

WOJSKOWA AKADEMIA TECHNICZNA

im. Jarosława Dąbrowskiego

WYDZIAŁ INŻYNIERII LĄDOWEJ I GEODEZJI



ROZPRAWA DOKTORSKA

**BADANIE CECH GEOMETRYCZNYCH
I RADIOMETRYCZNYCH PODZIEMNYCH
ORAZ PODPOWIERZCHNIOWYCH OBIEKTÓW
ANTROPOGENICZNYCH POZYSKANYCH
TECHNIKAMI TELEDETEKCYJNYMI**

Autor: **mgr inż. Klaudia Pasternak**

Promotor pracy: **dr hab. inż. Anna Fryśkowska-Skibniewska, prof. WAT**

Warszawa 2025

Rozprawa doktorska wykonana przez doktoranta: mgr inż. Klaudię Pasternak

Dziedzina nauki: nauki inżynieryjno-techniczne

Dyscyplina naukowa: inżynieria lądowa, geodezja i transport

STRESZCZENIE W JĘZYKU POLSKIM

Wraz z postępującą urbanizacją zarządzanie przestrzenią miejską, w tym również gęstą infrastrukturą podziemną, staje się kluczowe we współczesnych dziedzinach nauki i gospodarki takich jak: budownictwo, architektura, geodezja czy archeologia. Coraz większą rolę w tym obszarze odgrywają bezinwazyjne techniki teledetekcyjne, umożliwiające wykrycie wraz z określeniem rodzaju podziemnych i podpowierzchniowych obiektów pochodzenia antropogenicznego. Jednak w celu opracowania algorytmu detekcji czy klasyfikacji tych obiektów kluczowym etapem jest zdefiniowanie, wybór i wyodrębnienie ich charakterystycznych cech w zależności od rodzaju pozyskiwanych danych pomiarowych. Analiza dotychczasowych badań pozwoliła na zidentyfikowanie problemów badawczych związanych z automatyzacją wskazanych zagadnień. Na podstawie przeglądu literatury można zauważyć, że brak jest prac realizujących proces automatycznej selekcji cech obiektów antropogenicznych na potrzeby ich detekcji i klasyfikacji. Zauważono również, że brakuje też rozwiązań oceny wpływu jakości echogramów na wyniki wykrywania obiektów podziemnych. Z kolei w kontekście pozyskiwania cech historycznych obiektów podpowierzchniowych brakuje metod automatyzacji ich detekcji i ekstrakcji cech charakterystycznych.

Zidentyfikowane problemy badawcze wskazują na wyraźną potrzebę rozwoju metod automatycznego wyboru unikalnych i istotnych cech obiektów usytuowanych pod powierzchnią ziemi. Tak usytuowane obiekty nie są wykrywalne za pomocą każdej techniki teledetekcyjnej. Zazwyczaj wymagają wykorzystania sensorów aktywnych takich jak RADAR czy LiDAR. W związku z tym w niniejszej rozprawie podjęta została problematyka analizy i charakterystyki radiometrycznych oraz geometrycznych cech obiektów pochodzenia antropogenicznego zlokalizowanych pod powierzchnią ziemi. Dlatego też, głównym celem pracy była ekstrakcja cech geometrycznych i radiometrycznych na danych obrazowych oraz wysokościowych w celu opracowania metod automatyzacji procesów detekcji i klasyfikacji obiektów antropogenicznych. Jak już wspomniano, etapem poprzedzającym te procesy jest określenie i wybór istotnych cech tych obiektów. W celu możliwości selekcji atrybutów tego typu obiektów pozyskano chmury punktów i echogramy georadarowe. Na podstawie określonych technik pomiarowych i wybranych obiektów badawczych, usytuowanych pod powierzchnią ziemi, przeanalizowano i usystematyzowano zbiór ich charakterystycznych cech. W ramach prowadzonych badań zaproponowano nowe podejście automatyzacji selekcji cech radiometrycznych i geometrycznych podziemnych sieci uzbrojenia

terenu oraz cech geomorfometrycznych historycznych grodzisk podpowierzchniowych w kontekście opracowania algorytmu detekcji i klasyfikacji obiektów antropogenicznych. Wykonane analizy i usystematyzowany zbiór cech sieci podziemnych pozwoliły na opracowanie algorytmu klasyfikacji typów podziemnych sieci uzbrojenia terenu. Echogramy georadarowe (łącznie ponad 240) pozyskano na czterech obszarach badawczych. Opracowano również nowy współczynnik oceny jakości i skuteczności klasyfikacji, który uwzględnia skuteczność klasyfikacji dla uzyskanych przypadków różnego rodzaju sieci podziemnych.

Rozwój technologiczny georadarów i możliwość pozyskiwania nawet kilkudziesięciu echogramów przy pojedynczym przejeździe doprowadziła do opracowania nowego podejścia selekcji pozyskanych danych GPR. Zaproponowane podejście adaptacyjne, w oparciu o niereferencyjne wskaźniki, umożliwia wyodrębnienie echogramów georadarowych, charakteryzujących się najwyższą jakością występowania sygnałów użytkowych. W pracy udowodniono, że selekcja echogramów bezpośrednio wpłynęła na zwiększenie efektywności detekcji infrastruktury podziemnej.

Ostatnim zagadnieniem rozprawy było opracowanie sposobu ekstrakcji cech geomorfometrycznych grodzisk, ich detekcji i klasyfikacji na podstawie danych LiDAR pozyskanych z lotniczego i niskiego pułapu. Proponowane rozwiązanie obejmuje kompleksową analizę cech obiektów podpowierzchniowych głównie pod względem ich istotności w kontekście automatycznej detekcji grodzisk. Wykorzystanie danych LiDAR umożliwia ich identyfikację nawet na obszarach porośniętych gęstą roślinnością.

Podsumowując, zaproponowana w pracy metodyka pozwala na automatyzację detekcji, ekstrakcji i klasyfikacji zarówno podziemnych jak i podpowierzchniowych obiektów pochodzenia antropogenicznego z wybranych danych teledetekcyjnych.

STRESZCZENIE W JEZYKU ANGIELSKIM

As city development progresses, managing urban spaces, including dense underground infrastructure, becomes crucial for some modern fields of science and economy, including construction, architecture, geodesy, and archaeology. Non-invasive remote sensing techniques that enable the detection of underground and sub-surface objects of anthropogenic origin and the determination of their type are playing an increasingly important role in this domain. However, the key stage in the development of algorithms for the detection or classification of such objects consists in defining, selecting, and distinguishing their characteristic attributes, depending on the type of the acquired measurement data. The review of existing studies allowed the author to identify the research problems related to the automation of the issues mentioned above. Literature review reveals that there are no existing works that would tackle the process of automated selection of attributes of anthropogenic objects for the purposes of their detection and classification. It was also noted that there are no solutions for the assessment of the influence of the quality of radargrams on the results of the detection of underground objects. Furthermore, as far as the acquisition of attributes of historic sub-surface objects is concerned, there are few existing methods of the automation of their detection and the extraction of characteristic properties.

The identified research problems point to an urgent need to develop methods for the automated selection of the unique, important properties of objects situated below ground surface. Objects located in this way cannot be detected using each remote sensing technique. It usually requires the use of active sensors such as RADARs or LiDARs. Due to that, the author of the present dissertation discusses the problems related to analysing and characterising the radiometric and geometric properties of anthropogenic objects that are situated below the surface of the ground. Therefore, the main objective of the study was the extraction of the geometric and radiometric properties from imagery and elevation data in order to develop methods for the automation of the processes of the detection and classification of anthropogenic objects. As it has been already mentioned, the stage that precedes these processes is the determination and selection of important attributes of those objects. In order to enable the selection of attributes of this type of objects, point clouds and ground-penetrating radar echograms were acquired. Based on the specified measurement techniques and selected research objects situated below the surface of the ground, the set of their characteristic properties was analysed and organised. As part of the research, the author proposed an innovative approach to the automation of the selection of the radiometric and geometric

attributes of underground utility networks and the geomorphometric properties of sub-surface settlements in the context of the development of an algorithm for the detection and classification of anthropogenic objects. The conducted analyses and the systematised set of properties of underground utility networks allowed for the development of an algorithm for the classification of such structures. GPR radargrams (over 240 in total) were obtained in four research areas. A new coefficient for the assessment of the quality and effectiveness of classification was also developed that takes into account the effectiveness of classification for the acquired cases of various types of underground utility networks.

The development in the ground-penetrating radar technology that enables to acquire even several tens of radargrams from a single pass enabled to develop a new approach to the selection of the acquired GPR data. The proposed adaptative approach based on non-referential indicators, allows for the distinction of GPR radargrams that are characterised by the highest quality of the present usable signals. The author demonstrated that the selection of radargrams had a direct influence on the improvement of the effectiveness of underground infrastructure detection.

The final issue discussed in the dissertation was the development of a method of extraction of the geomorphometric properties of settlements, their detection and classification based on LiDAR data obtained from aviation and low altitudes. The proposed solution involves a comprehensive analysis of the properties of sub-surface structures, mainly in terms of their significance for the automated detection of settlements. The use of LiDAR data enables their identification even in areas overgrown with a dense plant cover.

In conclusion, the methodology proposed in the study enables the automation of the detection, extraction, and classification of both underground and sub-surface anthropogenic objects from the selected remote sensing data.

SPIS TREŚCI

STRESZCZENIE W JĘZYKU POLSKIM	3
STRESZCZENIE W JĘZYKU ANGIELSKIM	5
WYKAZ UŻYTYCH SKRÓTÓW	8
1. WPROWADZENIE	9
2. TEZA, CELE BADAWCZE, CYKL PUBLIKACYJNY	15
3. METODYKA BADAŃ	21
3.1. Metoda detekcji sieci uzbrojenia terenu na echogramach georadarowych (Publikacja P1)	21
3.2. Metoda klasyfikacji typów sieci uzbrojenia terenu na echogramach georadarowych (Publikacja P2)	28
3.3. Koncepcja selekcji i oceny jakości echogramów pozyskanych georadarem wielokanałowym (Publikacja P3)	40
3.4. Metoda ekstrakcji cech geomorfometrycznych grodzisk podpowierzchniowych na danych LiDAR (Publikacja P4)	47
PODSUMOWANIE I WNIOSKI	60
ZAŁĄCZNIKI	63
LITERATURA	64

WYKAZ UŻYTYCH SKRÓTÓW

- RADAR – ang. *Radar Detection and Ranging*
- LiDAR – ang. *Light Detection and Ranging*, skanowania laserowe
- GPR – ang. *Ground Penetrating Radar*, metoda georadarowa
- PCA – ang. *Principal Component Analysis*, analiza głównych składowych
- GESUT – Geodezyjna Ewidencja Sieci Uzbrojenia Terenu
- DEM, NMT – ang. *digital elevation model*, numeryczny model terenu
- SUT – sieci uzbrojenia terenu
- mGPR – ang. *Multichannel GPR*, georadar wielokanałowy
- PODGiK – Powiatowy Ośrodek Dokumentacji Geodezyjnej i Kartograficznej
- ALS – ang. *Aerial Laser Scanning*, lotniczy skanowanie laserowe
- SMRF – ang. *A simple morphological filter algorithm*
- PIQE – ang. *Perception-Based Image Quality Evaluator*
- BRISQUE – Blind/Referenceless Image Spatial Quality Evaluator
- NIQE – The Natural Image Quality Evaluator
- MSCN – ang. *Mean Subtracted Contrast Normalized*

1. WPROWADZENIE

Techniki teledetekcyjne i fotogrametryczne umożliwiają zdalne pozyskiwanie informacji o obiektach lub zjawiskach. Istotnym ich atutem jest możliwość dostarczania danych dotyczących geometrii i położenia przestrzennego badanych struktur. Niemniej ważną cechą jest zdolność do pasywnej i aktywnej rejestracji danych [1, 2]. Cechą systemów pasywnych jest rejestrowanie promieniowania odbitego w zakresie optycznym, natomiast aktywne systemy pozyskiwania danych charakteryzują się rejestrowaniem własnej emitowanej i odbitej energii od powierzchni Ziemi lub obiektów na niej występujących. Wraz z rozwojem fotogrametrii i teledetekcji zauważalny jest trend zastosowania tych technik w różnych dziedzinach nauki i gospodarki takich jak: archeologia, architektura, geodezja, inżynieria środowiska, urbanistyka, czy geomorfologia. W zależności od charakteru i usytuowania analizowanego obiektu zainteresowania, dobór odpowiedniej techniki pomiarowej determinuje kompletność i jakość danych. Wpływa to z kolei bezpośrednio na późniejszą analizę obiektów będących przedmiotem zainteresowania oraz ich cech charakterystycznych. Szczególnie trudnym zagadnieniem jest tematyka obserwacji obiektów niewidocznych na powierzchni terenu lub jego pokryciu, czyli elementów nieujawnionych takich jak podziemne i podpowierzchniowe: struktury budowlane, inżynierskie, czy obiekty historyczne np. pochodzenia antropogenicznego. Pod pojęciem obiektów podpowierzchniowych pochodzenia antropogenicznego należy rozumieć struktury powstałe w wyniku działalności człowieka usytuowane pod powierzchnią terenu charakteryzujące się odmiennymi właściwościami fizycznymi niż otaczające struktury geologiczne. Od obiektów podziemnych wyróżnia je fakt, że bardzo często elementy lub całość struktury wznoszą się ponad poziom niwelacji terenu. Do grupy antropogenicznych obiektów podpowierzchniowych można zaliczyć także relikty danych budowli (mury, fundamenty), groby czy grodziska. Grodziska są jedynymi obiektami pochodzenia antropogenicznego wystającymi ponad niwelację terenu, cechującymi się zbliżonym kształtem do rzeźby i ukształtowania przyległego terenu. Zadanie ich detekcji jest proste w przypadku pozyskiwania danych na obszarze niepokrytym średnią i wysoką roślinnością. Dodatkową trudnością jest także występowanie innych struktur geomorfologicznych o geometrii zbliżonej do dawnych osad. Zastosowanie wybranych aktywnych metod teledetekcyjnych pozwala na zlokalizowanie grodzisk, jako wybranych antropogenicznych obiektów podpowierzchniowych (niezależnie od stopnia pokrycia danego obszaru pokrywą roślinną), oraz charakterystykę ich cech.

Z kolei w przypadku podziemnych struktur pochodzenia antropogenicznego brakuje ich jednoznacznej definicji. Przykładowo, w ustawie „Prawo Budowlane” [3] w obrębie tej grupy znajdują się komory podziemne, tunele i przejścia techniczne, zbiorniki podziemne oraz kanały techniczne, a w praktycznym rozumieniu tej definicji grupę tę można uzupełnić o sieci uzbrojenia terenu. Z kolei „Ustawa Prawo Geodezyjne i Kartograficzne” [4] odnosi się do pojęcia sieci uzbrojenia terenu, kwalifikując je jako *„wszelkiego rodzaju nadziemne, naziemne i podziemne przewody i urządzenia: wodociągowe, kanalizacyjne, gazowe, ciepłne, telekomunikacyjne, elektroenergetyczne i inne, z wyłączeniem urządzeń melioracji szczegółowych, a także podziemne budowle, które w rozumieniu przepisów o statystyce publicznej nie są budynkami”* [4]. W obliczu potencjalnych zagrożeń bezpieczeństwa i szkód materialnych, wynikających obecnie między innymi z częściowo niekompletnej bazy danych Geodezyjnej Ewidencji Sieci Uzbrojenia Terenu (GESUT), współczesne badania w coraz większym zakresie koncentrują się na bezinwazyjnej detekcji antropogenicznych obiektów podziemnych. Dostarczenie informacji dotyczących lokalizacji sieci jest fundamentalnym zadaniem poprzedzającym rozpoczęcie jakichkolwiek prac ziemnych.

Jak już wspomniano wcześniej w procesie detekcji różnego typu obiektów podziemnych czy podpowierzchniowych kluczowy jest dobór adekwatnej metody pomiarowej. Niezależnie od typu wybranego obiektu niewidocznego jak i nieujawnionego w terenie, przypuszczalnie najbardziej zasadne jest pozyskanie danych źródłowych za pośrednictwem aktywnych technik teledetekcyjnych. Wybór ten podyktowany jest ograniczeniami sensorów pasywnych, które zazwyczaj nie mają możliwości rejestrowania cech takich obiektów, które mogłyby stanowić wyróżniki w procesie ich automatycznej detekcji czy też klasyfikacji. Ponadto coraz bardziej zauważalny jest rozwój zaawansowanych algorytmów wspomagających automatyzację procesów analiz danych związanych z tego typu obiektami [5–9]. Analizowane zbiory są obszerniejsze, a sensory dostarczają coraz więcej rodzajów danych, co w konsekwencji skutkuje także wzrostem liczby pozyskiwanych atrybutów tych obiektów. W związku z tym zasadne i nieuniknione staje się stosowanie i rozwój algorytmów przetwarzania i analizy danych geoprzestrzennych w klasycznym rozumieniu oraz tych wykorzystujących sztuczną inteligencję [10–13]. Kluczowym zagadnieniem łączącym wszystkie te metody jest skuteczne i prawidłowe wyodrębnienie oraz odpowiednie wagowanie właściwych i istotnych atrybutów pochodzących z różnych typów danych pozyskanych dla badanych obiektów. W tym kontekście szczególnego znaczenia nabiera pojęcie inżynierii cech, nazywane również inżynierią atrybutów. Proces ten ma na celu przekształcenie poziomów jasności pikseli obrazu na odpowiednią reprezentację lub określony wektor cech. Na tym etapie dokonuje się wydobycia

nowych cech z danych wejściowych (np. obrazowych czy wysokościowych). Na podstawie zastosowania różnych operacji arytmetycznych, inżynieria cech pozwala odnaleźć i wyodrębnić wzorce, które będą miały kluczowe znaczenie w procesach detekcji oraz klasyfikacji obiektów. Wybór istotnych atrybutów obiektów, czyli prawidłowo przeprowadzony proces inżynierii cech, oraz ich ekstrakcja bezpośrednio wpływa na skuteczność działania algorytmów detekcji i klasyfikacji [14]. Warto zauważyć, że innymi cechami charakteryzują się obiekty podziemne, a innymi obiekty podpowierzchniowe. Na przykład w przypadku obiektów podziemnych sieci uzbrojenia terenu, rejestrowane na echogramach georadarowych, uwidaczniane jako hiperbole reprezentujące daną sieć. Wówczas szukane cechy odnoszą się do parametrów tych hiperbol. Z kolei do obiektów podpowierzchniowych możemy zaliczyć grodziska szczególnie dobrze widoczne na danych wysokościowych. Szukane cechy dotyczyć mogą na przykład parametrów geometrycznych profili czy też zbiorów punktów charakterystycznych. Należy zauważyć, że nie istnieje jedna technika pomiarowa umożliwiająca rejestrację tak zróżnicowanych obiektów, ponieważ dla przykładu sieci podziemne (elektroenergetyczne, telekomunikacyjne, wodociągowe, kanalizacyjne, ciepłne i gazowe) charakteryzują się na obrazie cechami geometrycznymi i radiometrycznymi takimi jak: krzywizna, wielkość, rozpiętość, głębokość, z kolei grodziska podpowierzchniowe cechami geomorfometrycznymi na przykład: wysokość, powierzchnia, nachylenie czy rozpiętość. Dotychczas w literaturze tematu nie pojawiły się badania realizujące proces selekcji cech na potrzeby detekcji i klasyfikacji. Nie znaleziono także propozycji automatycznego wyboru takich cech.

Podsumowując, w celu realizacji procesu detekcji czy klasyfikacji obiektów koniecznym etapem jest wyodrębnienie, zdefiniowanie i wybór charakterystycznych cech dla konkretnego typu danych. W pracy poruszono dwa główne wątki koncentrując się na obiektach nieujawnionych wprost: podziemnych obiektach antropogenicznych mierzonych z wykorzystaniem GPR (ang. *Ground Penetrating Radar*, metoda georadarowa) oraz obiektach podpowierzchniowych, dla których pozyskano dane LIDAR (ang. *Light Detection and Ranging*, skanowanie laserowe):

1. W pierwszym przypadku analizie poddawane są echogramy georadarowe i cechy hiperbol, reprezentujących podziemne sieci uzbrojenia terenu (SUT). Dynamiczny postęp uczenia maszynowego i głębokiego uczenia w ostatnich latach przyczynił się do wzrostu skuteczności klasyfikacji różnych typów obiektów na obrazach GPR. Dostępne badania koncentrują się na klasyfikacji pustek podpowierzchniowych [9], kopalń [15], włazów [8], gleb oraz sieci podziemnych [7]. Jednak istniejące metody klasyfikacji infrastruktury

ograniczają się do odróżnienia rur podziemnych od studzienek [7]. Natomiast nie znaleziono publikacji przedstawiających klasyfikację typów sieci. Ponadto istniejące badania (i publikacje) dotyczące opracowania algorytmów detekcji i klasyfikacji obiektów podziemnych wykorzystują cechy radiometryczne wyekstrahowane m. in. z zastosowaniem banku filtrów Gabora [16, 17]. W publikacji [16] przetestowano różne parametry filtrów Gabora do usprawnienia badania informacji geometrycznych (orientacji) w dwuwymiarowych danych GPR. I tak w pracy [17] autorzy zaproponowali metodę automatycznej detekcji szczelin lodowych z echogramów georadarowych. Sugerowane rozwiązanie opierało się na wykorzystaniu banków filtrów Gabora oraz analizy głównych składowych (ang. *Principal Component Analysis*, PCA) do redukcji wymiaru wyodrębnionych cech Gabora. Autorzy publikacji [7, 18] dotyczących ekstrakcji i detekcji hiperbol wskazują jednak pewne ograniczenia rozwiązań automatycznych. Dotyczą one asymetrii wykrywanych obiektów, nieciągłych ramion hiperbol, detekcji jedynie krawędzi hiperbol bez kształtu całego obiektu oraz szumów związanych z występującymi odbiciami od innych obiektów podziemnych. W kontekście zastosowania sztucznej inteligencji do ekstrakcji cech obiektów podziemnych, ich detekcji oraz klasyfikacji częstym ograniczeniem jest konieczność pozyskiwania dużych zbiorów danych, które powinny zostać uwzględnione w trenowaniu sieci. W publikacji [19] autorzy zauważyli zależność pomiędzy skutecznością detekcji obiektów podziemnych, a jakością zbioru danych źródłowych. W przypadku niewystarczającego zbioru danych [19] interpretacja wyników modelu detekcji była niezadowalająca. Odpowiedzią na to wyzwanie jest wykorzystanie w trenowaniu sieci echogramów symulowanych [20]. Warto jednak zaznaczyć, że dane te nie odzwierciedlają w pełni złożoności rzeczywistego środowiska podziemnego i charakteryzują się mniejszym stopniem zaszumienia niż echogramy pozyskane bezpośrednio w terenie. Ponadto wymagają wykorzystania dużych mocy obliczeniowych i jest to proces czasochłonny. Mimo to, w dostępnej literaturze wciąż brakuje badań skupiających się na zagadnieniach związanych z klasyfikacją typów podziemnych sieci uzbrojenia terenu czy też oceną jakości zaszumionych echogramów pozyskanych georadarem. Reasumując, w proponowanym w pracy rozwiązaniu stosowane są klasyczne metody analizy obrazu uwzględniające jego jakość a przede wszystkim parametry radiometryczne i geometryczne hiperbol. Stanowi to jednocześnie nowatorskie i holistyczne podejście do analizy echogramów georadarowych i może w przyszłości służyć detekcji także innych obiektów podziemnych niebędących SUT.

2. W drugim przypadku analizie poddawane są dane wysokościowe i cechy geometryczne odzwierciedlające parametry geomorfometryczne grodzisk. Istniejące obecnie badania z zakresu ekstrakcji cech geomorfometrycznych podpowierzchniowych obiektów antropogenicznych skupiają się na analizie cech grodzisk [21] oraz innych typów obiektów takich jak zapory [22] czy kanały i sieci kanałów [23]. W pracach [22] i [23] na podstawie danych LiDAR w sposób automatyczny wyznaczono cechy zapór oraz powiązanych z nimi jezior takie jak: wysokość, długość, szerokość, objętość, obwód i nachylenie czy krzywizna. Dotychczas w literaturze istnieją również publikacje związane z wyznaczaniem cech geomorfometrycznych grodzisk, przy czym zagadnienie to było realizowane jedynie w sposób manualny [21]. Autorzy tej pracy [21] wyznaczają takie cechy jak: powierzchnia, obwód, kubatura form oraz wskaźnik wyniesienia obiektu, będący ilorazem kubatury i powierzchni. Na podstawie przeglądu literatury zauważono, że każdy typ obiektu pochodzenia antropogenicznego posiada swoje unikalne cechy charakterystyczne w procesie jego rozpoznania. Dlatego wybór cech geomorfometrycznych jest determinowany rodzajem i charakterystyką wykrywanych obiektów antropogenicznych oraz typem i rozdzielczością wykorzystywanych danych źródłowych. Warto zaznaczyć także, że w dostępnej literaturze coraz więcej zagadnień dotyczy również automatycznego wykrywania historycznych grodzisk. W publikacji [24] zaproponowano półautomatyczną metodę ich detekcji. Metoda, wykorzystująca konwolucyjne sieci neuronowe, została opracowana i przetestowana na trzech obszarach badawczych na danych wysokościowych NMT (Numeryczny Model Terenu) – wygenerowanych z chmur punktów LiDAR. Autorzy [24] wskazali pewne ograniczenia proponowanego rozwiązania związane z małą liczbą próbek, brakiem różnorodności typów grodzisk oraz koniecznością weryfikacji wyników detekcji przez człowieka ze względu na licznie wykryte fałszywie pozytywne obiekty. Z kolei w pracy [25] zaproponowano wykorzystanie danych LiDAR do automatyzacji niezidentyfikowanych stanowisk archeologicznych. Publikacja ta przedstawia automatyczną metodę detekcji grodzisk na przykładzie studium przypadku reprezentującego historyczne grodziska występujące w Anglii. Autorzy [25] podkreślają, że są to wstępne badania, a zbiór danych LiDAR w przyszłych pracach powinien zostać rozszerzony w celu zminimalizowania i tak już dużej liczby fałszywie pozytywnych wykrywanych obiektów antropogenicznych. Podsumowując, w powyższych pracach wskazano ograniczenia proponowanych rozwiązań związane głównie z niewielkimi zbiorami danych źródłowych, występującą pokrywą roślinną oraz dużą liczbą fałszywie pozytywnych wykrytych obiektów, co skutkuje koniecznością weryfikacji istnienia

grodziska przez użytkownika in situ. Proponowane w niniejszej pracy rozwiązanie obejmuje syntetyczną, ale kompleksową analizę cech obiektów głównie pod względem ich istotności w procesie automatycznej detekcji grodzisk porośniętych roślinnością. Stanowić to może uniwersalną metodę selekcji parametrów geomorfometrycznych dotyczącą także innych struktur rzeźby terenu.

2. TEZA, CELE BADAWCZE, CYKL PUBLIKACYJNY

Rozprawę doktorską pt. *Badanie cech geometrycznych i radiometrycznych podziemnych oraz podpowierzchniowych obiektów antropogenicznych pozyskanych technikami teledetekcyjnymi* stanowi cykl czterech powiązanych tematycznie artykułów naukowych. Zawierają one autorskie propozycje rozwiązań w zakresie automatyzacji procesu ekstrakcji cech geometrycznych i radiometrycznych hiperbol w kontekście klasyfikacji podziemnych typów sieci uzbrojenia terenu na echogramach georadarowych oraz rozwiązań w zakresie podnoszenia stopnia automatyzacji wyznaczania cech geomorfometrycznych historycznych grodzisk podpowierzchniowych z danych LiDAR i ich późniejszej klasyfikacji. Proponowane rozwiązania zostały zweryfikowane na podstawie danych referencyjnych. Opracowane w ramach prowadzonych badań autorskie metody automatycznej detekcji, klasyfikacji i ekstrakcji cech obiektów podziemnych i podpowierzchniowych są praktyczną odpowiedzią na codzienne wyzwania związane z bezinwazyjnym wykrywaniem obiektów pochodzenia antropogenicznego.

Podpowierzchniowe grodziska antropogeniczne są obiektami historycznymi, gdzie ich detekcję można przeprowadzić głównie w oparciu o zdefiniowane uprzednio (szczególnie w przypadku technik teledetekcyjnych) wyróżniki wysokościowe, geomorfologiczne, wegetacyjne oraz inne o charakterze dystynktywnym. Zaproponowane podejście umożliwiłoby ekstrakcję cech geomorfometrycznych grodzisk w sposób automatyczny z dokładnością porównywalną do metod manualnych, ale przede wszystkim pozwalałoby na znacznie szerszą analizę parametrów nie tylko o charakterze sytuacyjnym, ale także wysokościowym. Ważną zaletą opracowanego rozwiązania jest odporność na pokrycie szukanych obiektów szatą roślinną. Sposób ten znacząco skróciłby czas wykrywania tego typu obiektów nieujawnionych, często znajdujących się właśnie pod wysoką i gęstą szatą roślinną w miejscach, gdzie przeszukiwane są rozległe obszary potencjalnych lokalizacji tego typu niezidentyfikowanych obiektów podpowierzchniowych. Wyznaczenie parametrów geomorfometrycznych pozwoliłoby na dokładniejszą i wielokontekstową analizę nie tylko grodzisk. Detekcja grodzisk i wyznaczenie ich cech geomorfometrycznych mogą stanowić podstawę do dalszego planowania prac związanych z pomiarami inwazyjnymi, weryfikującymi istnienie podpowierzchniowego obiektu antropogenicznego.

Zarówno zagadnienie analizy cech obiektów podpowierzchniowych, jak i podziemnych, docelowo zmierza do umożliwienia ich automatycznej charakterystyki, detekcji oraz klasyfikacji na podstawie cech geometrycznych i radiometrycznych. Podczas analiz

charakterystyki obiektów podziemnych, wykrytych na pozyskanych w terenie echogramach georadarowych, zaobserwowano istotne zależności pomiędzy cechami geometrycznymi i radiometrycznymi hiperbol, reprezentującymi podziemne sieci uzbrojenia terenu, a ich typem tj. siecią elektroenergetyczną, telekomunikacyjną, wodociągową, ciepłowniczą, kanalizacyjną, gazową. Automatyzacja procesu wyszukiwania tych parametrów lub klasyfikacji jest utrudniona, co wynika z braku jednoznacznie zdefiniowanych i ustrukturyzowanych zbiorów danych hiperbol przedstawiających infrastrukturę podziemną. Automatyczne poszukiwanie tych parametrów i wyników klasyfikacji jest utrudnione, ponieważ nie istnieją tak zdefiniowane i usystematyzowane zbiory danych, reprezentujące infrastrukturę podziemną na echogramach georadarowych. Jednocześnie w przypadku wykorzystania metod głębokiego uczenia do detekcji czy klasyfikacji typów sieci podziemnych konieczne jest posiadania i wytrenowanie bardzo dużych zbiorów danych. Poza tym dotychczasowe rozwiązania oferują jedynie detekcję hiperbol, umożliwiając potwierdzenie występowania i usytuowania sieci, a nie klasyfikację ich typów. Ze względu na dynamiczny rozwój technologiczny georadarów i możliwość jednoczesnego pozyskiwania kilkudziesięciu echogramów, charakteryzujących się zbliżoną zawartością, metodyka detekcji hiperbol powinna być możliwie najbardziej uniwersalna w kontekście danych pozyskanych różnymi typami georadarów. Mając to na uwadze opracowano także koncepcję adaptacyjnego podejścia do selekcji echogramów GPR, pozyskanych georadarem wielokanałowym (ang. *multichannel*, mGPR). Umożliwia on pozyskanie jednocześnie ponad kilkudziesięciu echogramów, w przeciwieństwie do pojedynczych echogramów pozyskanych georadarem jednokanałowym. Ze względu na duży zbiór danych, pozyskanych przy pojedynczym przejeździe, zaproponowano podejście selekcji echogramów charakteryzujących się najwyższą jakością występowania sygnałów użytkowych. Uwzględnienie jakości echogramów jest kluczowe ze względu na opracowanie metody detekcji hiperbol, bazującej na analizie cech geometrycznych i radiometrycznych obiektów na obrazie.

Podsumowując, dążenie do podniesienia stopnia automatyzacji jest kluczowe w kontekście skrócenia czasu przetwarzania i opracowania danych pozyskanych technikami bezinwazyjnymi. W związku z tym na podstawie przeanalizowanej literatury w niniejszej rozprawie zdefiniowano **główny problem badawczy**, który koncentruje się na **określeniu cech obiektów podziemnych i podpowierzchniowych możliwych do ekstrakcji z wybranych typów danych teledetekcyjnych**. Następstwem tak zdefiniowanego głównego problemu badawczego było wyszczególnienie innych problemów bezpośrednio związanych z aktywnymi technikami teledetekcyjnymi i obiektami podziemnymi:

- **Problem badawczy 1:** Usystematyzowanie cech potrzebnych do wykrywania obiektów w zależności od ich typów oraz pozyskanych danych;
- **Problem badawczy 2:** Brak istniejących metod klasyfikacji typów podziemnych sieci uzbrojenia terenu na echogramach georadarowych;
- **Problem badawczy 3:** Brak analiz wpływu jakości echogramów georadarowych na skuteczność ekstrakcji cech i procesów przetwarzania danych.
- **Problem badawczy 4:** Brak istniejących metod automatycznej ekstrakcji cech geomorfometrycznych historycznych grodzisk podpowierzchniowych na podstawie danych LiDAR;

Na podstawie powyższych założeń postawiono następującą tezę badawczą: **zastosowanie opracowanych metod określania i automatycznej ekstrakcji cech geometrycznych oraz radiometrycznych podziemnych i podpowierzchniowych obiektów antropogenicznych na podstawie obrazowych i wysokościowych danych teledetekcyjnych umożliwi automatyzację procesu ich detekcji i klasyfikacji.**

Głównym celem pracy jest zatem **ekstrakcja cech geometrycznych i radiometrycznych na danych obrazowych i wysokościowych w celu opracowania metod automatyzacji procesów detekcji i klasyfikacji obiektów antropogenicznych.** Na podstawie głównego celu pracy zdefiniowano następujące zadania badawcze:

- **Zadanie badawcze 1:** Opracowanie metody detekcji hiperbol, reprezentujących podziemne sieci uzbrojenia terenu, na echogramach georadarowych z uwzględnieniem i zdefiniowaniem cech obiektów na echogramach georadarowych (**P1, P2**);
- **Zadanie badawcze 2:** Opracowanie metody klasyfikacji typów podziemnych sieci uzbrojenia terenu w oparciu o uprzednio wykryte hiperbole przedstawiające podziemne sieci uzbrojenia terenu (**P2**);
- **Zadanie badawcze 3:** Wybór cech geometrycznych i radiometrycznych hiperbol wykorzystywanych w klasyfikacji typów podziemnych sieci uzbrojenia terenu (**P2**);
- **Zadanie badawcze 4:** Weryfikacja zaproponowanej metody detekcji i klasyfikacji hiperbol wraz z oceną dokładności uzyskanych wyników. Opracowanie współczynnika skuteczności i jakości klasyfikacji – F_{EQ} (**P1, P2**);
- **Zadanie badawcze 5:** Ocena jakości i adaptacyjna selekcja echogramów pozyskanych georadarem wielokanałowym w kontekście późniejszych wyników jakości detekcji hiperbol stanowiących infrastrukturę podziemną (**P1, P3**);

- **Zadanie badawcze 6:** Opracowanie metody automatycznej detekcji struktur grodzisk na podstawie chmur punktów pozyskanych ze skaningu laserowego z pułapu lotniczego i z niskiego pułapu (**P4**);
- **Zadanie badawcze 7:** Przeprowadzenie kompleksowej analizy możliwości ekstrakcji parametrów geomorfometrycznych z danych archiwalnych, obrazowych oraz wysokościowych (**P4**);
- **Zadanie badawcze 8:** Przedstawienie metodyki ekstrakcji różnych cech geometrycznych i radiometrycznych na echogramach georadarowych oraz danych LiDAR, sprawdzenie jej wiarygodności w oparciu o dane referencyjne, a także analiza zastosowania tych rozwiązań w różnych dziedzinach (**P1, P2, P4**).

Badania stanowiące podstawę niniejszej rozprawy doktorskiej zostały przedstawione w powiązanych tematycznie artykułach naukowych (**P1, P2, P3, P4**), opublikowanych w czasopismach indeksowanych w bazie Journal Citation Reports. Suma punktów MEiN za publikacje uwzględnione w cyklu wynosi 500, a sumaryczny Impact Factor czasopism to 12.2 (z uwzględnieniem % udziału: punkty – 388, IF – 9.4).

Tabela 2.1. Wykaz artykułów naukowych wchodzących do cyklu (źródło: opracowanie własne)


Ozn.	Artykuły z cyklu	Punkty wg. MEiN, IF
P1	Onyszko K. (80%), Fryśkowska-Skibniewska A. (20%), 2021, A new methodology for the detection and extraction of hyperbolas in GPR images. <i>Remote Sensing</i> , 13(23): 4892. DOI: 10.3390/rs13234892	100 pkt IF: 5.3
P2	Pasternak K. (80%), Fryśkowska-Skibniewska A. (20%), 2024, Automatic classification of underground utilities in Urban Areas: A novel method combining ground penetrating radar and image processing, <i>Archives of Civil Engineering</i> , 70(2). DOI: 10.24425/ace.2024.149851	100 pkt IF: 1.1
P3	Pasternak K. (70%), Fryśkowska-Skibniewska A. (20%), Ortyl Ł. (10%), 2025, An Adaptive Non-Reference Approach for Characterizing and Assessing Image Quality in Multichannel GPR for Automatic Hyperbola Detection, <i>Applied Sciences</i> , DOI: 10.3390/app15095126	100 pkt IF: 2.5

Ozn.	Artykuły z cyklu	Punkty wg. MEiN, IF
P4	Pasternak K. (80%), Fryśkowska-Skibniewska A. (20%), 2025, Automated analysis of Slavic buried settlements based on LiDAR point cloud, UAV and image processing. <i>Journal of Cultural Heritage</i> , 70. DOI: 10.1016/j.culher.2025.04.009	200 pkt IF: 3.3

Powyższe publikacje odnoszą się do głównego oraz do szczegółowych problemów badawczych rozpatrywanych w cyklu:

- **Główny problem badawczy:** Określenie cech obiektów podziemnych i podpowierzchniowych możliwych do ekstrakcji z wybranych typów danych teledetekcyjnych – **P1, P2, P3, P4;**
- **Problem badawczy 1:** Usystematyzowanie cech potrzebnych do wykrywania obiektów w zależności od ich typów oraz pozyskanych danych – **P1, P2, P4;**
- **Problem badawczy 2:** Brak istniejących metod klasyfikacji typów podziemnych sieci uzbrojenia terenu na echogramach georadarowych – **P2;**
- **Problem badawczy 3:** Brak analiz wpływu jakości echogramów georadarowych na skuteczność ekstrakcji cech i procesów przetwarzania danych GPR – **P3;**
- **Problem badawczy 4:** Brak istniejących metod automatycznej ekstrakcji cech geomorfometrycznych historycznych grodzisk podpowierzchniowych na podstawie danych LiDAR – **P4.**

W wyniku realizacji rozprawy doktorskiej wykonany został najpierw przegląd istniejących antropogenicznych obiektów podziemnych i podpowierzchniowych oraz aktywnych pomiarowych technik teledetekcyjnych, które w zakresie analizy obrazu można wykorzystać do ekstrakcji cech poszukiwanych obiektów badawczych. Następnie na podstawie określonych aktywnych technik pomiarowych (georadar, LiDAR) przeanalizowano i usystematyzowano zbiór cech obiektów antropogenicznych (podziemnych i podpowierzchniowych) w zależności od typu obiektu i rodzaju danych teledetekcyjnych. Na podstawie wyznaczonych cech geometrycznych, radiometrycznych i geomorfometrycznych obiektów zaproponowano metodę detekcji i klasyfikacji obiektów. Ostatnim etapem przeprowadzonych badań była ocena jakościowa uzyskanych wyników. Schemat planowanych badań w niniejszej rozprawie doktorskiej przedstawiono na rysunku 2.1.



Rys. 2.1. Schemat planowanych badań (źródło: opracowanie własne)

3. METODYKA BADAŃ

W ramach niniejszej rozprawy doktorskiej zaproponowano autorską metodykę określania i ekstrakcji cech geometrycznych i radiometrycznych obiektów antropogenicznych na danych obrazowych (echogramy georadarowe) i wysokościowych (dane LiDAR) pozyskanych aktywnymi technikami teledetekcyjnymi. Na podstawie wyodrębnionych cech obiektów opracowano metodę detekcji i klasyfikacji podziemnych sieci uzbrojenia terenu oraz podpowierzchniowych grodzisk historycznych. Zaproponowane w pracy nowatorskie rozwiązania są odpowiedzią na rosnące potrzeby zwiększania stopnia automatyzacji procesu detekcji i klasyfikacji antropogenicznych obiektów podziemnych oraz podpowierzchniowych w kontekście prowadzonych prac modernizacyjnych infrastruktury podziemnej, badań poprzedzających wykonanie przewierć lub poznawaniem geometrii dawnych osad wczesnośredniowiecznych. Opracowane algorytmy automatycznych analiz danych nie tylko zapewniają powtarzalność wyników, dokładność i kompletność analiz, ale także skutecznie skracają czas otrzymania żądanych informacji.

W niniejszych podrozdziałach przedstawiono szczegółowy opis proponowanych metod rozwiązania podstawowych problemów i zadań badawczych w powiązaniu z artykułami z cyklu publikacyjnego oraz wyników badań.


W podrozdziałach 3.1 i 3.2 zaproponowano odpowiednio autorską metodę detekcji i klasyfikacji hiperbol, reprezentujących różne typy podziemnych sieci uzbrojenia terenu, wraz z analizą i wyborem cech radiometrycznych i geometrycznych charakteryzujących wykryte obiekty podziemne (**publikacje P1 i P2**). W podrozdziale 3.3 zaproponowano ocenę jakości echogramów pozyskanych georadarem wielokanałowym wraz z koncepcją opracowanego podejścia adaptacyjnego selekcji danych GPR charakteryzujących się najwyższą jakością (**publikacja P3**). Podrozdział 3.4 przedstawia proces detekcji i klasyfikacji historycznych grodzisk podpowierzchniowych oraz automatyczną ekstrakcję ich cech geomorfometrycznych na podstawie pozyskanych danych LiDAR (**publikacja P4**).

3.1. Metoda detekcji sieci uzbrojenia terenu na echogramach georadarowych (Publikacja P1)

Coraz więcej badań w istniejącej literaturze koncentruje się na zagadnieniu automatycznej detekcji hiperbol, reprezentujących podziemne sieci uzbrojenia terenu [10–13]. Powszechnym problemem w opracowaniu skutecznego algorytmu detekcji tych obiektów jest występowanie na echogramach wielu hiperbol, reprezentujących także inne obiekty znajdujące

się pod powierzchnią ziemi (takie jak kamienie, korzenie) niezwiązane z obiektami inżynierskimi [26, 27]. Obiekty te, w kontekście detekcji sieci podziemnych, stanowią odbicia fali elektromagnetycznej interpretowane jako obiekty (hiperbole) niewłaściwe. Dlatego też, zaproponowano algorytm automatycznej detekcji hiperbol, reprezentujących jedynie infrastrukturę podziemną na echogramach pozyskanych georadarem. W pracy przeanalizowano cechy (radiometryczne i geometryczne) tych obiektów oraz różne filtracje (analiza falkowa, filtry teksturowe, filtry krawędziowe) i ich skuteczność w kontekście wykrywania podziemnej infrastruktury.


Podziemne sieci uzbrojenia terenu są podstawowym elementem infrastruktury miejskiej i obejmują instalacje elektroenergetyczne, telekomunikacyjne, wodociągowe, kanalizacyjne, ciepłne i gazowe [4]. Ich przebieg jest dokumentowany w bazie danych GESUT. Dotyczy to zarówno istniejących jak i projektowanych przewodów sieci uzbrojenia terenu oraz urządzeń z nimi związanych. Zgodnie z istniejącymi przepisami tj. Ustawą Prawo Geodezyjne i Kartograficzne [4], Geodezyjna Ewidencja Sieci Uzbrojenia Terenu stanowi integralną część cyfrowych baz danych przestrzennych i jest dokumentowana w formie baz danych w systemie teleinformatycznym. Kluczowe informacje o infrastrukturze podziemnej tj. ich cechy radiometryczne i geometryczne mogą zostać pozyskane z echogramów georadarowych metodą GPR. Metoda ta to bezinwazyjna technika pomiarowa, której działanie polega na emisji fali elektromagnetycznej (przechodzącej przez różne ośrodki), a następnie na odbiorze wiązki odbitej od nieciągłości struktury gruntu, ośrodka skalnego lub materiałowego. Dostarcza informacji o istnieniu, przebiegu i rozkładzie obiektów podziemnych i podpowierzchniowych. Obiekt podziemny jest wykrywany i widoczny na echogramie georadarowym na skutek występującego zjawiska odbicia fali elektromagnetycznej na granicy dwóch ośrodków różniących się własnościami elektrycznymi. Georadar umożliwia wykrywanie zarówno metalowych, jak i niemetalowych instalacji podziemnych. Pomiar i opracowanie danych georadarowych sprowadza się do pozyskania echogramów na badanym terenie, przeprowadzenia wstępnego przetwarzania echogramów oraz do manualnego wskazania na obrazie wierzchołka hiperboli, stanowiącego górną część podziemnej sieci uzbrojenia terenu. Określenie lokalizacji wierzchołka jest procesem subiektywnym zwłaszcza w przypadku interpretacji echogramów przez niedoświadczonych analityków. Schemat pozyskiwania danych georadarowych oraz ich wstępnego przetworzenia wraz ze wskazaniem lokalizacji sieci podziemnej przedstawiono na rysunku 3.1.



Rys. 3.1. Schemat pozyskania i wstępnego przetworzenia danych GPR (źródło: opracowanie własne)


Zagadnienie pozyskania i opracowania danych GPR jest proste i ekonomiczne w przypadku badań wykonywanych na niewielkim obszarze. Problem pojawia się w przypadku konieczności przeprowadzenia prospekcji georadarowej na dużym obszarze charakteryzującym się dużym zagęszczeniem występowania infrastruktury podziemnej. Zagadnienie to było główną motywacją do podjęcia prac nad automatyzacją ekstrakcji cech obiektów antropogenicznych, a w konsekwencji do ich detekcji (**publikacja P1, P2**) i klasyfikacji (**publikacja P2**) na danych teledetekcyjnych.

Pierwszy etap przetwarzania danych GPR dotyczył wyeliminowania hiperbol fałszywych w procesie analizy informacji radiometrycznej obrazów. Pod pojęciem hiperbol fałszywych, nazywanych również obiektami niewłaściwymi, należy rozumieć elementy widoczne na echogramach wskazujące na obecność obiektów niebędących podziemnymi sieciami uzbrojenia terenu. Reprezentują one struktury takie jak kamienie czy korzenie. Porównywalnie zdefiniowano również hiperbole właściwe, czyli uwidocznione na echogramach GPR obiekty będące podziemnymi sieciami uzbrojenia terenu. Drugi etap prac nad automatyzacją detekcji hiperbol to wykrycie krawędzi hiperbol filtrem krawędziowym Sobela. Następnie w pracy **P1** zaproponowano wyeliminowanie wykrytych obiektów niewłaściwych poprzez wprowadzenie warunków geometrycznych (warunki na krzywiznę, wielkość i lokalizację na obrazie, czyli głębokość posadowienia sieci uzbrojenia terenu). Przykładowe obiekty właściwe i niewłaściwe przedstawiono na rys. 3.2.




Rys. 3.2. Obiekty podziemne widoczne na echogramach georadarowych: a – h obiekty właściwe (gdzie: a., d. – sieć elektroenergetyczna, b., h. – sieć gazowa, c. – sieć telekomunikacyjna, e. – sieć ciepłownicza, f. – sieć wodociągowa, g. – sieć kanalizacyjna), i. – p. obiekty niewłaściwe (źródło: opracowanie własne na podstawie [28])

Proponowany algorytm detekcji hiperbol, po wstępnym przetworzeniu echogramów, bazuje na aproksymacji obrazu na zadanym poziomie dekompozycji w analizie falkowej oraz na wykorzystaniu filtracji Gabora. Schemat proponowanego w publikacji **P1** algorytmu detekcji hiperbol właściwych przedstawiono na rys. 3.3.



Rys. 3.3. Schemat proponowanego algorytmu detekcji hiperbol właściwych (źródło: opracowanie własne na podstawie [28])


W proponowanym algorytmie echogramy poddano analizie falkowej, która opiera się na dekompozycji obrazu, czyli rozwinięciu falkowym obrazu. W wyniku tego procesu uzyskiwane są 4 komponenty tj. aproksymacja i detale (pionowy, poziomy i przekątny). W procesie dekompozycji obrazu, echogram jest poddawany górno- i dolnoprzepustowej filtracji będącej wielopoziomowym procesem iteracyjnym, w którym kolejne aproksymacje podlegają następnym dekompozycjom. Uzyskany w procesie dekompozycji obraz aproksymacji jest składową niskoczęstotliwościową uzyskaną po wyeliminowaniu detali [29,30]. W procesie filtracji echogramów georadarowych wykorzystano obraz aproksymacji uzyskany na pierwszym poziomie dekompozycji na podstawie falki Symlet5. Wybór falki macierzystej jest zależny od kształtu i właściwości sygnałów. Zestaw powinien być dobrany zgodnie ze specyfiką badanych obiektów. Schemat przeprowadzonej dekompozycji przedstawiono na rysunku 3.4.



Rys. 3.4. Schemat dekompozycji echogramu na poziomie 1 (źródło: opracowanie własne na podstawie [28])

Echogramy zostały poddane następnie analizie tekstur z zastosowaniem filtru teksturowego Gabora. Jego działanie bazuje na analizie częstotliwości w zadanych przez użytkownika kierunkach.

Selektywna zmiana parametrów funkcji Gabora pozwala na dopasowanie filtru do określonych wzorów obiektów występujących na obrazie. Parametry filtracji Gabora dobrano w sposób zapewniający jak największy stopień wykrycia hiperbol właściwych przy jednoczesnym zminimalizowaniu wykrycia hiperbol niewłaściwych. Pozyskane obrazy poddano dwukrotnej filtracji Gabora [31–33]. Obrazy wynikowe z przeprowadzonej filtracji poddano segmentacji k-średnich (ang. *k-means clustering*). Następnie na podstawie uzyskanych dwóch obrazów wynikowych wygenerowano obraz, będący iloczynem logicznym wyodrębniającym część wspólną dwóch obrazów. Proces przeprowadzenia filtracji Gabora i segmentacji k-średnich przedstawiono na przykładowym echogramie na rys. 3.5.




Rys. 3.5. Schemat filtracji Gabora i segmentacji k-średnich echogramu (źródło: opracowanie własne na podstawie [28])

Uzyskano wstępnie przefiltrowany obraz z wieloma hiperbolami właściwymi i niewłaściwymi. W celu częściowej eliminacji wykrytych obiektów niewłaściwych, nie będących sieciami uzbrojenia terenu, określono warunki geometryczne hiperbol stanowiących SUT:

- Wielkość obiektu (C_S) jest większa niż 45 px;
- Krzywizna obiektu (C_C) zawiera się w przedziale $<0.016; 0.160>$;
- Głębokość obiektu (C_D) jest większa niż 13 px.

Wprowadzone warunki umożliwiają wyselekcjonowanie na obrazie hiperbol, reprezentujących sieci podziemne, których określone cechy zawierają się w powyższych przedziałach (C_S , C_C , C_D). Wynik detekcji hiperbol przedstawiono na przykładowym echogramie na rys. 3.6.



Rys. 3.6. Wynik detekcji hiperbol na echogramie GPR: a. – echogram po wstępnym przetworzeniu, b. – obraz wynikowy detekcji SUT (źródło: opracowanie własne na podstawie [28])

W publikacji **P1** ocenę skuteczności wykrywania sieci podziemnych przeprowadzono za pomocą dwóch opracowanych parametrów M (wzór 3.1) i L (wzór 3.2).

$$M = \frac{M_2 - M_1}{M_2} \cdot 100\% \quad (3.1)$$

$$L = \frac{N_L - (n_{L1} + n_{L2})}{N_L} \cdot 100\% \quad (3.2)$$

gdzie:

M_2 – liczba wykrytych na obrazie obiektów po wstępnym przetworzeniu i detekcji krawędzi;

M_1 – liczba wykrytych na obrazie obiektów na obrazie wynikowym (tj. po wstępnym przetworzeniu, filtracji, detekcji krawędzi i wprowadzeniu warunków C_S , C_C i C_D);

N_L – liczba wszystkich wykrytych obiektów na obrazie wynikowym;

n_{L1} – liczba wykrytych hiperbol niebędących podziemnymi sieciami uzbrojenia terenu;

n_{L2} – liczba niewykrytych hiperbol będących podziemnymi sieciami uzbrojenia terenu.

Średnia skuteczność detekcji hiperbol właściwych wyniosła 91% (parametr M) oraz 13% (parametr L). Niska wartość parametru L świadczy o dużej liczbie wykrytych niewłaściwych hiperbol.

Ocenę jakości i skuteczności detekcji hiperbol przeprowadzono również z wykorzystaniem metryk: czułość (ang. *recall*), precyzja (ang. *precision*) i *F-measure*. Uzyskano następujące wartości metryk: 0.86 (*recall*), 0.14 (*precision*) i 0.24 (*f-measure*).

Podobnie jak w przypadku parametru L niska wartość *precyzji* oraz świadczy o dużej liczbie wykrytych hiperbol niewłaściwych pomimo wprowadzonych warunków geometrycznych i zaproponowanych metod filtracji w badaniach wstępnych. Problem ten jest związany z występującą na echogramach dużą liczbą innych struktur niż SUT. Przeprowadzone analizy pozwoliły na rozwiązanie **problemu badawczego 1** i zrealizowanie **zadań badawczych 1, 4, 5 oraz 8**. W dalszych badaniach (**publikacja P2**) informacja o wykrytej sieci podziemnej została wzbogacona o rodzaj wykrytej infrastruktury podziemnej.

Ograniczeniem proponowanego rozwiązania w publikacji **P1** jest duża liczba obiektów fałszywie pozytywnych oraz detekcja jedynie górnej krawędzi hiperboli, reprezentującej obiekt podziemny. W związku z tym w publikacji **P2** zaproponowano rozwiązanie pozwalające na ekstrakcję kształtu całej hiperboli z echogramu georadarowego.


3.2. Metoda klasyfikacji typów sieci uzbrojenia terenu na echogramach georadarowych (Publikacja P2)

W świetle rosnących wyzwań związanych z analizą zbiorów danych georadarowych oraz dynamicznym postępem technologicznym, zagadnienie automatyzacji detekcji i klasyfikacji obiektów podziemnych stało się przedmiotem coraz większego zainteresowania badaczy. Większość prac związanych z tą tematyką koncentruje się na opracowaniu jedynie rozwiązań automatycznej detekcji obiektów podziemnych [8, 10, 12]. Niewiele badań skupia się na opracowaniu rozwiązań mających na celu klasyfikację obiektów podziemnych. Opublikowane badania koncentrują się na klasyfikacji pustek podpowierzchniowych [9], kopalń [15], włazów [8], gleb oraz sieci podziemnych [7]. Klasyfikacja sieci ogranicza się do wyszczególnienia dwóch typów obiektów: rur podziemnych i studzienek [7]. Brak istniejących badań z zakresu klasyfikacji typów sieci podziemnych był motywacją do podjęcia tematu badawczego związanego z analizą cech hiperbol uwidocznionych na echogramach GPR, które znalazły zastosowanie w analizie semantycznej. Zaproponowany algorytm klasyfikacji typów infrastruktury podziemnej przedstawiono w publikacji **P2**. Jednak w celu opracowania skutecznego rozwiązania, koniecznym etapem poprzedzającym opracowanie klasyfikatora była szczegółowa analiza hiperbol, stanowiących podstawowy element w identyfikacji sieci podziemnych na echogramach. Analiza (zrozumienie i właściwa interpretacja) ich cech zarówno radiometrycznych jak i geometrycznych jest kluczowa w kontekście precyzyjnej detekcji oraz klasyfikacji. Właściwości radiometryczne odnoszą się do wartości intensywności pikseli występujących w obrębie i w otoczeniu badanych hiperbol. Z kolei geometryczne przedstawiają liczbową charakterystykę analizowanych obiektów, czyli ich geometryczne

parametry na obrazie. Analizując charakterystyczne atrybuty hiperbol zauważono istotne zależności pomiędzy różnymi cechami geometrycznymi obiektów, a typem sieci podziemnej (sieć elektroenergetyczna – „p”, telekomunikacyjna – „t”, wodociągowa – „w”, ciepłownicza – „h”, kanalizacyjna – „s” i gazowa – „g”). W początkowych badaniach analizowano wiele różnych cech hiperbol wyekstrahowanych na podstawie danych:

- dwuwymiarowych (2D): wielkość, krzywizna, głębokość, liczebność, rozpiętość, wysokość, kompletność, grubość w wierzchołku;
- jednowymiarowych (1D): długość, wysokość, liczba wierzchołków.

Podczas prac związanych z opracowywaniem algorytmu klasyfikacji typów sieci podziemnych pojawiły się dwa wyzwania badawcze związane z niekompletnością i wielokrotnością występowania hiperbol na echogramach (rys. 3.7).




Rys. 3.7. Niekompletność i wielokrotność występowania hiperbol (źródło: opracowanie własne)

Zagadnienie niekompletności wyrytych hiperbol związane było z tłumieniem fali elektromagnetycznej przez inne ośrodki gruntowe lub występujące obiekty podziemne. Na zjawisko tłumienia wpływ może mieć również zawartość wody w gruncie, częstotliwość fali elektromagnetycznej, skład i rodzaj występujących ośrodków gruntowych oraz przewodnictwo elektryczne. Konsekwencją niekompletności hiperbol jest ich częściowe wykrycie w procesie binaryzacji obrazu. Drugi aspekt badawczy, związany z wielokrotnością hiperbol, dotyczył głównie sieci elektroenergetycznej i telekomunikacyjnej. Te dwa problemy badawcze doprowadziły do konieczności zaproponowania rozwiązania klasyfikacji hiperbol pod względem stopnia ich kompletności na hiperbole:

- kompletne (Grupa A) – hiperbole posiadające wierzchołek i dwa ramiona,
- kompletne częściowo (Grupa B) – hiperbole posiadające wierzchołek i jedno ramię (lewe lub prawe),
- niekompletne (Grupa C) – hiperbole posiadające tylko jedno ramię lub wierzchołek.

Hiperbole z grupy C nie były brane pod uwagę w procesie klasyfikacji typów sieci podziemnych. Podział hiperbol ze względu na ich kompletności przedstawiono na rysunku 3.8.



Rys. 3.8. Klasyfikacja hiperbol ze względu na ich kompletność (źródło: opracowanie własne na podstawie [34])

Klasyfikacja hiperbol ze względu na ich kompletność wykonana została na echogramach po detekcji hiperbol, reprezentujących infrastrukturę podziemną. Zaproponowany algorytm detekcji, wykorzystujący metodę binaryzacji Sauvola, opiera się na analizie cech radiometrycznych obrazów i obiektów. Jest to zmodyfikowany algorytm detekcji, który zaproponowano w publikacji **P1**. Etap detekcji krawędzi z zastosowaniem filtru Sobela zastąpiony został binaryzacją obrazu metodą Sauvola. Proces ten miał na celu wyodrębnienie całego kształtu hiperbol, a nie tylko ich górnych krawędzi, w kontekście opracowania późniejszego algorytmu klasyfikacji typów sieci bazującego na analizie cech wykrytych obiektów. Próg binaryzacji (T) został wyznaczony automatycznie dla każdego przetwarzanego echogramu na podstawie wzoru 3.3.

$$T = m \cdot \left[1 + k \cdot \left(\frac{s}{R} - 1 \right) \right] \quad (3.3)$$

gdzie:

m – średnia w otoczeniu piksela;

k – parametr określający stopień zaszumienia obrazu, $k \in <0;1>$;


s – odchylenie standardowe w otoczeniu piksela;

R – maksymalna wartość odchylenia standardowego, jakie może pojawić się w obrazie (dla obrazów o wartości pikseli $[0, 255]$ przyjmuje się wartość $R = 128$) [34].

W pracy [34] zaproponowano wartość parametru k , określającego stopień zaszumienia, wynoszącą 0.2. Wartość tego parametru można zmieniać w zależności od jakości pozyskanych echogramów GPR. Cechy radiometryczne hiperbol, obejmujące intensywność odbicia sygnału oraz rozkład wartości pikseli w otoczeniu badanych obiektów, są kluczowe na etapie filtracji i binaryzacji obrazu w procesie automatycznego wyznaczania progu binaryzacji T . Informacja radiometryczna jest uzupełnieniem danych geometrycznych hiperbol. Wykorzystanie zarówno cech radiometrycznych i geometrycznych może być skuteczne szczególnie w przypadku


analizy obiektów o zbliżonej strukturze przestrzennej, ale różnej charakterystyce materiałowej takich jak np. SUT.

Następnie po przeprowadzeniu procesu binaryzacji proponowana metoda detekcji bazuje na ekstrakcji hiperbol spełniających predefiniowane warunki geometryczne (C_S , C_C , C_D) zaproponowane w publikacji **P1**. Na podstawie wprowadzonych warunków geometrycznych na obrazie usuwane są hiperbole, których wielkość, krzywizna i głębokość nie zawierają się w określonych w **P1** przedziałach (C_S , C_C , C_D). Schemat proponowanych etapów algorytmu detekcji hiperbol przedstawiono na rys. 3.9.




Rys. 3.9. Schemat detekcji hiperbol (źródło: opracowanie własne na podstawie [34])

Dla osoby niedoświadczonej w zakresie analizy danych georadarowych, poprawna identyfikacja i klasyfikacja typów sieci podziemnych jest trudnym zadaniem obciążonym ryzykiem błędnej interpretacji echogramów. Przykładowe hiperbole, reprezentujące różne typy podziemnych sieci uzbrojenia terenu i charakteryzujące się różnym stopniem kompletności, przedstawiono na rys. 3.10.



Rys. 3.10. Hiperbole przedstawiające różne typy sieci uzbrojenia terenu (źródło: opracowanie własne na podstawie [34])

W celu automatycznego wyznaczenia cech hiperbol zaproponowano algorytm ekstrakcji tych obiektów oraz ich połówek (ze względu na różny stopień kompletności hiperbol) z buforem 3 pikseli. Algorytm wycinania połówek hiperbol z obrazów obiektów, zaklasyfikowanych do grupy A lub B, jest różny w zależności od kompletności hiperbol. W przypadku hiperbol niekompletnych, algorytm nie uwzględnia hiperbol i je odrzuca nie uwzględniając ich w dalszych analizach. Schemat działania algorytmu ekstrakcji hiperbol został przedstawiony na rys. 3.11.



Rys. 3.11. Schemat działania algorytmu ekstrakcji hiperbol i ich połówek (źródło: opracowanie własne na podstawie [34])

Dopiero po etapie ekstrakcji hiperbol przedstawiono, usystematyzowano i wybrano do klasyfikacji typów sieci następujące cechy geometryczne hiperbol:

- krzywiznę (C_c),
- rozpiętość (R) i wysokość (H),
- wielkość (C_s),
- głębokość (C_d),

- długość (L_S) i wysokość sygnału (H_S).

Na podstawie określonych wartości cech geometrycznych hiperbol obliczono parametr K oraz zaproponowano parametr f i ODL (wzory 3.4 – 3.6).

$$K = \frac{H}{R} \quad (3.4)$$

$$f = \frac{2R^2}{16H} \quad (3.5)$$


$$ODL = \sqrt{H^2 + R^2} \quad (3.6)$$

gdzie:

H – wysokość hiperboli (H_L – dla lewej połowy, H_R – dla prawej połowy) [px],


R – szerokość hiperboli (R_L – dla lewej połowy, R_R – dla prawej połowy) [px].

Ekstrahowane cechy geometryczne hiperbol i ich połówek przedstawiono schematycznie na rysunku 3.12.



Rys. 3.12. Analizowane cechy geometryczne hiperbol (źródło: opracowanie własne na podstawie [35])

Długość i wysokość sygnału zostały wyznaczone na podstawie przekonwertowanych obrazów połówek hiperbol na dane 1-wymiarowe z wykorzystaniem metody Ring-Projection-Wavelet-Fractal. Schemat redukcji wymiaru obrazu, przedstawiającego hiperbolę sieci elektroenergetycznej, do sygnału przedstawiono na rys. 3.13.



Rys. 3.13. Schemat redukcji wymiaru obrazu do sygnału: (a) binarny obraz hiperboli, (b) środek ciężkości rozkładu masy na płaszczyźnie x–y z pierścieniami o danym promieniu, (c) reprezentacja 1D pierścieniowa obrazu hiperboli (źródło: opracowanie własne na podstawie [34])

W metodzie tej współrzędne kartezjańskie konwertowane są do układu biegunowego do przestrzeni $\gamma - \theta$ na podstawie wzoru 3.7.


$$\begin{cases} x = \gamma \cos \theta \\ y = \gamma \sin \theta \end{cases} \quad (3.7)$$

gdzie:

$$\gamma \in [0, \infty),$$

$$\theta \in (0, 2\pi] \text{ [35, 36].}$$

W kolejnym kroku redukcji danych 2D na 1D generowane są pierścienie o promieniach $(r + \Delta r)$ w wyznaczonym środku ciężkości wykrytego obiektu na podstawie funkcji gęstości rozkładu masy na płaszczyźnie. Finalnym etapem algorytmu jest zliczenie liczby pikseli w zasięgu danego promienia r [35, 36]. Na podstawie określonych wartości cech hiperbol zaproponowano algorytm klasyfikacji bazujący na wyznaczonych wartościach cech geometrycznych hiperbol (C_C , R , H , C_S , C_D , L_S , H_S) oraz parametrów (f , K , ODL) wyznaczonych na ich podstawie. Omówiony powyżej algorytm klasyfikacji przedstawiono schematycznie na rysunku 3.14.



Rys. 3.14. Schemat działania algorytmu klasyfikacji typów sieci podziemnych na echogramach (źródło: opracowanie własne na podstawie [34])

Wprowadzono 12 podstawowych warunków klasyfikujących hiperbole, a ich przedziały określono heurystycznie na podstawie hiperbol testowych (przedstawiono szczegółowo w publikacji **P2**). Ostatecznym wynikiem klasyfikacji jest jeden lub dwa typy sieci podziemnych. Na podstawie tych wyników przyporządkowano daną sieć do jednej z trzech grup, których podział uwarunkowany był właściwościami fizycznymi analizowanych

obiektów. Sieci podziemne zostały przyporządkowane do określonych grup w następujący sposób:

- Grupa 1: obejmuje infrastrukturę w postaci kabli podziemnych (sieć elektroenergetyczna „p”, sieć telekomunikacyjna „t”);
- Grupa 2: obejmuje infrastrukturę w postaci rurociągów podziemnych (sieć wodociągowa „w”, sieć ciepłownicza „h”, sieć kanalizacyjna „s”) przeznaczonych do transportu mediów w postaci płynnej;
- Grupa 3: obejmuje sieć gazową „g” przeznaczoną do transportu paliw w postaci gazowej.

Zaproponowane warunki (rys. 3.14) pozwalają na sklasyfikowanie wszystkich typów sieci podziemnych. Na podstawie wyników klasyfikacji, sieci podziemne przyporządkowano do grup sieci wyznaczając średnią skuteczność R_g . Algorytm klasyfikacji opracowano na podstawie 150 echogramów. Weryfikację poprawności klasyfikacji sieci przeprowadzono w oparciu o dane referencyjne pozyskane z PODGiK. Wyniki klasyfikacji typów sieci podziemnych, opartej na analizie cech hiperbol, przedstawiono w postaci średniej skuteczności przyporządkowania wykrytej sieci do danej grupy (R_g), średniej skuteczności klasyfikacji hiperboli wg typu sieci podziemnej (R_s) oraz średniej skuteczności klasyfikacji typu sieci z uwzględnieniem klasyfikacji grupowej (R_{sg}). Ocenę skuteczności klasyfikacji przeprowadzono na podstawie wielu analiz statystycznych. W pierwszej analizie wyznaczono wartości metryk tj. czułość (ang. *recall*), precyzja (ang. *precision*), *F-measure* i dokładność (ang. *accuracy*)

Accuracy jest metryką, która dostarcza informacji o zachowaniu danego modelu w tym przypadku klasyfikatora hiperbol. *Accuracy* opisuje skuteczność działania klasyfikacji hiperbol we wszystkich typach sieci. Stanowi iloraz liczby poprawnie sklasyfikowanych sieci (TP i TN) do całkowitej liczby wyników klasyfikacji. Dokładność powinna być jak najwyższa. *Recall* jest ilorazem liczby hiperbol dodatnich prawidłowo sklasyfikowanych jako dodatnie (TP) i całkowitej liczby hiperbol dodatnich sklasyfikowanych we wszystkich typach sieci (TP i FN). Im wyższa wartość parametru *Recall*, tym większa liczba pozytywnie sklasyfikowanych hiperbol. *Precision* odzwierciedla wiarygodność modelu w klasyfikowaniu hiperbol jako dodatnich. Parametr ten jest ilorazem liczby hiperbol dodatnich prawidłowo sklasyfikowanych (TP) i całkowitej liczby hiperbol sklasyfikowanych jako dodatnie (TP, FP). Parametr *F-measure* jest średnią ważoną parametrów *Precision* i *Recall*, uwzględniającą zarówno wyniki fałszywie pozytywne jak i fałszywie negatywne. Wyniki uzyskanych wartości metryk (*recall*, *precision*, *f-measure* i *accuracy*) przedstawiono w tabeli 3.1.

Tabela 3.1. Wyniki uzyskanej oceny skuteczności klasyfikacji typów sieci (źródło: opracowanie własne na podstawie [34])

Rodzaj sieci	p	w	h	s	g	t
Recall	0.7097	0.7429	0.5714	0.4286	0.4167	0.6400
Precision	0.7586	0.6341	0.3333	0.5294	0.8333	0.7273
F-measure	0.7333	0.6842	0.4211	0.4737	0.5556	0.6809
Accuracy	0.8416	0.7818	0.7944	0.8095	0.9140	0.8500

Najwyższe wartości metryk *Recall*, *Precision*, *F-measure* i *Accuracy* (powyżej 60%) dla określanych typów sieci osiągnięto dla sieci energetycznej, telekomunikacyjnej i wodociągowej. Uzupełniającą analizą jakości polegała na porównaniu wyników automatycznej klasyfikacji hiperbol z danymi referencyjnymi pozyskanymi z PODGiK. Ocena uzyskanych wyników została oparta wyznaczenie dwóch macierzy: *error matrix* and *confusion matrix*. Macierz błędów (ang. *error matrix*) przedstawia wyniki klasyfikacji hiperbol według typów sieci uzbrojenia terenu w odniesieniu do danych referencyjnych. Stanowi analizę dokładności, na podstawie której można określić całkowitą dokładność klasyfikacji (A_o), błąd przeszacowania (E_c), błąd niedoszacowania (E_o), dokładność producenta (A_p) oraz dokładność użytkownika (A_u). Całkowita dokładność klasyfikacji (ang. *overall accuracy*) określa jaka część wszystkich hiperbol została poprawnie sklasyfikowana. Wartości usytuowane w macierzy na przekątnej stanowią liczbę poprawnie sklasyfikowanych hiperbol. Całkowita dokładność stanowi zatem iloraz sumy poprawnie sklasyfikowanych sieci oraz całkowitej liczby sieci (wzór 3.8) i wyniosła 61%.

$$A_o = \frac{\sum_{p=1}^k n_{pp}}{n} \quad (3.8)$$

gdzie:

n_{pp} – liczba poprawnie sklasyfikowanych sieci w danej klasie $k = 1, 2, \dots, 6$, dla $p = 1, 2, \dots, 6$,

n – liczba wszystkich sieci klasyfikowanych sieci.

Błąd przeszacowania E_c (ang. *Error of commission*) dla danego typu sieci i określa liczbę hiperbol znajdujących się w wierszach macierzy błędów, które należą do innego typu sieci według danych referencyjnych. Błąd przeszacowania jest ilorazem liczby hiperbol sklasyfikowanych niepoprawnie do całkowitej liczby pikseli (wzór 3.9).

$$E_c = 1 - \frac{n_{ii}}{\sum_{j=1}^k n_{ij}} \quad (3.9)$$

Błąd niedoszacowania E_o (ang. *Error of omission*) dla klasy j określa liczbę hiperbol znajdujących się w kolumnach macierzy błędów, które nie zostały sklasyfikowane jako dany typ sieci a jako inne typy (wzór 3.10).

$$E_o = 1 - \frac{n_{jj}}{\sum_{i=1}^k n_{ij}} \quad (3.10)$$

Dokładność użytkownika (ang. *User's accuracy*) jest ilorazem liczby hiperbol poprawnie sklasyfikowanych w danym typie sieci do całkowitej liczby hiperbol należących do danego typu sieci (wzór 3.11).

$$A_u = \frac{n_{ii}}{\sum_{j=1}^k n_{ij}} \quad (3.11)$$

Dokładność producenta (ang. *Producer's accuracy*) jest ilorazem liczby hiperbol poprawnie sklasyfikowanych w danym typie sieci do całkowitej liczby hiperbol danej grupy sieci w danych referencyjnych (wzór 3.12).

$$A_p = \frac{n_{jj}}{\sum_{i=1}^k n_{ij}} \quad (3.12)$$

Wyniki przeprowadzonej analizy dokładności klasyfikacji hiperbol przedstawiono tabeli 3.2. Najwyższa dokładność producenta została osiągnięta dla sieci wodociągowej i energetycznej, a dokładność użytkownika dla sieci gazowej i energetycznej. Największy błąd przeszacowania osiągnięto dla hiperbol należących do sieci gazowej, a błąd niedoszacowania dla sieci kanalizacyjnej i gazowej.

Tabela 3.2. Wyniki uzyskanej oceny skuteczności klasyfikacji typów sieci na podstawie macierzy błędów (źródło: opracowanie własne na podstawie [34])

Typ sieci	p	w	h	s	g	t
A_p [%]	69	74	57	41	42	64
A_u [%]	79	61	32	53	83	73
E_c [%]	21	39	68	47	17	27
E_o [%]	31	26	43	59	58	36

Maksymalne wyniki osiągnięte dla błędów E_c i E_o wskazują na dużą liczbę sklasyfikowanych błędnie hiperbol (w przypadku E_c) w danym typie sieci (dla sieci ciepłowniczej – 68%) oraz niesklasyfikowanych w danym typie sieci (w przypadku E_o) dla sieci kanalizacyjnej – 59%.

Jednym z ograniczeń powyższych metryk oceny klasyfikacji jest ich nieodporność na niezrównoważony zbiór danych. W takim przypadku wyznaczona wartość *Accuracy* przypisuje jednakową wagę zdolności modelu do klasyfikacji wszystkich kategorii. Należy zwrócić

również uwagę na sposób określenia wartości TP, TN, FP i FN, ponieważ w przypadku uzyskania wyniku klasyfikacji w postaci dwóch sieci należy dany wynik wziąć pod uwagę np. w TP i FP. Przykładowo hiperbola, reprezentująca sieć elektroenergetyczną „p” (według danych referencyjnych), uzyskała wynik klasyfikacji: „pt”. Wynik ten powinien zostać uwzględniony jako TP i FP. W związku ze wspomnianymi ograniczeniami klasycznych metryk oceny klasyfikacji zasadne okazało się opracowanie metryki uwzględniającej zróżnicowane wyniki klasyfikacji. W publikacji **P2** zaproponowano wprowadzenie nowego współczynnika oceny jakości i skuteczności klasyfikacji typów sieci F_{EQ} (ang. *Effectiveness and Quality factor*) w celu uwzględnienia właśnie w ocenie skuteczności klasyfikacji wyników uzyskiwanych przypadków różnych typów sieci (np. „pt”, „wh”, „sw”). Współczynnik F_{EQ} obliczany jest jako średnia ważona ze średniej skuteczności klasyfikacji typów sieci dla uzyskanych wyników przypadków oraz liczbę występujących przypadków. Wzory 3.13 – 3.18 przedstawiają sposób wyznaczenia współczynnika dla uzyskanych przypadków klasyfikacji typów sieci.

$$F_{EQ_{p,pt}} = \frac{n_p \cdot \overline{R_{sgp}} + n_{pt} \cdot \overline{R_{sgpt}}}{n_p + n_{pt}} \cong 78\% \quad (3.13)$$

$$F_{EQ_{t,pt}} = \frac{n_t \cdot \overline{R_{sgp}} + n_{pt} \cdot \overline{R_{sgpt}}}{n_t + n_{pt}} \cong 78\% \quad (3.14)$$

$$F_{EQ_{w,wc,kw}} = \frac{n_w \cdot \overline{R_{sgw}} + n_{wc} \cdot \overline{R_{sgwc}} + n_{kw} \cdot \overline{R_{sgkw}}}{n_w + n_{wc} + n_{kw}} \cong 72\% \quad (3.15)$$

$$F_{EQ_{h,wh,sh}} = \frac{n_h \cdot \overline{R_{sgh}} + n_{wh} \cdot \overline{R_{sgwh}} + n_{sh} \cdot \overline{R_{sgsh}}}{n_h + n_{wh} + n_{sh}} \cong 59\% \quad (3.16)$$

$$F_{EQ_{s,sw,sh}} = \frac{n_s \cdot \overline{R_{sgs}} + n_{sw} \cdot \overline{R_{sgsw}} + n_{sh} \cdot \overline{R_{sgsh}}}{n_s + n_{sw} + n_{sh}} \cong 72\% \quad (3.17)$$

$$F_{EQ_g} = \frac{n_g \cdot \overline{R_{sgg}}}{n_g} \cong 81\% \quad (3.18)$$

gdzie:

n_i – liczba wystąpienia danego przypadku, gdzie $i = p, pt, t, w, wh, sw, h, sh, g$,

R_{sg_i} – średnia skuteczność klasyfikacji sieci dla wystąpienia danego przypadku i .

Najwyższą wartość współczynnika F_{EQ_i} uzyskano dla sieci gazowej (F_{EQ_g}). Jest to spowodowane faktem, iż gaz jako jedyna sieć nie została zaklasyfikowana razem z innym typem sieci. Najniższą wartość współczynnika F_{EQ_i} uzyskano dla sieci ciepłowniczej ($F_{EQ_{h,wh,sh}}$). Występujące przypadki klasyfikacji danej sieci z innym typem sieci (np. et, kw, kc, wc) wpłynęły na obniżenie współczynnika F_{EQ_i} – np. dla sieci ciepłowniczej (58%). Jednakowe

wyniki F_{EQ_i} uzyskano dla sieci energetycznej i telekomunikacyjnej. Wpływ na to miały: niewielka liczba przypadków n_i występująca w obydwu sieciach (tj. „p”, „pt”, „t”), jednakowe przypadki n_i występujące we współczynniku $F_{EQ_{p,pt}}$ i $F_{EQ_{t,pt}}$ (tj. $i = pt$) oraz przynależność do tej samej grupy sieci (Group I). Analogiczną sytuację uzyskano dla sieci wodociągowej i kanalizacyjnej (72%). Również są to sieci należące do tej samej grupy sieci (Group II) i posiadają jeden wspólny przypadek ($i = sw$).


Podsumowując, kluczowym etapem opracowania metody klasyfikacji typów sieci podziemnych na echogramach georadarowych była analiza cech radiometrycznych i geometrycznych hiperbol. Etap ten pozwolił scharakteryzować i rozróżnić dane rodzaje sieci. Pomimo proponowanej skutecznej metody klasyfikacji można zauważyć jej pewne ograniczenia związane z manualnymi etapami klasyfikatora (weryfikacja kompletności, manualna ekstrakcja wierzchołka hiperboli), pozyskiwaniem echogramów w jednorodnym środowisku gruntowym oraz małym zbiorem danych. Przeprowadzone analizy pozwoliły na rozwiązanie **problemów badawczych 1 – 2** i zrealizowanie **zadań badawczych 1 – 4 oraz 8**.

3.3. Koncepcja selekcji i oceny jakości echogramów pozyskanych georadarem wielokanałowym (Publikacja P3)

Dynamicznie rozwijające się technologie georadarowe doprowadziły do umożliwienia pozyskiwania przez georadary wielokanałowe jednocześnie ponad kilkudziesięciu echogramów. Dane te cechują się zbliżoną charakterystyką, ale nawet wizualnie różnią się jakością pod względem rozmycia i zaszumienia obrazu. Jakość obrazów determinuje skuteczność detekcji obiektów, która bazuje na analizie ich cech radiometrycznych i geometrycznych [37, 38]. Ze względu na bardzo duży zbiór echogramów pozyskiwanych przy pojedynczym przejeździe GPR, kluczowym etapem jest wybór obrazów charakteryzujących się najwyższą jakością. Obecnie w istniejącej literaturze brak jest rozwiązań analizujących wpływ jakości danych na skuteczność ekstrakcji cech i procesów przetwarzania danych GPR, co zostało określone jako **problem badawczy 3**.

W związku powyższym w publikacji **P3** zaproponowano nowe adaptacyjne podejście do selekcji echogramów zarejestrowanych podczas pomiaru georadarem wielokanałowym w pojedynczym profilu. Podejście to opiera się na analizie wartości wskaźników jakościowych (entropia, wariancja Laplacjana, PIQE) i selekcji echogramów charakteryzujących się największą ilością sygnałów użytkowych. Docelowe rozwiązanie umożliwia selekcję tych

echogramów co skutkuje poprawą skuteczności automatycznej detekcji infrastruktury podziemnej. Schemat proponowanej metody selekcji echogramów przedstawiono na rys. 3.15.



Rys. 3.15. Schemat podejścia selekcji echogramów na podstawie ich oceny jakości (źródło: opracowanie własne na podstawie [39])

Zagadnienie oceny jakości echogramów jest obszerne, jak również związane z wieloma czynnikami tj. tłumienie fali elektromagnetycznej, ciągłość zarejestrowanych anomalii, wartości stałych dielektrycznych ośrodków, częstotliwość pozyskiwania danych czy głębokość penetracji. W publikacji **P3** zaproponowano ocenę jakości echogramów wybranymi metodami niereferencyjnymi tj. entropia, wariancja Laplacjana i PIQE (ang. *Perception-Based Image Quality Evaluator*). Wybór tych metod był uwarunkowany przetestowaniem wyników oceny jakości uzyskanych również na podstawie innych wskaźników niereferencyjnych tj. BRISQUE (ang. *Blind/Referenceless Image Spatial Quality Evaluator*), NIQE (ang. *Natural Image Quality Evaluator*), co szczegółowo opisano w publikacji **P3**. Publikacja ta jest odpowiedzią na postawione w pracy **zadanie badawcze 5**.

Pierwszy etap badań dotyczył ogólnej oceny jakości echogramów pod względem liczby wykrytych obiektów na obrazie po binaryzacji i wprowadzonych warunkach geometrycznych (C_C , C_S , C_D). W kolejnym etapie przeprowadzono ocenę jakości echogramów wskaźnikami

entropii, PIQE i wariancji Laplacjana. Wartości wskaźników entropii i wariancji Laplacjana zostały wyznaczone odpowiednio ze wzorów 3.19 – 3.20.

$$H_N = \frac{1}{L} \sum_{i=0}^{2^L-1} p_i \log_2 \frac{1}{p_i} \quad (3.19)$$

$$\sigma = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^N |p(i, j) - \mu| \quad (3.20)$$

gdzie:

L – liczba występujących wartości intensywności,,

p_i – prawdopodobieństwo wystąpienia danej intensywności i na obrazie,

μ_L – średnia wartość Laplacjana na obrazie,

N – liczba pikseli na obrazie.

Algorytm PIQE ocenia jakość obrazu poprzez podział na bloki (np. 8×8 , 16×16) i analizę lokalnych właściwości. W pierwszym etapie oblicza współczynnik MSCN (ang. *Mean Subtracted Contrast Normalized*), który uwypukla lokalne kontrasty poprzez odjęcie średniej i normalizację względem wariancji (wzór 3.21). Następnie identyfikuje bloki o niskiej wariancji, gdzie analizuje odchylenie standardowe intensywności pikseli – wyższe wartości wskazują na obecność szumów. Algorytm dodatkowo wykrywa szum gaussowski w blokach. Ostateczny wskaźnik PIQE (wzór 3.22) jest obliczany jako stosunek liczby zdegradowanych bloków do całkowitej liczby bloków w obrazie, przy czym niższa wartość oznacza wyższą jakość obrazu.

$$MSCN(x, y) = \frac{I(x, y) - \mu(x, y)}{\sigma(x, y) + C} \quad (3.21)$$

$$\sigma = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^N |p(i, j) - \mu| \quad (3.22)$$

gdzie:

$I(x, y)$ – wartość intensywności piksela (x, y) ,

$\mu(x, y)$ – wartość średniej lokalnej w otoczeniu piksela (x, y) ,


$\sigma(x, y)$ – wartość lokalnego odchylenie standardowego w otoczeniu piksela (x, y) ,

C – wartość stałej zapobiegającej dzieleniu przez 0,

μ – wartość średniej intensywności w obrębie bloku,

N – liczba pikseli w danym bloku.

Wybrane wskaźniki jakości pozwoliły ocenić stopień rozmycia, szumu i szczegółowość występującą na obrazach GPR. Kolejny etap, po wyznaczeniu wartości wskaźników dla analizowanych obrazów, polegał na selekcji echogramów na podstawie wartości entropii i przyjętego progu istotności ($\alpha = 0.1$). W oparciu o to kryterium ($\alpha = 10\%$ i odpowiednio $1-\alpha = 90\%$) wyznaczono obrazy o najniższej jakości (10%) i najwyższej jakości (90%). Następnie na podstawie wskaźnika PIQE, wariancji Laplacjana, jak również na podstawie progu istotności 10% wybrano kanały o najwyższej jakości. Wyniki wybranych kanałów, z których uzyskano echogramy o najwyższej jakości, przedstawiono na diagramach Venna na poniższym rysunku na przykładzie wybranej trasy pomiarowej – rys. 3.16.



Rys. 3.16. Diagram Venna przedstawiający wyniki selekcji echogramów dla trasy 1 na podstawie ich oceny jakości (źródło: opracowanie własne na podstawie [39])

Echogramy wybrane na podstawie kryterium 90% przedstawiono na powyższych rysunkach w kolorze zielonym, a kryterium 10% kolorem czerwonym. W centralnej części diagramu uwidoczniiony jest zbiór wspólny wyselekcjonowanych kanałów, reprezentujących obrazy o najwyższej jakości. Wyniki selekcji, uzyskane dla analizowanych tras pomiarowych, pokazują zróżnicowanie w jakości echogramów i skuteczności detekcji hiperbol. W niektórych przypadkach nie wybrano kanałów na podstawie kryterium 90% w oparciu o jednocześnie trzy wskaźniki. W takich sytuacjach należało wybrać kolejne kanały, które uzyskały kolejne najwyższe wartości na podstawie wariancji Laplacjana. Takie podejście pozwala zachować kompromis pomiędzy wymaganiami jakościowymi a dostępnością danych, minimalizując


ryzyko pominięcia istotnych anomalii podziemnych, w przypadku braku wyselekcjonowanych kanałów spełniających jednocześnie wszystkie trzy warunki brzegowe 90%.

Na echogramach, które przeanalizowano pod względem jakości, wykonano detekcję hiperbol, reprezentujących infrastrukturę podziemną. Skuteczność detekcji infrastruktury podziemnej oceniono na podstawie zaproponowanych w publikacji **P1** parametrów M i L . Wyniki uzyskanych wartości skuteczności detekcji przedstawiono w tabeli 3.3 dla wybranej trasy pomiarowej.

Tabela 3.3. Wyniki parametrów (M , L) oceny skuteczności detekcji i entropii dla jednej trasy pomiarowej (H – najwyższa jakość, N – najniższa jakość) (źródło: opracowanie własne na podstawie [39])

Kanał	25	27	31	20	8	14	28	2	22	24	32	29	11	26	15
Entropia	0.983	0.990	1.000	0.905	0.905	0.905	0.907	0.918	0.930	0.940	0.960	0.965	0.000	0.207	0.209
Jakość	H	H	H	H	H	H	H	H	H	H	H	H	N	N	N
M	0.436	0.595	0.367	0.391	0.444	0.421	0.438	0.269	0.690	0.409	0.342	0.258	0.273	0.412	0.278
L	0.727	0.600	0.789	0.714	0.800	0.818	0.667	0.789	0.778	0.692	0.800	0.696	0.688	0.650	0.846

Wyniki parametrów M i L są różne w zależności od kanału, z którego pozyskano echogramy. Zauważalne są istotne zależności pomiędzy jakością obrazów, a skutecznością detekcji hiperbol. Wyniki uzyskanych wartości wskaźników oceny jakości i parametrów oceny skuteczności detekcji hiperbol przedstawiono na rys. 3.17.



Rys. 3.17. Wyniki wskaźników oceny jakości oraz parametrów oceny skuteczności detekcji hiperbol dla trasy 1 (źródło: opracowanie własne na podstawie [39])


Echogramy, dla których uzyskano wyższe wartości wskaźnika PIQE charakteryzują się niższym stopniem rozmycia obrazu. Wysoka wartości entropii cechuje się mniejszą liczbą niewykrytych obiektów będących infrastrukturą podziemną (n_{L2}). Wyższe wartości wariancji Laplacjana są związane ze wzrostem ogólnej liczby obiektów (n_{L1} i n_{L2}) oraz spadkiem skuteczności detekcji obiektów będących sieciami podziemnymi. W tabeli 3.4 przedstawiono porównanie wartości parametrów oceny skuteczności detekcji hiperboli w odniesieniu do obrazów GPR zarejestrowanych z kanałów charakteryzujących się skrajnymi wartościami wskaźników (wariancji Laplacjana, PIQE i entropii) w uzyskanej ocenie jakości. Tabela pokazuje różnice w wartościach parametrów M i L dla skrajnych echogramów charakteryzujących się najwyższą i najniższą jakością dla wybranych trzech tras pomiarowych.

Tabela 3.4. Ocena poprawy skuteczności detekcji hiperbol na podstawie analizowanych wskaźników jakości obrazu (źródło: opracowanie własne na podstawie [39])

Parametr	Wariancja Laplacjana			Entropia			PIQE		
Nr trasy	1	2	3	1	2	3	1	2	3
$M_{\max-\min}$ [%]	16.5	14.7	17.5	41.7	20.0	10.9	13.6	39.3	16.9
$M_{\max-\text{average}}$ [%]	2.8	9.3	8.3	28.0	9.3	1.7	6.9	28.9	5.9
$L_{\max-\min}$ [%]	4.0	40.5	17.3	16.8	40.5	11.4	10.3	6.7	11.4
$L_{\max-\text{average}}$ [%]	0.5	9.6	8.5	9.6	9.6	2.5	4.7	6.2	2.5

Proponowane innowacyjne podejście adaptacyjne do wyboru obrazów pozyskanych przez GPR pozwoliło na znaczącą poprawę skuteczności wykrywania hiperbol, reprezentujących podziemne sieci, o 15-40% ($M_{\max-\min}$, $L_{\max-\min}$). Jest to maksymalny wzrost skuteczności detekcji względem najniższej skuteczności detekcji na obrazach o najniższej jakości. Uzyskane wyniki skuteczności detekcji hiperbol wskazują, że w każdym przypadku różnice między maksymalnymi i minimalnymi wartościami ($M_{\max-\min}$, $L_{\max-\min}$) parametrów M i L są większe niż różnice między maksymalnymi i średnimi wartościami parametrów M i L dla całych tras ($M_{\max-\text{average}}$, $L_{\max-\text{average}}$).

Dodatkowym produktem oceny jakości było opracowanie map oceny jakości obrazów przedstawiających rozkład entropii na analizowanych echogramach. Rozkład ten odzwierciedla stopień uporządkowania i złożoności sygnału. Obszary o niskiej entropii wskazują na fragmenty o bardziej jednorodnej strukturze, natomiast wysokie wartości entropii przedstawiają większą różnorodność i potencjalną obecność istotnych anomalii podpowierzchniowych. Na rys. 3.18 przedstawiono przykładowe mapy oceny jakości dla najniższych i najwyższych wartości entropii.



Rys. 3.18. Mapy oceny jakości obrazów wygenerowane dla uzyskanych najniższych i najwyższych wartości entropii (źródło: opracowanie własne na podstawie [39])

Obszary charakteryzujące się mniejszą zawartością informacji lub nieskorelowanym poziomem szumu na mapach oceny jakości oznaczone zostały niebieską barwą (niskie wartości entropii). Natomiast wysokie wartości entropii (większą ilość informacji) oznaczono barwą żółtą. Niższe wartości entropii mogą wynikać z wystąpienia czynników tj. szum czy utrata sygnału GPR spowodowana większym tłumieniem ośrodka gruntowego.

W procesie oceny jakości danych GPR wykorzystanie metryk takich jak entropia, PIQE i wariancja Laplasjanu pozwala na identyfikację i eliminację obrazów o niskiej jakości, co bezpośrednio przekłada się na wzrost efektywności detekcji, co przedstawiono w tabeli 3.4. Metoda ta jest szczególnie przydatna w analizie wielokanałowych danych GPR, gdzie jakość poszczególnych kanałów jest zróżnicowana. W ramach niniejszej publikacji **P3** rozwiązano **problem badawczy 3** i zrealizowano **zadanie badawcze 5**.


Jednym z ograniczeń proponowanego podejścia jest to, że dla analizowanego obrazu wyznaczana jest jedna wartość parametru oceniającego jego jakość. Globalna ocena nie uwzględnia lokalnych artefaktów, które mogłyby mieć wpływ na detekcję hiperbol. Rozwiązaniem tego problemu mogłoby być zaproponowanie podejścia oceny jakości obrazów w oparciu o wskaźniki sektorowe. Oceniałyby one wówczas jakość echogramów w obrębie mniejszych części obrazów wynikających z ich podziału na bloki o zadanym rozmiarze.

3.4. Metoda ekstrakcji cech geomorfometrycznych grodzisk podpowierzchniowych na danych LiDAR (Publikacja P4)

Cechy radiometryczne i geometryczne zaimplementowane w klasyfikacji echogramów różnią się od cech typowych dla danych wysokościowych, ale ich wydobywanie jest również obligatoryjnym krokiem w procesie automatycznej detekcji czy klasyfikacji obiektów podpowierzchniowych, takich jak grodziska. Są to historyczne obiekty pochodzenia antropogenicznego, będące archeologicznymi i topograficznymi pozostałościami ufortyfikowanych osad (działalności osadniczej oraz gospodarczej). Analiza ich kształtu pozwala odkryć społeczną, polityczną i ekonomiczną dynamikę żyjących w tamtych czasach środowisk. W tym kontekście istotnym aspektem jest badanie cech geomorfometrycznych tych obiektów i prace związane nad automatyzacją wykrywania grodzisk oraz ekstrakcji ich cech charakterystycznych. Ma to szczególne znaczenie, ponieważ wiele historycznych grodzisk podpowierzchniowych nie zostało obecnie jeszcze zidentyfikowanych [23, 40–42]. Częściowo dane wysokościowe (dotyczące geometrii) można pozyskać wykorzystując technologię LiDAR, która umożliwia zarejestrowanie reprezentacji powierzchni terenu w postaci chmury punktów pomiarowych o określonych współrzędnych.

Istniejące obecnie badania w zakresie detekcji i ekstrakcji cech geomorfometrycznych podpowierzchniowych obiektów antropogenicznych koncentrują się na analizie obiektów takich jak kurhany czy kanały i sieci kanałów [23]. Innymi podpowierzchniowymi obiektami pochodzenia antropogenicznego są grodziska. Większość prac badawczych skupia się na detekcji grodzisk na danych obrazowych (ortofotomapa). Jednak w przypadku występowania grodziska na obszarze zalesionym koniecznością jest wykorzystanie danych wysokościowych tj. LiDAR. Grodziska są obiektami historycznymi, gdzie ich detekcję można przeprowadzić głównie w oparciu o zdefiniowane uprzednio (szczególnie w przypadku technik teledetekcyjnych) wyróżniki wysokościowe, geomorfologiczne, wegetacyjne oraz inne o charakterze dystynktywnym. W związku z powyższym w publikacji **P4** zaproponowano sposób ekstrakcji cech oraz detekcji i klasyfikacji grodzisk na podstawie danych LiDAR pozyskanych z lotniczego i z niskiego pułapu. W początkowych pracach badawczych planowana była integracja danych LiDAR i GPR. Po wykonaniu wstępnych pomiarów georadarowych okazało się, że metoda GPR jest w tym przypadku nieskuteczna. W celu wykrycia zarówno płytko-, jak i głęboko posadowionych struktur antropogenicznych dane zarejestrowano w dwóch częstotliwościach: 250 i 700 MHz. Interpretacja pozyskanych echogramów nie pozwoliła na detekcję anomalii przedstawiających antropogeniczne struktury

podpowierzchniowe. Przykładowe pozyskane echogramy z obszaru grodziska (Chlebnia, Błonie) przedstawiono na rys. 3.19.



Rys. 3.19. Echogramy georadarowe pozyskane na grodzisku Chlebnia w Błoniach (źródło: opracowanie własne)

W związku z powyższym w publikacji **P4** skupiono się na ekstrakcji cech geomorfometrycznych z danych LiDAR pozyskanych z lotniczego i niskiego pułapu. Cechy te zostały wyznaczone na podstawie wysokorozdzielczych modeli wysokościowych wygenerowanych z chmur punktów reprezentujących powierzchnię terenu obszaru grodzisk. Analiza cech geomorfometrycznych ma na celu wyodrębnienie struktur o regularnych kształtach i wysokościach typowych dla grodzisk. Proces ekstrakcji cech geomorfometrycznych grodzisk dotyczył obiektów różnego typu (grodziska jedno- i dwuczłonowe) z różnym stopniem pokrycia roślinnością (brak roślinności, obszar pokryty niską i średnią roślinnością oraz obszar całkowicie zalesiony). Na podstawie wygenerowanych numerycznych modeli terenu (NMT) wyekstrahowano następujące cechy geomorfometryczne:

- Powierzchnia (P),
- Rozpiętość ($r_{\min}$, $R_{\max}$),
- Współczynnik kształtu (F_{shape}),
- Eccentricity (E),
- Circularity (C),
- Wysokość bezwzględna (H_B) i względna (H_W).

Cechy geomorfometryczne grodzisk zostały wyznaczone w sposób automatyczny (A) i manualny (M). Automatyczna ekstrakcja cech została wykonana dla obszarów grodzisk wykrytych na podstawie algorytmu detekcji (omówionego w dalszej części niniejszego podrozdziału) na danych NMT. Manualna ekstrakcja cech została wykonana na podstawie danych źródłowych tj. NMT, ortofotomapa i mapa archiwalna (dane referencyjne). Otrzymane wartości parametrów geomorfometrycznych badanych grodzisk zestawiono w poniższych tabelach 3.5 i 3.6 odpowiednio dla danych ALS i UAV-ALS.

Tabela 3.5. Wyekstrahowane cechy geomorfometryczne dla grodziska Rokitno z danych ALS (opracowanie własne)






Cecha	Dane źródłowe				Różnice wyekstrahowanych wartości cech [%]		
	NMT (A)	NMT (M)	ORTO (M)	REF (M)	REF(M)-NMT(A)	REF(M)-NMT(M)	REF(M)-ORTO(M)
P [m ²]					REF(M)-NMT(A)	REF(M)-NMT(M)	REF(M)-ORTO(M)
	9397.60	9250.80	9125.60	9324.40	-0.8%	0.8%	2.1%
r _{min}	98.10	99.10	99.30	102.30	4.1%	3.1%	2.9%
R _{max}	128.20	124.30	122.90	124.00	-3.4%	-0.2%	0.9%
F _{shape}	0.77	0.80	0.81	0.83	7.2%	3.6%	2.4%
E	0.64	0.60	0.58	0.56	-14.3%	-7.1%	-3.6%
C	0.63	0.92	0.96	0.90	30.0%	-2.2%	-6.7%
H _B [m]	96.25	96.10	brak	brak			
H _W [m]	7.95	7.80	brak	brak			

Tabela 3.6. Wyekstrahowane cechy geomorfometryczne dla grodziska Rokitno z danych UAV-ALS (opracowanie własne)

Cecha	Dane źródłowe				Różnice wyekstrahowanych wartości cech [%]		
	NMT (A)	NMT (M)	ORTO (M)	REF (M)	REF(M)-NMT(A)	REF(M)-NMT(M)	REF(M)-ORTO(M)
P [m ²]					REF(M)-NMT(A)	REF(M)-NMT(M)	REF(M)-ORTO(M)
	9293.00	9308.80	9125.60	9324.40	0.3%	0.2%	2.1%
r _{min}	92.90	95.60	99.30	102.30	9.2%	6.5%	2.9%
R _{max}	124.10	124.20	122.90	124.00	-0.1%	-0.2%	0.9%
F _{shape}	0.75	0.77	0.81	0.83	9.6%	7.2%	2.4%
E	0.68	0.68	0.58	0.56	-21.4%	-21.4%	-3.6%
C	0.84	0.93	0.96	0.90	6.7%	-3.3%	-6.7%
H _B [m]	96.38	96.27	brak	brak			
H _W [m]	7.93	7.82	brak	brak			


Analiza wyników pokazuje, że nie wszystkie typy danych źródłowych pozwalają na ekstrakcję pełnego zestawu cech geomorfometrycznych obiektów. Dane wysokościowe (NMT wygenerowane na podstawie danych LiDAR) pozwalają na wyodrębnienie zarówno cech obrazowych, jak i wysokościowych, co stanowi ich przewagę na pozostałymi danymi geoprzestrzennymi. Wyniki pokazują, że wysoka rozdzielczość i możliwość penetracji pokrywy roślinnej umożliwiają precyzyjną analizę i ekstrakcję form terenowych (nasypy, fosy, wały) reprezentujących grodziska podpowierzchniowe. W większości przypadków różnice w wartościach wyznaczonych cech geomorfometrycznych względem danych referencyjnych nie przekraczają 10%. Na dokładność wyznaczonych wartości cech geomorfometrycznych grodzisk wpływ miały dwa czynniki. Pierwszy z nich dotyczył jakości danych archiwalnych, których niska rozdzielczość i wrysowana jedynie podziałka liniowa mogła wprowadzać błąd wyznaczania obrysu grodziska, a w konsekwencji wartości wyznaczanych cech obiektów. Drugim aspektem był błąd wskazania obrysu grodziska, obarczony w pewnym stopniu subiektywnością, szacowany na 2-3 piksele.

Dodatkowym elementem analiz geomorfometrycznych była interpretacja map spadków opracowanych dla analizowanych grodzisk. Zostały one wygenerowane na podstawie danych NMT. Mapy spadków, przedstawiające nachylenie terenu, określają zmianę wysokości terenu w jednostce odległości w kierunku największego nachylenia. Przykładowe mapy spadków, wygenerowane na podstawie danych ALS i UAV-ALS, przedstawiono na rys. 3.20.




Rys. 3.20. Mapy spadków opracowane dla Grodziska Chlebnia i Rokitno (źródło: opracowanie własne)

Innowacyjność proponowanego w publikacji **P4** rozwiązania polegała na automatyzacji ekstrakcji cech geomorfometrycznych grodzisk wczesnośredniowiecznych na podstawie danych LiDAR. Cechy te były wyznaczane dla uprzednio wykrytych grodzisk proponowanym algorytmem na podstawie danych ALS i UAV-ALS. Schemat proponowanego algorytmu detekcji grodzisk przedstawiono na rys. 3.21.




Rys. 3.21. Schemat detekcji grodzisk z danych LiDAR (źródło: opracowanie własne na podstawie [43])

Pierwszym etapem przetwarzania chmur punktów był proces ich filtracji, bazującej na algorytmie – *A simple morphological filter algorithm* (SMRF). Na podstawie warstwy gruntu, uzyskanej w wyniku filtracji SMRF, wykonano rasteryzację chmury punktów bazując na algorytmie binning. Schemat działania algorytmu przedstawiono na rys. 3.22.




Rys. 3.22. Schemat działania algorytmu binning (źródło: opracowanie własne na podstawie [43])

Algorytm dzieli chmurę punktów na regularną siatkę w płaszczyźnie XY o zadanej rozdzielczości wyznaczonej na podstawie gęstości pozyskanych danych (odpowiednio z danych ALS: 1.0 m, z danych UAV-ALS: 0.35 m). Wysokość dla każdego oczka siatki obliczana jest metodą średniej arytmetycznej (mean), uwzględniając wartości punktów mieszczących się w obrębie oczka. W przypadku braku punktów w danym oczku, wysokość interpolowana jest na podstawie średniej wartości wysokości sąsiednich pikseli. W celu wzmocnienia potencjału informacji o strukturach archeologicznych, opracowany NMT poddano wizualizacji z wykorzystaniem dostępnych metod (Hillshading, Slope gradient, Simple local relief model, Sky-View Factor, Openness Positive and Negative, Sky illumination, oraz Local dominance). Metody przetestowano w aplikacji RVT (Relief Visualization Toolbox). Wyniki wizualizacji dla trzech analizowanych grodzisk przedstawiono na rys. 3.23 (dla danych z ALS) oraz 3.24 (dla danych z UAV-ALS).



Rys. 3.23. Wizualizacja NMT wygenerowanego na podstawie danych ALS (źródło: opracowanie własne na podstawie [43])



Rys. 3.24. Wizualizacja NMT wygenerowanego na podstawie danych UAV-ALS (źródło: opracowanie własne na podstawie [43])

Na podstawie przeprowadzonych analiz (rys. 3.23, 3.24) do dalszych przetwarzań wybrano metodę wizualizacji NMT – Local dominance. W kolejnym etapie przeprowadzono proces binaryzacji metodą Sauvola. Próg binaryzacji (T) w tej metodzie wyznaczany był automatycznie na podstawie wartości średniej i odchylenia standardowego wartości pikseli w bloku bezpośredniego sąsiedztwa otaczającego analizowany piksel. Następnie, w zależności od typu danych (ALS, UAV-ALS), operacje morfologiczne przeprowadzono na obrazie w różnej kolejności. W przypadku wykorzystania danych ALS sekwencja operacji morfologicznych jest następująca:

- dylatacja;
- wypełnienie obiektów wewnątrz;
- erozja;
- usunięcie obiektów na krawędziach obrazu;
- usunięcie małych obiektów.

Z kolei w przypadku wykorzystania danych UAV-ALS sekwencja operacji morfologicznych jest następująca:

- dylatacja;
- usunięcie obiektów na krawędziach obrazu;
- otwarcie;
- usunięcie małych obiektów;
- wypełnienie obiektów wewnątrz.

Po przeprowadzeniu wybranych operacji morfologicznych na obrazie (rys. 3.21) wyznaczono wartości współczynnika kształtu (F_{shape}) na podstawie długości i szerokości wykrytego obiektu podpowierzchniowego ze wzoru 3.23.


$$F_{shape} = \frac{r_{min}}{R_{max}}, \quad (3.23)$$

gdzie:


r_{min} – szerokość wykrytego obiektu,

R_{max} – długość wykrytego obiektu.

Wartość parametru F_{shape} determinowała występowanie grodziska na analizowanym obszarze. Występowanie grodziska stwierdzono w przypadkach, gdy F_{shape} osiągnął wartość większą bądź równą 0.475. Uwzględnienie współczynnika kształtu pozwoliło na wyeliminowanie z detekcji obiektów o charakterze liniowym. Wyniki detekcji grodzisk z danych ALS i UAV-ALS przedstawiono odpowiednio na rys. 3.25 i 3.26.




Rys. 3.25. Wyniki detekcji grodzisk na podstawie danych ALS (źródło: opracowanie własne na podstawie [43])




Rys. 3.26. Wyniki detekcji grodzisk na podstawie danych UAV-ALS (źródło: opracowanie własne na podstawie [43])

Dla wykrytych obiektów (rys. 3.23 i 3.24) za pomocą cyfrowego przetwarzania obrazów z danych ALS i UAV-ALS wygenerowano profile terenowe. W obrębie wykrytego obiektu na podstawie wskazanych punktów linii bazowej zaproponowany algorytm generuje profile ortogonalne do profilu bazowego w odstępach 5 m. Schemat działania algorytmu generowania profili terenowych z NMT przedstawiono na rys. 3.27.




Rys. 3.27. Schemat generowania profili terenowych z NMT (źródło: opracowanie własne na podstawie [43])

Dodatkowo na wygenerowanych profilach algorytm wyznacza lokalne maksima wraz z częściowym wyeliminowaniem obserwacji odstających (ang. *outlier points*) spośród wszystkich lokalnych maksimów. Następnie algorytm wyznacza obszar (ang. *convex hull*) wykrytego obiektu (potencjalnego grodziska podpowierzchniowego) na podstawie wyselekcjonowanych lokalnych maksimów (ang. *correct points*). Istnienie grodziska na profilu terenowym można stwierdzić na podstawie występowania minimum trzech wierzchołków (reprezentujących wały grodziska) ponad wartość $1 - \sigma$ oraz w przypadku gdy $F_{shape} > 0.475$. Przykładowe profile terenowe przedstawiono na rys. 3.28.




Rys. 3.28. Schemat generowania profili terenowych z NMT (źródło: opracowanie własne na podstawie [43])

Na każdym profilu terenowym widoczne są wzniesienia reprezentujące wały grodziska. Na podstawie profilu terenowego można również określić typ grodziska: jedno- lub dwuczłonowe. W przypadku wykrycia obiektu, nie będącego grodziskiem, dodatkową weryfikacją może być wykorzystanie danych uzupełniających, takich jak ortofotomapa (rys. 3.27). W procesie detekcji wykryte zostały zbiorniki o okrągłym kształcie (rys. 3.29).



Rys. 3.29. Przykład detekcji obiektu niebędącego grodziskiem (źródło: opracowanie własne na podstawie [43])

Dla każdego wykrytego obiektu (algorytm rys. 3.21) wygenerowano profile terenowe na podstawie wskazanych linii bazowych, co przedstawiono na rys. 3.30. Wyznaczoną wartość warunku istnienia grodziska $1 - \sigma$ oznaczono na poniższych wykresach czerwoną przerywaną linią.



Rys. 3.30. Profile terenu wygenerowane dla wykrytych obiektów (źródło: opracowanie własne na podstawie [43])

Zaproponowane podejście pozwala określić lokalizację i geometrię wykrytych grodzisk podpowierzchniowych. Automatyczna detekcja obiektów oraz podwójna weryfikacja

(współczynnik kształtu, profil terenowy) istnienia grodziska są efektywniejszym podejściem niż manualne wykrywanie dawnych osad, szczególnie na obszarach pokrytych wysoką roślinnością. Na podstawie przeprowadzonych analiz można stwierdzić, że zarówno lotniczy skanowanie laserowe, jak i skanowanie wykonane z niskiego pułapu można zastosować do detekcji grodzisk i ekstrakcji ich cech geomorfometrycznych. Wykorzystanie danych LiDAR pokazało, że nawet na zalesionych obszarach wiązka lasera przenika przez pokrywę roślinną umożliwiając zarejestrowanie gruntu i struktur grodzisk. Publikacja **P4** jest odpowiedzią na **problem badawczy 1 i 4**. W ramach tej pracy zrealizowano postawione **zadania badawcze 6–8**.

Analizując cechy geomorfometryczne, wyznaczone na podstawie wykrytych obiektów z danych LiDAR, można również podjąć próbę sklasyfikowania typu wykrytego grodziska. Istnieje wiele podziałów na rodzaje grodzisk. Można je podzielić ze względu na: położenie topograficzne, istnienie lub domniemanie występowania grodziska oraz kształt i wielkość grodziska [44].

Uwzględniając analizowane cechy wykrytych grodzisk wczesnośredniowiecznych na podstawie uzyskanych wyników można podjąć próbę klasyfikacji wykrytych obiektów według ich kształtu i wielkości. Wśród nich wyróżnia się podział na grodziska jedno- i dwuczłonowe. Wśród grodzisk jednoczłonowych można wyodrębnić grodziska: pierścieniowate, podkowiaste oraz grodziska z wałem poprzecznym. W grupie grodzisk dwuczłonowych wyróżnia się grodziska pierścieniowate, podkowiaste oraz z dwoma wałami poprzecznymi [44]. Na rys. 3.31 przedstawiono klasyfikację grodzisk ze względu na ich kształt i powierzchnię.

		Typy grodzisk																				
		I. Jednoczłonowe						II. Dwuczłonowe												Niezrębelne	Ilość	%
		A.			B.	C.	A.						B.			C.						
		Pierścieniowate			Podkowiaste	Z wałem poprzecznym	Pierścieniowate						Podkowiaste			Z dwoma wałami poprzecznymi						
		1	2	3		1	2	1	2	3	4a	4b	1	2	3							
Grupy wielkościowe grodzisk	Powierzchnia w ha	0	0	0	U	-	=	⊙	⊖	⊗	⊗	⊗	⊗	⊗	⊗	⊗						
	I do 0,05																					
	II 0,05 - 0,25	•••	•••	•	•••	••	••									•••						
	III 0,25 - 0,5	•••	•••	••	•••	••	••						•	•		•••						
	IV 0,5 - 1,0	•••	•••	••	•••	••	••			•	••			•		•••						
	V 1,0 - 2,5	•	••		••		••		•	••			•	••	•	•						
	VI 2,5 - 4,5		•										•			•						
		Razem																	152	100		

Rys. 3.31. Relacje pomiędzy typami grodzisk a ich grupami wielkościowymi [44]

Uzyskane powierzchnie wykrytych grodzisk wyniosły: 1.3 - 1.4 ha (Grodzisko Chlebnia), 0.9 ha (Grodzisko Rokitno) oraz 0.7 ha (Grodzisko Chwaliszowice). Uzyskane wartości powierzchni i kształt wykrytych obiektów pozwalają sklasyfikować:

- Grodzisko Chlebnia – jako typ dwuczłonowy pierścieniowaty, grupa wielkościowa V;
- Grodzisko Rokitno – jako typ jednoczłonowy pierścieniowaty, grupa wielkościowa IV;
- Grodzisko Chwaliszowice – jako typ jednoczłonowy pierścieniowaty, grupa wielkościowa IV.

Podsumowując, należy wspomnieć również o ograniczeniach proponowanych rozwiązań. Jednym z nich był ograniczony zestaw danych reprezentujących osady podpowierzchniowe. Drugie ograniczenie dotyczy przeprowadzenia prac badawczych na określonym obszarze ograniczającym się do terenów występowania grodzisk wczesnośredniowiecznych typu słowiańskiego, charakteryzujących się unikalnymi cechami geomorfometrycznymi. Ostatnim dostrzeżonym ograniczeniem były fałszywie pozytywne obiekty wykryte na danych NMT, charakteryzujące się zbliżonym typem i kształtem do antropogenicznych grodzisk podpowierzchniowych. Pomimo wymienionych ograniczeń proponowane rozwiązanie umożliwia detekcję grodzisk oraz automatyczną ekstrakcję ich cech geomorfometrycznych.

PODSUMOWANIE I WNIOSKI

Niniejsza rozprawa doktorską pt. *Badanie cech geometrycznych i radiometrycznych podziemnych oraz podpowierzchniowych obiektów antropogenicznych pozyskanych technikami teledetekcyjnymi* stanowi cykl czterech powiązanych tematycznie artykułów naukowych. Celem pracy była ekstrakcja cech geometrycznych i radiometrycznych na danych obrazowych oraz wysokościowych w celu opracowania metod automatyzacji procesów detekcji i klasyfikacji obiektów antropogenicznych. Przedstawiona w pracy metodyka pozwoliła na automatyzację procesu detekcji, ekstrakcji i klasyfikacji podziemnych oraz podpowierzchniowych obiektów antropogenicznych z wybranych danych teledetekcyjnych.

W niniejszej rozprawie doktorskiej udowodniono postawioną tezę badawczą: zastosowanie opracowanych metod określania i automatycznej ekstrakcji cech geometrycznych oraz radiometrycznych podziemnych i podpowierzchniowych obiektów antropogenicznych na podstawie obrazowych i wysokościowych danych teledetekcyjnych umożliwi automatyzację procesu ich detekcji i klasyfikacji.

W ramach przeprowadzonych badań opracowano metodę detekcji i klasyfikacji typów podziemnych sieci uzbrojenia terenu na echogramach pozyskanych georadarem, co przedstawiono w publikacji **P1** i **P2**. W pracach tych rozwiązano postawione problemy badawcze dotyczące: określenia, usystematyzowania i ekstrakcji cech hiperbol właściwych oraz opracowania prototypu klasyfikatora typów infrastruktury podziemnej.

Istotnym zagadnieniem, w kontekście rozwoju technologicznego georadarów i ich możliwości, było opracowanie podejścia selekcji i oceny jakości danych charakteryzujących się dużą liczbą sygnałów użytkowych, co przedstawiono w publikacji **P3**. Zaproponowane w pracy podejście adaptacyjne pozwoliło ocenić wpływ jakości echogramów georadarowych (z wykorzystaniem wybranych niereferencyjnych wskaźników oceny jakości) na skuteczność automatycznej detekcji podziemnych sieci uzbrojenia terenu. Przeprowadzone analizy w publikacji **P3** doprowadziły do rozwiązania problemu badawczego dotyczącego braku istniejących analiz wpływu jakości danych na skuteczność ekstrakcji cech i procesów przetwarzania danych teledetekcyjnych.

W kolejnych badaniach nad ekstrakcją cech geomorfometrycznych obiektów podpowierzchniowych zaproponowano automatyczne wykrywanie grodzisk oraz wyznaczanie ich parametrów geometrycznych na danych obrazowych i wysokościowych. Przeprowadzone w publikacji **P4** analizy doprowadziły do rozwiązania postawionego problemów badawczych dotyczących doboru technik teledetekcyjnych do określonego typu obiektu antropogenicznego,

usystematyzowania cech niezbędnych do detekcji grodzisk oraz do opracowania sposobu automatycznej ekstrakcji ich cech geomorfometrycznych z danych LiDAR.

Wszystkie opracowane w ramach badań metody przyczyniły się do osiągnięcia celu głównego jakim była ekstrakcja cech geometrycznych i radiometrycznych na danych obrazowych i wysokościowych w celu opracowania metod automatyzacji procesów detekcji i klasyfikacji obiektów antropogenicznych.

Pomimo zalet opracowanych rozwiązań, związanych z automatyzacją procesu detekcji, klasyfikacji obiektów oraz ekstrakcji ich cech, należy omówić ich ograniczenia. Pierwszym z nich jest detekcja jedynie krawędzi hiperboli na echogramach georadarowych oraz duża liczba wykrytych obiektów fałszywie pozytywnych (**P1**). Kolejnym jest niewielki zbiór danych GPR uwzględniony w procesie klasyfikacji typów sieci uzbrojenia terenu (**P2**). Ograniczeniem proponowanego rozwiązania oceny wpływu jakości echogramów georadarowych na skuteczność detekcji hiperbol jest globalna ocena jakości obrazu, nieuwzględniająca lokalnych artefaktów (**P3**). W kontekście ekstrakcji obiektów podpowierzchniowych ograniczeniem proponowanego rozwiązania jest skupienie się jedynie na wczesnośredniowiecznych osadach podpowierzchniowych typu słowiańskiego, nie uwzględniając innych struktur rzeźby terenu (**P4**).

W świetle przeprowadzonych analiz i zaproponowanych rozwiązań przyszłe badania powinny koncentrować się na kilku kluczowych zagadnieniach, które będą miały na celu podniesienie skuteczności detekcji, ekstrakcji oraz klasyfikacji podziemnych oraz podpowierzchniowych obiektów pochodzenia antropogenicznego na danych teledetekcyjnych.

Jednym z podstawowych wyzwań pozostaje opracowanie bardziej efektywnych algorytmów filtracji echogramów georadarowych, co mogłoby znacząco zwiększyć skuteczność wykrywania hiperbol, a w konsekwencji klasyfikacji typów podziemnych sieci uzbrojenia terenu. Kolejnym istotnym aspektem jest zwiększenie liczebności zbioru danych teledetekcyjnych oraz rozszerzenie katalogu obiektów antropogenicznych. Algorytmy powinny zostać przetestowane w zróżnicowanym środowisku glebowym i w zmiennych warunkach geologicznych. Takie badania mogą pozwolić na opracowanie niezawodnego algorytmu zwiększającego uniwersalność i dokładność proponowanego rozwiązania.

W kontekście badań związanych z wykrywaniem i analizą kształtu grodzisk planowane jest zwiększenie zbioru danych o dawnych osadach uwzględniając zarówno zidentyfikowane jak i niezidentyfikowane obiekty występujące na terenach porośniętych niską, średnią i wysoką roślinnością. Planowane jest również rozszerzenie zbioru danych o inne typy obiektów. Integracja danych LiDAR z innym rodzajem danych mogłaby umożliwić przeprowadzenie

kompleksowej analizy przestrzennej oraz zwiększyć dokładność identyfikacji obiektów podpowierzchniowych.

Wyzwaniem pozostaje również kwestia rozwoju metod oceny jakości echogramów. Planowane w przyszłych pracach podejście, wykorzystania wskaźników sektorowych oceny jakości obrazów GPR, mogłoby przewyżżyć ograniczenia globalnych metod oceny jakości i umożliwić lokalną ocenę jakości w obrębie poszczególnych blokach obrazów.

Przyszłe badania, koncentrujące się na powyższych zagadnieniach, mogą umożliwić istotny postęp w zakresie wykrywania, ekstrakcji i klasyfikacji podziemnych oraz podpowierzchniowych obiektów pochodzenia antropogenicznego z wykorzystaniem technik teledetekcyjnych.

ZAŁĄCZNIKI

Artykuły stanowiące cykl publikacji wraz z oświadczeniami współautorów o procentowym udziale w poszczególnych publikacji:

1. **Onyszko K. (80%)**, Fryškowska-Skibniewska A. (20%), 2021, A new methodology for the detection and extraction of hyperbolas in GPR images. *Remote Sensing*, 13(23): 4892. DOI: 10.3390/rs13234892
2. **Pasternak K. (80%)**, Fryškowska-Skibniewska A. (20%), 2024, Automatic classification of underground utilities in Urban Areas: A novel method combining ground penetrating radar and image processing, *Archives of Civil Engineering*, 70(2). DOI: 10.24425/ace.2024.149851
3. **Pasternak K. (70%)**, Fryškowska-Skibniewska A. (20%), Ortyl Ł. (10%), 2025, An Adaptive Non-Reference Approach for Characterizing and Assessing Image Quality in Multichannel GPR for Automatic Hyperbola Detection, *Applied Sciences*, DOI: 10.3390/app15095126
4. **Pasternak K. (80%)**, Fryškowska-Skibniewska A. (20%), 2025, Automated analysis of Slavic buried settlements based on LiDAR point cloud, UAV and image processing. *Journal of Cultural Heritage*, 70. DOI: 10.1016/j.culher.2025.04.009

LITERATURA

1. Cisko-Lesicka, U.; Wężyk, P. Wprowadzenie do danych satelitarnych. *Dane satelitarne dla administracji publicznej* **2021**.
2. Fussell, J.; Rundquist, D. On Defining Remote Sensing. *Photogrammetric Engineering* **1986**.
3. Ustawa z Dnia 7 Lipca 1994 r. - Prawo Budowlane. Available online: <https://isap.sejm.gov.pl/> (accessed on 16 June 2025).
4. Ustawa z Dnia 17 Maja 1989 r. Prawo Geodezyjne i Kartograficzne. Available online: <https://isap.sejm.gov.pl/> (accessed on 27 May 2025).
5. Łabuz, A.; Borowiec, N.; Marmol, U. Automatic Detection of Lusatian Culture Fortified Settlement Based on Data from Airborne Laser Scanning. *Int J Conserv Sci* **2023**, *14*, 83–98, doi:10.36868/IJCS.2023.01.07.
6. Niculiță, M. Geomorphometric Methods for Burial Mound Recognition and Extraction from High-Resolution LiDAR DEMs. *Sensors* **2020**, *20*, 1192, doi:10.3390/s20041192.
7. Kim, N.; Kim, S.; An, Y.-K.; Lee, J.-J. A Novel 3D GPR Image Arrangement for Deep Learning-Based Underground Object Classification. *International Journal of Pavement Engineering* **2021**, *22*, 740–751, doi:10.1080/10298436.2019.1645846.
8. Kim, N.; Kim, S.; An, Y.-K.; Lee, J.-J. Triplanar Imaging of 3-D GPR Data for Deep-Learning-Based Underground Object Detection. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* **2019**, *12*, 4446–4456, doi:10.1109/JSTARS.2019.2953505.
9. Kang, M.-S.; Kim, N.; Im, S.B.; Lee, J.-J.; An, Y.-K. 3D GPR Image-Based UcnNet for Enhancing Underground Cavity Detectability. *Remote Sensing* **2019**, *11*, 2545, doi:10.3390/rs11212545.
10. Birkenfeld, S. Automatic Detection of Reflexion Hyperbolas in Gpr Data with Neural Networks. In Proceedings of the 2010 World Automation Congress; September 2010; pp. 1–6.
11. Liu, H.; Lin, C.; Cui, J.; Fan, L.; Xie, X.; Spencer, B.F. Detection and Localization of Rebar in Concrete by Deep Learning Using Ground Penetrating Radar. *Automation in Construction* **2020**, *118*, 103279, doi:10.1016/j.autcon.2020.103279.
12. Lei, W.; Hou, F.; Xi, J.; Tan, Q.; Xu, M.; Jiang, X.; Liu, G.; Gu, Q. Automatic Hyperbola Detection and Fitting in GPR B-Scan Image. *Automation in Construction* **2019**, *106*, 102839, doi:10.1016/j.autcon.2019.102839.

13. Al-Nuaimy, W.; Huang, Y.; Eriksen, A.; Nguyen, V.T. Automatic Detection of Hyperbolic Signatures in Ground-Penetrating Radar Data. In *Proceedings of the Subsurface and Surface Sensing Technologies and Applications III*; SPIE, November 27 2001; Vol. 4491, pp. 327–335.
14. Metody ekstrakcji cech w uczeniu maszynowym. Nowe trendy inżynierii cech Available online: <https://libra.ibuk.pl/reader/metody-ekstrakcji-cech-w-uczeniu-maszynowym-nowe-trendy-inzynierii-mariusz-topolski-304218> (accessed on 16 June 2025).
15. Khan, U.S.; Al-Nuaimy, W.; Abd El-Samie, F.E. Detection of Landmines and Underground Utilities from Acoustic and GPR Images with a Cepstral Approach. *Journal of Visual Communication and Image Representation* **2010**, *21*, 731–740, doi:10.1016/j.jvcir.2010.05.007.
16. Tzanis, A. Detection and Extraction of Orientation-and-Scale-Dependent Information from Two-Dimensional GPR Data with Tuneable Directional Wavelet Filters. *Journal of Applied Geophysics* **2013**, *89*, 48–67, doi:10.1016/j.jappgeo.2012.11.007.
17. Liu, Y.; Fang, C.; Ji, X.; Zhao, B.; Chen, D. Gabor Filter Banks Used for Crevasse Detection with Ground-Penetrating Radar Data. In *18th International Conference on Ground Penetrating Radar, Golden, Colorado, 14–19 June 2020*; SEG Global Meeting Abstracts; Society of Exploration Geophysicists, 2020; pp. 372–375.
18. Mertens, L.; Persico, R.; Matera, L.; Lambot, S. Automated Detection of Reflection Hyperbolas in Complex GPR Images With No A Priori Knowledge on the Medium. *IEEE Transactions on Geoscience and Remote Sensing* **2016**, *54*, 580–596, doi:10.1109/TGRS.2015.2462727.
19. Hou, F.; Lei, W.; Li, S.; Xi, J. Deep Learning-Based Subsurface Target Detection From GPR Scans. *IEEE Sensors Journal* **2021**, *21*, 8161–8171, doi:10.1109/JSEN.2021.3050262.
20. Ko, H.-Y.; Kim, N. Performance Analysis of Detecting buried pipelines in GPR images using Faster R-CNN. *Journal of Convergence for Information Technology* **2019**, *9*, 21–26, doi:10.22156/CS4SMB.2019.9.5.021.
21. Sobiech, M. Grodziska Ziemi Chełmińskiego-Dobrzyńskiej w Świetle Analiz Geoprzestrzennych. *Roczniki Geomatyki - Annals of Geomatics* **2013**, *11*, 81–92.
22. Korup, O. Geomorphometric Characteristics of New Zealand Landslide Dams. *Engineering Geology* **2004**, *73*, 13–35, doi:10.1016/j.enggeo.2003.11.003.

23. Passalacqua, P.; Belmont, P.; Foufoula-Georgiou, E. Automatic Geomorphic Feature Extraction from Lidar in Flat and Engineered Landscapes. *Water Resources Research* **2012**, *48*, doi:10.1029/2011WR010958.
24. Landauer, J.; Maddison, S.; Fontana, G.; Posluschny, A.G. Archaeological Site Detection: Latest Results from a Deep Learning Based Europe Wide Hillfort Search. *Journal of Computer Applications in Archaeology* **2025**, *8*, doi:10.5334/jcaa.178.
25. Landauer, J.; Vaart, W.V. der Find'em All: Large-Scale Automation to Detect Complex Archaeological Objects With Deep Learning -A Case Study on English Hillforts. *CAA 2021 – "Digital Crossroads"* **2021**.
26. Ma, Y.; Jong, Y.; Liu, Y. A New De-Noising Method for Ground Penetrating Radar Signal. *J. Phys.: Conf. Ser.* **2021**, *1802*, 022002, doi:10.1088/1742-6596/1802/2/022002.
27. Javadi, M.; Ghasemzadeh, H. Wavelet Analysis for Ground Penetrating Radar Applications: A Case Study. *Journal of Geophysics and Engineering* **2017**, *14*, 1189–1202, doi:10.1088/1742-2140/aa7303.
28. Onyszko, K.; Fryškowska-Skibniewska, A. A New Methodology for the Detection and Extraction of Hyperbolas in GPR Images. *Remote Sensing* **2021**, *13*, 4892, doi:10.3390/rs13234892.
29. Cheng, W.; Hirakawa, K. Minimum Risk Wavelet Shrinkage Operator for Poisson Image Denoising. *IEEE Transactions on Image Processing* **2015**, *24*, 1660–1671, doi:10.1109/TIP.2015.2409566.
30. Ma, Y.; Jong, Y.; Liu, Y. A New De-Noising Method for Ground Penetrating Radar Signal. *J. Phys.: Conf. Ser.* **2021**, *1802*, 022002, doi:10.1088/1742-6596/1802/2/022002.
31. Butnor, J.R.; Doolittle, J.A.; Kress, L.; Cohen, S.; Johnsen, K.H. Use of Ground-Penetrating Radar to Study Tree Roots in the Southeastern United States. *Tree Physiology* **2001**, *21*, 1269–1278, doi:10.1093/treephys/21.17.1269.
32. Marmol, U.; Lenda, G. Filtry teksturalne w procesie automatycznej klasyfikacji obiektów. *Archiwum Fotogrametrii, Kartografii i Teledetekcji* **2010**, *Vol. 21*.
33. Sezgin, M.; Nazlı, H.; Özkan, E.; Çelik, E. A False Alarm Reduction Method for GPR Sensor Moving at Varying Heights. In Proceedings of the Detection and Sensing of Mines, Explosive Objects, and Obscured Targets XXV; SPIE, April 29 2020; Vol. 11418, pp. 43–54.
34. Pasternak, K.; Fryškowska-Skibniewska, A. Automatic Classification of Underground Utilities in Urban Areas: A Novel Method Combining Ground Penetrating Radar and Image Processing. *Archives of Civil Engineering* **2024**, *70*.

35. Pasternak, K.; Fryskowska-Skibniewska, A. *Analysis of the Possibility of Classification the Types of Utilities Networks on the GPR Images*; 2022;
36. Pan, G. *A Tutorial of Wavelet for Pattern Recognition*.; 2011.
37. Hou, F.; Rui, X.; Fan, X.; Zhang, H. Review of GPR Activities in Civil Infrastructures: Data Analysis and Applications. *Remote Sensing* **2022**, *14*, 5972, doi:10.3390/rs14235972.
38. Yuan, C.; Li, S.; Cai, H.; Kamat, V.R. GPR Signature Detection and Decomposition for Mapping Buried Utilities with Complex Spatial Configuration. *Journal of Computing in Civil Engineering* **2018**, *32*, 04018026, doi:10.1061/(ASCE)CP.1943-5487.0000764.
39. Pasternak, K.; Fryśkowska-Skibniewska, A.; Ortyl, Ł. An Adaptive Non-Reference Approach for Characterizing and Assessing Image Quality in Multichannel GPR for Automatic Hyperbola Detection. *Applied Sciences* **2025**, *15*, 5126.
40. Weryfikacja terenowa przynależności kulturowej domniemanego grodziska na wzniesieniu Grodzisko w Jaworznie | Muzeum Miasta Jaworzna 2021.
41. Instytut Archeologii i Etnologii PAN Atlas Grodzisk Wczesnośredniowiecznych z Obszaru Polski Available online: <http://atlasgrodzisk.pl/mapa.html> (accessed on 27 May 2025).
42. Najwer, A.; Zwoliński, Z. Semantyka i metodyka oceny georóżnorodności – przegląd i propozycja badawcza. *Landform Analysis* **2014**, *26*, 115–127, doi:10.12657/landfana.026.011.
43. Pasternak, K.; Fryśkowska-Skibniewska, A. Automated Analysis of Slavic Buried Settlements Based on LiDAR Point Cloud, UAV and Image Processing. *Journal of Cultural Heritage* **2025**, *73*, 305–316.
44. Olczak, J.; Siucgniński, K. Typologia Wczesnośredniowiecznych Grodzisk Pomorza Środkowego. **1976**, *23*.