wodzie i biegnącej wzdłuż brzegu. Na początku należy wyznaczyć krzywą, która będzie złożona z N_w punktów wyrysowanych przez użytkownika i znajdujących się na akwenu wzdłuż linii brzegowej przy względnie stałej odległości od brzegu. Następnie wymagane jest obliczenie średniej odległości euklidesowej od utworzonej krzywej dla wszystkich potencjalnych punktów granicznych. W drugiej kolejności trzeba wykonać filtrację w oparciu o średnią odległość od utworzonej krzywej. Punkty znajdujące się dalej niż średnia odległość powinny zostać usunięte. Ostatni etap wymaga od użytkownika ręcznego wyrysowania linii brzegowej na podstawie punktów.

Metoda wyznaczania przebiegu linii brzegowej zaproponowana przez Xu i in. jest metodą parametryczną, co oznacza, że wymaga od użytkownika dostosowania etapów metody i ich parametrów pod zarejestrowane dane. Ponadto proces ekstrakcji linii brzegowej może być przeprowadzany różnie, zależnie od charakteru linii brzegowej lub warunków pogodowych. Na przykład należy mieć na uwadze, że nie wszystkie filtracje powinny być stosowane dla danego zestawu danych. Rozważmy linię brzegową, wzdłuż której występują liczne drzewa. Zastosowanie filtracji danych opartej na wysokości granicznej dla takiej linii brzegowej skutkuje uzyskaniem bardzo małej liczby punktów. W konsekwencji metoda pozwoli na ekstrakcję linii brzegowej z niską dokładnością. Dlatego istotny jest rozważny wybór odpowiednich filtrów. Podsumowując, parametry i etapy metody mogą się różnić w zależności od typu akwenu i właściwości otrzymanej chmury punktów.


Metodę ekstrakcji linii brzegowej zaproponowaną przez Xu i in. postanowiono przetestować na danych pozyskanych dla akwenu testowego. Dane LiDAR z ALS zostały zarejestrowane dnia 13 września 2023 r. przy użyciu skanera laserowego Velodyne Puck VLP-16 zintegrowanego z systemem GNSS/INS SBG Ellipse-D, który był zamontowany na UAV Aurelia X8 Standard LE. W wyniku pomiarów otrzymano chmurę punktów LiDAR zawierającą współrzędne prostokątne płaskie i wysokościowe punktów terenowych oraz informacje o intensywności odbicia promienia lasera. Zarejestrowana chmura punktów LiDAR pokrywa przede wszystkim część lądową badanego obszaru.

W pierwszym etapie opracowania danych LiDAR postanowiono oczyścić chmurę punktów z podwójnych odbić i szumów (**Rys. 2.19**). Ze względu na złożoność chmury wybrano metodę manualną.




Rys. 2.19. Oczyszczona chmura punktów LiDAR z ALS dla akwenu testowego (opracowanie własne).

LiDAR z 16 wiązkami laserowymi, pionowo oddzielonymi na przestrzeni 30° i rozdzielczości kątowej 2° umożliwia precyzyjne i trójwymiarowe skanowanie otoczenia. Co więcej, dane LiDAR charakteryzują się największą gęstością spośród wszystkich analizowanych danych geoprzestrzennych. Z przeprowadzonych analiz statystycznych wynika, że na 1 m^2 przypada średnio 63.26 punkta, przy odchyleniu standardowym wynoszącym 104.38 punkta. Minimalna liczba punktów w komórce siatki GRID jest równa 0, a maksymalna wartość wynosi aż 1068. Warto zwrócić uwagę, że miary R68 i R95 osiągnęły bardzo wysokie wartości wynoszące odpowiednio 52 i 283 punkty. Ponadto można stwierdzić, że 14 719 komórek w regularnej siatce kwadratów (27.59%) nie posiada żadnych danych (**Rys. 2.20**).




Rys. 2.20. Histogram przedstawiający częstość występowania punktów LiDAR z ALS w komórce siatki GRID dla akwenu testowego (opracowanie własne).

Następnie do wyznaczenia przebiegu linii brzegowej na akwencie testowym postanowiono wykorzystać zmodyfikowaną metodę Xu i in. zaproponowaną przez Halicki i in. (**Rys. 2.21**) (**Halicki A. i in., 2023**).



Rys. 2.21. Schemat blokowy przedstawiający wybrane etapy zmodyfikowanej metody ekstrakcji linii brzegowej (**Xu S. i in., 2019**) dostosowanej do danych LiDAR z ALS (opracowanie własne).

Jak można zauważyć na **Rys. 2.19**, dane LiDAR pokrywają przede wszystkim część lądową badanego obszaru. Dlatego można było pominąć cały etap dotyczący identyfikacji obszarów wodnych. Prace rozpoczęto dopiero od zastosowania filtrów gęstościowo-odległościowych. Na początku postanowiono zidentyfikować trajektorię UAV. Z tego powodu zastosowano filtr minimalnej wysokości (70 m). Następnie wykorzystując wysokość linii brzegowej akwenu (0 m) określono wartości dla następujących filtrów: maksymalnej wysokości (1 m), minimalnej wysokości (-1 m) i maksymalnej gęstości (50 pkt) w obszarze o promieniu (1 m). Potem zastosowano euklidesową ekstrakcję klastrow przy tolerancji (0.5) i minimalnej liczbie punktów w klastrze (1000 pkt). Proces ten pozwala na połączenie klastrow w jeden. W dalszej kolejności postanowiono wykryć krawędzie przy wykorzystaniu algorytmu otoczki wypukłej. W ten sposób otrzymano punkty wzdłuż granicy przefiltrowanych danych. Ostatni etap opracowania danych polegał na zastosowaniu dwukrotnie filtracji opartej o średnią odległość od trajektorii bezzałogowego statku powietrznego. Dodatkowo połączono otrzymane punkty. Linie brzegową wyznaczoną na podstawie danych LiDAR z ALS dla akwenu testowego przedstawiono na **Rys. 2.22**.



Rys. 2.22. Linia brzegowa wyrysowana na podstawie wygenerowanych punktów LiDAR z ALS i linia brzegowa wyznaczona przy użyciu punktów GCP dla akwenu testowego (opracowanie własne).

Na **Rys. 2.22** można zauważyć, że większość wygenerowanych punktów, które tworzą linię brzegową, znajduje się na pomostach. Metoda ekstrakcji linii brzegowej opiera się w całości na danych wysokościowych. Zastosowanie lotniczego skaningu laserowego dla tego akwenu spowodowało zarejestrowanie danych na pomostach. Wysokości te są zbliżone do tych zarejestrowanych wzdłuż linii brzegowej. Dlatego zostały one wzięte pod uwagę podczas ekstrakcji linii brzegowej. Już we wstępnym etapie następuje ograniczenie danych do zadanego zakresu wysokości. Zazwyczaj jest to ± 1 m od linii brzegowej. Dla akwenu testowego oznaczało to, że wśród wyselekcjonowanych punktów znajdują się również te, które leżą na pomostach. Ponadto w późniejszym etapie tworzona jest otoczka wypukła, która wyznacza punkty graniczne na podstawie zbioru danych. Jak już wspomniano wcześniej, problemem algorytmu otoczki wypukłej jest niejednoznaczność wyznaczania przebiegu linii brzegowej na podstawie otrzymanego zbioru punktów. W związku z tym, można przypuszczać, że ten etap przetwarzania danych LiDAR z ALS przyczynia się również do wyznaczenia linii brzegowej z uwzględnieniem pomostów.

Ponadto w celu oceny dokładności wyznaczonej linii brzegowej postanowiono przeprowadzić analizę dokładnościową. Polega ona na obliczeniu odległości pomiędzy wygenerowanymi punktami za pomocą metody ekstrakcji linii brzegowej a linią brzegową wyrysowaną na podstawie naziemnych punktów kontrolnych (ang. *Ground Control Point* – GCP) w najbliższym sąsiedztwie. Następnie na podstawie tych odległości obliczono miary statystyczne, takie jak: średnia arytmetyczna, odchylenie standardowe z populacji (σ) i $2.45 \cdot \sigma$ ($p=0.95$).

Na podstawie przeprowadzonych analiz statystycznych wynika, że dokładność ekstrakcji linii brzegowej z wykorzystaniem zmodyfikowanej metody Xu. i in. zaproponowanej przez Halicki i in. dla danych LiDAR z ALS zarejestrowanych na akwenu testowym wynosi: 1.24 m (średnia arytmetyczna), 1.37 m (σ) i 3.36 m ($2.45 \cdot \sigma$). Na podstawie miary $2.45 \cdot \sigma$ ($p=0.95$) można stwierdzić, że zaproponowana metoda spełnia minimalne wymagania dokładnościowe dla pomiarów hydrograficznych związanych

z określeniem przebiegu linii brzegowej, które są realizowane w ramach kategorii szczególnej IHO (błąd pozycji horyzontalnej ≤ 5 m ($p=0.95$)).

Podsumowując, zmodyfikowana metoda ekstrakcji linii brzegowej wykorzystująca dane LiDAR z ALS, na których występują przeszkody terenowe w pobliżu granicy między lądem a wodą, powinna być uzupełniana o inne dane. Brakujące dane można uzupełnić danymi z ortofotomapy. Ortofotomapy zapewniają wysoką rozdzielczość przestrzenną i dokładność, co umożliwi precyzyjne określenie przebiegu linii brzegowej. Z kolei można przypuszczać, że zmodyfikowana metoda ekstrakcji linii brzegowej opierająca się na danych LiDAR z ALS sprawdzi się na otwartych akwenach, gdzie nie występują przeszkody terenowe, takie jak np. pomosty.

2.1.4. Ekstrakcja linii brzegowej na podstawie danych LiDAR z mobilnego skaningu laserowego


Dane z mobilnego skaningu laserowego stanowią cenny zasób informacji w kontekście ekstrakcji linii brzegowej. Dlatego metodę ekstrakcji linii brzegowej zaproponowaną przez Xu i in. postanowiono przetestować na danych pozyskanych dla akwenu testowego. W związku z tym, że proces przetwarzania danych LiDAR z MLS jest przeprowadzany tak samo jak dla danych LiDAR z ALS, to postanowiono pominąć część dotyczącą szczegółowego opisu metody ekstrakcji linii brzegowej. Dane LiDAR z MLS zostały zarejestrowane dnia 30 kwietnia 2024 r. przy użyciu skanera laserowego Velodyne Puck VLP-16 zintegrowanego z systemem GNSS/INS SBG Ekinox2-U, który był zamontowany na bezzałogowej jednostce pływającej HydroDron-1. Należy zaznaczyć, że pomiary z wykorzystaniem mobilnego skaningu laserowego były wykonywane na wysokości ok. 1 m nad powierzchnią lustra wody.

W pierwszym etapie opracowania danych LiDAR z MLS przeprowadzono proces ich transformacji do układu prostokątnych płaskich PL-UTM (ang. *Universal Transverse Mercator*) (strefa 34N) i układu wysokościowego PL-EVRF2007-NH przy użyciu oprogramowania HYPACK. Następnie postanowiono oczyścić chmurę punktów z podwójnych odbić i szumów. Oczyszczona chmura punktów LiDAR z MSL została przedstawiona na **Rys. 2.23**.




Rys. 2.23. Oczyszczona chmura punktów LiDAR z MSL dla akwenu testowego (opracowanie własne).

Jak można zauważyć na **Rys. 2.23**, dane LiDAR precyzyjnie określiły położenie pomostów. Poza tym, wyraźnie widać granicę między lądem a wodą. Jednakże po oczyszczeniu danych jest ich zdecydowanie mniej niż w przypadku danych LiDAR pochodzących z ALS. Z przeprowadzonych analiz statystycznych wynika, że na 1 m² przypada średnio 44.53 punkta, przy odchyleniu standardowym wynoszącym 168.47 punkta. Minimalna liczba punktów w komórce siatki GRID jest równa 0, a maksymalna wartość wynosi aż 3161. Miary R68 i R95 wynoszą odpowiednio 1 i 260 punktów. Należy zwrócić uwagę, że miara R95 osiągnęła bardzo wysoką wartość. Ponadto można stwierdzić, że aż 30 604 komórek w regularnej siatce kwadratów (65.55%) nie posiada żadnych danych (**Rys. 2.24**).



Rys. 2.24. Histogram przedstawiający częstość występowania punktów LiDAR z MSL w komórce siatki GRID dla akwenu testowego (opracowanie własne).

Po uprzednim przygotowaniu danych przystąpiono do przetestowania zmodyfikowanej metody ekstrakcji linii brzegowej zaproponowanej przez Xu i in. na danych LiDAR z MLS. Na **Rys. 2.25** przedstawiono schemat blokowy przedstawiający wybrane etapy zmodyfikowanej metody ekstrakcji linii brzegowej (**Xu S. i in., 2019**) dostosowanej do danych LiDAR z MLS.



Rys. 2.25. Schemat blokowy przedstawiający wybrane etapy zmodyfikowanej metody ekstrakcji linii brzegowej (**Xu S. i in., 2019**) dostosowanej do danych LiDAR z MLS (opracowanie własne).

Jak można zauważyć na **Rys. 2.23**, dane LiDAR pokrywają przede wszystkim część lądową badanego obszaru, dlatego można było pominąć cały etap dotyczący identyfikacji obszarów wodnych. Prace rozpoczęto dopiero od zastosowania filtrów gęstościowo-odległościowych. Na początku wykorzystując wysokość linii brzegowej akwenu (0 m) określono wartości dla następujących filtrów: maksymalnej wysokości (0.5 m), minimalnej wysokości (-0.5 m) i maksymalnej gęstości (50 pkt) w obszarze o promieniu (1 m). Potem zastosowano euklidesową ekstrakcję klastrów przy tolerancji (0.5) i minimalnej liczbie punktów w klastrze (1000 pkt). Proces ten pozwala na połączenie klastrów w jeden. W dalszej kolejności postanowiono wykryć krawędzie przy wykorzystaniu algorytmu otoczki wypukłej. W ten sposób otrzymano punkty wzdłuż granicy przefiltrowanych danych. Ostatni etap opracowania danych polegał na zastosowaniu dwukrotnie filtracji opartej o średnią odległość od punktów wyznaczonych na akwenu wzdłuż linii brzegowej przy względnie stałej odległości od brzegu. Dodatkowo połączono otrzymane punkty. Linię brzegową wyznaczoną na podstawie danych LiDAR z MLS dla akwenu testowego przedstawiono na **Rys. 2.26**. Na jego podstawie można stwierdzić, że większość punktów tworzących linię brzegową została wygenerowana wzdłuż jej naturalnej granicy.

Ponadto w celu oceny dokładności wyznaczonej linii brzegowej postanowiono wykonać identyczną analizę odległościową jak dla danych LiDAR z ALS. Na podstawie przeprowadzonych analiz statystycznych wynika, że dokładność ekstrakcji linii brzegowej z wykorzystaniem zmodyfikowanej metody Xu. i in. zaproponowanej przez Halicki i in. dla danych LiDAR z MLS zarejestrowanych na akwenu testowym wynosi: 0.9 m (średnia arytmetyczna), 0.99 m (σ) i 2.43 m ($2.45 \cdot \sigma$). Na podstawie miary $2.45 \cdot \sigma$ ($p=0.95$) można stwierdzić, że zaproponowana metoda spełnia minimalne wymagania dokładnościowe dla pomiarów hydrograficznych związanych z określeniem przebiegu linii brzegowej, które są realizowane w ramach kategorii szczególnej IHO.



Rys. 2.26. Linia brzegowa wyrysowana na podstawie wygenerowanych punktów MSL i linia brzegowa wyznaczona przy użyciu punktów GCP dla akwenu testowego (opracowanie własne).


Badania wykazały, że zaproponowana metoda ekstrakcji linii brzegowej pozwala zdecydowanie dokładniej wyznaczyć jej naturalny przebieg na podstawie danych pozyskanych z wykorzystaniem LiDAR-u mobilnego niż LiDAR-u lotniczego. Wynikało to z tego, że prawie wszystkie punkty wyznaczone przy użyciu MLS były położone wzdłuż naturalnej granicy między lądem a wodą. Natomiast w przypadku ALS zdecydowana większość punktów tworzących linię brzegową akwenu została wygenerowana wzdłuż obrysu pomostów. Przyczyną tego stanu rzeczy są różne zakresy pola widzenia skanerów laserowych.

2.1.5. Ekstrakcja linii brzegowej na podstawie ortofotomapy

Ekstrakcja linii brzegowej na podstawie ortofotomapy jest procesem polegającym na identyfikacji i wyznaczeniu granicy między lądem a wodą na obrazie satelitarnym lub lotniczym. Proces ten może być wykonywany zarówno przez użytkownika poprzez ręczne wyrysowanie przebiegu linii brzegowej, jak i przy użyciu technik uczenia maszynowego (ang. *Machine Learning* – ML). Podejście oparte na uczeniu maszynowym polega na trenowaniu modeli na dużych zbiorach danych, które zawierają obrazy linii brzegowych, aby nauczyć się rozpoznawania cech charakterystycznych i wzorców dla linii brzegowych. Jak już wspomniano wcześniej, w celu opracowania modelu potrzebny jest duży zbiór danych, który będzie zawierał ortofotomapę z widoczną linią brzegową. W związku z tym i faktem, że wzdłuż rozpatrywanej linii brzegowej znajdują się liczne przeszkody terenowe, to postanowiono wyrysować ręcznie jej przebieg. Co więcej, dla akwenu testowego wyrysowano naturalną linię brzegową (**Rys. 2.27**), jak i linię brzegową przechodzącą przez pomosty (**Rys. 2.28**).



Rys. 2.27. Naturalna linia brzegowa wyrysowana na podstawie ortofotomapy i linia brzegowa wyznaczona przy użyciu punktów GCP dla akwenu testowego (opracowanie własne).



Rys. 2.28. Linia brzegowa uzupełniona o pomosty, która została wyrysowana na podstawie ortofotomapy i linia brzegowa wyznaczona przy użyciu punktów GCP dla akwenu testowego (opracowanie własne).

Jak można zauważyć na **Rys. 2.27** i **2.28** zarówno naturalna, jak i linia brzegowa uzupełniona o pomosty pokrywa się z linią brzegową wyznaczoną za pomocą punktów GCP. Potwierdza to również przeprowadzona analiza odległościowa. Średnia odległość między naturalną linią brzegową wyznaczoną na podstawie ortofotomapy a linią brzegową wyznaczoną za pomocą naziemnych punktów kontrolnych wynosi 0.04 m. Natomiast odchylenie standardowe z populacji i miara $2.45 \cdot \sigma$ ($p=0.95$) wynoszą odpowiednio 0.03 m i 0.07 m. Co więcej, dla linii brzegowej przechodzącej przez pomosty uzyskano również bardzo wysokie dokładności. Średnia odległość między linią brzegową uzupełnioną o pomosty i wyznaczoną na podstawie ortofotomapy a linią brzegową wyznaczoną za pomocą punktów GCP wynosi 0.04 m. Natomiast odchylenie standardowe z populacji i miara $2.45 \cdot \sigma$ ($p=0.95$) wynoszą odpowiednio 0.03 m i 0.08 m.

Podsumowując, metoda wyznaczania przebiegu linii brzegowej na podstawie ortofotomapy spełnia minimalne wymagania dokładnościowe dla pomiarów hydrograficznych, które są realizowane w ramach kategorii szczególnej IHO. Omówiona metoda może stanowić uzupełnienie zmodyfikowanej metody Xu. i in. zaproponowanej przez Halicki i in. lub być główną metodą wykorzystywaną do ekstrakcji linii brzegowej.


2.2. Etapy metody monitoringu batymetrycznego strefy brzegowej

W tym podrozdziale przedstawiono etapy metody monitoringu batymetrycznego strefy brzegowej. Należy zaznaczyć, że metoda ta będzie wykorzystywała dane pozyskane z sensorów pokładowych bezałogowych platform pomiarowych, takich jak: echosonda jednowiązkowa i wielowiązkowa, kamera fotogrametryczna oraz LiDAR z mobilnego i lotniczego skaningu laserowego. W ramach metody monitoringu batymetrycznego strefy brzegowej dane geoprzestrzenne będą przetwarzane przy użyciu trzech modułów: opracowania danych głębokowodnych, opracowania danych płytkowodnych

i wyznaczania linii brzegowej (**Rys. 2.29**). Ponadto zostanie opisana autorska metoda fuzji danych średnich ważonych, w której wagi dla poszczególnych źródeł danych będą ustalane na podstawie dokładności pomiaru.

Moduł opracowania danych głębokowodnych będzie wykorzystywał dane pochodzące wyłącznie z echosondy wielowiązkowej. Po zarejestrowaniu danych przez echosondę MBES, w pierwszej kolejności należy odnieść zmierzone głębokości przez echosondę wielowiązkową do obowiązującego w danym państwie układu wysokościowego. Przykładowo, na obszarze Polski głębokości mogą być podawane w układzie PL-EVRF2007-NH. Po odniesieniu głębokości do układu wysokościowego powinno się zidentyfikować, a następnie usunąć obserwacje odstające za pomocą metody wykrywania wartości odstających opartej na odległości: minimalnej i maksymalnej głębokości. Wstępna, automatyczna filtracja głębokości ma na celu eliminację błędów pomiarów wynikających m.in. z wpływu warunków atmosferycznych, zakłóceń w środowisku wodnym, czy z zanieczyszczeń na powierzchni przetwornika echosondy. Ponadto automatyczną filtrację danych można przeprowadzić wykorzystując jedną z pięciu powszechnie stosowanych metod wykrywania wartości odstających opartych na: statystyce, odległości, gęstości, klastrowaniu i modelowaniu powierzchni. Ostatni komponent modułu opracowania danych głębokowodnych polega na ręcznym usunięciu danych batymetrycznych. Procedura opracowania danych MBES i opis metod wykrywania wartości odstających zostały szczegółowo opisane w podrozdziale 2.1.1. Należy dodać, że dokładność pomiaru głębokości z wykorzystaniem echosondy interferometrycznej PING 3DSS-DX-450 podczas realizacji kampanii pomiarowej na akwenu testowym wyniosła 0.15 m ($p=0.95$).

Moduł opracowania danych płytkowodnych wykorzystuje dane zarejestrowane z trzech sensorów: echosondy jednowiązkowej (dane SBES), kamery fotogrametrycznej (dane fotogrametryczne) i odbiornika GNSS RTK (dane geodezyjne i georeferencyjne). Moduł ten pozwala na pozyskanie danych płytkowodnych na dwa sposoby. Pierwszy z nich polega na rejestracji danych batymetrycznych przy użyciu echosondy SBES. Procedura przetwarzania danych batymetrycznych pozyskanych z wykorzystaniem echosondy jednowiązkowej jest analogiczna jak w przypadku echosondy wielowiązkowej i została opisana w podrozdziale 2.1.1. Należy dodać, że dokładność pomiaru głębokości za pomocą echosondy jednowiązkowej SonarMite BTX podczas realizacji kampanii pomiarowej na akwenu testowym wyniosła 0.07 m ($p=0.95$) w zakresie głębokości od 0.4 m do 0.99 m i 0.06 m ($p=0.95$) w zakresie głębokości od 1 m do 7.09 m.



Rys. 2.29. Moduły opracowania danych pomiarowych (opracowanie własne).

Drugim sposobem pozyskania danych płytkowodnych jest wygenerowanie chmury punktów przy użyciu metody regresji wektora nośnego (**Agrafiotis P. i in., 2019**). Do jej utworzenia będą potrzebne dane zarejestrowane z dwóch sensorów: kamery fotogrametrycznej (dane fotogrametryczne) i odbiornika GNSS RTK (dane geodezyjne i georeferencyjne). W pierwszej kolejności należy wykorzystać zdjęcia lotnicze wykonane przez kamerę fotogrametryczną i trójwymiarowe współrzędne naziemnych punktów kontrolnych wyznaczone przy użyciu odbiornika GNSS RTK do przeprowadzenia procesu georeferencji zdjęć. Dalszy etap prac obejmuje utworzenie gęstej, trójwymiarowej chmury punktów przy wykorzystaniu techniki SfM. Po jej wygenerowaniu można zauważyć, że niektóre elementy chmury punktów znajdują się wyżej niż w rzeczywistości. Różnice te mogą prowadzić do błędów w późniejszym etapie przetwarzania danych, dlatego konieczne jest ich usunięcie. W tym celu można zastosować algorytm uczenia maszynowego oparty na regresji wektora nośnego. Prace nad modelem SVR powinny rozpocząć się od wstępnego przygotowania danych, na podstawie którego zostanie stworzony model predykcji. Na początku należy dokonać filtracji chmury punktów, usuwając punkty znajdujące się poza obszarem zainteresowania, czyli na obszarze lądowym. Następnym krokiem w przygotowaniu danych jest obliczenie głębokości względem wysokości zwierciadła wody. Potem zaleca się usunięcie punktów znajdujących się powyżej powierzchni wody oraz tych, które przekraczają ustalony zakres ze zbioru danych. Na podstawie wcześniejszych badań przeprowadzonych w ramach eksperymentu ustalono, że maksymalna głębokość to 1 m. Kolejnym etapem przygotowania danych jest utworzenie odpowiedników dla profili sondażowych, wzdłuż których wykonywano pomiar głębokości metodą geodezyjną przy użyciu odbiornika GNSS RTK, na podstawie wygenerowanej chmury punktów SfM. Wyznaczono je poprzez uśrednianie głębokości najbliższych elementów chmury punktów (± 10 cm od punktu wyznaczonego z wykorzystaniem odbiornika GNSS RTK). Ponadto w celu zwiększenia dokładności modelu predykcji powinno się dokonać filtracji danych z ewentualnego szumu pomiarowego. Filtrację można wykonać manualnie lub wykorzystując kryterium statystyczne 2σ . Po odpowiednim przygotowaniu danych możliwe jest obliczenie nowej wartości średniej głębokości w punkcie. W dalszej kolejności należy dokonać procesu ich normalizacji. Jest to konieczny proces z uwagi na wrażliwość algorytmu SVR na duże różnice skali pomiędzy poszczególnymi cechami (takimi jak głębokość) danych wejściowych. Do przeprowadzenia normalizacji danych najczęściej stosuje się metodę Z-score. Po uprzednim przygotowaniu zbioru treningowego, znormalizowane dane głębokościowe wykorzystuje się do stworzenia modelu matematycznego dna akwenu. W tym celu można zastosować algorytm SVR, który umożliwia określenie takiej funkcji liniowej, aby jak największa liczba pomiarów głębokości znajdowała się nie dalej niż ϵ od aproksymowanej funkcji (**Smola A.J., Schölkopf B., 2004**). Aby wyznaczyć aproksymowaną funkcję należy rozwiązać pierwszy problem optymalizacyjny przy użyciu metody TRON (**Lin C.-J. i in., 2008**). Wynikiem implementacji algorytmu SVR jest model regresji liniowej, za pomocą którego korygowane są dane płytkowodne. Trzeba zaznaczyć, że zastosowanie korekty danych jest konieczne dla punktów położonych poniżej zwierciadła wody, które są obarczone błędami wynikającymi z prawa Snella. Metoda SVR została szczegółowo opisana w podrozdziale 2.1.2. Należy dodać, że dokładność pomiaru głębokości za pomocą metody SVR podczas realizacji kampanii pomiarowej na akwenu testowym wyniosła 0.22-0.24 m ($p=0.95$) na głębokościach nieprzekraczających 1 m. Jednakże dla zakresu głębokości do 2 m, błąd pozycji wertykalnej przy poziomie ufności 95% przekracza wartość 0.3 m na analizowanym akwenu.

Trzecim modułem metody monitoringu batymetrycznego strefy brzegowej jest wyznaczenie linii brzegowej. Do określenia jej przebiegu można wykorzystać dane pozyskane z czterech sensorów: kamery fotogrametrycznej (dane fotogrametryczne), lotniczego skaningu laserowego (dane LiDAR z ALS), mobilnego skaningu laserowego (dane LiDAR z MLS) i odbiornika GNSS RTK (dane


georeferencyjne). W pierwszej kolejności należy dokonać automatycznego usunięcia danych z tzw. szumów wykorzystując jedną z metod wykrywania wartości odstających. Następnie zaleca się ręczne usunięcie danych zakwalifikowanych jako błędnie zarejestrowane. Potem można rozpocząć proces ekstrakcji linii brzegowej z wykorzystaniem zmodyfikowanej metody Xu i in. (Xu S. i in., 2019). Na początku w ramach tej metody należy dokonać wstępnej selekcji danych LiDAR. Do wstępnej selekcji danych chmury punktów LiDAR z ALS można wykorzystać filtry opierające swoje działanie na minimalnej i maksymalnej wysokości oraz maksymalnej gęstości w obszarze o promieniu. W dalszej kolejności dokonuje się euklidesowej ekstrakcji klastrów przy zadanej tolerancji i minimalnej liczbie punktów w klastrze (Rusu R.B., 2009). Proces ten pozwala na połączenie klastrów w jeden. Dzięki tak połączonym klastrów zostają następnie wskazane potencjalne punkty brzegowe przy wykorzystaniu algorytmu testowego opartego o otoczkę wypukłą. W wyniku działania tego algorytmu otrzymuje się punkty wzdłuż granicy przefiltrowanych danych. Poza tym, należy jeszcze wykonać detekcję danych w oparciu o średnią odległość. W przypadku danych LiDAR z ALS zastosowano detekcję opartą o średnią odległość od trajektorii UAV. Wykonuje się ją w celu odrzucenia punktów granicznych znajdujących się dalej od brzegu. Po przeprowadzeniu tej operacji otrzymuje się linię brzegową wyznaczoną na podstawie danych LiDAR z ALS. Procedura opracowania danych LiDAR z ALS została szczegółowo opisana w podrozdziale 2.1.3. Należy dodać, że dokładność wyznaczenia przebiegu linii brzegowej na podstawie danych LiDAR z ALS podczas realizacji kampanii pomiarowej na akwenu testowym wyniosła 3.36 m ($p=0.95$).

Drugi sposób wyznaczenia linii brzegowej polega na wykorzystaniu danych LiDAR z MLS. W pierwszej kolejności należy dokonać automatycznego usunięcia danych z tzw. szumów. Następnie zaleca się ręczne usunięcie danych zakwalifikowanych jako błędnie zarejestrowane. Potem można rozpocząć proces ekstrakcji linii brzegowej z wykorzystaniem zmodyfikowanej metody Xu i in. (Xu S. i in., 2019). Na początku w ramach tej metody należy dokonać wstępnej filtracji danych LiDAR. Do wstępnej selekcji danych chmury punktów LiDAR z MLS można wykorzystać filtry opierające swoje działanie na minimalnej i maksymalnej wysokości oraz maksymalnej gęstości w obszarze o promieniu. W dalszej kolejności dokonuje się euklidesowej ekstrakcji klastrów przy zadanej tolerancji i minimalnej liczbie punktów w klastrze (Rusu R.B., 2009). Proces ten pozwala na połączenie klastrów w jeden. Dzięki tak połączonym klastrów zostają następnie wskazane potencjalne punkty brzegowe przy wykorzystaniu algorytmu testowego opartego o otoczkę wypukłą. W wyniku działania tego algorytmu otrzymuje się punkty wzdłuż granicy przefiltrowanych danych. Poza tym, należy jeszcze wykonać detekcję danych w oparciu o średnią odległość. W przypadku danych LiDAR z MLS zastosowano detekcję danych opartą o średnią odległość od punktów wyznaczonych na akwenu wzdłuż linii brzegowej przy względnie stałej odległości od brzegu. Wykonuje się ją w celu odrzucenia punktów granicznych znajdujących się dalej od brzegu. Po przeprowadzeniu tej operacji otrzymuje się linię brzegową wyznaczoną na podstawie danych LiDAR z MLS. Procedura opracowania danych LiDAR z MLS została szczegółowo opisana w podrozdziale 2.1.4. Należy dodać, że dokładność wyznaczenia przebiegu linii brzegowej na podstawie danych LiDAR z MLS podczas realizacji kampanii pomiarowej na akwenu testowym wyniosła 2.43 m ($p=0.95$).

Trzeci sposób wyznaczenia linii brzegowej polega na wykorzystaniu zdjęć lotniczych wykonanych przez kamerę fotogrametryczną i trójwymiarowych współrzędnych naziemnych punktów kontrolnych wyznaczonych przy użyciu odbiornika GNSS RTK. W pierwszej kolejności należy przeprowadzić proces georeferencji zdjęć. Następnie na podstawie zgeoreferowanych obrazów tworzone są chmura punktów i NMT, które zawierają informacje o wysokości terenu. Potem zdjęcia są projektowane na powierzchnię terenu. Proces projekcji obrazów polega na dostosowaniu zdjęć wykonanych z UAV do

numerycznego modelu terenu, aby uwzględnić zniekształcenia perspektywiczne i różnice w wysokości terenu. Kolejny etap prac przy tworzeniu ortofotomapy to nakładanie tzw. tekstury, czyli szczegółów i wzorów, które są widoczne na powierzchni terenu, takie jak budynki, drogi, drzewa i inne elementy krajobrazu. Nakładając teksturę na NMT możliwe jest uzyskanie ortofotomapy, która odzwierciedla rzeczywiste cechy terenu, takie jak kształty i kolory obiektów, zachowując jednocześnie poprawne proporcje i dokładność. Następnym, dodatkowym etapem jest sprawdzenie jakości oraz dokładności uzyskanej ortofotomapy. W wyniku połączenia zdjęć lotniczych otrzymuje się ortofotomapę, na podstawie której należy przeprowadzić proces ekstrakcji linii brzegowej. Może ona być wykonana zarówno przez użytkownika poprzez ręczne wyznaczenie jej przebiegu, jak i przy użyciu technik uczenia maszynowego. Procedura opracowania danych fotogrametrycznych została szczegółowo opisana w podrozdziale 2.1.5. Należy dodać, że dokładność wyznaczenia przebiegu linii brzegowej na podstawie danych ortofotomapy podczas realizacji kampanii pomiarowej na akwenu testowym wyniosła 0.07 m ($p=0.95$) dla naturalnej linii brzegowej i 0.08 m ($p=0.95$) dla linii brzegowej z pomostami.

Ostatnim modułem metody monitoringu batymetrycznego strefy brzegowej jest wielosensoryczna fuzja danych (**Rys. 2.30**). W ramach tego modułu dane pozyskane z sensorów pokładowych bezzałogowych platform pomiarowych będą łączone ze sobą w celu odwzorowania ukształtowania strefy brzegowej.



Rys. 2.30. Moduł wielosensorycznej fuzji danych (opracowanie własne).

Aby można było zastosować metodę średnich ważonych, należy uprzednio obliczyć wagi dla poszczególnych danych. Do ich wyznaczenia postanowiono zmodyfikować wzór pozwalający obliczyć funkcję wagową stosowaną w metodzie odwrotnych ważonych odległości (IDW), która jest zależna od odległości pomiędzy punktem pomiarowym a punktem interpolowanym (Lu G.Y., Wong D.W., 2008). Na potrzeby wielosensorycznej fuzji danych zastąpiono tą odległość na dokładność pomiaru punktu. Funkcję wagową w metodzie średnich ważonych można obliczyć za pomocą następującej zależności:

$$w_i = \frac{1}{(a_i)^u} \quad (2.35)$$

gdzie:

w_i – waga i -tego punktu,

a_i – dokładność pomiaru głębokości/współrzędnych prostokątnych płaskich i -tego punktu ($p=0.95$),

u – wykładnik potęgi.

Należy zauważyć, że wartości wagi są odwrotnie proporcjonalne do dokładności pomiaru punktu. Drugim czynnikiem wpływającym na wyznaczenie głębokości punktu będzie wykładnik potęgi u , który jest wykorzystywany w metodzie odwrotnych odległości do potęgi (ang. *Inverse Distance to a Power* – IDP) (Bartier P.M., Keller C.P., 1996; Davis J.C., 2002). Na podstawie przeprowadzonych badań w tym zakresie wynika, że do wyznaczenia wartości funkcji wagowej najczęściej przyjmuje się wartość wykładnika potęgi wynoszącą 1 lub 2 (Babak O., Deutsch C.V., 2008; Maleika W., 2020).

Znając funkcję wagową można obliczyć średnią ważoną głębokości w m -tej komórce siatki GRID:

$$\bar{d}_m = \frac{\sum_i^M w_i \cdot d_i}{\sum_i^M w_i} = \frac{\sum_i^M \frac{d_i}{(a_i)^u}}{\sum_i^M \frac{1}{(a_i)^u}} \quad (2.36)$$

gdzie:

$\bar{d}_m$ – średnia ważona głębokości w m -tej komórce siatki GRID,

M – liczba punktów leżących w m -tej komórce siatki GRID.

Jak wynika z równania (2.36) metoda średniej ważonej głębokości nie może być zastosowana na punktach linii brzegowej, ponieważ mają one zawsze tą samą głębokość (0 m). Z tego powodu postanowiono użyć metody średnich ważonych współrzędnych prostokątnych płaskich dla tych punktów. Metoda ta zakłada, że na początku wybierane są komórki siatki GRID, które zawierają punkty linii brzegowej. Dopiero potem można wyznaczyć średnie ważne współrzędnych prostokątnych płaskich w komórkach regularnej siatki kwadratów:

$$\bar{x}_m = \frac{\sum_i^M w_i \cdot x_i}{\sum_i^M w_i} = \frac{\sum_i^M \frac{x_i}{(a_i)^u}}{\sum_i^M \frac{1}{(a_i)^u}} \quad (2.37)$$

$$\bar{y}_m = \frac{\sum_i^M w_i \cdot y_i}{\sum_i^M w_i} = \frac{\sum_i^M \frac{y_i}{(a_i)^u}}{\sum_i^M \frac{1}{(a_i)^u}} \quad (2.38)$$


gdzie:

$\bar{x}_m, \bar{y}_m$ – średnie ważone współrzędnych prostokątnych płaskich w m -tej komórce siatki GRID zawierającej punkty linii brzegowej.

2.3. Ustalenie metody monitoringu batymetrycznego strefy brzegowej

Po oczyszczeniu danych batymetrycznych należy dokonać ich integracji. W tym celu zastosowanie środowiska GIS jest kluczowe, ponieważ pozwala ono na przeprowadzenie fuzji danych pochodzących z różnych źródeł. Poza tym, w środowisku GIS można tworzyć własne modele fuzji, co umożliwia dostosowanie procesu łączenia danych do konkretnego akwenu. Dzięki temu proces fuzji danych może być dostosowany do badanego obszaru, co z kolei przekłada się na uzyskanie bardziej dokładnego modelu.

W pierwszej kolejności opracowane dane głębokowodne, płytkowodne i obejmujące linie brzegową należy przygotować w formacie warstwy wektorowej np. .shp (shapefile). Należy również upewnić się, że wszystkie dane dotyczą tego samego obszaru, czyli są zapisane w tym samym układzie współrzędnych prostokątnych płaskich. Co więcej, zaleca się wykonanie dodatkowego oczyszczania danych. Mając widok na wszystkie dane można zweryfikować te błędnie zarejestrowane. Dotyczy to szczególnie danych, które zostały pozyskane za pomocą metody SVR. Potwierdzają to dane SVR, które obejmowały niewielki obszar z głębokościami powyżej 3 m. Wobec czego postanowiono usunąć te dane. Ponadto usunięto dane SVR, które znalazły się w granicach linii brzegowej. Wynika to z faktu, że w pobliżu linii brzegowej występuje zjawisko załamania fali, a to z kolei uniemożliwia dokładne wyznaczenie głębokości akwenu. Podsumowując, usunięto łącznie 530 punktów SVR. Pozostałe dane nie wymagały zmian. Całkowita liczba danych wyniosła 126 242 punkty. Na **Rys. 2.31** przedstawiono lokalizację przetworzonych danych geoprzestrzennych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na akwencie testowym.



Rys. 2.31. Lokalizacja przetworzonych danych geoprzestrzennych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na akwenu testowym (opracowanie własne).

Jak można zauważyć na **Rys. 2.31**, nie została uwzględniona naturalna linia brzegowa (bez budowli hydrotechnicznych i innych) wyrysowana na podstawie ortofotomapy. Została ona pominięta, ponieważ w przypadku tego akwenu bardziej odpowiednia jest linia brzegowa obejmująca pomosty. Decyzja ta wynika z faktu, że w opracowanej metodzie monitoringu batymetrycznego strefy brzegowej można wybrać tylko jedną linię brzegową.

Następny etap prac obejmuje obliczenie wag dla poszczególnych danych. Wobec tego postanowiono obliczyć wagi dla poszczególnych danych zarejestrowanych podczas kampanii pomiarowej na akwenu testowym zakładając, że wartość wykładnika potęgi będzie wynosić 1 i 2. Zestawienie wag dla poszczególnych danych pomiarowych zarejestrowanych podczas realizacji pomiarów batymetryczno-fotogrametrycznych na akwenu testowym przedstawiono w **Tab. 2.1**.

Tab. 2.1. Zestawienie wag dla poszczególnych danych zarejestrowanych podczas kampanii pomiarowej na akwenu testowym (opracowanie własne).

Dane	Dokładność pomiaru głębokości/ współrzędnych płaskich ($p=0.95$)	$w(u=1)$	$w(u=2)$
MBES	0.15	6.67	44.44
SBES (zakres głębokości 1-7.09 m)	0.06	16.67	277.78
SBES (zakres głębokości 0.4-0.99 m)	0.07	14.29	204.08
SVR	0.23*	4.35	18.90
LiDAR z ALS	3.36	0.30	0.09
LiDAR z MLS	2.43	0.41	0.17
Fotogrametryczne (naturalna linia brzegowa)	0.07	14.29	204.08
Fotogrametryczne (linia brzegowa z pomostami)	0.08	12.50	156.25

* Uśredniona dokładność pomiaru głębokości ($p=0.95$) dla danych płytkowodnych wygenerowanych przy użyciu metody SVR.

Przykładowo, dla danych zarejestrowanych przy użyciu echosondy SBES w zakresie głębokości od 1 m do 7.09 m, które charakteryzowały się największą dokładnością pomiaru (0.06 m ($p=0.95$)), waga ma najwyższą wartość wynoszącą 16.67 dla $u=1$ i 277.78 dla $u=2$. Natomiast dla danych LiDAR z ALS, które charakteryzowały się najniższą dokładnością pomiaru (3.36 m ($p=0.95$)), waga ma najmniejszą wartość wynoszącą 0.30 dla $u=1$ i 0.09 dla $u=2$. Na podstawie **Tab. 2.1** można stwierdzić, że wartość wagi rośnie wraz z dokładności pomiaru dla wykładnika potęgi $u=1$. Natomiast zwiększenie wartości wykładnika potęgi z 1 na 2 spowodowało przyrost wartości wagi dla danych, których dokładność pomiaru była większa niż 1 m (MBES, SBES, SVR i fotogrametryczne), a także doprowadziło do obniżenia wartości wagi dla danych, których dokładność pomiaru była mniejsza od 1 m (LiDAR).


W dalszej kolejności postanowiono połączyć wszystkie dane batymetryczne. Można to zrobić za pomocą narzędzia „Merge” dostępnego w oprogramowaniu ArcGIS Pro i QGIS. Na podstawie danych połączonych w jedną warstwę wektorową wygenerowano siatkę GRID o długości boku 0.5 m, ponieważ umożliwia ona dokładne odwzorowanie ukształtowania terenu. Należy zaznaczyć, że zastosowanie regularnej siatki kwadratów o większej długości boku mogłoby doprowadzić do znaczących błędów wynikających z dużych odległości między punktami pomiarowymi.

Wygenerowana siatka GRID pokrywa zazwyczaj większy obszar, aby zapewnić pełne pokrycie badanej powierzchni. Wobec tego zdecydowano się wybrać tylko te komórki w siatce GRID, które zawierają dane przy użyciu narzędzia „Select by location”. W efekcie wyselekcjonowano 65 635 komórek GRID na analizowanym akwenie.

Kolejny ważny etap dotyczy dołączenia danych batymetrycznych do komórek siatki GRID. Proces ten można przeprowadzić korzystając z narzędzia „Spatial join” w oprogramowaniu ArcGIS Pro lub „Join attributes by location” w programie QGIS. Dzięki wykorzystaniu tego narzędzia można uzyskać warstwę GRID, która zawiera również informacje pochodzące z połączonej warstwy wektorowej.


W celu uzyskania pełnego pokrycia terenu danymi i wizualizacji ukształtowania strefy brzegowej, zdecydowano się przypisać pustym komórkom siatki GRID wartości głębokości za pomocą metody naturalnego sąsiada (**Lewicka O., 2023a**). Wybrano tę metodę, ponieważ wcześniejsze badania wykazały, że sprawdza się ona doskonale w przypadku danych wielomodalnych. Zgodnie z wynikami badań (**Lewicka O., 2023b**), metoda naturalnego sąsiada uzyskała najwyższy współczynnik determinacji (0.999). Co więcej, metoda ta osiągnęła najniższą wartość miary R68 (0.01 m). Dodatkowo jej niski poziom złożoności obliczeniowej umożliwia łatwą integrację z innymi metodami modelowania ukształtowania strefy brzegowej. W związku z tym, metoda naturalnego sąsiada została zastosowana wyłącznie w celu wizualizacji danych i nie była użyta do oceny dokładności modelu fuzji danych średnich ważonych.

Ostatnim etapem jest obliczenie głębokości dla każdej komórki GRID za pomocą metody średniej ważonej. Opisana metoda w środowisku GIS została przedstawiona na **Rys. 2.32**.



Rys. 2.32. Moduł wielosensorycznej fuzji danych w środowisku GIS (opracowanie własne).


Na **Rys. 2.33** przedstawiono model fuzji danych średnich ważonych o wykładniku potęgi 1 w lokalnym układzie wysokościowym dla akwenu testowego.



Rys. 2.33. Model fuzji danych średnich ważonych o wykładniku potęgi 1 w lokalnym układzie wysokościowym dla akwenu testowego (opracowanie własne).

Jak można zauważyć na wygenerowanym modelu bardzo dobrze widać przebieg linii brzegowej. Wynika to z faktu, że komórki GRID były generowane tylko w miejscach, gdzie występowały dane batymetryczne. Największe zagęszczenie komórek GRID występuje na obszarze pomierzonym przez echosondę MBES. Z kolei najmniej danych jest pomiędzy izobatą 1 m a 3 m. Na tym obszarze użyto danych batymetrycznych pochodzących z echosondy SBES. Na uwagę zasługują dane pomiarowe uzyskane metodą SVR. Dane te umożliwiły uzyskanie bardzo dużego pokrycia danymi na obszarach trudnodostępnych. Maksymalna i minimalna głębokość akwenu wynoszą odpowiednio 11.06 m i 0 m. Średnia głębokość to 3.93 m, a średnia kwadratowa (ang. *Root Mean Square* – RMS) głębokości wynosi 3.17 m.

Na **Rys. 2.34** przedstawiono model fuzji danych średnich ważonych o wykładniku potęgi 2 w lokalnym układzie wysokościowym dla akwenu testowego.



Rys. 2.34. Model fuzji danych średnich ważonych o wykładniku potęgi 2 w lokalnym układzie wysokościowym dla akwenu testowego (opracowanie własne).

Wizualnie **Rys. 2.33** i **Rys. 2.34** prezentują się tak samo. Wynika to z zastosowania tej samej skali głębokości. Ponadto maksymalna i minimalna głębokość akwenu wynoszą odpowiednio 11.06 m i 0 m. Średnia głębokość akwenu to 3.93 m, a średnia kwadratowa głębokości wynosi 3.17 m. Natomiast warto zwrócić uwagę, że średnia różnica głębokości komórek GRID pomiędzy dwoma modelami wyniosła 0.0004 m.

Prace nad przygotowaniem metody monitoringu batymetrycznego strefy brzegowej rozpoczęto od opisanie etapów opracowania danych batymetryczno-fotogrametrycznych pozyskanych przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych, takich jak: echosonda jednowiązkowa i wielowiązkowa, kamera fotogrametryczna oraz LiDAR z mobilnego i lotniczego skaningu laserowego. Następnie zastosowano opisane etapy opracowania danych batymetryczno-fotogrametrycznych do danych geoprzestrzennych zarejestrowanych podczas kampanii pomiarowej na akwenu testowym, w celu optymalizacji metody. Co więcej, szczegółowo opisano metodę średnich ważonych i proces dobierania do niej wag na przykładzie akwenu testowego. Zastosowanie danych testowych umożliwiło w rezultacie na opracowanie autorskiej metody monitoringu batymetrycznego strefy brzegowej. Metoda monitoringu batymetrycznego strefy brzegowej, oparta na fuzji wielomodalnych danych geoprzestrzennych, umożliwia odwzorowanie ukształtowania dna akwenu. Jej skuteczność opiera się na integracji danych geoprzestrzennych pozyskanych z różnych sensorów.

3. Badanie i weryfikacja metody modelowania powierzchni terenu w strefie brzegowej

Głównym celem niniejszego rozdziału jest ocena dokładności zaproponowanej metody modelowania powierzchni terenu w strefie brzegowej. W pierwszej części tego rozdziału zostanie omówiona realizacja i opracowanie danych geoprzestrzennych zarejestrowanych podczas czterech kampanii pomiarowych, które przeprowadzono na dwóch akwenach (morskim i śródlądowym) w latach 2022-2023. Warto zaznaczyć, że w trakcie realizacji tych kampanii nie użyto jednocześnie (podczas jednego dnia) wszystkich dostępnych sensorów pokładowych bezzałogowych platform pomiarowych (ALS, MBES, MLS, SBES i UAV). Ograniczyło to możliwość dokonania pełnej analizy otrzymanych modeli fuzji danych średnich ważonych. Z tego powodu podjęto decyzję o przeprowadzeniu kompleksowej, jednodniowej kampanii pomiarowej na wybranym akwencie, podczas której zostaną wykorzystane wszystkie dostępne sensory.

W drugiej części tego rozdziału zostanie omówiona realizacja i opracowanie danych geoprzestrzennych zarejestrowanych podczas kompleksowej kampanii pomiarowej na jeziorze Kłodno. Wybór tego jeziora był podyktowany możliwością jednoczesnego użycia wszystkich dostępnych sensorów pokładowych bezzałogowych platform pomiarowych (ALS, MBES, MLS, SBES i UAV).

W trzeciej części tego rozdziału została przeprowadzona analiza statystyczna wyników autorskiej metody monitoringu batymetrycznego strefy brzegowej uzyskanych na podstawie modeli fuzji danych średnich ważonych.

Należy zaznaczyć, że dokładności pomiaru głębokości uzyskane za pomocą echosond MBES i SBES zostały określone na podstawie specyfikacji technicznych urządzeń. Natomiast dokładności pomiaru głębokości uzyskane za pomocą metod i urządzeń, takich jak: ALS, MLS, SVR i UAV zostały obliczone na podstawie wskazań odbiornika GNSS RTK. Ponadto warto podkreślić, że opracowane modele fuzji danych średnich ważonych zostały zredukowane do lokalnych układów wysokościowych. Poziomym odniesieniem tych układów ($H=0.000$ m) jest poziom zwierciadła wody występujący podczas realizacji poszczególnych kampanii pomiarowych.

3.1. Realizacja i opracowanie pomiarów batymetryczno-fotogrametrycznych w strefie brzegowej wybranych akwenów przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych

Pomiary batymetryczno-fotogrametryczne w strefie brzegowej zostały przeprowadzone na akwencie morskim przyległym do plaży miejskiej w Gdyni i na akwencie śródlądowym - jeziorze Kłodno. Wybór tego jeziora wynikał z możliwości wykorzystania wszystkich dostępnych sensorów pokładowych bezzałogowych platform pomiarowych (ALS, MBES, MLS, SBES i UAV) podczas jednodniowych badań.

3.1.1. Miejsca realizacji pomiarów batymetryczno-fotogrametrycznych

Jako pierwszy akwen testowy wybrano akwen morski przyległy do publicznej plaży miejskiej w Gdyni. Akwen ten ma typowo przebiegającą linię brzegową (400-metrowy, prostoliniowy odcinek piaszczysty), a głębokości rosną wraz z odległością od brzegu morskiego. Jednakże w niektórych miejscach można zaobserwować występujące na zmianę wypłyenia i zagłębienia pojawiające się do


izobaty 1 m. Obszar badań był zlokalizowany przy brzegu morza. Obejmował on zarówno część lądową i wodną zbiornika. Teren był pozbawiony jakichkolwiek obiektów hydrotechnicznych (**Rys. 3.1**).



Rys. 3.1. Lokalizacja pomiarów batymetryczno-fotogrametrycznych, które przeprowadzono w dniach 10.06.2022 r. i 05.09-07.11.2023 r. na akwenie morskim przyległym do plaży miejskiej w Gdyni (opracowanie własne).

Na akwenie morskim przyległym do plaży miejskiej w Gdyni przeprowadzono dwie kampanie pomiarowe w dniach 10.06.2022 r. i 05.09-07.11.2023 r.

Jako drugi akwen testowy wybrano jezioro Kłódno w powiecie kartuskim (województwo pomorskie). Jest to akwen śródlądowy położony na obszarze Kaszubskiego Parku Krajobrazowego. Ogólna powierzchnia jeziora wynosi: 134.9 ha, długość: 2.0 km, maksymalna głębokość: 38.5 m. Na podstawie raportu z badań przeprowadzonych przez Główny Inspektorat Ochrony Środowiska (GIOŚ) w latach 2017-2018 wynika, że jest to zbiornik o umiarkowanym stanie ekologicznym. Obszar badań jest zlokalizowany przy brzegu jeziora. Obejmuje on zarówno część lądową i wodną zbiornika. Linia brzegowa jest porośnięta drzewami (**Rys. 3.2**).



Rys. 3.2. Lokalizacja pomiarów batymetryczno-fotogrametrycznych, które przeprowadzono w dniach 02-03.06.2022 r., 01.08-02.10.2023 r. i 14.08.2024 r. na jeziorze Kłodno (opracowanie własne).

Na jeziorze Kłodno przeprowadzono trzy kampanie pomiarowe w dniach 02-03.06.2022 r., 01.08-02.10.2023 r. i 14.08.2024 r.

3.1.2. Kampania pomiarowa na akwenu morskim przyległym do plaży miejskiej w Gdyni w dniu 10.06.2022 r.

Aparatura pomiarowa

Podczas realizacji pomiarów batymetryczno-fotogrametrycznych, które przeprowadzono dnia 10 czerwca 2022 r. na akwenu morskim przyległym do plaży miejskiej w Gdyni, wykorzystano następujące urządzenia pomiarowe:

1. Bezzałogowa jednostka pływająca „AutoDron” to niewielki katamaran o wymiarach 110 cm x 70 cm x 10 cm, którego masa wraz z niezbędną aparaturą pomiarową wynosi ok. 18 kg. USV jest urządzeniem należącym do Uniwersytetu Morskiego w Gdyni. Jednostka „AutoDron” jest wyposażona w miniaturową echosondę SBES SonarMite BTX, która służy do pomiaru głębokości wody i odbiornik geodezyjny Trimble R10, którego zadaniem jest wyznaczanie współrzędnych płaskich dla głębokości zmierzonych przez echosondę. Należy podkreślić, że odbiornik GNSS RTK jest również wykorzystywany do pomiarów batymetrycznych akwenu metodą geodezyjną. Podstawowe parametry techniczne jednostki „AutoDron” zostały przedstawione w **Tab. 3.1**.

Tab. 3.1. Dane techniczne USV „AutoDron” (opracowanie własne).

Dane techniczne	„AutoDron”	Zdjęcie
Wymiary	110 cm x 70 cm x 10 cm	
Masa	18 kg	
Prędkość robocza	3 w.	
Prędkość maksymalna	6 w.	
Zasięg pracy	1 km	
Monitoring telemetry	Zintegrowany z aparaturą RC	
Czas pracy	3 godz.	
Klasa szczelności	IP56	

2. Bezzałogowy statek powietrzny DJI Phantom 4 RTK to kwadrokopter z popularnej serii Phantom. UAV zapewnia w czasie rzeczywistym dane pozycjonujące o centymetrowej dokładności w celu poprawy dokładności metadanych obrazu. Bezzałogowy statek powietrzny posiada szerokokątny obiektyw z ogniskową 24 mm (odpowiednik dla formatu 35 mm). Zdjęcia i filmy są zapisywane na 1-calowej matrycy CMOS o rozdzielczości 20 Mpx. Podstawowe parametry techniczne UAV DJI Phantom 4 RTK zostały przedstawione w **Tab. 3.2**.

Tab. 3.2. Dane techniczne UAV DJI Phantom 4 RTK (opracowanie własne).

Dane techniczne	DJI Phantom 4 RTK	Zdjęcie
Masa	1391 g	
Maksymalny pułap	6000 m	
Maksymalna prędkość wznoszenia	5-6 m/s	
Maksymalna prędkość opadania	3 m/s	
Maksymalna prędkość	50-58 km/h	
Maksymalny czas lotu	30 min	
Dokładność mapowania	Standardy dokładności ASPRS dla cyfrowych ortofotomap klasy III	
Wielkość piksela terenowego (GSD)	$(H/36.5)$ (cm/px), H – pułap lotu UAV (m)	
Efektywność otrzymywania danych	Maksymalnie obszar ok. 1 km ² na jeden przelot	

3. Odbiornik geodezyjny Trimble R10. Użyto go do realizacji pomiarów batymetrycznych akwenu metodą geodezyjną (do głębokości 0.6 m). Poza tym, na podstawie wskazań odbiornika GNSS RTK określono dokładność pomiaru głębokości ($p=0.95$) dla danych SVR i UAV.

Realizacja pomiarów batymetryczno-fotogrametrycznych

Pierwszy etap badań polegał na wykonaniu zdjęć lotniczych przez UAV DJI Phantom 4 RTK. Posłużyły one do wygenerowania chmury punktów SfM dla akwenu płytkowodnego i ortofotomapy. Przed rozpoczęciem pomiarów zaprojektowano osnowę fotogrametryczną w celu georeferencji zdjęć wykonanych przez bezzałogowy statek powietrzny. W tym celu wykorzystano 6 punktów georeferencyjnych w postaci drewnianych tablic, które rozmieszczono równomiernie na badanym obszarze. Następnie pomierzono ich środki geometryczne z wykorzystaniem odbiornika GNSS RTK. W dalszej kolejności zaprojektowano plan lotu fotogrametrycznego dla UAV. Ustalono wysokość lotu na 70 m, kąt nachylenia gimbala na 90° oraz pokrycie podłużne i poprzeczne zdjęć na 80%. Pomiaru fotogrametryczne przy użyciu bezzałogowego statku powietrznego przeprowadzono dnia 10 czerwca 2022 r. w odpowiednich warunkach meteorologicznych tzn. przy braku opadów atmosferycznych, bezwietrznej pogodzie (prędkość wiatru nieprzekraczająca 6-7 m/s) i słonecznym dniu. Do rejestracji i georeferencji zdjęć wykorzystano oprogramowanie DJI GO. W trakcie pomiarów fotogrametrycznych wykonano 340 zdjęć, których wielkość GSD wynosiła 1.4 cm/px.

W drugiej kolejności przystąpiono do realizacji pomiarów batymetrycznych. Przed ich rozpoczęciem zaplanowano układ profili sondażowych dla jednostki „AutoDron”. Wyznaczono 41 podstawowych profili pomiarowych prostopadle do kierunku przebiegu linii brzegowej oraz

przyjęto, że odległość między kolejnymi profilami będzie wynosić 10 m. Istotnym czynnikiem wpływającym na otrzymane wyniki mają warunki hydrometeorologiczne, stąd pomiary batymetryczne zrealizowano przy bezwietrznej pogodzie i stanie morza wynoszącym 0-1 w skali Douglasa (brak falowania oraz prądów morskich). Ze względu na brak przeszkód terenowych, USV realizowała misję wyłącznie w trybie automatycznym. W trakcie badań zarejestrowano 4697 punktów w układach PL-UTM (strefa 34N) i PL-EVRF2007-NH.

Trzeci etap badań polegał na określeniu głębokości akwenu w miejscach, gdzie niemożliwy był pomiar z wykorzystaniem jednostki „AutoDron”. Były to punkty o głębokościach nieprzekraczających 0.6 m. Pomiary batymetryczne przy użyciu odbiornika GNSS RTK zrealizowano na tych samych 41 profilach sondażowych, po których poruszała się jednostka „AutoDron”. Przeprowadzono je metodą geodezyjną, która polega na pomiarze głębokości akwenu przez mierniczego znajdującego się w toni wodnej z wykorzystaniem odbiornika GNSS zamontowanego na tyczce geodezyjnej. Badania wykonano na ściśle określonych głębokościach od 0 m do 0.6 m co 10 cm. W trakcie pomiarów batymetrycznych zarejestrowano 288 punktów w układach PL-UTM (strefa 34N) i PL-EVRF2007-NH, których dokładność określenia pozycji przy poziomie ufności 95% wyniosła 0.01 m w płaszczyźnie horyzontalnej i 0.01 m w płaszczyźnie wertykalnej.

Opracowanie modeli fuzji danych średnich ważonych

Opracowanie modeli fuzji danych średnich ważonych rozpoczęto od przetwarzania danych głębokościowych pozyskanych przy użyciu jednostki „AutoDron”. Najpierw dane SBES poddano wstępnej filtracji opartej na minimalnej głębokości (0.3 m). Następnie po szczegółowej analizie przefiltrowanych punktów usunięto manualnie pojedyncze głębokości. Dane SBES dla zakresu głębokości od 0.4 m do 0.99 m (2069 punktów) miały przypisaną dokładność pomiaru głębokości wynoszącą 0.01 m ($p=0.95$). Identyczną dokładność pomiaru głębokości miały również dane SBES dla zakresu głębokości od 1 m do 1.57 m (949 punktów).

Do opracowania modeli fuzji danych średnich ważonych wykorzystano również dane głębokościowe, które zostały pozyskane na podstawie zdjęć lotniczych wykonanych przez bezzałogowy statek powietrzny. Chmura punktów UAV pokrywała zarówno część lądową, jak i podwodną strefy brzegowej (14 370 027 punktów). W dalszej części prac została ona wykorzystana w modelu SVR, generując 1 591 008 punktów głębokościowych. Następnie usunięto manualnie część danych SVR. Potem dane te poddano próbkowaniu z rozdzielczością 0.5 m. Dane SVR (65 582 punkty) cechowały się dokładnością pomiaru głębokości wynoszącą 0.16 m ($p=0.95$). Tak wysoka dokładność określenia głębokości przy użyciu metody SVR była możliwa przede wszystkim dzięki dużej przejrzystości wody i braku roślin podwodnych.

Ostatnim etapem prac przygotowawczych było wyznaczenie przebiegu linii brzegowej na podstawie danych pochodzących z ortofotomapy. Ze względu na brak występowania na badanym obszarze budowli hydrotechnicznych i innych przeszkód terenowych wyznaczono jedynie naturalny przebieg linii brzegowej. Przebieg tej linii został określony z dokładnością 0.07 m ($p=0.95$).

Na **Rys. 3.3** przedstawiono lokalizację przetworzonych danych geoprzestrzennych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na akwenu morskim przyległym do plaży miejskiej w Gdyni w dniu 10.06.2022 r.



Rys. 3.3. Lokalizacja przetworzonych danych geoprzestrzennych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na akwenie morskim przyległym do plaży miejskiej w Gdyni w dniu 10.06.2022 r. (opracowanie własne).


W dalszej kolejności obliczono wagi dla poszczególnych metod i urządzeń pomiarowych (**Tab. 3.3**).

Tab. 3.3. Zestawienie wag dla poszczególnych danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na akwenie morskim przyległym do plaży miejskiej w Gdyni w dniu 10.06.2022 r. (opracowanie własne).

Dane	Dokładność pomiaru głębokości/ współrzędnych płaskich ($p=0.95$)	$w(u=1)$	$w(u=2)$
SBES (zakres głębokości: 0.4-0.99 m) *	0.01	100	10 000
SBES (zakres głębokości: 1-1.57 m) *	0.01	100	10 000
SVR	0.16	6.25	39.06
Fotogrametryczne (naturalna linia brzegowa)	0.07	14.29	204.08

* Dokładność pomiaru głębokości ($p=0.95$) została określona na podstawie specyfikacji technicznych urządzeń.

W związku z tym, że dane dotyczące linii brzegowej pochodziły tylko z jednego źródła, to nie można było zastosować dla nich metody średniej ważonej. Jednakże jak widać na poniższym rysunku, ortofotomapa opracowana na podstawie zdjęć lotniczych wykonanych przez UAV stanowi wysokiej jakości źródło danych. Na **Rys. 3.4** przedstawiono modele fuzji danych średnich ważonych o wykładniku potęgi 1 i 2 w lokalnym układzie wysokościowym dla kampanii pomiarowej przeprowadzonej na akwenie morskim przyległym do plaży miejskiej w Gdyni w dniu 10.06.2022 r.



Rys. 3.4. Modele fuzji danych średnich ważonych o wykładniku potęgi 1 (a) i 2 (b) w lokalnym układzie wysokościowym dla kampanii pomiarowej przeprowadzonej na akwenu morskim przyległym do plaży miejskiej w Gdyni w dniu 10.06.2022 r. (opracowanie własne).

Opracowane modele fuzji danych średnich ważonych pokrywają głównie obszar płytkowodny. Co warte odnotowania, skrajne wartości głębokości dla obu modeli o wykładniku 1 i 2 są identyczne. Minimalna głębokość wygenerowanych modeli wynosi 0 m, natomiast ich maksymalna głębokość ma wartość 1.57 m. Można zatem stwierdzić, że zwiększanie wykładnika potęgi nie wpływa znacząco na uzyskane głębokości przy użyciu zaproponowanej metody modelowania powierzchni terenu w strefie brzegowej.


3.1.3. Kampania pomiarowa na akwenu morskim przyległym do plaży miejskiej w Gdyni w dniach 05.09-07.11.2023 r.

Aparatura pomiarowa

Podczas realizacji pomiarów batymetryczno-fotogrametrycznych, które przeprowadzono w dniach 05.09-07.11.2023 r. na akwenu morskim przyległym do plaży miejskiej w Gdyni, wykorzystano następujące urządzenia pomiarowe:

1. Bezzałogowa jednostka pływająca „AutoDron”. Była ona wyposażona w miniaturową echosondę SBES SonarMite BTX służącą do pomiaru głębokości wody i odbiornik geodezyjny Trimble R10, którego zadaniem jest wyznaczanie współrzędnych płaskich dla głębokości zmierzonych przez echosondę.

2. Bezzałogowy statek powietrzny Aurelia X8 Standard LE to oktokoptyr, na którym został zamontowany prototyp modułu optoelektronicznego służący do pozyskiwania danych geoprzestrzennych na akwenach płytkowodnych. Składa się on z następujących urządzeń: kamery cyfrowej (Sony A6500 i Sony E 35 mm f/1.8 OSS) zintegrowanej z gimbalem (Gremisy T3V3), modułu obsługującego kamerę i gimbala (AIR Commander Entire), LiDAR-u (Velodyne Puck LITE) zintegrowanego z systemem GNSS/INS (SBG Ellipse-D), komputera pokładowego (AAEON PICO-WHU-4), modemu internetowego (Alcatel LTE), modułu komunikacyjnego oraz modułu sterującego zasilaniem (**Rys. 3.5**).



Rys. 3.5. Prototyp modułu optoelektronicznego (a) zamontowany na UAV Aurelia X8 Standard LE (b) (opracowanie własne).

3. Odbiornik geodezyjny Trimble R10. Użyto go do realizacji pomiarów batymetrycznych akwenu metodą geodezyjną (do głębokości 0.6 m). Poza tym, na podstawie wskazań odbiornika GNSS RTK określono dokładność pomiaru głębokości/współrzędnych płaskich ($p=0.95$) dla danych: LiDAR z ALS, SVR i UAV.

Realizacja pomiarów batymetryczno-fotogrametrycznych

W pierwszej kolejności przystąpiono do realizacji pomiarów hydrograficznych. Układ profili sondażowych, po których miała poruszać się jednostka „AutoDron”, był identyczny jak podczas badań przeprowadzonych dnia 10 czerwca 2022 r. Pomiarów batymetrycznych z wykorzystaniem USV przeprowadzono dnia 5 września 2023 r. w odpowiednich warunkach hydrometeorologicznych. Ze względu na brak przeszkód terenowych, jednostka „AutoDron” realizowała misję wyłącznie w trybie automatycznym. W trakcie badań zarejestrowano 12 480 punktów w układach PL-UTM (strefa 34N) i PL-EVRF2007-NH.

Równolegle z pomiarami hydrograficznymi przy użyciu jednostki „AutoDron” wykonano pomiary batymetryczne akwenu metodą geodezyjną. Pomiarów batymetrycznych z wykorzystaniem odbiornika GNSS RTK zrealizowano na tych samych 41 profilach sondażowych, po których poruszała się jednostka „AutoDron”. Badania wykonano na ściśle określonych głębokościach od 0 m do 0.6 m co 10 cm. W trakcie pomiarów batymetrycznych zarejestrowano 343 punkty w układach PL-UTM (strefa 34N) i PL-EVRF2007-NH, których dokładność określenia pozycji przy poziomie ufności 95% wyniosła 0.05 m w płaszczyźnie horyzontalnej i 0.06 m w płaszczyźnie wertykalnej.

Drugi etap badań polegał na wykonaniu lotniczego skaningu laserowego obszaru lądowego przyległego do brzegu przy użyciu UAV Aurelia X8 Standard LE, na którym był zamontowany prototyp modułu optoelektronicznego. ALS przeprowadzono dnia 14 września 2023 r. w odpowiednich warunkach meteorologicznych. Lotniczy skaningu laserowy wykonano na wysokości 70 m wzdłuż 2 profili lotu równoległych do linii brzegowej, które były oddalone od siebie o 13 m. Do rejestracji i georeferencji chmury punktów LiDAR wykorzystano oprogramowanie HYPACK. W trakcie badań zarejestrowano 6 072 287 punktów w układach PL-UTM (strefa 34N) i PL-EVRF2007-NH.

Trzeci etap badań polegał na wykonaniu zdjęć lotniczych przez UAV Aurelia X8 Standard LE, na którym był zamontowany prototyp modułu optoelektronicznego. Posłużyły one do wygenerowania chmury punktów SfM i ortofotomapy. Przed rozpoczęciem pomiarów zaprojektowano osnowę fotogrametryczną w celu georeferencji zdjęć wykonanych przez bezzałogowy statek powietrzny. W tym celu wykorzystano 24 punkty georeferencyjne, które rozmieszczono równomiernie na badanym obszarze. Następnie pomierzono ich środki geometryczne z wykorzystaniem odbiornika GNSS RTK. W dalszej kolejności zaprojektowano plan lotu fotogrametrycznego dla UAV. Ustalono wysokość lotu na 120 m, kąt nachylenia gimbala na 90° oraz pokrycie podłużne i poprzeczne zdjęć na 80%. Pomiarów fotogrametrycznych przy użyciu bezzałogowego statku powietrznego przeprowadzono dnia 7 listopada 2023 r. w odpowiednich warunkach meteorologicznych. Do rejestracji i georeferencji zdjęć wykorzystano oprogramowanie QGroundControl. W trakcie pomiarów fotogrametrycznych wykonano 1113 zdjęć, których wielkość GSD wynosiła 0.8 cm/px.

Opracowanie modeli fuzji danych średnich ważonych


Opracowanie modeli fuzji danych średnich ważonych rozpoczęto od przetwarzania danych głębokościowych pozyskanych przy użyciu jednostki „AutoDron”. Najpierw dane SBES poddano wstępnej filtracji opartej na minimalnej (0.3 m) i maksymalnej (1.71 m) głębokości. Następnie po szczegółowej analizie przefiltrowanych punktów usunięto manualnie pojedyncze głębokości. Dane SBES dla zakresu głębokości od 0.4 m do 0.99 m (5709 punktów) cechowały się dokładnością pomiaru głębokości wynoszącą 0.01 m ($p=0.95$). Identyczną dokładność pomiaru głębokości miały również dane SBES dla zakresu głębokości od 1 m do 1.71 m (2950 punktów).

Do opracowania modeli fuzji danych średnich ważonych wykorzystano również dane głębokościowe, które zostały pozyskane na podstawie zdjęć lotniczych wykonanych przez bezzałogowy statek powietrzny. Chmura punktów UAV pokrywała zarówno część lądową, jak i podwodną strefy brzegowej. Najpierw dane UAV zostały poddane procesowi tworzenia chmury punktów metodą SfM (52 197 630 punktów). W dalszej kolejności na chmurze punktów zastosowano algorytm SVR (2 191 041 punktów). W związku z tym, że model SVR wygenerował dane na części lądowej usunięto manualnie część tych danych SVR. Potem dane te poddano próbkowaniu z rozdzielczością 0.5 m. Dane SVR (50 748 punktów) cechowały się dokładnością pomiaru głębokości wynoszącą 0.37 m ($p=0.95$). Tak niska dokładność określenia głębokości przy użyciu metody SVR była spowodowana przede wszystkim dwumiesięcznym odstępem czasu między rejestracją chmury punktów UAV a pomiarami GNSS RTK, które posłużyły do oceny dokładności modelu płytkowodnego.

Ostatnim etapem prac przygotowawczych było wyznaczenie przebiegu linii brzegowej na podstawie danych pochodzących z lotniczego skaningu laserowego i ortofotomapy. Na początku określono linię brzegową na podstawie danych LiDAR z ALS przy użyciu metody ekstrakcji linii brzegowej zaproponowanej przez Xu i in. W ten sposób wygenerowano 223 punkty wzdłuż linii brzegowej z dokładnością 2.92 m ($p=0.95$). Następnie wyznaczono linię brzegową na podstawie

ortofotomapy z dokładnością 0.06 m ($p=0.95$). Linie brzegowe określone na podstawie danych LiDAR z ALS i ortofotomapy różnią się znacznie zasięgiem przestrzennym, ponieważ zarejestrowano je w różnych okresach czasu (blisko dwa miesiące różnicy). Zmienność warunków atmosferycznych i hydrometeorologicznych mogła wpłynąć na ich przebieg. W związku z tym, podjęto decyzję o opracowaniu modeli fuzji danych średnich ważonych osobno dla linii brzegowej wyznaczonej na podstawie danych LiDAR z ALS i ortofotomapy, aby uniknąć nieścisłości w analizie danych.

Na **Rys. 3.6** przedstawiono lokalizację przetworzonych danych geoprzestrzennych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na akwenie morskim przyległym do plaży miejskiej w Gdyni w dniach 05.09-07.11.2023 r.



Rys. 3.6. Lokalizacja przetworzonych danych geoprzestrzennych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na akwenie morskim przyległym do plaży miejskiej w Gdyni w dniach 05.09-07.11.2023 r. (opracowanie własne).


W dalszej kolejności obliczono wagi dla poszczególnych metod i urządzeń pomiarowych (**Tab. 3.4**).

Tab. 3.4. Zestawienie wag dla poszczególnych danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na akwenie morskim przyległym do plaży miejskiej w Gdyni w dniach 05.09-07.11.2023 r. (opracowanie własne).

Dane	Dokładność pomiaru głębokości/ współrzędnych płaskich ($p=0.95$)	$w(u=1)$	$w(u=2)$
SBES (zakres głębokości: 0.4-0.99 m) *	0.01	100	10 000
SBES (zakres głębokości: 1-1.7 m) *	0.01	100	10 000
SVR	0.37	2.70	7.30
Fotogrametryczne (naturalna linia brzegowa)	0.06	16.67	277.78
LiDAR z ALS	2.92	0.34	0.12

* Dokładność pomiaru głębokości ($p=0.95$) została określona na podstawie specyfikacji technicznych urządzeń.

Na **Rys. 3.7** przedstawiono modele fuzji danych średnich ważonych o wykładniku potęgi 1 z zaznaczoną linią brzegową wyznaczoną na podstawie danych LiDAR z ALS i UAV w lokalnym układzie wysokościowym dla kampanii pomiarowej przeprowadzonej na akwenie morskim przyległym do plaży miejskiej w Gdyni w dniach 05.09-07.11.2023 r.



Rys. 3.7. Modele fuzji danych średnich ważonych o wykładniku potęgi 1 z zaznaczoną linią brzegową wyznaczoną na podstawie danych LiDAR z ALS (a) i UAV (b) w lokalnym układzie wysokościowym dla kampanii pomiarowej przeprowadzonej na akwenie morskim przyległym do plaży miejskiej w Gdyni w dniach 05.09-07.11.2023 r. (opracowanie własne).

Opracowane modele fuzji danych średnich ważonych, podobnie jak te z 2022 r., pokrywają głównie obszar płytkowodny. Minimalna głębokość wygenerowanych modeli wynosi 0 m, natomiast ich maksymalna głębokość ma wartość 1.7 m. Na podstawie **Rys. 3.7** można stwierdzić, że linie brzegowe różnią się znacznie zasięgiem przestrzennym. Jest to spowodowane blisko dwumiesięcznym odstępem czasu między rejestracją danych LiDAR z ALS a UAV. Dlatego w celu dokonania pełnej analizy metody modelowania powierzchni terenu w strefie brzegowej konieczne jest przeprowadzenie kompleksowej kampanii pomiarowej na wybranym akwenie, podczas której wszystkie dane geoprzestrzenne zostaną zarejestrowane w trakcie jednego dnia.

3.1.4. Kampania pomiarowa na jeziorze Kłódno w dniach 02-03.06.2022 r.

Aparatura pomiarowa

Podczas realizacji pomiarów batymetryczno-fotogrametrycznych, które przeprowadzono w dniach 02-03.06.2022 r. na jeziorze Kłódno, wykorzystano następujące urządzenia pomiarowe:

1. Bezzałogowa jednostka pływająca „AutoDron”. Była ona wyposażona w miniaturową echosondę SBES SonarMite BTX służącą do pomiaru głębokości wody i odbiornik geodezyjny Trimble R10, którego zadaniem jest wyznaczanie współrzędnych płaskich dla głębokości zmierzonych przez echosondę.
2. Bezzałogowa jednostka pływająca HydroDron-1 to katamaran o wymiarach: 4 m x 2 m x 0.5 m, którego masa wraz z niezbędną aparaturą pomiarową wynosi ok. 300 kg. Została ona zaprojektowana przez prof. Andrzeja Statecznego. Sensory nawigacyjne są zamontowane na automatycznie składanym maszcie. Głowica hydrograficzna jest montowana na ruchomym siłowniku umożliwiającym zdalne podnoszenie i opuszczanie głowicy, a profilomierz prędkości dźwięku w wodzie jest automatycznie opuszczany i podnoszony za pomocą specjalnej windy kotwicznej. USV jest również wyposażona w system sensorów do monitoringu sytuacji na i wokół platformy w celu zwiększenia świadomości sytuacyjnej, w tym dwie kamery wideo (obrotowa i stacjonarna) oraz stację pogodową. Podstawowe parametry techniczne jednostki HydroDron-1 zostały przedstawione w **Tab. 3.5**.

Tab. 3.5. Dane techniczne USV HydroDron-1 (opracowanie własne).

Dane techniczne	HydroDron-1	Zdjęcie
Wymiary	4 m x 2 m x 0.5 m	
Masa	300 kg	
Prędkość robocza	3-4 w.	
Prędkość maksymalna	14 w.	
Zasięg pracy	6 km	
Monitoring telemetry	Zintegrowany z aparaturą RC	
Czas pracy	12 godz.	

Na potrzeby badań wykorzystano dwa urządzenia pomiarowe wchodzące w skład wyposażenia jednostki HydroDron-1. Były nimi: LiDAR Velodyne VLP-16 Puck, którym wykonano mobilny skaningu laserowy obszaru lądowego przyległego do brzegu oraz system GNSS/INS SBG Ekinox2-U, który wykorzystano do określenia orientacji i położenia LiDAR-u podczas realizacji MLS.

3. Bezzałogowy statek powietrzny Aurelia X8 Standard LE. Był on wyposażony w prototyp modułu optoelektronicznego. Umożliwił on pozyskanie chmury punktów LiDAR dla obszaru lądowego przyległego do brzegu. Ponadto dzięki wykonanym zdjęciom lotniczym można było wygenerować chmurę punktów SfM i ortofotomapę.
4. Odbiornik geodezyjny Trimble R10. Użyto go do realizacji pomiarów batymetrycznych akwenu metodą geodezyjną (do głębokości 0.6 m). Poza tym, na podstawie wskazań odbiornika GNSS RTK określono dokładność pomiaru głębokości/współrzędnych płaskich ($p=0.95$) dla danych: LiDAR z MLS, SVR i UAV.

Realizacja pomiarów batymetryczno-fotogrametrycznych

W pierwszej kolejności przystąpiono do realizacji pomiarów hydrograficznych. Przed ich rozpoczęciem zaplanowano układ profili sondażowych dla jednostki „AutoDron”. Wyznaczono 42 podstawowe profile pomiarowe prostopadłe do kierunku przebiegu linii brzegowej oraz przyjęto, że odległość między kolejnymi profilami będzie wynosić 10 m. Pomiary batymetryczne z wykorzystaniem USV przeprowadzono dnia 2 czerwca 2022 r. w odpowiednich warunkach

hydrometeorologicznych. Ze względu na liczne rośliny występujące w toni wodnej oraz jednostki pływające zacumowane przy brzegu, jednostka „AutoDron” realizowała misję w dwóch trybach: automatycznym i bezpośrednim. W trakcie badań zarejestrowano 7993 punkty w układach PL-UTM (strefa 34N) i PL-EVRF2007-NH.

Równolegle z pomiarami hydrograficznymi przy użyciu jednostki „AutoDron” wykonano mobilny skanowanie laserowe obszaru lądowego przyległego do brzegu z wykorzystaniem jednostki HydroDron-1. Podczas badań wykorzystano LiDAR mobilny, który był zintegrowany z systemem GNSS/INS. MLS przeprowadzono wzdłuż 7 profili sondażowych równoległych do brzegu w odległości 30-100 m od linii brzegowej. Do rejestracji i georeferencji chmury punktów LiDAR wykorzystano oprogramowanie HYPACK. W trakcie badań zarejestrowano 5 000 000 punktów w układach PL-UTM (strefa 34N) i PL-EVRF2007-NH.

Drugi etap badań polegał na wykonaniu zdjęć lotniczych przez UAV DJI Phantom 4 RTK. Posłużyły one do wygenerowania chmury punktów SfM i ortofotomapy. Przed rozpoczęciem pomiarów zaprojektowano osnowę fotogrametryczną w celu georeferencji zdjęć wykonanych przez bezzałogowy statek powietrzny. W tym celu wykorzystano 10 punktów georeferencyjnych, które rozmieszczono równomiernie na badanym obszarze. Następnie pomierzono ich środki geometryczne z wykorzystaniem odbiornika GNSS RTK. W dalszej kolejności zaprojektowano plan lotu fotogrametrycznego dla UAV. Ustalono wysokość lotu na 80 m, kąt nachylenia gimbala na 90° oraz pokrycie podłużne i poprzeczne zdjęć na 80%. Pomiary fotogrametryczne przy użyciu bezzałogowego statku powietrznego przeprowadzono dnia 3 czerwca 2022 r. w odpowiednich warunkach meteorologicznych. Do rejestracji i georeferencji zdjęć wykorzystano oprogramowanie DJI GO. W trakcie pomiarów fotogrametrycznych wykonano 242 zdjęć, których wielkość GSD wynosiła 1.5 cm/px.

Trzeci etap badań polegał na określeniu głębokości akwenu w miejscach, gdzie niemożliwy był pomiar z wykorzystaniem jednostki „AutoDron”. Były to punkty o głębokościach nieprzekraczających 0.6 m. Pomiary batymetryczne przy użyciu odbiornika GNSS RTK zrealizowano dnia 3 czerwca 2023 r. na tych samych 42 profilach sondażowych, po których poruszała się jednostka „AutoDron”. Badania wykonano na ściśle określonych głębokościach od 0 m do 0.6 m co 10 cm. W trakcie pomiarów batymetrycznych zarejestrowano 225 punktów w układach PL-UTM (strefa 34N) i PL-EVRF2007-NH, których dokładność określenia pozycji przy poziomie ufności 95% wyniosła 0.04 m w płaszczyźnie horyzontalnej i 0.05 m w płaszczyźnie wertykalnej.

Opracowanie modeli fuzji danych średnich ważonych

Opracowanie modeli fuzji danych średnich ważonych rozpoczęto od przetwarzania danych głębokościowych pozyskanych przy użyciu jednostki „AutoDron”. Najpierw dane SBES poddano wstępnej filtracji opartej na minimalnej głębokości (0.3 m). Następnie po szczegółowej analizie przefiltrowanych punktów usunięto manualnie pojedyncze głębokości. Dane SBES dla zakresu głębokości od 0.4 m do 0.99 m (3024 punkty) cechowały się dokładnością pomiaru głębokości wynoszącą 0.01 m ($p=0.95$). Identyczną dokładność pomiaru głębokości miały również dane SBES dla zakresu głębokości od 1 m do 6.56 m (2265 punktów).

Do opracowania modeli fuzji danych średnich ważonych wykorzystano również dane głębokościowe, które zostały pozyskane na podstawie zdjęć lotniczych wykonanych przez bezzałogowy statek powietrzny. Chmura punktów UAV pokrywała zarówno część lądową, jak i podwodną strefy brzegowej (13 448 186 punktów). Po zastosowaniu metody SVR otrzymano 747 720 punktów w części

wodnej. Następnie usunięto manualnie część danych SVR (np. znajdujących się na pomostach). Potem dane te poddano próbkowaniu z rozdzielczością 0.5 m. Dane SVR (18 124 punkty) cechowały się dokładnością pomiaru głębokości wynoszącą 0.23 m ($p=0.95$). Tak wysoka dokładność określenia głębokości przy użyciu metody SVR była możliwa przede wszystkim dzięki dużej przejrzystości wody i braku roślin podwodnych/wodnych. Należy dodać, że uzyskana dokładność jest zbliżona do tej, którą otrzymano podczas kampanii pomiarowej przeprowadzonej na akwenu morskim przyległym do plaży miejskiej w Gdyni w dniu 10.06.2022 r.

Ostatnim etapem prac przygotowawczych było wyznaczenie przebiegu linii brzegowej na podstawie danych pochodzących z mobilnego skaningu laserowego i ortofotomapy. Ponieważ wzdłuż linii brzegowej jeziora Kłodno znajdują się liczne drzewa i krzewy, to wystąpiły trudności z realizacją pomiarów batymetrycznych akwenu metodą geodezyjną. Mimo to postanowiono wyznaczyć naturalny przebieg linii brzegowej oraz przebieg linii brzegowej uwzględniającej pomosty na podstawie ortofotomapy. Otrzymane w ten sposób linie brzegowe zostały następnie porównane z referencyjną linią brzegową wyznaczoną przy użyciu odbiornika GNSS RTK. Dokładność określenia przebiegu linii brzegowej przy poziomie ufności 95% wyniosła 0.07 m dla naturalnej linii brzegowej i 0.08 m dla linii brzegowej uwzględniającej obiekty infrastruktury wodnej. Jak już wcześniej wspomniano, linia brzegowa została również wyznaczona na podstawie danych pochodzących z mobilnego skaningu laserowego. W wyniku zastosowania zmodyfikowanej metody ekstrakcji linii brzegowej zaproponowanej przez Xu i in. na danych LiDAR z MLS wygenerowano 73 punkty wzdłuż linii brzegowej z dokładnością 2.43 m ($p=0.95$). Należy zauważyć, że wygenerowana liczba punktów reprezentujących linię brzegową jeziora Kłodno jest zdecydowanie mniejsza niż w przypadku akwenu morskiego przyległego do plaży miejskiej w Gdyni. Było to spowodowane tym, że na badanym obszarze występowały liczne przeszkody terenowe, takie jak np. drzewa, jednostki pływające, czy pomosty. Dane pochodzące z mobilnego skaningu laserowego mogą stanowić uzupełnienie informacji o linii brzegowej dla ortofotomapy.

Na **Rys. 3.8** przedstawiono lokalizację przetworzonych danych geoprzestrzennych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniach 02-03.06.2022 r.



Rys. 3.8. Lokalizacja przetworzonych danych geoprzestrzennych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniach 02-03.06.2022 r. (opracowanie własne).


W dalszej kolejności obliczono wagi dla poszczególnych metod i urządzeń pomiarowych (Tab. 3.6).

Tab. 3.6. Zestawienie wag dla poszczególnych danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniach 02-03.06.2022 r. (opracowanie własne).

Dane	Dokładność pomiaru głębokości/ współrzędnych płaskich ($p=0.95$)	$w(u=1)$	$w(u=2)$
SBES (zakres głębokości 0.4-0.99 m) *	0.01	100	10 000
SBES (zakres głębokości 1-7.09 m) *	0.01	100	10 000
SVR	0.23	4.35	18.90
Fotogrametryczne (naturalna linia brzegowa)	0.07	14.29	204.08
Fotogrametryczne (linia brzegowa z pomostami)	0.08	12.50	156.25
LiDAR z MLS	2.43	0.41	0.17

* Dokładność pomiaru głębokości ($p=0.95$) została określona na podstawie specyfikacji technicznych urządzeń.

Na Rys. 3.9 przedstawiono modele fuzji danych średnich ważonych o wykładniku potęgi 1 i 2 w lokalnym układzie wysokościowym dla kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniach 02-03.06.2022 r.



Rys. 3.9. Modele fuzji danych średnich ważonych o wykładniku potęgi 1 (a) i 2 (b) w lokalnym układzie wysokościowym dla kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniach 02-03.06.2022 r. (opracowanie własne).

Opracowane modele fuzji danych średnich ważonych pokrywają głównie obszar płytkowodny. Co warte odnotowania, skrajne wartości głębokości dla obu modeli o wykładniku 1 i 2 są identyczne (podobnie jak dla akwenu morskiego przyległego do plaży miejskiej w Gdyni). Minimalna głębokość wygenerowanych modeli wynosi 0 m, natomiast ich maksymalna głębokość ma wartość 6.53 m. Po raz kolejny dowiedziono, że zwiększanie wykładnika potęgi nie wpływa znacząco na uzyskane głębokości przy użyciu zaproponowanej metody modelowania powierzchni terenu w strefie brzegowej.

3.1.5. Kampania pomiarowa na jeziorze Kłodno w dniach 01.08-02.10.2023 r.

Aparatura pomiarowa

Podczas realizacji pomiarów batymetryczno-fotogrametrycznych, które przeprowadzono w dniach 01.08-02.10.2023 r. na jeziorze Kłodno, wykorzystano następujące urządzenia pomiarowe:

1. Bezzałogowa jednostka pływająca „AutoDron”. Była ona wyposażona w miniaturową echosondę SBES SonarMite BTX służącą do pomiaru głębokości wody i odbiornik geodezyjny Trimble R10, którego zadaniem jest wyznaczanie współrzędnych płaskich dla głębokości zmierzonych przez echosondę.
2. Bezzałogowa jednostka pływająca HydroDron-1. Była ona wyposażona w echosondę interferometryczną Ping DSP 3DSS-DX-450 służącą do pomiaru głębokości wody i system GNSS/INS SBG Ekinox2-U, którego zadaniem jest wyznaczanie współrzędnych płaskich dla głębokości zmierzonych przez echosondę. Ponadto czujnik prędkości dźwięku AML SV Xchange był zintegrowany z głowicą sondy wielowiązkowej Ping DSP 3DSS-DX-450, dzięki czemu możliwe było uzyskanie bardziej precyzyjnych danych głębokościowych.
3. Bezzałogowy statek powietrzny Aurelia X8 Standard LE. Był on wyposażony w prototyp modułu optoelektronicznego. Umożliwił on pozyskanie chmury punktów LiDAR dla obszaru lądowego przyległego do brzegu. Ponadto dzięki wykonanym zdjęciom lotniczym można było wygenerować chmurę punktów SfM i ortofotomapę.
4. Odbiornik geodezyjny Trimble R10. Użyto go do realizacji pomiarów batymetrycznych akwenu metodą geodezyjną (do głębokości 0.6 m). Poza tym, na podstawie wskazań odbiornika GNSS RTK określono dokładność pomiaru głębokości/współrzędnych płaskich ($p=0.95$) dla danych: LiDAR z MLS, SVR i UAV.

Realizacja pomiarów batymetryczno-fotogrametrycznych

W pierwszej kolejności przystąpiono do realizacji pomiarów batymetrycznych z wykorzystaniem jednostki HydroDron-1. Zrealizowano je dnia 1 sierpnia 2023 r. wzdłuż 7 profili sondażowych równoległych do linii brzegowej. Badania przeprowadzono w odpowiednich warunkach hydrometeorologicznych. W trakcie pomiarów batymetrycznych zarejestrowano 34 017 280 punktów w układach PL-UTM (strefa 34N) i PL-EVRF2007-NH za pomocą oprogramowania HYPACK.

Drugi etap badań polegał na wykonaniu pomiarów batymetrycznych z wykorzystaniem jednostki „AutoDron”. Zrealizowano je dnia 23 sierpnia 2023 r. wzdłuż tych samych profili sondażowych, po których poruszała się jednostka USV podczas badań przeprowadzonych dnia 2 czerwca 2022 r. Badania przeprowadzono w odpowiednich warunkach hydrometeorologicznych. Ze względu na liczne rośliny występujące w toni wodnej oraz jednostki pływające zacumowane przy brzegu, jednostka „AutoDron” realizowała misję w dwóch trybach: automatycznym i bezpośrednim. W trakcie badań zarejestrowano 7005 punktów w układach PL-UTM (strefa 34N) i PL-EVRF2007-NH.

Równoległe z pomiarami hydrograficznymi przy użyciu jednostki „AutoDron” wykonano pomiary batymetryczne akwenu metodą geodezyjną. Pomiary batymetryczne z wykorzystaniem odbiornika GNSS RTK zrealizowano na tych samych 42 profilach sondażowych, po których poruszała się jednostka „AutoDron”. Badania wykonano na ściśle określonych głębokościach od 0 m do 0.6 m co 10 cm. W trakcie pomiarów batymetrycznych zarejestrowano 224 punkty w układach PL-UTM (strefa 34N)

i PL-EVRF2007-NH, których dokładność określenia pozycji przy poziomie ufności 95% wyniosła 0.09 m w płaszczyźnie horyzontalnej i 0.11 m w płaszczyźnie wertykalnej.

Trzeci etap badań polegał na wykonaniu lotniczego skaningu laserowego obszaru lądowego przyległego do brzegu przy użyciu UAV Aurelia X8 Standard LE, na którym był zamontowany prototyp modułu optoelektronicznego. ALS przeprowadzono dnia 13 września 2023 r. w odpowiednich warunkach meteorologicznych. Lotniczy skaningu laserowy wykonano na wysokości 70 m wzdłuż 2 profili lotu równoległych do linii brzegowej, które były oddalone od siebie o 10 m. Do rejestracji i georeferencji chmury punktów LiDAR wykorzystano oprogramowanie HYPACK. W trakcie badań zarejestrowano 3 374 099 punktów w układach PL-UTM (strefa 34N) i PL-EVRF2007-NH.

Czwarty etap badań polegał na wykonaniu zdjęć lotniczych przez UAV Aurelia X8 Standard LE, na którym był zamontowany prototyp modułu optoelektronicznego. Posłużyły one do wygenerowania chmury punktów SfM dla akwenu i ortofotomapy. Przed rozpoczęciem pomiarów zaprojektowano osnowę fotogrametryczną w celu georeferencji zdjęć wykonanych przez bezzałogowy statek powietrzny. W tym celu wykorzystano 8 punktów georeferencyjnych, które rozmieszczono równomiernie na badanym obszarze. Następnie pomierzono ich środki geometryczne z wykorzystaniem odbiornika GNSS RTK. W dalszej kolejności zaprojektowano plan lotu fotogrametrycznego dla UAV. Ustalono wysokość lotu na 70 m, kąt nachylenia gimbala na 90° oraz pokrycie podłużne i poprzeczne zdjęć na 80%. Pomiar fotogrametryczny przy użyciu bezzałogowego statku powietrznego przeprowadzono dnia 2 października 2023 r. w odpowiednich warunkach meteorologicznych. Do rejestracji i georeferencji zdjęć wykorzystano oprogramowanie QGroundControl. W trakcie pomiarów fotogrametrycznych wykonano 376 zdjęć, których wielkość GSD wynosiła 0.8 cm/px.

Opracowanie modeli fuzji danych średnich ważonych

Opracowanie modeli fuzji danych średnich ważonych rozpoczęto od przetwarzania danych głębokowodnych pozyskanych przy użyciu jednostki HydroDron-1. Na początku usunięto błędnie zarejestrowane dane MBES przy użyciu metod wykrywania wartości odstających opartych na minimalnej (2 m) i maksymalnej (13 m) głębokości. Następnie po szczegółowej analizie przefiltrowanych punktów usunięto manualnie pojedyncze głębokości. W końcowym etapie przetwarzania danych MBES dokonano ich uśredniania w regularnych odstępach wynoszących 0.3 m. Warto podkreślić, że proces uśredniania danych batymetrycznych co 0.3 m pozwala zredukować szumy pomiarowe i stanowi nieodłączną część procesu przetwarzania danych głębokościowych. W ten sposób otrzymano 113 307 punktów, których dokładność pomiaru głębokości według urządzenia wynosi 0.15 m ($p=0.95$).


W drugiej kolejności przystąpiono do przetwarzania danych głębokościowych pozyskanych przy użyciu jednostki „AutoDron”. Na początku usunięto błędnie zarejestrowane dane SBES przy użyciu metody wykrywania wartości odstających opartej na minimalnej głębokości (0.3 m). Następnie po szczegółowej analizie przefiltrowanych punktów usunięto manualnie pojedyncze głębokości. Dane SBES dla zakresu głębokości od 0.4 m do 0.99 m (2864 punkty) cechowały się dokładnością pomiaru głębokości wynoszącą 0.01 m ($p=0.95$). Identyczną dokładność pomiaru głębokości miały również dane SBES dla zakresu głębokości od 1 m do 7.09 m (2845 punktów).

Dane płytkowodne (poniżej głębokości 1 m) zostały wyznaczone również na podstawie chmury punktów UAV i metody SVR. Dane te cechują się bardzo niską dokładnością pomiaru głębokości wynoszącą 0.83 m ($p=0.95$). Jedną z przyczyn tego stanu rzeczy było to, że podczas badań pomierzono

jedynie 8 punktów georeferencyjnych, które znajdowały się na pomostach nad jeziorem Kłodno. Niewystarczająca liczba GCP mogła spowodować większe błędy w transformacji danych, co miało bezpośredni wpływ na jakość uzyskanej chmury punktów. Drugą przyczyną było to, że chmura punktów UAV została zarejestrowana prawie półtora miesiąca później niż pomiary geodezyjne, względem których dokonywano oceny jej dokładności. Pomimo bardzo niskiej dokładności określenia głębokości dla danych SVR (10 475 punktów) postanowiono uwzględnić je przy opracowywaniu modeli fuzji danych średnich ważonych. Było to spowodowane tym, że takie dane o mniejszej dokładności (SVR) mają mniejszy wpływ na tworzony model batymetryczny niż dane o wyższej dokładności (MBES i SBES).

Ostatnim etapem prac przygotowawczych było wyznaczenie przebiegu linii brzegowej na podstawie danych pochodzących z lotniczego skaningu laserowego i ortofotomapy. Na początku określono linię brzegową na podstawie danych LiDAR z ALS przy użyciu metody ekstrakcji linii brzegowej zaproponowanej przez Xu i in. W ten sposób wygenerowano 70 punktów wzdłuż linii brzegowej z dokładnością 3.36 m ($p=0.95$). Należy zauważyć, że wygenerowana liczba punktów reprezentujących linię brzegową jeziora Kłodno jest zbliżona do tej uzyskanej podczas lotniczego skaningu laserowego wykonanego dnia 2 czerwca 2022 r. Brakujące informacje o linii brzegowej uzupełniono danymi z ortofotomapy. Na jej podstawie wyznaczono naturalny przebieg linii brzegowej z dokładnością 0.07 m ($p=0.95$) i przebieg linii brzegowej uwzględniającej pomosty z dokładnością 0.08 m ($p=0.95$).

Na **Rys. 3.10** przedstawiono lokalizację przetworzonych danych geoprzestrzennych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniach 01.08-02.10.2023 r.



Rys. 3.10. Lokalizacja przetworzonych danych geoprzestrzennych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniach 01.08-02.10.2023 r. (opracowanie własne).


W dalszej kolejności obliczono wagi dla poszczególnych metod i urządzeń pomiarowych (**Tab. 3.7**).

Tab. 3.7. Zestawienie wag dla poszczególnych danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniach 01.08-02.10.2023 r. (opracowanie własne).

Dane	Dokładność pomiaru głębokości/ współrzędnych płaskich ($p=0.95$)	$w(u=1)$	$w(u=2)$
SBES (zakres głębokości 0.4-0.99 m) *	0.01	100	10 000
SBES (zakres głębokości: 1-7.09 m) *	0.01	100	10 000
MBES (zakres głębokości: 2.20-11.10 m) *	0.15	6.67	44.44
SVR	0.83	2.04	8.650
Fotogrametryczne (naturalna linia brzegowa)	0.07	14.29	204.08
Fotogrametryczne (linia brzegowa z pomostami)	0.08	12.50	156.25
LiDAR z ALS	3.20	0.31	0.09

* Dokładność pomiaru głębokości ($p=0.95$) została określona na podstawie specyfikacji technicznych urządzeń.

Na **Rys. 3.11** przedstawiono modele fuzji danych średnich ważonych o wykładniku potęgi 1 i 2 w lokalnym układzie wysokościowym dla kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniach 01.08-02.10.2023 r.



Rys. 3.11. Modele fuzji danych średnich ważonych o wykładniku potęgi 1 (**a**) i 2 (**b**) w lokalnym układzie wysokościowym dla kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniach 01.08-02.10.2023 r. (opracowanie własne).

Opracowane modele fuzji danych średnich ważonych pokrywają głównie obszar płytkowodny. Co warto odnotowania, skrajne wartości głębokości dla obu modeli o wykładniku 1 i 2 są identyczne. Minimalna głębokość wygenerowanych modeli wynosi 0 m, natomiast ich maksymalna głębokość ma wartość 11.06 m. Po raz kolejny dowiedziono, że zwiększanie wykładnika potęgi nie wpływa znacząco na uzyskane głębokości przy użyciu zaproponowanej metody modelowania powierzchni terenu w strefie brzegowej.

Z całą pewnością dane uzyskane przy użyciu metody SVR cechują się bardzo niską dokładnością określenia głębokości wynoszącą 0.83 m ($p=0.95$). Niska dokładność tych punktów wynika głównie z niewielkiej liczby punktów georeferencyjnych (8) i ich nieoptymalnego rozmieszczenia. Jednakże zastosowanie metody fuzji danych średnich ważonych opartej na przypisaniu wag do poszczególnych

metod i urządzeń pomiarowych skutecznie ogranicza ich wpływ na tworzony model batymetryczny. Ponadto wykorzystanie tej metody pozwoliło na pomyślną integrację danych geoprzestrzennych o różnej dokładności pomiaru głębokości. Dzięki temu w stworzonym modelu batymetrycznym dominują dane głębokościowe o wysokiej jakości (MBES i SBES), minimalizując wpływ mniej dokładnych danych, takich jak SVR.

3.2. Kompleksowa realizacja pomiarów batymetryczno-fotogrametrycznych w strefie brzegowej dla wybranego akwenu przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych

W niniejszym podrozdziale zostanie przedstawiona kompleksowa realizacja pomiarów batymetryczno-fotogrametrycznych w strefie brzegowej dla wybranego akwenu. Omówiony zostanie również szczegółowy proces opracowania modeli fuzji danych średnich ważonych na podstawie zarejestrowanych danych.

Należy zaznaczyć, że dokładności pomiaru głębokości uzyskane za pomocą echosond MBES i SBES zostały określone na podstawie specyfikacji technicznych urządzeń. Natomiast dokładności pomiaru głębokości uzyskane za pomocą metod i urządzeń, takich jak: ALS, MLS, SVR i UAV zostały obliczone na podstawie wskazań odbiornika GNSS RTK. Ponadto warto podkreślić, że opracowane modele fuzji danych średnich ważonych zostały zredukowane do lokalnych układów wysokościowych, co zapewnia ich spójność z istniejącymi modelami i ułatwia dalszą analizę przestrzenną.


Akwenem, na którym przeprowadzono pomiary, było jezioro Kłodno. Wybór tego jeziora był podyktowany możliwością jednoczesnego użycia wszystkich dostępnych sensorów pokładowych bezzałogowych platform pomiarowych. Dodatkowym atutem była możliwość bezpiecznego zastosowania tych urządzeń dzięki panującym na jeziorze korzystnym warunkom hydrometeorologicznym.

3.2.1. Realizacja pomiarów batymetryczno-fotogrametrycznych

Pierwszy etap prac polegał na wykonaniu lotniczego skaningu laserowego obszaru lądowego przyległego do brzegu i zdjęć lotniczych przy użyciu UAV Aurelia X8 Standard LE. Z uwagi na zaplanowaną sekwencyjność pomiarów wynikającą z wykorzystania tej samej jednostki, zdecydowano się na wcześniejsze zaprojektowanie osnowy fotogrametrycznej w celu zapewnienia georeferencji zdjęć wykonanych przez bezzałogowy statek powietrzny. Następnie pomierzono ich środki geometryczne z wykorzystaniem odbiornika GNSS RTK. W tym celu wykorzystano 19 punktów georeferencyjnych, które rozmieszczono na obszarze lądowym strefy brzegowej. W dalszej kolejności wykonano lotniczy skaning laserowy w odpowiednich warunkach meteorologicznych. ALS wykonano na wysokości 30 m wzdłuż trzech profili lotu równoległych do linii brzegowej, które były oddalone od siebie o ok. 10 m. Dzięki oprogramowaniu HYPACK zarejestrowano 9 651 836 punktów w układach PL-UTM (strefa 34N) i PL-EVRF2007-NH.

Po zakończeniu skanowania obszaru lądowego strefy brzegowej LiDAR został zastąpiony kamerą cyfrową zamontowaną na gimbalu. Pomiary fotogrametryczne wykonano na wysokości 120 m, przy kącie nachylenia gimbala wynoszącym 90° oraz pokryciu podłużnym i poprzecznym zdjęć na poziomie 80%. Do rejestracji oraz georeferencji zdjęć wykorzystano oprogramowanie QGroundControl. W trakcie tych pomiarów zarejestrowano 489 zdjęć o rozdzielczości GSD wynoszącej 1.3 cm/px.

Na **Rys. 3.12** przedstawiono autorkę rozprawy doktorskiej podczas realizacji ALS i pomiarów fotogrametrycznych z wykorzystaniem UAV Aurelia X8 Standard LE na jeziorze Kłodno.



Rys. 3.12. Autorka rozprawy doktorskiej podczas realizacji ALS i pomiarów fotogrametrycznych z wykorzystaniem UAV Aurelia X8 Standard LE na jeziorze Kłodno (opracowanie własne).

Równolegle z pomiarami ALS przy użyciu UAV wykonano pomiary linii brzegowej akwenu metodą geodezyjną. Zarejestrowano 343 punkty w układach PL-UTM (strefa 34N) i PL-EVRF2007-NH, których dokładność określenia pozycji przy poziomie ufności 95% wyniosła 0.07 m w płaszczyźnie horyzontalnej i 0.09 m w płaszczyźnie wertykalnej.

W drugim etapie prac wykonano pomiary batymetryczne i MLS przy użyciu jednostki HydroDron-1. Na początku przeprowadzono pomiary echosondą wielowiązkową i mobilny skaning laserowy na jednym profilu sondażowym biegnącym równolegle do linii brzegowej. Pomiary batymetryczne pozwoliły na zarejestrowanie łącznie 4 061 827 punktów MBES, podczas gdy MLS zarejestrowało 8 407 446 punktów. Dane zostały zapisane w układach współrzędnych PL-UTM (strefa 34N) i PL-EVRF2007-NH. Warto podkreślić, że do rejestracji tych danych wykorzystano oprogramowanie HYPACK. Na **Rys. 3.13** przedstawiono członków zespołu badawczego, w tym autorkę i promotora niniejszej rozprawy doktorskiej, podczas realizacji pomiarów hydrograficznych przy użyciu jednostki HydroDron-1 na jeziorze Kłodno.



Rys. 3.13. Członkowie zespołu badawczego podczas realizacji pomiarów hydrograficznych z wykorzystaniem jednostki HydroDron-1 na jeziorze Kłodno (opracowanie własne).

W trzecim etapie prac skupiono się na pomiarach przy użyciu dwóch echosond SBES Airmar EchoRange również z wykorzystaniem jednostki HydroDron-1. Pomiary przeprowadzono w trybie manualnym wzdłuż 25 profili sondażowych, aby uzyskać dane w trudnodostępnych miejscach pomiędzy pomostami. Pomiary batymetryczne z echosond jednowiązkowych przeprowadzono w odpowiednich warunkach meteorologicznych. W trakcie badań zarejestrowano 2691 punktów SBES w układach PL-UTM (strefa 34N) i PL-EVRF2007-NH.

Ostatni etap prac opierał się na określeniu głębokości akwenu za pomocą odbiornika GNSS RTK w punktach o głębokościach nieprzekraczających 0.9 m. Dane z odbiornika GNSS RTK są niezbędne do określenia dokładności danych wygenerowanych za pomocą metody SVR i chmury punktów UAV. Badania wykonano na ściśle określonych głębokościach od 0 m do 0.9 m co około 10 cm. W trakcie pomiarów batymetrycznych zarejestrowano 225 punktów w układach PL-UTM (strefa 34N) i PL-EVRF2007-NH, których dokładność określenia pozycji przy poziomie ufności 95% wyniosła 0.03 m w płaszczyźnie horyzontalnej i 0.04 m w płaszczyźnie wertykalnej. Na **Rys. 3.14** przedstawiono autorkę rozprawy doktorskiej podczas realizacji pomiarów batymetrycznych akwenu metodą geodezyjną przy użyciu odbiornika GNSS RTK Trimble R10 na jeziorze Kłodno.



Rys. 3.14. Autorka rozprawy doktorskiej podczas realizacji pomiarów batymetrycznych akwenu metodą geodezyjną z wykorzystaniem GNSS RTK Trimble R10 na jeziorze Kłodno (opracowanie własne).

3.2.2. Aparatura pomiarowa

Podczas realizacji pomiarów batymetryczno-fotogrametrycznych, które przeprowadzono w dniu 13.08.2024 r. na jeziorze Kłodno, wykorzystano następujące urządzenia pomiarowe:

1. Bezzałogowa jednostka pływająca HydroDron-1. Była ona wyposażona w echosondę interferometryczną Ping DSP 3DSS-DX-450 zintegrowaną z czujnikiem prędkości dźwięku AML SV Xchange, służącą do pomiaru głębokości akwenu głębokowodnego i system GNSS/INS SBG Ekinox2-U, którego zadaniem jest wyznaczanie współrzędnych płaskich dla głębokości zmierzonych przez echosondę. Ponadto zamontowane były dwie echosondy jednowiązkowe Airmar EchoRange, które mierzą głębokość pod USV. Echosondy SBES były zintegrowane z systemem GNSS/INS SBG Ekinox2-U, dzięki czemu otrzymano współrzędne płaskie przypisane do głębokości. Dodatkowo zamontowano profilomierz prędkości dźwięku AML SVP Base X2, aby zapewnić echosondzie wielowiązkowej dostęp do aktualnych danych o prędkości dźwięku w wodzie.

2. Bezzałogowy statek powietrzny Aurelia X8 Standard LE. Był on wyposażony w prototyp modułu optoelektronicznego. Umożliwił on pozyskanie chmury punktów LiDAR dla obszaru lądowego przyległego do brzegu. Ponadto dzięki wykonanym zdjęciom lotniczym można było wygenerować chmurę punktów SfM dla akwenu płytkowodnego i ortofotomapę.
3. Odbiornik geodezyjny Trimble R10. Użyto go do realizacji pomiarów batymetrycznych akwenu metodą geodezyjną (do głębokości 0.9 m). Poza tym, na podstawie wskazań odbiornika GNSS RTK określono dokładność pomiaru głębokości/współrzędnych płaskich ($p=0.95$) dla danych: LiDAR z ALS, LiDAR z MLS, SVR i UAV.

3.2.3. Opracowanie modeli fuzji danych średnich ważonych

Opracowanie modeli fuzji danych średnich ważonych rozpoczęto od przetwarzania danych głębokościowych pozyskanych przy użyciu echosondy interferometrycznej. Na początku usunięto błędnie zarejestrowane dane MBES przy pomocy filtra progowego o minimalnej (4 m) i maksymalnej (11 m) głębokości. Przedziały te zostały dobrane na podstawie analizy rozkładu zarejestrowanych danych. Następnie po szczegółowej analizie przefiltrowanych punktów usunięto manualnie pojedyncze głębokości. W końcowym etapie przetwarzania danych MBES dokonano ich uśredniania w regularnych odstępach wynoszących 0.3 m. Zgodnie ze specyfikacją urządzenia dokładność pomiaru głębokości dla tych punktów wyniosła 0.15 m ($p=0.95$).

W drugiej kolejności przystąpiono do przetwarzania danych głębokościowych pozyskanych przy użyciu echosondy jednowiązkowej. Wstępna analiza tych danych wykazała, że zostały one zarejestrowane poprawnie. W związku z tym, nie było konieczności ich dalszego filtrowania ani usuwania. Dane SBES dla zakresu głębokości od 0.48 m do 0.99 m (291 punktów) cechowały się dokładnością pomiaru głębokości wynoszącą 0.01 m ($p=0.95$). Identyczną dokładność pomiaru głębokości miały również dane SBES dla zakresu głębokości od 1 m do 8.68 m (2399 punktów).

Chmura punktów UAV pokrywająca część lądową i podwodną akwenu zawierała 35 062 623 punkty. Po zastosowaniu metody SVR uzyskano 748 423 punkty w części wodnej. Następnie zdecydowano się na usunięcie punktów SVR znajdujących się na pomostach. Kolejnym etapem prac było próbkowanie danych SVR z rozdzielczością 0.5 m. Dane SVR (33 168 punktów) cechowały się dokładnością pomiaru głębokości wynoszącą 0.23 m ($p=0.95$). Dane SVR charakteryzują się większą dokładnością w porównaniu do danych z 2023 r., ponieważ pomiary przeprowadzone w 2024 r. były oparte na wcześniej zdobytym doświadczeniu zespołu. Grupa badawcza prawidłowo rozmieściła i określiła liczbę punktów georeferencyjnych.

Ostatnim etapem prac przygotowawczych było wyznaczenie przebiegu linii brzegowej na podstawie danych pochodzących z lotniczego skaningu laserowego, mobilnego skaningu laserowego i ortofotomapy. Otrzymane dane dotyczące linii brzegowej zostały porównane z referencyjną linią brzegową wyznaczoną przy użyciu odbiornika GNSS RTK. Na początku określono linię brzegową na podstawie danych LiDAR z ALS przy użyciu metody ekstrakcji linii brzegowej zaproponowanej przez Xu i in. W ten sposób wygenerowano 61 punktów wzdłuż linii brzegowej z dokładnością 2.12 m ($p=0.95$). Następnie linia brzegowa została wyznaczona w oparciu o dane LiDAR z MLS przy użyciu metody ekstrakcji linii brzegowej zaproponowanej przez Xu i in. W efekcie otrzymano 233 punkty zlokalizowane wzdłuż linii brzegowej jeziora Kłodna z dokładnością 1.16 m ($p=0.95$). Ponadto wyznaczono naturalny przebieg linii brzegowej oraz przebieg linii brzegowej uwzględniającej pomosty na podstawie ortofotomapy. Dokładność określenia przebiegu linii brzegowej przy poziomie ufności 95% wyniosła

0.05 m dla naturalnej linii brzegowej i 0.06 m dla linii brzegowej uwzględniającej budowlę hydrotechniczne. Można przypuszczać, że większa dokładność danych LiDAR z ALS i MLS wynikała ze zdobytych wcześniej doświadczeń zespołu, który wiedział, jak optymalnie wykorzystać możliwości sprzętu oraz dobrać odpowiednie parametry pomiarowe.

Podsumowując, kampania pomiarowa przeprowadzona w 2024 r. charakteryzowała się wysoką dokładnością uzyskanych danych, co było wynikiem optymalnego doboru metod pomiarowych i zdobytych wcześniej doświadczeń zespołu.

Na **Rys. 3.15** przedstawiono lokalizację przetworzonych danych geoprzestrzennych zarejestrowanych podczas kompleksowej kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniu 13.08.2024 r.



Rys. 3.15. Lokalizacja przetworzonych danych geoprzestrzennych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniu 13.08.2024 r. (opracowanie własne).


W dalszej kolejności obliczono wagi dla poszczególnych metod i urządzeń pomiarowych (**Tab. 3.8**).

Tab. 3.8. Zestawienie wag dla poszczególnych danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniu 13.08.2024 r. (opracowanie własne).

Dane	Dokładność pomiaru głębokości/ współrzędnych płaskich ($p=0.95$)	$w(u=1)$	$w(u=2)$
SBES (zakres głębokości 0.4-0.99 m) *	0.01	100	10 000
SBES (zakres głębokości: 1-8.68 m) *	0.01	100	10 000
MBES (zakres głębokości: 6.39-11 m) *	0.15	6.67	44.44
SVR	0.23	4.35	18.90
Fotogrametryczne (naturalna linia brzegowa)	0.05	20	400
Fotogrametryczne (linia brzegowa z pomostami)	0.06	16.67	277.78
LiDAR z ALS	2.12	0.47	0.22
LiDAR z MLS	1.16	0.86	0.74

* Dokładność pomiaru głębokości ($p=0.95$) została określona na podstawie specyfikacji technicznych urządzeń.

Na podstawie tak opracowanych danych przystąpiono następnie do opracowania modeli fuzji danych średnich ważonych o wykładniku potęgi 1 i 2 w lokalnym układzie wysokościowym dla kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniu 13.08.2024 r. (**Rys. 3.16**).



Rys. 3.16. Modele fuzji danych średnich ważonych o wykładniku potęgi 1 (**a**) i 2 (**b**) w lokalnym układzie wysokościowym dla kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniu 13.08.2024 r. (opracowanie własne).

Opracowane modele fuzji danych średnich ważonych pokrywają obszar płytkowodny i głębokowodny. Wynika to z faktu, że podczas kampanii pomiarowej użyto wszystkich dostępnych sensorów. Dodatkowo dane z ortofotomapy zostały wzbogacone o informacje pochodzące z lotniczego i mobilnego skaningu laserowego, co pozwoliło na uzyskanie bardziej dokładnego przebiegu linii brzegowej. Można zauważyć, że skrajne wartości głębokości dla modeli o wykładniku potęgi 1 i 2 są identyczne. Minimalna głębokość wygenerowanych modeli wynosi 0 m, natomiast maksymalna głębokość osiąga 11 m. Ponownie udowodniono, że zwiększanie wartości wykładnika potęgi nie ma istotnego wpływu na uzyskane głębokości, gdy stosuje się zaproponowaną metodę modelowania powierzchni terenu w strefie brzegowej.

3.3. Analiza ilościowa wyników metody

W tym podrozdziale przeprowadzono analizę ilościową wyników autorskiej metody modelowania powierzchni terenu w strefie brzegowej uzyskanych na podstawie sześciu modeli fuzji danych średnich ważonych, które zostały opracowane dla akwenu morskiego przyległego do plaży miejskiej w Gdyni i jeziora Kłodno.

3.3.1. Wskaźniki ilościowe

W pierwszej kolejności obliczono różnice głębokości między punktami pomiarowymi a odpowiadającymi im (o tych samych współrzędnych prostokątnych płaskich) punktami wygenerowanego NMT przy użyciu następującej zależności:

$$\Delta d_i = |d_i - d_{NMT_i}| \quad (3.1)$$

gdzie:

Δd_i – różnica głębokości między i -tym punktem pomiarowym a i -tym punktem opracowanego modelu fuzji danych średnich ważonych,

d_i – głębokość i -tego punktu pomiarowego,

d_{NMT_i} – głębokość i -tego punktu wygenerowanego NMT.

Po obliczeniu różnic głębokości między punktami pomiarowymi a odpowiadającymi im punktami wygenerowanego NMT można było przeprowadzić analizę ilościową wyników autorskiej metody modelowania powierzchni terenu w strefie brzegowej. Zanim do tego przystąpiono, postanowiono wyznaczyć miary statystyczne opisujące poszczególne NMT, takie jak: średnia kwadratowa, minimalna i maksymalna wartość, rozstęp (ang. *Range* – R) oraz rozstęp ćwiartkowy:

$$RMS = \sqrt{\frac{\sum_i^N (d_{NMT_i})^2}{N}} \quad (3.2)$$

$$R = \max(d_{NMT}) - \min(d_{NMT}) \quad (3.3)$$

$$IQR = Q_3(d_{NMT}) - Q_1(d_{NMT}) \quad (3.4)$$

gdzie:

N – liczba punktów pomiarowych,

$\max$ – maksymalna wartość,

$\min$ – minimalna wartość,

Q_1 – kwantyl rzędu $1/4 = 25\%$ obserwacji jest położonych poniżej = 25. procent,

Q_3 – kwantyl rzędu $3/4 = 75\%$ obserwacji jest położonych powyżej = 75. procent.

Następnie w celu oceny dokładności opracowanych modeli fuzji danych średnich ważonych postanowiono porównać wartości głębokości punktów pomiarowych z wartościami głębokości punktów wygenerowanego NMT wykorzystując następujące miary statystyczne: pierwiastek błędu średniokwadratowego, średni błąd bezwzględny i współczynnik determinacji (R^2):

$$RMSE = \sqrt{\frac{\sum_i^N (\Delta d_i)^2}{N}} \quad (3.5)$$

$$MAE = \frac{\sum_i^N |\Delta d_i|}{N} \quad (3.6)$$

$$R^2 = \frac{\sum_i^N (d_{NMT_i} - \bar{d}_{NMT})^2}{\sum_i^N (d_i - \bar{d}_{NMT})^2} \quad (3.7)$$

gdzie:

$\bar{d}_{NMT}$ – średnia arytmetyczna różnic głębokości wygenerowanego NMT.

Ponadto obliczono dwie miary statystyczne: R68 i R95, które wynikają z sortowania danych według wartości w kolejności od najmniejszej do największej.

Na koniec postanowiono zwizualizować uzyskane wyniki badań. W tym celu narysowano histogram przedstawiający częstość występowania błędów określenia głębokości w danym przedziale liczbowym. Poza tym, wyznaczono dystrybuantę błędu określenia głębokości dla rozkładu empirycznego ($F_N(\Delta d)$) wyliczoną wprost z danych i dla rozkładu normalnego ($G(\Delta d)$), który jest najczęściej stosowanym rozkładem statystycznym w analizie błędów.

Dystrybuanta empiryczna opisuje rozkład prawdopodobieństwa na podstawie danych z próby. Dla danej próby składającej się z obserwacji $\Delta d_1, \Delta d_2, \dots, \Delta d_N$ (gdzie Δd_i są uporządkowane rosnąco) dystrybuanta $F_N(\Delta d)$ jest zdefiniowana jako stosunek liczby obserwacji mniejszych lub równych Δd do całkowitej liczby obserwacji w próbie N . Wartość dystrybuanty empirycznej można obliczyć za pomocą wzoru:

$$F_N(\Delta d) = \frac{1}{N} \cdot (\text{liczba } \Delta d_i \leq \Delta d) = \frac{1}{N} \cdot \sum_{i=1}^N I(\Delta d_i \leq \Delta d) \quad (3.8)$$

gdzie:

$I(.)$ – funkcja charakterystyczna zbioru.

Natomiast dystrybuanta dla rozkładu normalnego to funkcja, która opisuje prawdopodobieństwo, że zmienna losowa o rozkładzie normalnym przyjmie wartość mniejszą lub równą pewnej wartości. Dla zmiennej losowej ΔD o rozkładzie normalnym z wartością oczekiwaną μ_d i odchyleniem standardowym σ_d , dystrybuanta $G(\Delta d)$ jest zdefiniowana wzorem:

$$G(\Delta d) = P(\Delta D \leq \Delta d) = \int_{-\infty}^{\Delta d} \frac{1}{\sigma_d \cdot \sqrt{2\pi}} \cdot e^{-\frac{(td - \mu_d)^2}{2(\sigma_d)^2}} dt \quad (3.9)$$

3.3.2. Kampania pomiarowa na akwenie morskim przyległym do plaży miejskiej w Gdyni w dniu 10.06.2022 r.

W pierwszej kolejności przystąpiono do analizy ilościowej uzyskanych zbiorów danych (**Tab. 3.9**). Na początku przeanalizowano model fuzji danych średnich ważonych o wykładniku potęgi 1. Blisko 98.5% danych (67 578 punktów) cechuje się głębokościami poniżej 1 m, natomiast ok. 1.5% danych (1022 punkty) jest położona na głębokościach wynoszących co najmniej 1 m. Średnia kwadratowa (RMS) głębokości interpolowanych ma wartość 0.477 m. Minimalna głębokość wygenerowanego NMT wynosi 0 m, natomiast jego maksymalna głębokość ma wartość 1.570 m. Oznacza to, że głębokości na

analizowanym akwenie nie są za bardzo zróżnicowane. Dlatego rozstęp, czyli różnica między największą i najmniejszą wartością głębokości interpolowanej (R), wynosi 1.570 m, podczas gdy rozstęp ćwiartkowy, czyli różnica między pierwszym i trzecim kwartylem głębokości interpolowanej (IRQ), jest zdecydowanie mniejszy i wynosi 0.249 m.


Następnie przeanalizowano model fuzji danych średnich ważonych o wykładniku potęgi 2. Blisko 98.5% danych (67 578 punktów) cechuje się głębokościami poniżej 1 m, natomiast ok. 1.5% danych (1022 punkty) jest położona na głębokościach wynoszących co najmniej 1 m. Średnia kwadratowa głębokości interpolowanych ma wartość 0.477 m. Minimalna głębokość wygenerowanego NMT wynosi 0 m, natomiast jego maksymalna głębokość ma wartość 1.570 m. Oznacza to, że głębokości na analizowanym akwenie nie są za bardzo zróżnicowane. Dlatego rozstęp wynosi 1.367 m, podczas gdy rozstęp ćwiartkowy jest zdecydowanie mniejszy i wynosi 0.249 m.

Tab. 3.9. Zestawienie informacji o modelach fuzji danych średnich ważonych o wykładniku potęgi 1 i 2 dla akwenu morskiego przyległego do plaży miejskiej w Gdyni na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniu 10.06.2022 r. (opracowanie własne).

Miara statystyczna	Model fuzji danych średnich ważonych	
	$u=1$	$u=2$
RMS (m)	0.477	0.477
$d_{NMT_{min}}^1$ (m)	0.000	0.000
$d_{NMT_{max}}^2$ (m)	1.570	1.570
R (m)	1.570	1.570
IRQ (m)	0.249	0.249

Minimalna¹ i maksymalna² głębokość opracowanego modelu fuzji danych średnich ważonych.

Na podstawie **Tab. 3.9** należy stwierdzić, że wartości miar statystycznych modeli fuzji danych średnich ważonych o wykładniku potęgi 1 i 2 są identyczne. Następnie obliczono różnice głębokości między punktami pomiarowymi (SVR i USV) a odpowiadającymi im (o tych samych współrzędnych prostokątnych płaskich) punktami wygenerowanych NMT (**Rys. 3.17**).



Rys. 3.17. Graficzne przedstawienie różnic głębokości między punktami pomiarowymi a odpowiadającymi im punktami wygenerowanych NMT o wykładniku potęgi 1 (a) i 2 (b) dla akwenu morskiego przyległego do plaży miejskiej w Gdyni na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniu 10.06.2022 r. (opracowanie własne).

Na podstawie **Rys. 3.17** można stwierdzić, że modele fuzji danych średnich ważonych o wykładniku potęgi 1 i 2 wykazują się wysoką dokładnością. Blisko 91% danych dla NMT o wykładniku potęgi 1 (62 201 punktów) i 2 (62 189 punktów) cechuje się błędami określenia głębokości do 0.25 m. Natomiast nieco ponad 9% danych dla NMT o wykładniku potęgi 1 (6399 punktów) i 2 (6411 punktów) ma błędy wyznaczenia głębokości powyżej 0.25 m. Należy zaznaczyć, że wszystkie punkty o błędach określenia głębokości powyżej 0.25 m zostały pozyskane przy użyciu algorytmu SVR. Największe błędy wyznaczenia głębokości (powyżej 0.25 m) można zaobserwować na najpłytszych wodach. Punkty o błędach określenia głębokości powyżej 0.25 m znajdują się między izobatami: 0.39 m a 0.95 m dla NMT o wykładniku potęgi 1 i 0.39 m a 0.98 m dla NMT o wykładniku potęgi 2. Na podstawie uzyskanych wyników można stwierdzić, że różnice głębokości między punktami pomiarowymi a odpowiadającymi im punktami wygenerowanych NMT o wykładniku potęgi 1 i 2 są identyczne.

Po wyznaczeniu różnic głębokości między punktami pomiarowymi a odpowiadającymi im punktami wygenerowanych NMT postanowiono dokonać analizy statystycznej błędów określenia głębokości (**Tab. 3.9**).


Tab. 3.10. Miary dokładności modeli fuzji danych średnich ważonych o wykładniku potęgi 1 i 2 dla akwenu morskiego przyległego do plaży miejskiej w Gdyni na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniu 10.06.2022 r. (opracowanie własne).

Miara statystyczna	Model fuzji danych średnich ważonych	
	$u=1$	$u=2$
RMSE (m)	0.016	0.016
MAE (m)	0.070	0.070
R^2 (–)	0.702	0.703
R68 (m)	0.067	0.067
R95 (m)	0.280	0.281

Na początku określono dokładność opracowanych NMT w stosunku do pomiarów rzeczywistych. Wartości miar RMSE i MAE dla modeli fuzji danych średnich ważonych o wykładniku potęgi 1 i 2 są identyczne i wynoszą odpowiednio 0.016 m i 0.131 m. Wartości tych miar wskazują na małe różnice między wartościami interpolowanymi a rzeczywistymi. Współczynnik determinacji (R^2) dla obu modeli osiągnął poziom ok. 0.70. Oznacza to, że dopasowanie modeli fuzji danych średnich ważonych o wykładniku potęgi 1 i 2 do danych pomiarowych jest słabe. Błąd określenia głębokości dla 68% danych (miara R68) wyniósł 0.067 m dla obu modeli, natomiast błąd określenia głębokości dla 95% danych (miara R95) osiągnął wartość 0.280 m dla modelu o wykładniku potęgi 1 i 0.281 m dla modelu o wykładniku potęgi 2.


Na podstawie wyników przedstawionych w **Tab. 3.9** i **3.10** należy stwierdzić, że miary statystyczne opisujące modele fuzji danych średnich ważonych o wykładniku potęgi 1 i 2 są niemal identyczne. Maksymalne różnice między poszczególnymi miarami wynoszą zaledwie 0.001 (R^2) lub 0.001 m (R95). Oznacza to, że zwiększanie wykładnika potęgi nie ma praktycznie wpływu na wygenerowany model. Dlatego też, w tym i kolejnych podrozdziałach będą analizowane wyłącznie modele fuzji danych średnich ważonych o wykładniku potęgi 1.

Na koniec postanowiono zwizualizować uzyskane wyniki badań. W tym celu narysowano histogram przedstawiający częstość występowania błędów określenia głębokości (**Rys. 3.18**). Poza tym, wyznaczono dystrybuantę błędu określenia głębokości dla rozkładu empirycznego i normalnego (**Rys. 3.19**).



Rys. 3.18. Histogram przedstawiający częstość występowania błędów określenia głębokości dla akwenu morskiego przyległego do plaży miejskiej w Gdyni na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniu 10.06.2022 r. (opracowanie własne).

Na podstawie **Rys. 3.18** można stwierdzić, że 81.62% danych ma błąd określenia głębokości nieprzekraczający wartości 0.2 m, natomiast 96.78% danych ma błąd nie większy niż 0.3 m. Istotny z punktu widzenia realizacji pomiarów hydrograficznych błąd określenia głębokości przy poziomie ufności 95% wynosi 0.28 m. Oznacza to, że dokładność opracowanego modelu fuzji danych średnich ważonych o wykładniku potęgi 1 nie spełnia minimalnych wymagań dokładnościowych, które są przewidziane dla kategorii specjalnej IHO.



Rys. 3.19. Dystrybuanta błędu określenia głębokości dla akwenu morskiego przyległego do plaży miejskiej w Gdyni na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniu 10.06.2022 r. (opracowanie własne).

Na podstawie **Rys. 3.19** można zauważyć, że dystrybuanta empiryczna znacznie odbiega od dystrybuanty rozkładu normalnego (Gaussa). W niektórych miejscach różnica między prawdopodobieństwami wystąpienia błędu określenia głębokości dla rozkładu empirycznego i normalnego wynosi ok. 0.36. Przykładowo, miara R68 dla rozkładu empirycznego wynosi 0.067 m, natomiast miara R68 dla rozkładu normalnego wynosi aż 0.119 m. Oznacza to, że błędy określenia głębokości nie podlegają rozkładowi normalnemu.

3.3.3. Kampania pomiarowa na akwenu morskim przyległym do plaży miejskiej w Gdyni w dniach 05.09-07.11.2023 r.


W pierwszej kolejności przystąpiono do analizy ilościowej uzyskanego zbioru danych (**Tab. 3.11**). Blisko 95% danych (56 411 punktów) cechuje się głębokościami poniżej 1 m, natomiast ok. 5% danych (2995 punktów) jest położona na głębokościach wynoszących co najmniej 1 m. Średnia kwadratowa głębokości interpolowanych ma wartość 0.484 m. Minimalna głębokość wygenerowanego NMT wynosi 0 m, natomiast jego maksymalna głębokość ma wartość 1.700 m. Oznacza to, że głębokości na analizowanym akwenu nie są za bardzo zróżnicowane. Dlatego rozstęp wynosi 1.700 m, podczas gdy rozstęp ćwiartkowy jest zdecydowanie mniejszy i wynosi 0.237 m.

Tab. 3.11. Zestawienie informacji o modelu fuzji danych średnich ważonych o wykładniku potęgi 1 dla akwenu morskiego przyległego do plaży miejskiej w Gdyni na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 05.09-07.11.2023 r. (opracowanie własne).

Miara statystyczna	Model fuzji danych średnich ważonych ($u=1$)
RMS (m)	0.484
$d_{NMT_{min}}^1$ (m)	0.000
$d_{NMT_{max}}^2$ (m)	1.700
R (m)	1.700
IRQ (m)	0.237

Minimalna¹ i maksymalna² głębokość opracowanego modelu fuzji danych średnich ważonych.

Następnie obliczono różnice głębokości między punktami pomiarowymi (SVR i USV) a odpowiadającymi im (o tych samych współrzędnych prostokątnych płaskich) punktami wygenerowanego NMT (**Rys. 3.20**).



Rys. 3.20. Graficzne przedstawienie różnic głębokości między punktami pomiarowymi a odpowiadającymi im punktami wygenerowanego NMT dla akwenu morskiego przyległego do plaży miejskiej w Gdyni na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 05.09-07.11.2023 r. (opracowanie własne).

Na podstawie **Rys. 3.20** można stwierdzić, że model fuzji danych średnich ważonych o wykładniku potęgi 1 wykazuje się umiarkowaną dokładnością. Ponad 73% danych (43 530 punktów) cechuje się błędami określenia głębokości do 0.25 m. Natomiast niespełna 27% danych (15 876 punktów) ma błędy wyznaczenia głębokości powyżej 0.25 m. Należy zaznaczyć, że wszystkie punkty o błędach określenia głębokości powyżej 0.25 m zostały pozyskane przy użyciu algorytmu SVR. Największe błędy wyznaczenia głębokości (powyżej 0.25 m) można zaobserwować na najpłytszych wodach. Punkty o błędach określenia głębokości powyżej 0.25 m znajdują się między izobatami 0.36 m a 1.04 m.


Po wyznaczeniu różnic głębokości między punktami pomiarowymi a odpowiadającymi im punktami wygenerowanego NMT postanowiono dokonać analizy statystycznej błędów określenia głębokości (**Tab. 3.12**).

Tab. 3.12. Miary dokładności modelu fuzji danych średnich ważonych o wykładniku potęgi 1 dla akwenu morskiego przyległego do plaży miejskiej w Gdyni na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 05.09-07.11.2023 r. (opracowanie własne).

Miara statystyczna	Model fuzji danych średnich ważonych ($u=1$)
RMSE (m)	0.037
MAE (m)	0.131
R^2 (-)	0.625
R68 (m)	0.232
R95 (m)	0.356


Dokładność opracowanego NMT w stosunku do pomiarów rzeczywistych została określona za pomocą miar RMSE – 0.037 m i MAE – 0.131 m. Wartości miar RMSE i MAE wskazują na małe różnice między wartościami interpolowanymi a rzeczywistymi. Współczynnik determinacji osiągnął poziom 0.625. Oznacza to, że dopasowanie modelu fuzji danych średnich ważonych o wykładniku potęgi 1 do danych pomiarowych jest bardzo słabe. Błąd określenia głębokości dla 68% danych (miara R68) wyniósł 0.232 m, natomiast błąd określenia głębokości dla 95% danych (miara R95) osiągnął wartość 0.356 m.

Na koniec postanowiono zwizualizować uzyskane wyniki badań. W tym celu narysowano histogram przedstawiający częstość występowania błędów określenia głębokości (**Rys. 3.21**). Poza tym, wyznaczono dystrybuantę błędu określenia głębokości dla rozkładu empirycznego i normalnego (**Rys. 3.22**).



Rys. 3.21. Histogram przedstawiający częstość występowania błędów określenia głębokości dla akwenu morskiego przyległego do plaży miejskiej w Gdyni na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 05.09-07.11.2023 r. (opracowanie własne).

Na podstawie **Rys. 3.21** można stwierdzić, że 61.12% danych ma błąd określenia głębokości nieprzekraczający wartości 0.2 m, natomiast 85.58% danych ma błąd nie większy niż 0.3 m. Istotny z punktu widzenia realizacji pomiarów hydrograficznych błąd określenia głębokości przy poziomie ufności 95% wynosi 0.356 m. Oznacza to, że dokładność opracowanego modelu fuzji danych średnich ważonych o wykładniku potęgi 1 nie spełnia minimalnych wymagań dokładnościowych, które są przewidziane dla kategorii specjalnej IHO.



Rys. 3.22. Dystrybucja błędów określenia głębokości dla akwenu morskiego przyległego do plaży miejskiej w Gdyni na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 05.09-07.11.2023 r. (opracowanie własne).

Na podstawie **Rys. 3.22** można zauważyć, że dystrybucja empiryczna znacznie odbiega od dystrybucji rozkładu normalnego (Gausa). W niektórych miejscach różnica między prawdopodobieństwami wystąpienia błędów określenia głębokości dla rozkładu empirycznego i normalnego wynosi ok. 0.25. Przykładowo, miara R68 dla rozkładu empirycznego wynosi 0.197 m, natomiast miara R68 dla rozkładu normalnego wynosi aż 0.232 m. Oznacza to, że błędy określenia głębokości nie podlegają rozkładowi normalnemu.

3.3.4. Kampania pomiarowa na jeziorze Kłodno w dniach 02-03.06.2022 r.

W pierwszej kolejności przystąpiono do analizy ilościowej uzyskanego zbioru danych (**Tab. 3.13**). Blisko 90% danych (21 036 punktów) cechuje się głębokościami poniżej 1 m, natomiast ok. 10% danych (2377 punktów) jest położona na głębokościach wynoszących co najmniej 1 m. Średnia kwadratowa głębokości interpolowanych ma wartość 1.231 m. Minimalna głębokość wygenerowanego NMT wynosi 0 m, natomiast jego maksymalna głębokość ma wartość 6.535 m. Oznacza to, że głębokości na analizowanym akwenie są zróżnicowane. Dlatego rozstęp wynosi 6.535 m, podczas gdy rozstęp ćwiartkowy jest zdecydowanie mniejszy i wynosi 0.371 m.

Tab. 3.13. Zestawienie informacji o modelu fuzji danych średnich ważonych o wykładniku potęgi 1 dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 02-03.06.2022 r. (opracowanie własne).

Miara statystyczna	Model fuzji danych średnich ważonych ($u=1$)
RMS (m)	1.231
$d_{NMT_{min}}^1$ (m)	0.000
$d_{NMT_{max}}^2$ (m)	6.535
R (m)	6.535
IRQ (m)	0.371

Minimalna¹ i maksymalna² głębokość opracowanego modelu fuzji danych średnich ważonych.

Następnie obliczono różnice głębokości między punktami pomiarowymi (SVR i USV) a odpowiadającymi im (o tych samych współrzędnych prostokątnych płaskich) punktami wygenerowanego NMT (**Rys. 3.23**).



Rys. 3.23. Graficzne przedstawienie różnic głębokości między punktami pomiarowymi a odpowiadającymi im punktami wygenerowanego NMT dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 02-03.06.2022 r. (opracowanie własne).

Na podstawie **Rys. 3.23** można stwierdzić, że model fuzji danych średnich ważonych o wykładniku potęgi 1 wykazuje się wysoką dokładnością. Ponad 95% danych (22 332 punkty) cechuje się błędami określenia głębokości do 0.25 m. Natomiast niespełna 5% danych (1081 punktów) ma błędy wyznaczenia głębokości powyżej 0.25 m. Należy zaznaczyć, że prawie wszystkie punkty o błędach określenia głębokości powyżej 0.25 m zostały pozyskane przy użyciu algorytmu SVR. Największe błędy wyznaczenia głębokości (powyżej 0.25 m) można zaobserwować na najpłytszych wodach i wzdłuż obrysów pomostów. Punkty o błędach określenia głębokości powyżej 0.25 m znajdują się między izobatami 0.38 m a 6.44 m.


Po wyznaczeniu różnic głębokości między punktami pomiarowymi a odpowiadającymi im punktami wygenerowanego NMT postanowiono dokonać analizy statystycznej błędów określenia głębokości (**Tab. 3.14**).

Tab. 3.14. Miary dokładności modelu fuzji danych średnich ważonych o wykładniku potęgi 1 dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 02-03.06.2022 r. (opracowanie własne).

Miara statystyczna	Model fuzji danych średnich ważonych ($u=1$)
RMSE (m)	0.010
MAE (m)	0.046
R^2 (-)	0.988
R68 (m)	0.017
R95 (m)	0.246


Dokładność opracowanego NMT w stosunku do pomiarów rzeczywistych została określona za pomocą miar RMSE – 0.010 m i MAE – 0.046 m. Wartości miar RMSE i MAE wskazują na małe różnice między wartościami interpolowanymi a rzeczywistymi. Współczynnik determinacji osiągnął poziom 0.988. Oznacza to, że dopasowanie modelu fuzji danych średnich ważonych o wykładniku potęgi 1 do danych pomiarowych jest bardzo dobre. Błąd określenia głębokości dla 68% danych (miara R68) wyniósł 0.017 m, natomiast błąd określenia głębokości dla 95% danych (miara R95) osiągnął wartość 0.246 m.

Na koniec postanowiono zwizualizować uzyskane wyniki badań. W tym celu narysowano histogram przedstawiający częstość występowania błędów określenia głębokości (**Rys. 3.24**). Poza tym, wyznaczono dystrybuantę błędu określenia głębokości dla rozkładu empirycznego i normalnego (**Rys. 3.25**).



Rys. 3.24. Histogram przedstawiający częstość występowania błędów określenia głębokości dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 02-03.06.2022 r. (opracowanie własne).

Na podstawie **Rys. 3.24.** można stwierdzić, że 90.68% danych ma błąd określenia głębokości nieprzekraczający wartości 0.2 m, natomiast 97.92% danych ma błąd nie większy niż 0.3 m. Istotny z punktu widzenia realizacji pomiarów hydrograficznych błąd określenia głębokości przy poziomie ufności 95% wynosi 0.246 m. Oznacza to, że dokładność opracowanego modelu fuzji danych średnich ważonych o wykładniku potęgi 1 jest zbliżona do minimalnych wymagań dokładnościowych, które są przewidziane dla kategorii specjalnej IHO.



Rys. 3.25. Dystrybucja błędu określenia głębokości dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 02-03.06.2022 r. (opracowanie własne).

Na podstawie **Rys. 3.25.** można zauważyć, że dystrybucja empiryczna znacznie odbiega od dystrybucji rozkładu normalnego (Gaussa). W niektórych miejscach różnica między prawdopodobieństwami wystąpienia błędu określenia głębokości dla rozkładu empirycznego i normalnego wynosi ok. 0.30. Przykładowo, miara R68 dla rozkładu empirycznego wynosi 0.017 m, natomiast miara R68 dla rozkładu normalnego wynosi aż 0.088 m. Oznacza to, że błędy określenia głębokości nie podlegają rozkładowi normalnemu.

3.3.5. Kampania pomiarowa na jeziorze Kłodno w dniach 01.08-02.10.2023 r.

W pierwszej kolejności przystąpiono do analizy ilościowej uzyskanego zbioru danych (**Tab. 3.15**). Blisko 10% danych (13 286 punktów) cechuje się głębokościami poniżej 1 m, natomiast ok. 90% danych (116 204 punkty) jest położona na głębokościach wynoszących co najmniej 1 m. Średnia kwadratowa głębokości interpolowanych ma wartość 43.266 m. Minimalna głębokość wygenerowanego NMT wynosi 0 m, natomiast jego maksymalna głębokość ma wartość 11.055 m. Oznacza to, że głębokości na analizowanym akwenie są bardzo zróżnicowane. Dlatego rozstęp wynosi 11.055 m, podczas gdy rozstęp ćwiartkowy jest zdecydowanie mniejszy i wynosi 2.35 m.


Tab. 3.15. Zestawienie informacji o modelu fuzji danych średnich ważonych o wykładniku potęgi 1 dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 01.08-02.10.2023 r. (opracowanie własne).

Miara statystyczna	Model fuzji danych średnich ważonych ($u=1$)
RMS (m)	43.266
$d_{NMT_{min}}^1$ (m)	0.000
$d_{NMT_{max}}^2$ (m)	11.055
R (m)	11.055
IRQ (m)	2.350

Minimalna¹ i maksymalna² głębokość opracowanego modelu fuzji danych średnich ważonych.

Następnie obliczono różnice głębokości między punktami pomiarowymi (SVR i USV) a odpowiadającymi im (o tych samych współrzędnych prostokątnych płaskich) punktami wygenerowanego NMT (**Rys. 3.26**).

Na podstawie **Rys. 3.26** można stwierdzić, że model fuzji danych średnich ważonych o wykładniku potęgi 1 wykazuje się bardzo wysoką dokładnością. Blisko 99% danych (127 708 punktów) cechuje się błędami określenia głębokości do 0.25 m. Natomiast nieco ponad 1% danych (1782 punkty) ma błędy wyznaczenia głębokości powyżej 0.25 m. Należy zaznaczyć, że większość danych o błędach określenia głębokości powyżej 0.25 m (1172 punkty) zostało pozyskanych przy użyciu algorytmu SVR. Pozostała część danych o błędach wyznaczenia głębokości powyżej 0.25 m (600 punktów) została zarejestrowana przez echosondy MBES i SBES. Największe błędy określenia głębokości (powyżej 0.25 m) można zaobserwować na najpłytszych wodach i wzdłuż obrysów pomostów. Punkty o błędach wyznaczenia głębokości powyżej 0.25 m znajdują się między izobatami 0.36 m a 6.33 m.



Rys. 3.26. Graficzne przedstawienie różnic głębokości między punktami pomiarowymi a odpowiadającymi im punktami wygenerowanego NMT dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 01.08-02.10.2023 r. (opracowanie własne).


Po wyznaczeniu różnic głębokości między punktami pomiarowymi a odpowiadającymi im punktami wygenerowanego NMT postanowiono dokonać analizy statystycznej błędów określenia głębokości (**Tab. 3.16**).

Tab. 3.16. Miary dokładności modelu fuzji danych średnich ważonych o wykładniku potęgi 1 dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 01.08-02.10.2023 r. (opracowanie własne).

Miara statystyczna	Model fuzji danych średnich ważonych ($u=1$)
RMSE (m)	0.003
MAE (m)	0.024
R^2 (-)	1.000
R68 (m)	0.020
R95 (m)	0.083


Dokładność opracowanego NMT w stosunku do pomiarów rzeczywistych została określona za pomocą miar RMSE – 0.003 m i MAE – 0.024 m. Wartości miar RMSE i MAE wskazują na bardzo małe różnice między wartościami interpolowanymi a rzeczywistymi. Współczynnik determinacji osiągnął poziom 1.000. Oznacza to, że dopasowanie modelu fuzji danych średnich ważonych o wykładniku potęgi 1 do danych pomiarowych jest najwyższe z możliwych. Błąd określenia głębokości dla 68% danych (miara R68) wyniósł 0.020 m, natomiast błąd określenia głębokości dla 95% danych (miara R95) osiągnął wartość 0.083 m.

Na koniec postanowiono zwizualizować uzyskane wyniki badań. W tym celu narysowano histogram przedstawiający częstość występowania błędów określenia głębokości (**Rys. 3.27**). Poza tym, wyznaczono dystrybuantę błędu określenia głębokości dla rozkładu empirycznego i normalnego (**Rys. 3.28**).



Rys. 3.27. Histogram przedstawiający częstość występowania błędów określenia głębokości dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 01.08-02.10.2023 r. (opracowanie własne).

Na podstawie **Rys. 3.27** można stwierdzić, że 96.06% danych ma błąd określenia głębokości nieprzekraczający wartości 0.1 m, natomiast 97.95% danych ma błąd nie większy niż 0.2 m. Istotny z punktu widzenia realizacji pomiarów hydrograficznych błąd określenia głębokości przy poziomie ufności 95% wynosi 0.083 m. Oznacza to, że dokładność opracowanego modelu fuzji danych średnich ważonych o wykładniku potęgi 1 zdecydowanie spełnia minimalne wymagania dokładnościowe, które są przewidziane dla kategorii specjalnej IHO.



Rys. 3.28. Dystrybuanta błędu określenia głębokości dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 01.08-02.10.2023 r. (opracowanie własne).

Na podstawie **Rys. 3.28** można zauważyć, że dystrybuanta empiryczna znacznie odbiega od dystrybuanty rozkładu normalnego (Gausa). W niektórych miejscach różnica między prawdopodobieństwami wystąpienia błędu określenia głębokości dla rozkładu empirycznego i normalnego wynosi ok. 0.28. Przykładowo, miara R68 dla rozkładu empirycznego wynosi 0.020 m, natomiast miara R68 dla rozkładu normalnego wynosi aż 0.047 m. Oznacza to, że błędy określenia głębokości nie podlegają rozkładowi normalnemu.

3.3.6. Kompleksowa kampania pomiarowa na jeziorze Kłodno w dniu 13.08.2024 r.


W pierwszej kolejności przystąpiono do analizy ilościowej uzyskanego zbioru danych (Tab. 3.17). Blisko 22% danych (22 255 punktów) cechuje się głębokościami poniżej 1 m, natomiast ok. 78% danych (79 984 punkty) jest położona na głębokościach wynoszących co najmniej 1 m. Średnia kwadratowa głębokości interpolowanych ma wartość 49.616 m. Minimalna głębokość wygenerowanego NMT wynosi 0 m, natomiast jego maksymalna głębokość ma wartość 11 m. Oznacza to, że głębokości na analizowanym akwenie są bardzo zróżnicowane. Dlatego rozstęp wynosi 11 m, podczas gdy rozstęp ćwiartkowy jest zdecydowanie mniejszy i wynosi 1.829 m.

Tab. 3.17. Zestawienie informacji o modelu fuzji danych średnich ważonych o wykładniku potęgi 1 dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniu 13.08.2024 r. (opracowanie własne).

Miara statystyczna	Model fuzji danych średnich ważonych ($u=1$)
RMS (m)	49.616
$d_{NMT_{min}}^1$ (m)	0.000
$d_{NMT_{max}}^2$ (m)	11.000
R (m)	11.000
IRQ (m)	1.829

Minimalna¹ i maksymalna² głębokość opracowanego modelu fuzji danych średnich ważonych.

Następnie obliczono różnice głębokości między punktami pomiarowymi (SVR i USV) a odpowiadającymi im (o tych samych współrzędnych prostokątnych płaskich) punktami wygenerowanego NMT (Rys. 3.29).



Rys. 3.29. Graficzne przedstawienie różnic głębokości między punktami pomiarowymi a odpowiadającymi im punktami wygenerowanego NMT dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniu 13.08.2024 r. (opracowanie własne).

Na podstawie **Rys. 3.29** można stwierdzić, że model fuzji danych średnich ważonych o wykładniku potęgi 1 wykazuje się bardzo wysoką dokładnością. Ponad 98% danych (100 337 punktów) cechuje się błędami określenia głębokości do 0.25 m. Natomiast niespełna 2% danych (1902 punkty) ma błędy wyznaczenia głębokości powyżej 0.25 m. Należy zaznaczyć, że prawie wszystkie punkty o błędach określenia głębokości powyżej 0.25 m zostały pozyskane przy użyciu algorytmu SVR. Największe błędy wyznaczenia głębokości (powyżej 0.25 m) można zaobserwować na najpłytszych wodach i wzdłuż obrysów pomostów. Punkty o błędach określenia głębokości powyżej 0.25 m znajdują się między izobatami 0.22 m a 7.69 m.


Po wyznaczeniu różnic głębokości między punktami pomiarowymi a odpowiadającymi im punktami wygenerowanego NMT postanowiono dokonać analizy statystycznej błędów określenia głębokości (**Tab. 3.18**).

Tab. 3.18. Miary dokładności modelu fuzji danych średnich ważonych o wykładniku potęgi 1 dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniu 13.08.2024 r. (opracowanie własne).

Miara statystyczna	Model fuzji danych średnich ważonych ($u=1$)
RMSE (m)	0.003
MAE (m)	0.025
R^2 (-)	1.000
R68 (m)	0.020
R95 (m)	0.111


Dokładność opracowanego NMT w stosunku do pomiarów rzeczywistych została określona za pomocą miar RMSE – 0.003 m i MAE – 0.025 m. Wartości miar RMSE i MAE wskazują na bardzo małe różnice między wartościami interpolowanymi a rzeczywistymi. Współczynnik determinacji osiągnął poziom 1.000. Oznacza to, że dopasowanie modelu fuzji danych średnich ważonych o wykładniku potęgi 1 do danych pomiarowych jest najwyższe z możliwych. Błąd określenia głębokości dla 68% danych (miara R68) wyniósł 0.020 m, natomiast błąd określenia głębokości dla 95% danych (miara R95) osiągnął wartość 0.111 m.

Na koniec postanowiono zwizualizować uzyskane wyniki badań. W tym celu narysowano histogram przedstawiający częstość występowania błędów określenia głębokości (**Rys. 3.30**). Poza tym, wyznaczono dystrybuantę błędu określenia głębokości dla rozkładu empirycznego i normalnego (**Rys. 3.31**).



Rys. 3.30. Histogram przedstawiający częstość występowania błędów określenia głębokości dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniu 13.08.2024 r. (opracowanie własne).

Na podstawie **Rys. 3.30** można stwierdzić, że 94.80% danych ma błąd określenia głębokości nieprzekraczający wartości 0.1 m, natomiast 96.68% danych ma błąd nie większy niż 0.2 m. Istotny z punktu widzenia realizacji pomiarów hydrograficznych błąd określenia głębokości przy poziomie ufności 95% wynosi 0.111 m. Oznacza to, że dokładność opracowanego modelu fuzji danych średnich ważonych o wykładniku potęgi 1 zdecydowanie spełnia minimalne wymagania dokładnościowe, które są przewidziane dla kategorii specjalnej IHO.



Rys. 3.31. Dystrybuenta błędu określenia głębokości dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniu 13.08.2024 r. (opracowanie własne).

Na podstawie **Rys. 3.31** można zauważyć, że dystrybuenta empiryczna znacznie odbiega od dystrybenty rozkładu normalnego (Gaussa). W niektórych miejscach różnica między prawdopodobieństwami wystąpienia błędu określenia głębokości dla rozkładu empirycznego i normalnego wynosi ok. 0.28. Przykładowo, miara R68 dla rozkładu empirycznego wynosi 0.020 m, natomiast miara R68 dla rozkładu normalnego wynosi aż 0.050 m. Oznacza to, że błędy określenia głębokości nie podlegają rozkładowi normalnemu.

W tym rozdziale przeprowadzono analizę ilościową wyników autorskiej metody modelowania powierzchni terenu w strefie brzegowej. Prace rozpoczęto od szczegółowego opisu rejestracji i przetwarzania danych geoprzestrzennych pozyskanych podczas czterech kampanii pomiarowych przeprowadzonych w latach 2022–2023 na dwóch typach akwenów: morskim i śródlądowym.

Dodatkowo scharakteryzowano badane akweny, podkreślając ich specyfikę. Następnie dokonano szczegółowego opisu kompleksowej, jednodniowej kampanii pomiarowej na jeziorze Kłodno, podczas której zastosowano wszystkie dostępne sensory (ALS, MBES, MLS, SBES i UAV). Możliwość jednoczesnego wykorzystania pełnego zestawu sensorów pozwoliła na precyzyjne opracowanie danych. W ostatniej części rozdziału przeprowadzono analizę wygenerowanych modeli fuzji średnich ważonych, bazując na miarach statystycznych, takich jak: RMSE, MAE, współczynnik determinacji (R^2) oraz miary R68 i R95. Dodatkowo przeanalizowano różnice głębokości między punktami pomiarowymi a wartościami interpolowanymi z wygenerowanych modeli.

Wykazano, że opracowana metoda monitoringu batymetrycznego umożliwia tworzenie dokładnych modeli strefy brzegowej na podstawie danych geoprzestrzennych pozyskanych przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych. Pomimo odnotowania błędów określenia głębokości przekraczających 0.25 m, algorytm SVR okazał się szczególnie przydatny na obszarach trudnodostępnych, takich jak obszary płytkowodne (do 1 m). Podkreślono również, że metoda fuzji średnich ważonych jest efektywna przy redukcji nadmiernych danych geoprzestrzennych.

Wnioski końcowe

Niniejsza rozprawa doktorska koncentruje się na opracowaniu innowacyjnej metody tworzenia numerycznego modelu strefy brzegowej na podstawie danych geoprzestrzennych zarejestrowanych przy użyciu różnych sensorów. W opracowanej metodzie położono szczególny nacisk na pozyskanie wysokiej jakości danych głębokościowych do 1 m, co stanowi wyzwanie ze względu na zbyt duże zanurzenie załogowych jednostek hydrograficznych. Celem pracy było opracowanie metody monitoringu batymetrycznego strefy brzegowej na bazie fuzji wielomodalnych danych geoprzestrzennych pozyskanych z wykorzystaniem sensorów pokładowych bezzałogowych platform pomiarowych. Teza rozprawy opiera się na założeniu, że zaproponowana metoda umożliwi uzyskanie jakości danych wymaganej dla kategorii specjalnej IHO. Wymagania te są szczególnie istotne w strefie brzegowej, gdzie precyzyjne pomiary dna morskiego mają kluczowe znaczenie dla bezpieczeństwa nawigacji.

Przed przystąpieniem do opracowania metody zdefiniowano i omówiono zastosowanie urządzeń hydroakustycznych i optoelektronicznych, takich jak: echosonda jednowiązkowa i wielowiązkowa, kamera fotogrametryczna oraz LiDAR. Przedstawiono budowę i zasadę działania każdego z wyżej wymienionych sensorów. Dokonano również charakterystyki danych zarejestrowanych przy użyciu urządzeń hydroakustycznych i optoelektronicznych, w tym opisano czynniki wpływające na dokładność wyznaczenia współrzędnych pozycji i pokrycie terenu pomiarami. W dalszej części pracy dokonano przeglądu istniejących metod modelowania powierzchni terenu w strefie brzegowej oraz rodzajów fuzji wielomodalnych danych geoprzestrzennych w pomiarach batymetrycznych, co stanowiło istotną podstawę do opracowania nowej metody modelowania.

Realizując cel główny rozprawy, opracowano autorską metodę monitoringu batymetrycznego strefy brzegowej na bazie fuzji wielomodalnych danych geoprzestrzennych pozyskanych przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych. Cel ten został osiągnięty dzięki zrealizowaniu poszczególnych celów cząstkowych, które przedstawiono we wstępie pracy doktorskiej. Wykorzystując zdobyte doświadczenie i dane batymetryczno-fotogrametryczne zarejestrowane podczas realizacji kampanii pomiarowej na akwenu testowym opisano etapy opracowania danych geoprzestrzennych pozyskanych z wykorzystaniem sensorów pokładowych bezzałogowych platform pomiarowych, takich jak: echosonda jednowiązkowa i wielowiązkowa, kamera fotogrametryczna oraz LiDAR z mobilnego i lotniczego skaningu laserowego. Opisane etapy opracowania danych zostały zastosowane na danych testowych, co umożliwiło weryfikację i optymalizację procesu fuzji. Wynikiem przeprowadzonych prac jest autorska metoda fuzji danych średnich ważonych, w której wagi dla poszczególnych źródeł danych będą ustalane na podstawie dokładności pomiaru. Warto podkreślić, że w autorskiej metodzie zastosowano metodę ekstrakcji linii brzegowej wykorzystującą dane LiDAR i metodę SVR, która umożliwia pozyskanie głębokości płytkowodnych do 1 m na podstawie chmury punktów SfM z danych UAV.

Na potrzeby niniejszej rozprawy doktorskiej przeprowadzono pomiary batymetryczno-fotogrametryczne przy użyciu bezzałogowych platform latających i pływających na dwóch reprezentatywnych akwenach: morskim i śródlądowym. Opracowaną metodę zastosowano na danych zarejestrowanych podczas realizacji pięciu kampanii pomiarowych, z czego jedna była kampanią kompleksową, podczas której wszystkie dane pozyskano tego samego dnia, co umożliwiło wyeliminowanie wpływu zmiennych warunków hydrometeorologicznych na wyniki pomiarów. Dla każdej kampanii stworzono odrębny model fuzji danych średnich ważonych, który uwzględnił

charakterystykę badanego akwenu. Stworzone modele zostały następnie poddane szczegółowej analizie ilościowej. Analiza ta pozwoliła na weryfikację skuteczności opracowanej metody fuzji.

Na podstawie przeprowadzonych badań wyciągnięto następujące wnioski:

- Opracowana metoda monitoringu strefy brzegowej na bazie fuzji wielomodalnych danych umożliwia redukcję nadmiernych danych geoprzestrzennych;
- Metoda ta została zweryfikowana zarówno na obszarach morskich, jak i śródlądowych, co potwierdzono w pięciu kampaniach pomiarowych;
- Metoda monitoringu batymetrycznego strefy brzegowej jest metodą parametryczną. Jej skuteczność zależy od doboru parametrów przy opracowywaniu poszczególnych danych i tworzeniu modelu fuzji;
- Wzrost wykładnika potęgi w metodzie monitoringu batymetrycznego strefy brzegowej nie wpływa na dokładność opracowanego modelu fuzji danych średnich ważonych;
- Dane głębokościowe pozyskane przy użyciu metody SVR pozwoliły na bardzo duże pokrycie danymi w miejscach trudnodostępnych. Jednakże cechuje je najgorsza dokładność pomiaru głębokości ze wszystkich użytych sensorów;
- Na podstawie opracowanych modeli fuzji danych średnich ważonych stwierdzono, że wszystkie punkty pomiarowe z błędami określenia głębokości przekraczającymi 0.25 m zostały wygenerowane z wykorzystaniem metody SVR;
- Dane LiDAR z ALS i MLS przetworzone za pomocą zmodyfikowanej metody ekstrakcji linii brzegowej, które uwzględniają obecność przeszkód terenowych w pobliżu granicy lądu i wody, powinny zostać uzupełnione o dodatkowe dane. Dlatego też metoda wyznaczania linii brzegowej na podstawie ortofotomapy uznawana jest za główne źródło danych o jej przebiegu;
- Badania wykazały, że zaproponowana metoda ekstrakcji linii brzegowej pozwala na znacznie dokładniejsze wyznaczenie jej naturalnego przebiegu przy wykorzystaniu LiDAR-u mobilnego niż LiDAR-u lotniczego;
- Metoda średniej ważonej głębokości nie może być zastosowana na punktach linii brzegowej, ponieważ mają one zawsze tę samą głębokość (0 m). Z tego powodu postanowiono użyć metody średnich ważonych współrzędnych prostokątnych płaskich dla tych punktów;
- Na podstawie danych zarejestrowanych podczas kompleksowej kampanii pomiarowej opracowano model fuzji danych średnich ważonych z dokładnością określenia głębokości wynoszącą 0.111 m ($p=0.95$). Badania udowodniły, że zaproponowana metoda pozwala zdecydowanie spełnić minimalne wymagania dokładnościowe przewidziane dla kategorii specjalnej IHO;
- Do tworzenia modelu wykorzystuje się fuzję zdecentralizowaną, ponieważ w przypadku tego typu danych konieczny jest stały nadzór nad procesem integracji.

Przeprowadzona analiza ilościowa nie dała podstaw do odrzucenia tezy, że zaproponowana metoda monitoringu batymetrycznego umożliwi uzyskanie jakości danych wymaganej dla kategorii specjalnej IHO.

Po zakończeniu badań i osiągnięciu wszystkich założonych celów cząstkowych określono kierunki dalszych badań. Istotne wydaje się wprowadzenie do autorskiej metody monitoringu strefy brzegowej innych sensorów, takich jak LiDAR batymetryczny. Ponadto zasadne jest zastosowanie autorskiej

metody na danych pozyskanych w różnych porach roku, co pozwoli na ocenę wpływu zmiennych warunków hydrometeorologicznych na wyniki pomiarów. Bardzo ważne jest również wprowadzenie nowych metod ekstrakcji linii brzegowej i wyznaczania głębokości na akwenach płytkowodnych do 1 m, ponieważ zaproponowana metoda SVR nie umożliwia uzyskanie danych o wysokiej dokładności pomiaru głębokości. Wymienione wyżej badania będą w przyszłości podstawą do rozpoczęcia kolejnych prac związanych z ulepszeniem metody. Zdaniem autorki przyszłe kierunki badań to:

- Wprowadzenie do autorskiej metody monitoringu batymetrycznego strefy brzegowej nowych fotogrametrycznych metod wyznaczania głębokości akwenów ultrapłytkich (do 1 m);
- Rozwój algorytmów głębokiego uczenia wspierających procesy ekstrakcji linii brzegowej i wyznaczania głębokości na podstawie chmury punktów lub ortofotomapy;
- Opracowanie i wdrożenie systemu opartego na zaproponowanej metodzie monitoringu strefy brzegowej z automatycznym przetwarzaniem danych;
- Zastosowanie metody na danych pozyskanych w różnych porach roku i warunkach hydrometeorologicznych umożliwiających przeprowadzenie misji pomiarowych;
- Rozszerzenie badań na inne akweny w celu zbadania uniwersalności metody i dostosowania jej do różnych typów akwenów;
- Obliczenie w każdej komórce siatki GRID odchylenia standardowego pomiarów głębokości w celu selekcji najlepszych danych oraz porównanie wyników z modelem batymetrycznym;
- Dalsze badania związane z wykorzystaniem zaproponowanej metody monitoringu strefy brzegowej w kontekście długoterminowej analizy zmian ukształtowania strefy brzegowej.

Podsumowując, dalsze rozwijanie tych kierunków badań nie tylko przyczyni się do poprawy dokładności określenia głębokości na obszarach płytkowodnych, ale umożliwi również długoterminowe prognozowanie zmian ukształtowania terenu zachodzących w strefie brzegowej. Dzięki temu możliwe będzie uzyskanie informacji o zmienności tych obszarów, co znacząco wspomogę proces monitoringu i zarządzania strefą brzegową.

Bibliografia

1. Agrafiotis, P.; Skarlatos, D.; Georgopoulos, A.; Karantzas, K. Shallow Water Bathymetry Mapping from UAV Imagery Based on Machine Learning. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2019**, *42*, 9–16.
2. AI. Sztuczne sieci neuronowe – co to jest i jak działa? Dostępny w Internecie: <https://aioai.pl/sztuczne-sieci-neuronowe-co-to-jest-i-jak-dziala/> (dostęp dnia 4 stycznia 2025 r.).
3. Alevizos, E.; Oikonomou, D.; Argyriou, A.V.; Alexakis, D.D. Fusion of Drone-based RGB and Multi-spectral Imagery for Shallow Water Bathymetry Inversion. *Remote Sens.* **2022**, *14*, 1127.
4. Angelucci, G.; Mollaioli, F. Voronoi-like Grid Systems for Tall Buildings. *Front. Built Environ.* **2018**, *4*, 78.
5. Arge, L.; Larsen, K.G.; Mølhave, T.; van Walderveen, F. Cleaning Massive Sonar Point Clouds. In Proceedings of the 18th SIGSPATIAL International Conference on Advances in Geographic Information Systems (GIS 2010), San Jose, CA, USA, 2–5 November 2010.
6. Arnold, J.; Shaw, S. A Surface Weaving Approach to Multibeam Depth Estimation. In Proceedings of the OCEANS 1993, Victoria, BC, Canada, 18–21 October 1993.
7. Arseni, M.; Voiculescu, M.; Georgescu, L.P.; Iticescu, C.; Rosu, A. Testing Different Interpolation Methods Based on Single Beam Echosounder River Surveying. Case Study: Siret River. *ISPRS Int. J. Geo-Inf.* **2019**, *8*, 507.
8. Azam, K.S.F.; Ryabchykov, O.; Bocklitz, T. A Review on Data Fusion of Multidimensional Medical and Biomedical Data. *Molecules* **2022**, *27*, 7448.
9. Babak, O.; Deutsch, C.V. Statistical Approach to Inverse Distance Interpolation. *Stoch. Environ. Res. Risk Assess.* **2008**, *23*, 543–553.
10. Bagheri, O.; Ghodsian, M.; Saadatseresht, M. Reach Scale Application of UAV+SfM Method in Shallow Rivers Hyperspatial Bathymetry. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2015**, *40*, 77–81.
11. Bartier, P.M.; Keller, C.P. Multivariate Interpolation to Incorporate Thematic Surface Data Using Inverse Distance Weighting (IDW). *Comput. and Geosci.* **1996**, *22*, 795–799.
12. Basak, D.; Pal, S.; Patranabis, D.C. Support Vector Regression. *Neural Inf. Processing-Lett. Rev.* **2007**, *11*, 203–224.
13. Berteška, T.; Ruzgienė, B. Photogrammetric Mapping Based on UAV Imagery. *Geod. Cartogr.* **2013**, *39*, 158–163.
14. Bikonis, K. Algorytmy rekonstrukcji kształtu dna morskiego i trójwymiarowa wizualizacja obiektów podwodnych. Praca doktorska, Politechnika Gdańska, Polska, 2007. Dostępny w Internecie: https://pbc.gda.pl/Content/3563/bikonis_krzysztof.pdf (dostęp dnia 27 stycznia 2025 r.).
15. Bodus-Olkowska, I. Skrypt do zajęć z przedmiotu PODSTAWY HYDROGRAFII. Dostępny w Internecie: https://pm.szczecin.pl/uploads/faculties/wn/skrypt_podstawy_hydrografii_2018_cz_I.pdf (dostęp dnia 4 stycznia 2025 r.).
16. Bodus-Olkowska, O.; Włodarczyk-Sielicka, M. Analiza porównawcza i interpretacyjna uogólnionej wizualizacji widoku podwodnego uzyskanego za pomocą echosondy jedno- i wielowiązkowej. *Roczniki Geomatyki* **2013**, *11*, 27–36.
17. Born, M.; Wolf, E. *Principles of Optics: Electromagnetic Theory of Propagation, Interference and Diffraction of Light*, 1st ed.; Pergamon Press: London/New York/Paris, UK/USA/France, 1959.
18. Bowditch, N. *American Practical Navigator*; Paradise Cay Publications: Blue Lake, CA, USA, 2019; Volume 1 & 2.
19. Boyd, S.; Vandenberghe, L. *Convex Optimization*; Cambridge University Press: Cambridge, UK, 2004.
20. Burdziakowski, P.; Bobkowska, K. UAV Photogrammetry under Poor Lighting Conditions—Accuracy Considerations. *Sensors* **2021**, *21*, 3531.
21. Burša, M. *Základy Kosmické Geodézie. Díl I, Kosmická Geodézie Geometrická*; MNO: Prague, Czechoslovakia, 1967. (W języku czeskim)
22. Casella, E.; Collin, A.; Harris, D.; Ferse, S.; Bejarano, S.; Parravicini, V.; Hench, J.L.; Rovere, A. Mapping Coral Reefs Using Consumer-grade Drones and Structure from Motion Photogrammetry Techniques. *Coral Reefs* **2017**, *36*, 269–275.
23. Castanedo, F. A Review of Data Fusion Techniques. *Sci. World J.* **2013**, *2013*, 704504.

24. Chen, C.T.; Millero, F.J. Reevaluation of Wilson's Sound-speed Measurements for Pure Water. *J. Acoust. Soc. Am.* **1976**, *60*, 1270–1273.
25. Chen, C.T.; Millero, F.J. Speed of Sound in Seawater at High Pressures. *J. Acoust. Soc. Am.* **1977**, *62*, 1129–1135.
26. Chen, Y.; Guo, S.; He, Y.; Luo, Y.; Chen, W.; Hu, S.; Huang, Y.; Hou, C.; Su, S. Simulation and Design of an Underwater Lidar System Using Non-coaxial Optics and Multiple Detection Channels. *Remote Sens.* **2023**, *15*, 3618.
27. Chia-Hua, H.; Chih-Jen, L. Large-scale Linear Support Vector Regression. *J. Mach. Learn. Res.* **2012**, *13*, 3323–3348.
28. Chmielewski, M.; Kukietka, M.; Pieczonka, P.; Gutowski, T. Methods and Analytical Tools for Assessing Tactical Situation in Military Operations Using Potential Approach and Sensor Data Fusion. *Procedia Manuf.* **2020**, *44*, 559–566.
29. Clarke, T.A.; Fryer, J.G.; Wang, X. The Principal Point and CCD Cameras. *Photogramm. Rec.* **1998**, *16*, 293–312.
30. Contreras, M.A.; Staats, W.; Yiang, J.; Parrott, D. Quantifying the Accuracy of LiDAR-derived DEM in Deciduous Eastern Forests of the Cumberland Plateau. *J. Geogr. Inf. Syst.* **2017**, *9*, 339–353.
31. Coxeter, H.S.M. *Introduction to Geometry*, 2nd ed.; John Wiley & Sons, Inc.: Hoboken, NJ, USA, 1989.
32. Dąbrowski, P.S.; Specht, C.; Specht, M.; Burdziakowski, P.; Makar, A.; Lewicka, O. Integration of Multi-source Geospatial Data from GNSS Receivers, Terrestrial Laser Scanners, and Unmanned Aerial Vehicles. *Can. J. Remote Sens.* **2021**, *47*, 621–634.
33. Dai, F.; Lu, M. Three-dimensional Modeling of Site Elements by Analytically Processing Image Data Contained in Site Photos. *J. Constr. Eng. Manag. - ASCE* **2013**, *139*, 881–894.
34. Dai, F.; Dong, S.; Kamat, V.R.; Lu, M. Photogrammetry Assisted Measurement of Interstory Drift for Rapid Post-disaster Building Damage Reconnaissance. *J. Nondestruct. Eval.* **2011**, *30*, 201–212.
35. Dai, F.; Feng, Y.; Hough, R. Photogrammetric Error Sources and Impacts on Modeling and Surveying in Construction Engineering Applications. *Vis. Eng.* **2014**, *2*, 2.
36. Davis, J.C. *Statistics and Data Analysis in Geology*, 3rd ed.; John Wiley & Sons, Inc.: Hoboken, NJ, USA, 2002.
37. Deakin, R.E. A Note on the Bursa-Wolf and Molodensky-Badekas Transformations. *Sch. Math. Geospat. Sci. RMIT Univ.* **2006**, 1–21.
38. Del Grosso, V.A. New Equation for the Speed of Sound in Natural Waters (with Comparisons to Other Equations). *J. Acoust. Soc. Am.* **1974**, *56*, 1084–1091.
39. Delaunay, B. Sur la sphère vide. *Bulletin de l'Académie des Sciences de l'URSS, Classe des Sciences Mathématiques et Naturelles* **1934**, *6*, 793–800. (W języku rosyjskim)
40. Derpanis, K.G. Overview of the RANSAC Algorithm. Dostępny w Internecie: http://www.cse.yorku.ca/~kosta/CompVis_Notes/ransac.pdf (dostęp dnia 4 stycznia 2025 r.).
41. Dong, W.; Lan, J.; Liang, S.; Yao, W.; Zhan, Z. Selection of LiDAR Geometric Features with Adaptive Neighborhood Size for Urban Land Cover Classification. *Int. J. Appl. Earth Obs. Geoinf.* **2017**, *60*, 99–110.
42. Du, Z.; Wells, D.E.; Mayer, L.A. An Approach to Automatic Detection of Outliers in Multibeam Echo Sounding Data. *Oceanogr. Lit. Rev.* **1996**, *7*, 737.
43. Elaksher, A.; Ali, T.; Alharthy, A. A Quantitative Assessment of LIDAR Data Accuracy. *Remote Sens.* **2023**, *15*, 442.
44. Elamin, A.; Abdelaziz, N.; El-Rabbany, A. A GNSS/INS/LiDAR Integration Scheme for UAV-based Navigation in GNSS-challenging Environments. *Sensors* **2022**, *22*, 9908.
45. Elmquist, A.; Negrut, D. TR-2016-13 Virtual Sensing for Autonomous Vehicle Simulation in Chrono. Dostępny w Internecie: <https://sbel.wisc.edu/wp-content/uploads/sites/569/2018/05/TR-2016-13.pdf> (dostęp dnia 4 stycznia 2025 r.).
46. Fanchi, J.R. Chapter 2—Geological Modeling. In *Principles of Applied Reservoir Simulation*, 4th ed.; Fanchi, J.R., Ed.; Gulf Professional Publishing: Houston, TX, USA, 2018; pp. 9–33.
47. Feltens, J. Vector Methods to Compute Azimuth, Elevation, Ellipsoidal Normal, and the Cartesian (X, Y, Z) to Geodetic (ϕ , λ , h) Transformation. *J. Geod.* **2008**, *82*, 493–504.

48. Ficek, D. *Właściwości biooptyczne wód jezior Pomorza oraz ich porównanie z właściwościami wód innych jezior i Morza Bałtyckiego*, Rozprawy i Monografie 23/2013; Instytut Oceanologii PAN: Sopot, Polska, 2013.
49. Fischler, M.A.; Bolles, R.C. Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography. *Commun. ACM* **1981**, *24*, 381–395.
50. Fortune, S. A Sweepline Algorithm for Voronoi Diagrams. In Proceedings of the 2nd Annual ACM SIGACT/SIGGRAPH Symposium on Computational Geometry (SCG 1986), Yorktown Heights, NY, USA, 2–4 June 1986.
51. Gao, J. Bathymetric Mapping by Means of Remote Sensing: Methods, Accuracy and Limitations. *Prog. Phys. Geogr.* **2009**, *33*, 103–116.
52. Genchi, S.A.; Vitale, A.J.; Perillo, G.M.E.; Seitz, C.; Delrieux, C.A. Mapping Topobathymetry in a Shallow Tidal Environment Using Low-cost Technology. *Remote Sens.* **2020**, *12*, 1394.
53. Gilbert, P. *Physics in the Arts*, 3rd ed.; Academic Press: Cambridge, MA, USA, 2021.
54. Gnyp, J.T. Statystyka bayesowska i estymacja metodą maksymalnej wiarygodności. Praca inżynierska, Uniwersytet Gdański, Polska, 2022. Dostępny w Internecie: https://www.researchgate.net/publication/374579998_Statystyka_bayesowska_i_estymacja_metoda_maksymalnej_wiarygodnosci (dostęp dnia 27 stycznia 2025 r.).
55. González-Matesanz, J.; Dalda, A.; Malpica, J.A. A Range of ED50-ETRS89 Datum Transformation Models Tested on the Spanish Geodetic Network. *Surv. Rev.* **2006**, *38*, 654–667.
56. Grządziel, A. Application of Remote Sensing Techniques to Identification of Underwater Airplane Wreck in Shallow Water Environment: Case Study of the Baltic Sea, Poland. *Remote Sens.* **2022**, *14*, 5195.
57. Grządziel, A. Prędkość dźwięku w wodzie – istota i znaczenie w pomiarach hydrograficznych. Dostępny w Internecie: https://www.researchgate.net/publication/340266636_Predkosc_dzwieku_w_wodzie_-_istota_i_znaczenie_w_pomiarach_hydrograficznych_Sound_Velocity_in_Water_Column_-_the_importance_in_hydrographic_surveys (dostęp dnia 27 stycznia 2025 r.).
58. Grządziel, A.; Wąż, M. Estimation of Effective Swath Width for Dual-head MBES. *Annu. Navig.* **2016**, *23*, 173–183.
59. Grządziel, A.; Wąż, M. System echosondy wielowiązkowej w pomiarach batymetrycznych planowanych tras żeglugowych. *Logistyka* **2014**, *6*, 4250–4256.
60. Grządziel, A.; Wąż, M.; Naus, K.; Felski, A. Niepewność pomiaru głębokości w pasie pomiarowym Swath echosondy wielowiązkowej. *TTS Technika Transportu Szynowego* **2015**, *22*, 2575–2578.
61. Guo, Q.; Su, Y.; Hu, T. *LiDAR Principles, Processing and Applications in Forest Ecology*; Academic Press: Cambridge, MA, USA, 2023.
62. Hackeloeer, A.; Klasing, K.; Krisp, J.M.; Meng, L. Georeferencing: A Review of Methods and Applications. *Ann. GIS* **2014**, *20*, 61–69.
63. Hakimi, O.; Liu, H.; Abudayyeh, O.; Houshyar, A.; Almatared, M.; Alhawiti, A. Data Fusion for Smart Civil Infrastructure Management: A Conceptual Digital Twin Framework. *Buildings* **2023**, *13*, 2725.
64. Halicki, A.; Specht, M.; Stateczny, A.; Specht, C.; Lewicka, O. Shoreline Extraction Based on LiDAR Data Obtained Using an USV. *TransNav, Int. J. Mar. Navig. Saf. Sea Transp.* **2023**, *17*, 445–453.
65. Hall, D.; Llinas, J. An Introduction to Multisensor Data Fusion. *Proc. IEEE* **1997**, *85*, 6–23.
66. Hänsel, P.; Schindewolf, M.; Eltner, A.; Kaiser, A.; Schmidt, J. Feasibility of High-resolution Soil Erosion Measurements by Means of Rainfall Simulations and SfM Photogrammetry. *Hydrology* **2016**, *3*, 38.
67. Hansen, J.G.; de Figueiredo, R.P. Active Object Detection and Tracking Using Gimbal Mechanisms for Autonomous Drone Applications. *Drones* **2024**, *8*, 55.
68. Hare, R. Depth and Position Error Budgets for Multibeam Echosounding. *Int. Hydrogr. Rev.* **1995**, *72*, 37–69.
69. Hare, R.; Godin, A.; Mayer, L. Accuracy Estimation of Canadian Swath (Multibeam) and Sweep (Multi-transducer) Sounding Systems. Dostępny w Internecie: <https://waves-vagues.dfo-mpo.gc.ca/library-bibliotheque/191216.pdf> (dostęp dnia 4 stycznia 2025 r.).
70. Haris, K.; Chakraborty, B.; Ingole, B.; Menezes, A.; Srivastava, R. Seabed Habitat Mapping Employing Single and Multi-beam Backscatter Data: A Case Study from the Western Continental Shelf of India. *Cont. Shelf Res.* **2012**, *48*, 40–49.

71. Hashimoto, K.; Shimozone, T.; Matsuba, Y.; Okabe, T. Unmanned Aerial Vehicle Depth Inversion to Monitor River-mouth Bar Dynamics. *Remote Sens.* **2021**, *13*, 412.
72. Hirata, Y. The Effects of Footprint Size and Sampling Density in Airborne Laser Scanning to Extract Individual Trees in Mountainous Terrain. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2004**, *36*, 102–107.
73. Holman, R.; Plant, N.; Holland, T. cBathy: A Robust Algorithm for Estimating Nearshore Bathymetry. *J. Geophys. Res. Oceans* **2013**, *118*, 2595–2609.
74. Houzelle, S.; Giraudon, G. Contribution to Multisensor Fusion Formalization. *Robot. Auton. Syst.* **1994**, *13*, 69–85.
75. Humboldt State University. Lidar Data. Dostępny w Internecie: https://gsp.humboldt.edu/olm/Courses/GSP_216/lessons/lidar/data.html (dostęp dnia 4 stycznia 2025 r.).
76. Iglhaut, J.; Cabo, C.; Puliti, S.; Piermattei, L.; O'Connor, J.; Rosette, J. Structure from Motion Photogrammetry in Forestry: A Review. *Curr. For. Rep.* **2019**, *5*, 155–168.
77. International Hydrographic Organization. *IHO Standards for Hydrographic Surveys*, 6th ed.; IHO Publication No. 44; IHO: Monte Carlo, Monaco, 2022.
78. International Hydrographic Organization. *Manual on Hydrography*, 1st ed.; IHO Publication C-13; IHO: Monte Carlo, Monaco, 2005.
79. Jiang, C.; Zhao, D.; Zhang, Q.; Liu, W. A Multi-GNSS/IMU Data Fusion Algorithm Based on the Mixed Norms for Land Vehicle Applications. *Remote Sens.* **2023**, *15*, 2439.
80. Jiménez-Jiménez, S.I.; Ojeda-Bustamante, W.; Marcial-Pablo, M.d.J.; Enciso, J. Digital Terrain Models Generated with Low-cost UAV Photogrammetry: Methodology and Accuracy. *ISPRS Int. J. Geo-Inf.* **2021**, *10*, 285.
81. Jo, H.C.; Sohn, H.-G.; Lim, Y.M. A LiDAR Point Cloud Data-based Method for Evaluating Strain on a Curved Steel Plate Subjected to Lateral Pressure. *Sensors* **2020**, *20*, 721.
82. Jorge, O.R.; Bento, C.; Teresa, T.; Fernando, B.J.; Mourad, B. Geophysical Data Fusion of Ground-penetrating Radar and Magnetic Datasets Using 2D Wavelet Transform and Singular Value Decomposition. *Front. Earth Sci.* **2022**, *10*, 1011999.
83. Journel, A.G.; Huijbregts, Ch.J. *Mining Geostatistics*; Academic Press: Cambridge, MA, USA, 1978.
84. Kang, M. Overview of the Applications of Hydroacoustic Methods in South Korea and Fish Abundance Estimation Methods. *Fish. Aquat. Sci.* **2014**, *17*, 369–376.
85. Kasvi, A.; Salmela, J.; Lotsari, E.; Kumpula, T.; Lane, S.N. Comparison of Remote Sensing Based Approaches for Mapping Bathymetry of Shallow, Clear Water Rivers. *Geomorphology* **2019**, *33*, 180–197.
86. Klein, L.A. *Sensor and Data Fusion Concepts and Applications*; SPIE: Washington, DC, USA, 1999.
87. Kurczyński, Z. *Fotogrametria*; Wydawnictwo Naukowe PWN: Warszawa, Polska 2014.
88. Kurczyński, Z. *Lotnicze i satelitarne zobrazowanie Ziemi*, Tom 1; Oficyna Wydawnicza Politechniki Warszawskiej: Warszawa, Polska, 2006.
89. Kurczyński, Z. *Lotnicze i satelitarne zobrazowanie Ziemi*, Tom 2; Oficyna Wydawnicza Politechniki Warszawskiej: Warszawa, Polska, 2006.
90. La Salandra, M.; Miniello, G.; Nicotri, S.; Italiano, A.; Donvito, G.; Maggi, G.; Dellino, P.; Capolongo, D. Generating UAV High-resolution Topographic Data within a FOSS Photogrammetric Workflow Using High-performance Computing Clusters. *Int. J. Appl. Earth Obs. Geoinf.* **2021**, *105*, 102600.
91. Landero Figueroa, M.M.; Parsons, M.J.G.; Saunders, B.J.; Radford, B.; Salgado-Kent, C.; Parnum, I.M. The Use of Singlebeam Echo-sounder Depth Data to Produce Demersal Fish Distribution Models that Are Comparable to Models Produced Using Multibeam Echo-sounder Depth. *Ecol. Evol.* **2021**, *11*, 17873–17884.
92. Le Deunf, J.; Debesse, N.; Schmitt, T.; Billot, R. A Review of Data Cleaning Approaches in a Hydrographic Framework with a Focus on Bathymetric Multibeam Echosounder Datasets. *Geosciences* **2020**, *10*, 254.
93. Lee, I.-C.; Cheng, L.; Li, R. Optimal Parameter Determination for Mean-shift Segmentation-based Shoreline Extraction Using Lidar Data, Aerial Orthophotos, and Satellite Imagery. In Proceedings of the American Society for Photogrammetry and Remote Sensing Annual Conference 2010 (ASPRS 2010), San Diego, CA, USA, 26–30 April 2010.
94. Levin, D. The Approximation Power of Moving Least-squares. *Math. Comput.* **1998**, *67*, 1517–1531.

95. Lewicka, O. Analysis of Terrain Modelling Methods in the Coastal Zone. *Commun. Sci. Lett. Univ. Zilina* **2023**, *25*, E1–E14.
96. Lewicka, O. Method for Accuracy Assessment of Topo-bathymetric Surface Models Based on Geospatial Data Recorded by UAV and USV Vehicles. *Metrol. Meas. Syst.* **2023**, *30*, 461–480.
97. Lewicka, O.; Specht, M.; Specht, C. Assessment of the Steering Precision of a UAV along the Flight Profiles Using a GNSS RTK Receiver. *Remote Sens.* **2022**, *14*, 6127.
98. Lewicka, O.; Specht, M.; Stateczny, A.; Specht, C.; Brčić, D.; Jugović, A.; Widźgowski, S.; Wiśniewska, M. Analysis of GNSS, Hydroacoustic and Optoelectronic Data Integration Methods Used in Hydrography. *Sensors* **2021**, *21*, 7831.
99. Lewicka, O.; Specht, M.; Stateczny, A.; Specht, C.; Dardanelli, G.; Brčić, D.; Szostak, B.; Halicki, A.; Stateczny, M.; Widźgowski, S. Integration Data Model of the Bathymetric Monitoring System for Shallow Waterbodies Using UAV and USV Platforms. *Remote Sens.* **2022**, *14*, 4075.
100. Lewicka, O.; Specht, M.; Stateczny, A.; Specht, C.; Dyrz, C.; Dąbrowski, P.; Szostak, B.; Halicki, A.; Stateczny, M.; Widźgowski, S. Analysis of Transformation Methods of Hydroacoustic and Optoelectronic Data Based on the Tombolo Measurement Campaign in Sopot. *Remote Sens.* **2022**, *14*, 3525.
101. Li, C.; Xue, B.; Yang, Z. Direct Measurement of the Sound Velocity in Water Based on the Acousto-optic Signal. *Appl. Opt.* **2021**, *60*, 2455–2464.
102. Li, S.; Su, D.; Yang, F.; Zhang, H.; Wang, X.; Guo, Y. Bathymetric LiDAR and Multibeam Echo-sounding Data Registration Methodology Employing a Point Cloud Model. *Appl. Ocean Res.* **2022**, *123*, 103147.
103. Li, Z.; Peng, Z.; Zhang, Z.; Chu, Y.; Xu, C.; Yao, S.; García-Fernández, A.F.; Zhu, X.; Yue, Y.; Levers, A.; Zhang, J.; Ma, J. Exploring Modern Bathymetry: A Comprehensive Review of Data Acquisition Devices, Model Accuracy, and Interpolation Techniques for Enhanced Underwater Mapping. *Front. Mar. Sci.* **2023**, *10*, 1178845.
104. Li, Z.; Zhai, J.; Wu, F. Shape Similarity Assessment Method for Coastline Generalization. *ISPRS Int. J. Geo-Inf.* **2018**, *7*, 283.
105. Lin, C.-J.; Weng, R.C.; Keerthi, S.S. Trust Region Newton Method for Large-scale Logistic Regression. *J. Mach. Learn. Res.* **2008**, *9*, 627–650.
106. Liu, C.; Zhang, G.; Rong, Y.; Shao, W.; Meng, J.; Li, G.; Huang, Y. Hybrid Metric-feature Mapping Based on Camera and Lidar Sensor Fusion. *Measurement* **2023**, *207*, 112411.
107. Liu, H.; Sherman, D.; Gu, S. Automated Extraction of Shorelines from Airborne Light Detection and Ranging Data and Accuracy Assessment Based on Monte Carlo Simulation. *J. Coast. Res.* **2007**, *236*, 1359–1369.
108. Lu, G.Y.; Wong, D.W. An Adaptive Inverse-Distance Weighting Spatial Interpolation Technique. *Comput. Geosci.* **2008**, *34*, 1044–1055.
109. Lu, P.; Dai, F. A Study on Multi-sensor Data Fusion Algorithm. *Journal of Advances in Artificial Life Robotics* **2022**, *2*, 195–200.
110. Mackenzie, K.V. Nine Equation for Sound Speed in the Oceans. *J. Acoust. Soc. Am.* **1981**, *33*, 1498–1504.
111. Mackenzie, K.V. Nine-term Equation for Sound Speed in the Oceans. *J. Acoust. Soc. Am.* **1981**, *70*, 807–812.
112. Makar, A. Method of Determination of Acoustic Wave Reflection Points in Geodesic Bathymetric Surveys. *Annu. Navig.* **2008**, *14*, 1–89.
113. Makar, A. *Przyrządy i systemy pomiarowe: materiały pomocnicze dla studentów II roku nawigacji w DSW*; Wydawnictwo Naukowe Dolnośląskiej Szkoły Wyższej: Wrocław, Polska, 2011.
114. Makar, A.; Naus, K. Pozyskiwanie danych do tworzenia numerycznego modelu dna. *Archiwum Fotogrametrii, Kartografii i Teledetekcji* **2003**, *13A*, 163–170.
115. Maleika, W. Inverse Distance Weighting Method Optimization in the Process of Digital Terrain Model Creation Based on Data Collected from a Multibeam Echosounder. *Appl. Geomat.* **2020**, *12*, 397–400.
116. Marais, P.; Dellepiane, M.; Cignoni, P.; Scopigno, R. Semi-automated Cleaning of Laser Scanning Campaigns with Machine Learning. *ACM J. Comput. Cult. He.* **2019**, *12*, 1–29.
117. Marteau, B.; Vericat, D.; Gibbins, C.; Batalla, R.J.; Green, D.R. Application of Structure-from-Motion Photogrammetry to River Restoration. *Earth Surf. Process. Landf.* **2017**, *42*, 503–515.
118. Medwin, H. Speed of Sound in Water: A Simple Equation for Realistic Parameters. *J. Acoust. Soc. Am.* **1975**, *58*, 1318–1319.

119. Mert, B.A.; Dag, A. A Computer Program for Practical Semivariogram Modeling and Ordinary Kriging: A Case Study of Porosity Distribution in an Oil Field. *Open Geosci.* **2017**, *9*, 663–674.
120. Ministerstwo Obrony Narodowej. *Rozporządzenie Ministra Obrony Narodowej z dnia 28 marca 2018 r. w sprawie minimalnych wymagań dla pomiarów hydrograficznych*; MON: Warszawa, Polska, 2018.
121. Mitchell, N.C.; Hughes Clarke, J.E. Classification of Seafloor Geology Using Multibeam Sonar Data from the Scotian Shelf. *Mar. Geol.* **1994**, *121*, 143–160.
122. Montes, F.; Hernández, M.J.; Cañellas, I. A Geostatistical Approach to Cork Production Sampling Estimation in Quercus Suber Forests. *Can. J. For. Res.* **2005**, *35*, 2787–2796.
123. Morsy, S.; Shaker, A. Evaluation of LiDAR-derived Features Relevance and Training Data Minimization for 3D Point Cloud Classification. *Remote Sens.* **2022**, *14*, 5934.
124. Neumann, K.; Welzenbach, M.; Timm, M. CMOS Imaging Sensor Technology for Aerial Mapping Cameras. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2016**, *41*, 69–72.
125. Nikolakopoulos, K.G.; Lampropoulou, P.; Fakiris, E.; Sardelianos, D.; Papatheodorou, G. Synergistic Use of UAV and USV Data and Petrographic Analyses for the Investigation of Beachrock Formations: A Case Study from Syros Island, Aegean Sea, Greece. *Minerals* **2018**, *8*, 534.
126. NORBIT. Wideband Multibeam Sonar. Dostępny w Internecie: <https://www.uniquegroup.com/wp-content/uploads/2022/08/WBMS-datasheet.pdf> (dostęp dnia 4 stycznia 2025 r.).
127. Okła, K. (red.). *Geomatyka w Lasach Państwowych. Część I. Podstawy*; Centrum Informacyjne Lasów Państwowych: Warszawa, Polska, 2010.
128. Oniga, V.-E.; Breaban, A.-I.; Pfeifer, N.; Chirila, C. Determining the Suitable Number of Ground Control Points for UAS Images Georeferencing by Varying Number and Spatial Distribution. *Remote Sens.* **2020**, *12*, 876.
129. Orange, D.L.; Yun, J.; Maher, N.; Barry, J.; Greene, G. Tracking California Seafloor Seeps with Bathymetry, Backscatter and ROVs. *Cont. Shelf Res.* **2002**, *22*, 2273–2290.
130. Patro, S.; Sahu, K.K. Normalization: A Preprocessing Stage. *IARJSET* **2015**, *2*, 20–22.
131. Pedregosa, F.; Varoquaux, G.; Gramfort, A.; Michel, V.; Thirion, B.; Grisel, O.; Blondel, M.; Prettenhofer, P.; Weiss, R.; Dubourg, V.; et al. Scikit-learn: Machine Learning in Python. *J. Mach. Learn. Res.* **2011**, *12*, 2825–2830.
132. Peipe, J.; Stephani, M. Performance Evaluation of a 5 Megapixel Digital Metric Camera for Use in Architectural Photogrammetry. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2003**, *34*, 259–261.
133. Pham, H. A New Criterion for Model Selection. *Mathematics* **2019**, *7*, 1215.
134. Popielarczyk, D. Application of Global Navigation Satellite System and Hydroacoustic Techniques to Safety of Inland Water Navigation. *Arch. Transp.* **2011**, *23*, 191–207.
135. Press, W.H.; Teukolsky, S.A.; Vetterling, W.T.; Flannery, B.P. *Numerical Recipes in C: The Art of Scientific Computing*; Cambridge University Press: Cambridge, UK, 1988.
136. Pyrchla, K.; Dworaczek, A.; Wierzbicka, A. A Method of Estimating the Depths of Shallow Water Based on the Measurements of Upwelling Irradiance. *J. Coast. Conserv.* **2018**, *22*, 777–786.
137. Rada Ministrów RP. *Rozporządzenie Rady Ministrów z dnia 15 października 2012 r. w sprawie państwowego systemu odniesień przestrzennych*; Rada Ministrów RP: Warszawa, Polska, 2012.
138. Rada Ministrów RP. *Rozporządzenie Rady Ministrów z dnia 19 grudnia 2019 r. zmieniające rozporządzenie w sprawie państwowego systemu odniesień przestrzennych*; Rada Ministrów RP: Warszawa, Polska, 2019.
139. Ren, H.C.; Yan, Q.; Liu, Z.J.; Zuo, Z.Q.; Xu, Q.Q.; Li, F.F.; Song, C. Study on Analysis from Sources of Error for Airborne LIDAR. *IOP Conf. Ser. Earth Environ. Sci.* **2016**, *46*, 012030.
140. Rohrbach, F. An Introduction to LiDAR. Dostępny w Internecie: <https://felix.rohrba.ch/en/2015/an-introduction-to-lidar/> (dostęp dnia 4 stycznia 2025 r.).
141. Royo, S.; Ballesta-Garcia, M. An Overview of Lidar Imaging Systems for Autonomous Vehicles. *Appl. Sci.* **2019**, *9*, 4093.
142. Rusu, R.B. Semantic 3d Object Maps for Everyday Manipulation in Human Living Environments. PhD Thesis, Technische Universität München, München, Germany, 2009.
143. Rusu, R.B. Semantic 3D Object Maps for Everyday Manipulation in Human Living Environments. *KI Künstl. Intell.* **2010**, *24*, 345–348.

144. Ruzgienė, B.; Aksamitauskas, Č.; Daugėla, I.; Prokopimas, Š.; Puodžiukas, V.; Rekus, D. UAV Photogrammetry for Road Surface Modelling. *Balt. J. Road Bridge Eng.* **2015**, *10*, 151–158.
145. Salomon, R. *Systemy hydrolokacyjne*; Gdańskie Towarzystwo Naukowe: Gdańsk, Polska, 2006.
146. Santos, C.E.D.S.; Sampaio, R.C.; Coelho, L.D.S.; Bestard, G.A.; Llanos, C.H. Multi-objective Adaptive Differential Evolution for SVM/SVR Hyperparameters Selection. *Pattern Recognit.* **2021**, *110*, 107649.
147. Saylam, K.; Brown, R.A.; Hupp, J.R. Assessment of Depth and Turbidity with Airborne Lidar Bathymetry and Multiband Satellite Imagery in Shallow Water Bodies of the Alaskan North Slope. *Int. J. Appl. Earth Obs. Geoinf.* **2017**, *58*, 191–200.
148. Schonberger, J.L.; Frahm, J.-M. Structure-from-Motion Revisited. In Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2016), Las Vegas, NV, USA, 27–30 June 2016.
149. Sibson, R., A Brief Description of Natural Neighbor Interpolation. In *Interpreting Multivariate Data*; Barnett, V., Ed.; John Wiley & Sons, Inc.: Hoboken, NJ, USA, 1981; pp. 21–36.
150. Simarro, G.; Calvete, D.; Luque, P.; Orfila, A.; Ribas, F. UBathy: A New Approach for Bathymetric Inversion from Video Imagery. *Remote Sens.* **2019**, *11*, 2722.
151. Skarlatos, D.; Agrafiotis, P. A Novel Iterative Water Refraction Correction Algorithm for Use in Structure from Motion Photogrammetric Pipeline. *J. Mar. Sci. Eng.* **2018**, *6*, 77.
152. Slabaugh, G.G. Computing Euler Angles from a Rotation Matrix. Dostępny w Internecie: <https://eecs.qmul.ac.uk/~gslabaugh/publications/euler.pdf> (dostęp dnia 4 stycznia 2025 r.).
153. Smeetskaert, J.; Mallet, C.; David, N.; Chehata, N.; Ferraz, A. Large-scale Classification of Water Areas Using Airborne Topographic LiDAR Data. *Remote Sens. Environ.* **2013**, *138*, 134–148.
154. Smola, A.J.; Schölkopf, B. A Tutorial on Support Vector Regression. *Stat. Comput.* **2004**, *14*, 199–222.
155. Specht, C.; Specht, M.; Dabrowski, P. Comparative Analysis of Active Geodetic Networks in Poland. In Proceedings of the 17th International Multidisciplinary Scientific GeoConference (SGEM 2017), Albena, Bulgaria, 29 June – 5 July 2017.
156. Specht, M.; Szostak, B.; Lewicka, O.; Stateczny, A.; Specht, C. Method for Determining of Shallow Water Depths Based on Data Recorded by UAV/USV Vehicles and Processed Using the SVR Algorithm. *Measurement* **2023**, *221*, 113437.
157. Specht, O.; Specht, M.; Stateczny, A.; Specht, C. Concept of an Innovative System for Dimensioning and Predicting Changes in the Coastal Zone Topography Using UAVs and USVs (4DBatMap System). *Electronics* **2023**, *12*, 4112.
158. Sroka, R. *Metody fuzji danych w pomiarach parametrów ruchu drogowego*; Wydawnictwa AGH: Kraków, Polska, 2008.
159. Stateczny, A. (red.). *Metody nawigacji porównawczej*; Gdańskie Towarzystwo Naukowe: Gdynia, Polska, 2004.
160. Stateczny, A. *Nawigacja porównawcza*; Gdańskie Towarzystwo Naukowe: Gdańsk, Polska, 2001.
161. Stateczny, A.; Gronska-Sledz, D.; Motyl, W. Precise Bathymetry as a Step Towards Producing Bathymetric Electronic Navigational Charts for Comparative (Terrain Reference) Navigation. *J. Navig.* **2019**, *72*, 1623–1632.
162. Stateczny, A.; Halicki, A.; Specht, M.; Specht, C.; Lewicka, O. Review of Shoreline Extraction Methods from Aerial Laser Scanning. *Sensors* **2023**, *23*, 5331.
163. Stepnowski, A. *Systemy akustycznego monitoringu środowiska morskiego*; Gdańskie Towarzystwo Naukowe: Gdańsk, Polska, 2001.
164. Stockdon, H.F.; Sallenger Jr., A.H.; List, J.H.; Holman, R.A. Estimation of Shoreline Position and Change Using Airborne Topographic LiDAR Data. *J. Coast. Res.* **2002**, *18*, 502–513.
165. Stuart, A.; Ord, K. *Kendall's Advanced Theory of Statistics, Distribution Theory*, 6th ed.; John Wiley & Sons, Inc.: Hoboken, NJ, USA, 2010.
166. Su, D.; Yang, F.; Ma, Y.; Wang, X.H.; Yang, A.; Qi, C. Propagated Uncertainty Models Arising from Device, Environment, and Target for a Small Laser Spot Airborne LiDAR Bathymetry and its Verification in the South China Sea. *IEEE Trans. Geosci. Remote Sens.* **2020**, *58*, 3213–3231.

167. Suziedelyte Visockiene, J.; Puziene, R.; Stanionis, A.; Tumeliene, E. Unmanned Aerial Vehicles for Photogrammetry: Analysis of Orthophoto Images over the Territory of Lithuania. *Int. J. Aerosp. Eng.* **2016**, *2016*, 4141037.
168. Szostak, B.; Specht, M.; Burdziakowski, P.; Stateczny, A.; Specht, C.; Lewicka, O. Methodology for Performing Bathymetric Measurements of Shallow Waterbodies Using an UAV, and their Processing Based on the SVR Algorithm. *Measurement* **2023**, *223*, 113720.
169. Szubrycht, T.; Wiśniewski, Z. Identyfikacja i poprawianie współrzędnych znaków nawigacyjnych obciążonych grubymi błędami wystawienia. *Zeszyty Naukowe Akademii Marynarki Wojennej* **2004**, *156*, 49–70.
170. Teledyne RESON. SeaBat® 7125. Dostępny w Internecie: https://www.oceanscan.net/gallery/Data_Sheets/TELEDYNE_RESON_SEABAT_7125__8125_MULTIBEAM_ECHOSOUNDERS.pdf (dostęp dnia 4 stycznia 2025 r.).
171. Todd, B.J.; Fader, G.B.J.; Courtney, R.C.; Pickrill, R.A. Quaternary Geology and Surficial Sediment Processes, Browns Bank, Scotian Shelf, Based on Multibeam Bathymetry. *Mar. Geol.* **1999**, *161*, 165–214.
172. Tokarczyk, R. Rejestracja obrazu. Dostępny w Internecie: <https://geoforum.pl/strona/46816,46857,46956/teledetekcja-krotki-wyklad-fotogrametria-rejestracja-obrazu/> (dostęp dnia 4 stycznia 2025 r.).
173. Tonion, F.; Pirotti, F.; Faina, G.; Paltrinieri, D. A Machine Learning Approach to Multispectral Satellite Derived Bathymetry. *ISPRS Ann. Photogramm. Remote Sens. Spat. Inf. Sci.* **2020**, *5*, 565–570.
174. Trzcinska, K.; Janowski, L.; Nowak, J.; Rucinska-Zjadacz, M.; Kruss, A.; von Deimling, J.S.; Pocwiardowski, P.; Tegowski, J. Spectral Features of Dual-frequency Multibeam Echosounder Data for Benthic Habitat Mapping. *Mar. Geol.* **2020**, *427*, 106239.
175. United States Army Corps of Engineers. *EM 1110-2-1003 USACE Standards for Hydrographic Surveys*. USACE: Washington, DC, USA, 2013.
176. van Kreveld, M. Digital Elevation Models and TIN Algorithms. In *Algorithmic Foundations of Geographic Information Systems*; van Kreveld, M., Nievergelt, J., Roos, T., Widmayer, P., Eds.; Springer Berlin, Heidelberg: Berlin/Heidelberg, Germany, 1997; Volume 1340, pp. 37–78.
177. Wald, L. Some Terms of Reference in Data Fusion. *IEEE Trans. Geosci. Remote Sens.* **1999**, *37*, 1190–1193.
178. Wang, C.; Huang, K.; Shi, W. An Accurate and Efficient Quaternion-based Visualization Approach to 2D/3D Vector Data for the Mobile Augmented Reality Map. *ISPRS Int. J. Geo-Inf.* **2022**, *11*, 383.
179. Wang, C.; Wen, C.; Dai, Y.; Yu, S.; Liu, M. Urban 3D Modeling Using Mobile Laser Scanning: A Review. *Virtual Real. Intell. Hardw.* **2020**, *2*, 175–212.
180. Wang, J.; Shan, J. Segmentation of LiDAR Point Clouds for Building Extraction. In Proceedings of the American Society for Photogrammetry and Remote Sensing Annual Conference 2009 (ASPRS 2009), Baltimore, MD, USA, 9–13 March 2009.
181. Wehr, A.; Lohr, U. Airborne Laser Scanning—An Introduction and Overview. *ISPRS J. Photogramm. Remote Sens.* **1999**, *54*, 68–82.
182. Wessex Archeology. Explore the Seafloor. Dostępny w Internecie: <https://ets.wessexarch.co.uk/teachers/physics/> (dostęp dnia 4 stycznia 2025 r.).
183. Westoby, M.J.; Brasington, J.; Glasser, N.F.; Hambrey, M.J.; Reynolds, J.M. ‘Structure-from-Motion’ Photogrammetry: A Low-cost, Effective Tool for Geoscience Applications. *Geomorphology* **2012**, *179*, 300–314.
184. Wikimedia Commons. LiDAR. Dostępny w Internecie: https://commons.wikimedia.org/wiki/File:LiDAR-i_lend.gif (dostęp dnia 4 stycznia 2025 r.).
185. Willmott, C.J.; Matsuura, K. Advantages of the Mean Absolute Error (MAE) over the Root Mean Square Error (RMSE) in Assessing Average Model Performance. *Clim. Res.* **2005**, *30*, 79–82.
186. Wilson, J.P. (ed.). *Geographic Information Science & Technology Body of Knowledge*, 2nd ed.; University Consortium for Geographic Information Science: Ithaca, NY, USA, 2022.
187. Wilson, W.D. Equation for the Speed of Sound in Sea Water. *J. Acoust. Soc. Am.* **1960**, *32*, 1357.
188. Włodarczyk-Sielicka, M.; Połap, D.; Prokop, K.; Połap, K.; Stateczny, A. Spatial Visualization Based on Geodata Fusion Using an Autonomous Unmanned Vessel. *Remote Sens.* **2023**, *15*, 1763.

189. Wojskowe Centrum Normalizacji, Jakości i Kodyfikacji. PDNO-06-A073:2009. Hydrografia morska – Zasady gromadzenia danych i przedstawianie wyników. WCNJiK: Warszawa, Polska, 2009.
190. Wolf, H. Geometric Connection and Re-orientation of Three-dimensional Triangulation Nets. *Bull. Geod.* **1963**, 37, 165–169.
191. Wolf, H. Possibilities for the Joint Adjustment of Satellite and Terrestrial Triangulation and Trilateration Network. *DGK* **1967**, 153, 93–99.
192. Wong, A.H.; Kwon, T.J. Advances in Regression Kriging-based Methods for Estimating Statewide Winter Weather Collisions: An Empirical Investigation. *Future Transp.* **2021**, 1, 570–589.
193. Wu, J.; Ke, C.-Q.; Cai, Y.; Nourani, V.; Chen, J.; Duan, Z. GEDI: A New LiDAR Altimetry to Obtain the Water Levels of More Lakes on the Tibetan Plateau. *IEEE J. Sel. Top. Appl. Earth Obs.* **2023**, 16, 4024–4038.
194. Xu, S.; Xu, S. A Minimum-cost Path Model to the Bridge Extraction from Airborne LiDAR Point Clouds. *J. Indian Soc. Remote Sens.* **2018**, 46, 1423–1431.
195. Xu, S.; Ye, N.; Xu, S. A New Method for Shoreline Extraction from Airborne LiDAR Point Clouds. *Remote Sens. Lett.* **2019**, 10, 496–505.
196. Yang, F.; Li, J.; Chu, F.; Wu, Z. Automatic Detecting Outliers in Multibeam Sonar Based on Density of Points, In Proceedings of the OCEANS 2007, Aberdeen, UK, 18–21 June 2007.
197. Zahawi, R.A.; Dandois, J.P.; Holl, K.D.; Nadwodny, D.; Reid, J.L.; Ellis, E.C. Using Lightweight Unmanned Aerial Vehicles to Monitor Tropical Forest Recovery. *Biol. Conserv.* **2015**, 186, 287–295.

Wykaz rysunków

Rys. 0.1. Lokalizacja danych geoprzestrzennych zarejestrowanych przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych (a) i mapa batymetryczna akwenu testowego (b) (opracowanie własne).	7
Rys. 1.1. Schemat blokowy typowej echosondy (opracowanie własne na podstawie: (Salomon R., 2006)).	11
Rys. 1.2. Zasada pomiaru głębokości w echosondzie SBES (opracowanie własne na podstawie: (Alevizos E. i in., 2022)).	12
Rys. 1.3. Zakres zmian prędkości rozchodzenia się dźwięku w okresie letnim o charakterze dobowym w Zatoce Gdańskiej (Makar A., Naus K., 2003).	15
Rys. 1.4. Porównanie obszaru przeszukiwania dna przez echosondę SBES (a) i MBES (b) (opracowanie własne).	18
Rys. 1.5. Pomiar głębokości echosondą MBES (opracowanie własne na podstawie: (Wessex Archeology, 2024)).	19
Rys. 1.6. Porównanie stopnia pokrycia dna pomiarami zarejestrowanymi przy użyciu echosondy SBES (a) i MBES (b) (opracowanie własne).	20
Rys. 1.7. Zasady rzutu środkowego i rzutu ortogonalnego (opracowanie własne na podstawie: (Okła K., 2010)).	24
Rys. 1.8. Parametry geometryczne zespołu zdjęć wykonanych z niskiego pułapu przez UAV (opracowanie własne na podstawie: (Kurczyński Z., 2014)).	26
Rys. 1.9. Idea działania ALS w strefie brzegowej (opracowanie własne na podstawie (Wikimedia Commons, 2024)).	31
Rys. 1.10. Schemat przedstawiający etapy tworzenia NMT (opracowanie własne na podstawie: (Lewicka O., 2023a)).	35
Rys. 1.11. Proces tworzenia diagramu Woronoja (opracowanie własne na podstawie: (Angelucci G., Mollaioli F., 2018)).	37
Rys. 1.12. Rzut punktu P powierzchni terenowej na płaszczyznę poziomą (opracowanie własne na podstawie: (Coxeter H.S.M., 1989)).	37
Rys. 1.13. Rodzaje zdarzeń przy konstruowaniu siatki TIN na podstawie techniki zmiatania: pojawienie się nowej paraboli podczas przecięcia prostej zmiatającej z punktem pomiarowym (a) i zanikanie łuku paraboli w momencie styczności prostej zmiatającej z okręgiem opisanym na trójkącie (b) (opracowanie własne).	38
Rys. 1.14. Konstrukcja węzłów siatki GRID (opracowanie własne na podstawie: (Stateczny A., 2004)).	39
Rys. 1.15. Wykres przedstawiający semiwariogram eksperymentalny wraz z dopasowanym wariogramem teoretycznym (opracowanie własne na podstawie: (Wong A.H., Kwon T.J., 2021)).	41
Rys. 1.16. Przykłady powszechnie stosowanych teoretycznych modeli semiwariogramów: sferyczny (a), Gaussa (b) i liniowy (c) (opracowanie własne na podstawie: (Mert B.A., Dag A., 2017)).	42
Rys. 1.17. Architektura procesu fuzji zdecentralizowanej (opracowanie własne na podstawie: (Sroka R., 2008)).	46
Rys. 1.18. Architektura procesu fuzji scentralizowanej (opracowanie własne na podstawie: (Sroka R., 2008)).	48
Rys. 2.1. Schemat blokowy przedstawiający etapy metody wyznaczania głębokości w odniesieniu do ustalonego poziomu odniesienia (opracowanie własne na podstawie: (Lewicka O. i in., 2022c)).	51
Rys. 2.2. Schemat pomiarów poziomu wody i temperatury wykonywanych przez IMGW dla rzędnej zera wodowskazu w układzie PL-EVRF2007-NH (opracowanie własne na podstawie: (Lewicka O. i in., 2022c)).	52
Rys. 2.3. Oczyszczone dane SBES dla akwenu testowego (opracowanie własne).	53
Rys. 2.4. Histogram przedstawiający częstość występowania punktów SBES w komórce siatki GRID dla akwenu testowego (opracowanie własne).	54
Rys. 2.5. Klasyfikacja metod wykrywania wartości odstających danych MBES w oparciu o wybrane podejścia (opracowanie własne na podstawie: (Le Deunf J. i in., 2020)).	55
Rys. 2.6. Oczyszczone dane MBES dla akwenu testowego (opracowanie własne).	57

Rys. 2.7. Histogram przedstawiający częstość występowania punktów MBES w komórce siatki GRID dla akwenu testowego (opracowanie własne).	57
Rys. 2.8. Schemat blokowy przedstawiający działanie algorytmu SVR wg (Agrafiotis P. i in., 2019) (opracowanie własne na podstawie: (Lewicka O. i in., 2022b)).	59
Rys. 2.9. Schemat parametrów transformacji 7-parametrowej (opracowanie własne na podstawie: (González-Matesanz J. i in., 2006)).	60
Rys. 2.10. Schemat blokowy przedstawiający etapy transformacji 7-parametrowej (transformacja Bursy-Wolfa) (opracowanie własne na podstawie: (Lewicka O. i in., 2022c)).	60
Rys. 2.11. Schemat położenia trzech kątów RPY wokół trzech osi XYZ związanego z układem jednostki IMU: prawoskrętnym (a) i lewoskrętnym (b) (opracowanie własne na podstawie: (Elmqvist A., Negrut D., 2024))...	61
Rys. 2.12. Schemat blokowy przedstawiający etapy transformacji 7-parametrowej (transformacja Bursy-Wolfa) w postaci macierzowej (opracowanie własne na podstawie: (Lewicka O. i in., 2022c)).	64
Rys. 2.13. Wygenerowana chmura punktów SfM dla akwenu testowego (opracowanie własne).	69
Rys. 2.14. Chmura punktów wygenerowana za pomocą metody SVR dla akwenu testowego (opracowanie własne).	70
Rys. 2.15. Histogram przedstawiający częstość występowania punktów wygenerowanych za pomocą metody SVR w komórce siatki GRID dla akwenu testowego (opracowanie własne).	71
Rys. 2.16. Schemat blokowy przedstawiający etapy zmodyfikowanej metody ekstrakcji linii brzegowej (Xu S. i in., 2019) (opracowanie własne na podstawie: (Lewicka O. i in., 2022b)).	72
Rys. 2.17. Schemat prezentujący zastosowanie algorytmu testowego (Xu S. i in., 2019) dla sztucznego zbioru 100 punktów. Początek algorytmu testowego na zbiorze testowym (a), pierwsza otoczka wypukła utworzona w ramach algorytmu testowego (b) i końcowy wynik algorytmu testowego (c) (Halicki A. i in., 2023).	74
Rys. 2.18. Problem niejednoznaczności wyznaczania przebiegu linii brzegowej na podstawie zbioru liczącego 5 punktów (Xu S. i in., 2019).	75
Rys. 2.19. Oczyszczona chmura punktów LiDAR z ALS dla akwenu testowego (opracowanie własne).	76
Rys. 2.20. Histogram przedstawiający częstość występowania punktów LiDAR z ALS w komórce siatki GRID dla akwenu testowego (opracowanie własne).	76
Rys. 2.21. Schemat blokowy przedstawiający wybrane etapy zmodyfikowanej metody ekstrakcji linii brzegowej (Xu S. i in., 2019) dostosowanej do danych LiDAR z ALS (opracowanie własne).	77
Rys. 2.22. Linia brzegowa wyrysowana na podstawie wygenerowanych punktów LiDAR z ALS i linia brzegowa wyznaczona przy użyciu punktów GCP dla akwenu testowego (opracowanie własne).	78
Rys. 2.23. Oczyszczona chmura punktów LiDAR z MSL dla akwenu testowego (opracowanie własne).	79
Rys. 2.24. Histogram przedstawiający częstość występowania punktów LiDAR z MSL w komórce siatki GRID dla akwenu testowego (opracowanie własne).	80
Rys. 2.25. Schemat blokowy przedstawiający wybrane etapy zmodyfikowanej metody ekstrakcji linii brzegowej (Xu S. i in., 2019) dostosowanej do danych LiDAR z MLS (opracowanie własne).	80
Rys. 2.26. Linia brzegowa wyrysowana na podstawie wygenerowanych punktów MSL i linia brzegowa wyznaczona przy użyciu punktów GCP dla akwenu testowego (opracowanie własne).	81
Rys. 2.27. Naturalna linia brzegowa wyrysowana na podstawie ortofotomapy i linia brzegowa wyznaczona przy użyciu punktów GCP dla akwenu testowego (opracowanie własne).	82
Rys. 2.28. Linia brzegowa uzupełniona o pomosty, która została wyrysowana na podstawie ortofotomapy i linia brzegowa wyznaczona przy użyciu punktów GCP dla akwenu testowego (opracowanie własne).	83
Rys. 2.29. Moduły opracowania danych pomiarowych (opracowanie własne).	85
Rys. 2.30. Moduł wielosensorycznej fuzji danych (opracowanie własne).	89
Rys. 2.31. Lokalizacja przetworzonych danych geoprzestrzennych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na akwenu testowym (opracowanie własne).	92
Rys. 2.32. Moduł wielosensorycznej fuzji danych w środowisku GIS (opracowanie własne).	94
Rys. 2.33. Model fuzji danych średnich ważonych o wykładniku potęgi 1 w lokalnym układzie wysokościowym dla akwenu testowego (opracowanie własne).	95

Rys. 2.34. Model fuzji danych średnich ważonych o wykładniku potęgi 2 w lokalnym układzie wysokościowym dla akwenu testowego (opracowanie własne).	96
Rys. 3.1. Lokalizacja pomiarów batymetryczno-fotogrametrycznych, które przeprowadzono w dniach 10.06.2022 r. i 05.09-07.11.2023 r. na akwenu morskim przyległym do plaży miejskiej w Gdyni (opracowanie własne).	98
Rys. 3.2. Lokalizacja pomiarów batymetryczno-fotogrametrycznych, które przeprowadzono w dniach 02-03.06.2022 r., 01.08-02.10.2023 r. i 14.08.2024 r. na jeziorze Kłodno (opracowanie własne).	99
Rys. 3.3. Lokalizacja przetworzonych danych geoprzestrzennych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na akwenu morskim przyległym do plaży miejskiej w Gdyni w dniu 10.06.2022 r. (opracowanie własne).	102
Rys. 3.4. Modele fuzji danych średnich ważonych o wykładniku potęgi 1 (a) i 2 (b) w lokalnym układzie wysokościowym dla kampanii pomiarowej przeprowadzonej na akwenu morskim przyległym do plaży miejskiej w Gdyni w dniu 10.06.2022 r. (opracowanie własne).	103
Rys. 3.5. Prototyp modułu optoelektronicznego (a) zamontowany na UAV Aurelia X8 Standard LE (b) (opracowanie własne).	104
Rys. 3.6. Lokalizacja przetworzonych danych geoprzestrzennych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na akwenu morskim przyległym do plaży miejskiej w Gdyni w dniach 05.09-07.11.2023 r. (opracowanie własne).	106
Rys. 3.7. Modele fuzji danych średnich ważonych o wykładniku potęgi 1 z zaznaczoną linią brzegową wyznaczoną na podstawie danych LiDAR z ALS (a) i UAV (b) w lokalnym układzie wysokościowym dla kampanii pomiarowej przeprowadzonej na akwenu morskim przyległym do plaży miejskiej w Gdyni w dniach 05.09-07.11.2023 r. (opracowanie własne).	107
Rys. 3.8. Lokalizacja przetworzonych danych geoprzestrzennych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniach 02-03.06.2022 r. (opracowanie własne).	110
Rys. 3.9. Modele fuzji danych średnich ważonych o wykładniku potęgi 1 (a) i 2 (b) w lokalnym układzie wysokościowym dla kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniach 02-03.06.2022 r. (opracowanie własne).	111
Rys. 3.10. Lokalizacja przetworzonych danych geoprzestrzennych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniach 01.08-02.10.2023 r. (opracowanie własne).	114
Rys. 3.11. Modele fuzji danych średnich ważonych o wykładniku potęgi 1 (a) i 2 (b) w lokalnym układzie wysokościowym dla kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniach 01.08-02.10.2023 r. (opracowanie własne).	115
Rys. 3.12. Autorka rozprawy doktorskiej podczas realizacji ALS i pomiarów fotogrametrycznych z wykorzystaniem UAV Aurelia X8 Standard LE na jeziorze Kłodno (opracowanie własne).	117
Rys. 3.13. Członkowie zespołu badawczego podczas realizacji pomiarów hydrograficznych z wykorzystaniem jednostki HydroDron-1 na jeziorze Kłodno (opracowanie własne).	117
Rys. 3.14. Autorka rozprawy doktorskiej podczas realizacji pomiarów batymetrycznych akwenu metodą geodezyjną z wykorzystaniem GNSS RTK Trimble R10 na jeziorze Kłodno (opracowanie własne).	118
Rys. 3.15. Lokalizacja przetworzonych danych geoprzestrzennych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniu 13.08.2024 r. (opracowanie własne).	120
Rys. 3.16. Modele fuzji danych średnich ważonych o wykładniku potęgi 1 (a) i 2 (b) w lokalnym układzie wysokościowym dla kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniu 13.08.2024 r. (opracowanie własne).	121
Rys. 3.17. Graficzne przedstawienie różnic głębokości między punktami pomiarowymi a odpowiadającymi im punktami wygenerowanych NMT o wykładniku potęgi 1 (a) i 2 (b) dla akwenu morskiego przyległego do plaży miejskiej w Gdyni na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniu 10.06.2022 r. (opracowanie własne).	125
Rys. 3.18. Histogram przedstawiający częstość występowania błędów określenia głębokości dla akwenu morskiego przyległego do plaży miejskiej w Gdyni na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniu 10.06.2022 r. (opracowanie własne).	127

Rys. 3.19. Dystrybuanta błędów określenia głębokości dla akwenu morskiego przyległego do plaży miejskiej w Gdyni na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniu 10.06.2022 r. (opracowanie własne).....	127
Rys. 3.20. Graficzne przedstawienie różnic głębokości między punktami pomiarowymi a odpowiadającymi im punktami wygenerowanego NMT dla akwenu morskiego przyległego do plaży miejskiej w Gdyni na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 05.09-07.11.2023 r. (opracowanie własne).....	128
Rys. 3.21. Histogram przedstawiający częstość występowania błędów określenia głębokości dla akwenu morskiego przyległego do plaży miejskiej w Gdyni na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 05.09-07.11.2023 r. (opracowanie własne).....	130
Rys. 3.22. Dystrybuanta błędów określenia głębokości dla akwenu morskiego przyległego do plaży miejskiej w Gdyni na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 05.09-07.11.2023 r. (opracowanie własne).	130
Rys. 3.23. Graficzne przedstawienie różnic głębokości między punktami pomiarowymi a odpowiadającymi im punktami wygenerowanego NMT dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 02-03.06.2022 r. (opracowanie własne).....	131
Rys. 3.24. Histogram przedstawiający częstość występowania błędów określenia głębokości dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 02-03.06.2022 r. (opracowanie własne).....	133
Rys. 3.25. Dystrybuanta błędów określenia głębokości dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 02-03.06.2022 r. (opracowanie własne).	133
Rys. 3.26. Graficzne przedstawienie różnic głębokości między punktami pomiarowymi a odpowiadającymi im punktami wygenerowanego NMT dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 01.08-02.10.2023 r. (opracowanie własne).....	135
Rys. 3.27. Histogram przedstawiający częstość występowania błędów określenia głębokości dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 01.08-02.10.2023 r. (opracowanie własne).	136
Rys. 3.28. Dystrybuanta błędów określenia głębokości dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 01.08-02.10.2023 r. (opracowanie własne).	136
Rys. 3.29. Graficzne przedstawienie różnic głębokości między punktami pomiarowymi a odpowiadającymi im punktami wygenerowanego NMT dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniu 13.08.2024 r. (opracowanie własne).	137
Rys. 3.30. Histogram przedstawiający częstość występowania błędów określenia głębokości dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniu 13.08.2024 r. (opracowanie własne).....	139
Rys. 3.31. Dystrybuanta błędów określenia głębokości dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniu 13.08.2024 r. (opracowanie własne).	139

Wykaz tabel

Tab. 1.1. Zależność maksymalnego błędu pomiaru głębokości ($TVU_{max}(d)$) od głębokości akwenu dla pięciu kategorii pomiarów hydrograficznych IHO (opracowanie własne).	16
Tab. 1.2. Zestawienie wartości RMSE głębokości dla metod: cBathy, Depth Inversion, radiometrycznej, SVR, uBathy i UDB (opracowanie własne).	29
Tab. 1.3. Zestawienie osiągniętych poziomów dokładności i liczby wykorzystanych zbiorów danych dla wybranych metod ekstrakcji linii brzegowej na podstawie danych LiDAR z ALS (Stateczny A. i in., 2023).	33
Tab. 2.1. Zestawienie wag dla poszczególnych danych zarejestrowanych podczas kampanii pomiarowej na akwencie testowym (opracowanie własne).	92
Tab. 3.1. Dane techniczne USV „AutoDron” (opracowanie własne).	99
Tab. 3.2. Dane techniczne UAV DJI Phantom 4 RTK (opracowanie własne).	100
Tab. 3.3. Zestawienie wag dla poszczególnych danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na akwencie morskim przyległym do plaży miejskiej w Gdyni w dniu 10.06.2022 r. (opracowanie własne).	102
Tab. 3.4. Zestawienie wag dla poszczególnych danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na akwencie morskim przyległym do plaży miejskiej w Gdyni w dniach 05.09-07.11.2023 r. (opracowanie własne).	106
Tab. 3.5. Dane techniczne USV HydroDron-1 (opracowanie własne).	108
Tab. 3.6. Zestawienie wag dla poszczególnych danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniach 02-03.06.2022 r. (opracowanie własne).	111
Tab. 3.7. Zestawienie wag dla poszczególnych danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniach 01.08-02.10.2023 r. (opracowanie własne).	115
Tab. 3.8. Zestawienie wag dla poszczególnych danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej na jeziorze Kłodno w dniu 13.08.2024 r. (opracowanie własne).	120
Tab. 3.9. Zestawienie informacji o modelach fuzji danych średnich ważonych o wykładniku potęgi 1 i 2 dla akwenu morskiego przyległego do plaży miejskiej w Gdyni na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniu 10.06.2022 r. (opracowanie własne).	124
Tab. 3.10. Miary dokładności modeli fuzji danych średnich ważonych o wykładniku potęgi 1 i 2 dla akwenu morskiego przyległego do plaży miejskiej w Gdyni na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniu 10.06.2022 r. (opracowanie własne).	126
Tab. 3.11. Zestawienie informacji o modelu fuzji danych średnich ważonych o wykładniku potęgi 1 dla akwenu morskiego przyległego do plaży miejskiej w Gdyni na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 05.09-07.11.2023 r. (opracowanie własne).	128
Tab. 3.12. Miary dokładności modelu fuzji danych średnich ważonych o wykładniku potęgi 1 dla akwenu morskiego przyległego do plaży miejskiej w Gdyni na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 05.09-07.11.2023 r. (opracowanie własne).	129
Tab. 3.13. Zestawienie informacji o modelu fuzji danych średnich ważonych o wykładniku potęgi 1 dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 02-03.06.2022 r. (opracowanie własne).	131
Tab. 3.14. Miary dokładności modelu fuzji danych średnich ważonych o wykładniku potęgi 1 dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 02-03.06.2022 r. (opracowanie własne).	132
Tab. 3.15. Zestawienie informacji o modelu fuzji danych średnich ważonych o wykładniku potęgi 1 dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 01.08-02.10.2023 r. (opracowanie własne).	134
Tab. 3.16. Miary dokładności modelu fuzji danych średnich ważonych o wykładniku potęgi 1 dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniach 01.08-02.10.2023 r. (opracowanie własne).	135

Tab. 3.17. Zestawienie informacji o modelu fuzji danych średnich ważonych o wykładniku potęgi 1 dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniu 13.08.2024 r. (opracowanie własne).....	137
Tab. 3.18. Miary dokładności modelu fuzji danych średnich ważonych o wykładniku potęgi 1 dla jeziora Kłodno na podstawie danych zarejestrowanych podczas kampanii pomiarowej przeprowadzonej w dniu 13.08.2024 r. (opracowanie własne).....	138

Streszczenie

Doktorant: mgr Oktawia Specht

Promotor: prof. dr hab. inż. Andrzej Stateczny

Tytuł rozprawy doktorskiej: Metoda monitoringu batymetrycznego strefy brzegowej na bazie fuzji wielomodalnych danych geoprzestrzennych pozyskanych przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych

Niniejsza rozprawa doktorska koncentruje się na opracowaniu innowacyjnej metody tworzenia numerycznego modelu strefy brzegowej na podstawie danych geoprzestrzennych zarejestrowanych przy użyciu różnych sensorów. W opracowanej metodzie położono szczególny nacisk na pozyskanie wysokiej jakości danych głębokościowych do 1 m, co stanowi wyzwanie ze względu na zbyt duże zanurzenie załogowych jednostek hydrograficznych. Celem pracy było opracowanie metody monitoringu batymetrycznego strefy brzegowej na bazie fuzji wielomodalnych danych geoprzestrzennych pozyskanych z wykorzystaniem sensorów pokładowych bezzałogowych platform pomiarowych. Teza rozprawy opiera się na założeniu, że zaproponowana metoda umożliwi uzyskanie jakości danych wymaganej dla kategorii specjalnej IHO. Wymagania te są szczególnie istotne w strefie brzegowej, gdzie precyzyjne pomiary dna morskiego mają kluczowe znaczenie dla bezpieczeństwa nawigacji.

Realizując cel główny rozprawy, opracowano autorską metodę monitoringu batymetrycznego strefy brzegowej na bazie fuzji wielomodalnych danych geoprzestrzennych pozyskanych przy użyciu sensorów pokładowych bezzałogowych platform pomiarowych, takich jak: echosonda jednowiązkowa i wielowiązkowa, kamera fotogrametryczna oraz LiDAR z mobilnego i lotniczego skaningu laserowego. W ramach tej metody dane batymetryczno-fotogrametryczne zostały przetworzone z wykorzystaniem trzech modułów: opracowania danych głębokościowych, opracowania danych płytkowodnych i wyznaczania linii brzegowej. Po przetworzeniu danych geoprzestrzennych są one następnie integrowane przy użyciu autorskiej metody fuzji danych średnich ważonych, w której wagi dla poszczególnych źródeł danych są ustalane na podstawie dokładności pomiaru. Warto podkreślić, że w autorskiej metodzie zastosowano metodę ekstrakcji linii brzegowej wykorzystującą dane LiDAR i metodę SVR, która umożliwia pozyskanie głębokości płytkowodnych do 1 m na podstawie chmury punktów SfM z danych UAV.

Na potrzeby niniejszej rozprawy doktorskiej przeprowadzono pomiary batymetryczno-fotogrametryczne przy użyciu bezzałogowych platform latających i pływających na dwóch reprezentatywnych akwenach: morskim i śródlądowym. Opracowaną metodę zastosowano na danych zarejestrowanych podczas realizacji pięciu kampanii pomiarowych, z czego jedna była kampanią kompleksową, podczas której wszystkie dane pozyskano tego samego dnia, co umożliwiło wyeliminowanie wpływu zmiennych warunków hydrometeorologicznych na wyniki pomiarów. Dla każdej kampanii stworzono odrębny model fuzji danych średnich ważonych, który uwzględniał charakterystykę badanego akwenu. Stworzone modele zostały następnie poddane szczegółowej analizie ilościowej. Analiza ta pozwoliła na weryfikację skuteczności opracowanej metody fuzji.

Na podstawie przeprowadzonych badań wyciągnięto następujące wnioski:

- Opracowana metoda monitoringu strefy brzegowej na bazie fuzji wielomodalnych danych umożliwia redukcję nadmiernych danych geoprzestrzennych;
- Metoda ta została zweryfikowana zarówno na obszarach morskich, jak i śródlądowych, co potwierdzono w pięciu kampaniach pomiarowych;
- Metoda monitoringu batymetrycznego strefy brzegowej jest metodą parametryczną. Jej skuteczność zależy od doboru parametrów przy opracowywaniu poszczególnych danych i tworzeniu modelu fuzji;
- Wzrost wykładnika potęgi w metodzie monitoringu batymetrycznego strefy brzegowej nie wpływa na dokładność opracowanego modelu fuzji danych średnich ważonych;
- Dane głębokościowe pozyskane przy użyciu metody SVR pozwoliły na bardzo duże pokrycie danymi w miejscach trudnodostępnych. Jednakże cechuje je najgorsza dokładność pomiaru głębokości ze wszystkich użytych sensorów;
- Na podstawie opracowanych modeli fuzji danych średnich ważonych stwierdzono, że wszystkie punkty pomiarowe z błędami określenia głębokości przekraczającymi 0.25 m zostały wygenerowane z wykorzystaniem metody SVR;
- Dane LiDAR z ALS i MLS przetworzone za pomocą zmodyfikowanej metody ekstrakcji linii brzegowej, które uwzględniają obecność przeszkód terenowych w pobliżu granicy lądu i wody, powinny zostać uzupełnione o dodatkowe dane. Dlatego też metoda wyznaczania linii brzegowej na podstawie ortofotomapy uznawana jest za główne źródło danych o jej przebiegu;
- Badania wykazały, że zaproponowana metoda ekstrakcji linii brzegowej pozwala na znacznie dokładniejsze wyznaczenie jej naturalnego przebiegu przy wykorzystaniu LiDAR-u mobilnego niż LiDAR-u lotniczego;
- Metoda średniej ważonej głębokości nie może być zastosowana na punktach linii brzegowej, ponieważ mają one zawsze tę samą głębokość (0 m). Z tego powodu postanowiono użyć metody średnich ważonych współrzędnych prostokątnych płaskich dla tych punktów;
- Na podstawie danych zarejestrowanych podczas kompleksowej kampanii pomiarowej opracowano model fuzji danych średnich ważonych z dokładnością określenia głębokości wynoszącą 0.111 m ($p=0.95$). Badania udowodniły, że zaproponowana metoda pozwala zdecydowanie spełnić minimalne wymagania dokładnościowe przewidziane dla kategorii specjalnej IHO;
- Do tworzenia modelu wykorzystuje się fuzję zdecentralizowaną, ponieważ w przypadku tego typu danych konieczny jest stały nadzór nad procesem integracji.

Przeprowadzona analiza ilościowa nie dała podstaw do odrzucenia tezy, że zaproponowana metoda monitoringu batymetrycznego umożliwi uzyskanie jakości danych wymaganej dla kategorii specjalnej IHO.

Słowa kluczowe: monitoring batymetryczny, strefa brzegowa, fuzja danych, dane geoprzestrzenne, bezzałogowy statek powietrzny (UAV), bezzałogowa jednostka pływająca (USV)

Abstract

PhD student: MSc Oktawia Specht

Supervisor: Prof. Andrzej Stateczny

Title of the PhD thesis: Method for bathymetric monitoring of the coastal zone based on the fusion of multimodal geospatial data obtained using on-board sensors of unmanned measurement platforms

This PhD thesis focuses on developing an innovative method for creating a numerical model of the coastal zone based on geospatial data recorded using various sensors. The developed method places particular emphasis on obtaining high-quality depth data up to 1 m, which is a challenge due to the excessive draft of manned hydrographic vessels. The aim of the doctoral dissertation was to develop a method for bathymetric monitoring of the coastal zone based on the fusion of multimodal geospatial data obtained with the use of on-board sensors of unmanned measurement platforms. The thesis of the dissertation is based on the assumption that the proposed method will enable obtaining the data quality required for the International Hydrographic Organization (IHO) Special Order. These requirements are particularly important in the coastal zone, where precise measurements of the seabed are crucial for the safety of navigation.

To implement the main aim of the PhD thesis, an original method for bathymetric monitoring of the coastal zone was developed based on the fusion of multimodal geospatial data obtained using on-board sensors of unmanned measurement platforms, such as: Single Beam Echo Sounder (SBES) and MultiBeam EchoSounder (MBES), photogrammetric camera, as well as Light Detection and Ranging (LiDAR) from airborne and mobile laser scanning. As part of this method, bathymetric and photogrammetric data were processed with the use of three modules: processing depth data, processing shallow water data and determining the coastline. Once the geospatial data is processed, it is then integrated using an original weighted average data fusion method, in which weights for individual data sources are determined based on the measurement accuracy. It is worth emphasising that the author's method uses a shoreline extraction method with the use of LiDAR data and the Support Vector Regression (SVR) method, which allows obtaining shallow water depths of up to 1 m based on the Structure-from-Motion (SfM) point cloud from Unmanned Aerial Vehicle (UAV) data.

For the purposes of this PhD thesis, bathymetric and photogrammetric measurements were carried out using unmanned flying and floating measurement platforms in two representative waterbodies: sea and inland. The developed method was used on data recorded during five measurement campaigns, one of which was a comprehensive campaign during which all data were obtained on the same day, which made it possible to eliminate the influence of variable hydrometeorological conditions on the measurement results. For each campaign, a separate weighted average data fusion model was created, which took into account the characteristics of the studied waterbody. The created models were then subjected to detailed quantitative analysis. This analysis allowed for verification of the effectiveness of the developed fusion method.

Based on the research conducted, the following conclusions were drawn:

- The developed coastal zone monitoring method based on multimodal data fusion enables the reduction of excessive geospatial data;

- This method has been verified in both marine and inland areas, which was confirmed in five measurement campaigns;
- The method for bathymetric monitoring of the coastal zone is a parametric method. Its effectiveness depends on the selection of parameters when processing individual data and creating a fusion model;
- The increase in the power exponent in the bathymetric monitoring method of the coastal zone does not affect the accuracy of the developed weighted average data fusion model;
- Depth data obtained using the SVR method allowed for very large data coverage in hard-to-reach places. However, they have the worst depth measurement accuracy of all the sensors used;
- Based on the developed weighted average data fusion models, it was found that all measurement points with depth determination errors exceeding 0.25 m were generated with the use of the SVR method;
- LiDAR data from Airborne Laser Scanning (ALS) and Mobile Laser Scanning (MLS) processed using a modified shoreline extraction method that takes into account the presence of terrain obstacles near the boundary between land and water should be supplemented with additional data. Therefore, the method for determining the coastline based on an orthophotomap is considered the main source of data about its course;
- Research has shown that the proposed shoreline extraction method allows for much more accurate determination of its natural course using MLS than ALS;
- The weighted average depth method can not be used on coastline points because they always have the same depth (0 m). For this reason, it was decided to use the weighted average method of plane rectangular coordinates for these points;
- Based on data recorded during a comprehensive measurement campaign, a weighted average data fusion model was developed with a depth accuracy of 0.111 m ($p=0.95$). The tests have proven that the proposed method can definitely meet the minimum accuracy requirements for the IHO Special Order;
- Decentralized fusion is used to create the model, because in the case of this type of data, constant supervision of the integration process is necessary.

The quantitative analysis performed did not provide grounds to reject the thesis that the proposed bathymetric monitoring method will enable obtaining the data quality required for the IHO Special Order.

Keywords: bathymetric monitoring, coastal zone, data fusion, geospatial data, Unmanned Aerial Vehicle (UAV), Unmanned Surface Vessel (USV)