

Politechnika Warszawska

WYDZIAŁ GEODEZJI I KARTOGRAFII



Zakład Fotogrametrii, Teledetekcji i Systemów Informacji Przestrzennej

Praca dyplomowa inżynierska

na kierunku Geodezja i Kartografia

Analiza rozwoju aglomeracji wrocławskiej w latach 1999-2018
na podstawie zdjęć satelitarnych

Analysis of Wrocław agglomeration development in 1999-2018
based on satellite imagery

numer pracy według wydziałowej ewidencji prac

Katarzyna Lesisz

Numer albumu 274514

promotor

dr hab. inż. Przemysław Kupidura

WARSZAWA 2019

Streszczenie

W niniejszej pracy zbadano kierunek i natężenie rozwoju Wrocławia wraz z okolicznymi miejscowościami w latach 1999 – 2018 poprzez analizę zmian pokrycia i użytkowania terenu. Do tego celu wykorzystano zdjęcia satelitarne systemu Landsat generacji 5, 7 i 8 - wielospektralne o pikselu o rozmiarze 30 m oraz panchromatyczne o pikselu o rozmiarze 15 m. Zakres pracy obejmował wykonanie klasyfikacji spektralnej i spektralno-teksturowej obrazów, w celu określenia pokrycia i użytkowania terenu aglomeracji wrocławskiej w cztero- i pięcioletnich odstępach czasowych, oraz zestawienie i ocenę wyników obu procesów. Klasyfikację spektralno-teksturową przeprowadzono z wykorzystaniem map granulometrycznych. Ostatecznie porównano sklasyfikowane obrazy, określając stopień i rodzaj zmian zasięgu obszarów zabudowanych, jakie zaszły na badanym terenie.

Słowa kluczowe: teledetekcja, klasyfikacja, pokrycie terenu, zabudowa, Landsat

Abstract

In this project, the direction and intensity of Wrocław's and the surrounding areas' development in the years 1999 - 2018 were examined by analyzing changes in land cover and land use. For this purpose, satellite images of the Landsat 5, 7 and 8 were used - multi-spectral images with a pixel size of 30 m and panchromatic images with a pixel size of 15 m. The scope of project included the spectral and spectral-textural classification of images, in order to define land cover and land use of Wrocław agglomeration in four and five year intervals and a summary and evaluation of the results of both processes. A spectro-textural classification was performed using granulometric maps. In the end the classified images were compared, specifying a degree and type of changes in reach of built-up areas that occurred in the studied area.

Key words: remote sensing, classification, land cover, development, Landsat

Spis treści

Streszczenie	2
Abstract	3
Wstęp	5
1. Wykorzystanie teledetekcji do analiz pokrycia terenu.....	6
1.1. Podstawy teledetekcji	6
1.2. Przykłady zastosowań teledetekcji w analizach pokrycia terenu.....	6
2. Charakterystyka systemów satelitarnych Landsat	9
2.1. Misja Landsat	9
3. Podstawy teoretyczne klasyfikacji.....	11
3.1. Rodzaje klasyfikacji ze względu na proces uczenia maszynowego.....	11
3.2. Rodzaje klasyfikacji ze względu na wykorzystane cechy obrazu	12
4. Metodyka pracy.....	14
4.1. Ogólna charakterystyka aglomeracji wrocławskiej	14
4.2. Charakterystyka danych źródłowych.....	15
4.3. Wykorzystane oprogramowanie	18
4.4. Metodyka analizy rozwoju aglomeracji wrocławskiej.....	18
4.4.1. Klasyfikacja spektralna.....	20
4.4.2. Klasyfikacja spektralno-teksturowa.....	21
4.4.3. Ocena dokładności i analiza zmian pokrycia i użytkowania terenu	22
5. Przebieg opracowania i wyniki	23
5.1. Przygotowanie danych	23
5.2. Klasyfikacja spektralna	24
5.3. Klasyfikacja spektralno-teksturowa.....	31
5.4. Zestawienie wyników klasyfikacji	35
6. Analiza otrzymanych wyników	39
7. Podsumowanie i wnioski	42
8. Bibliografia.....	43
Wykaz symboli i skrótów	44
Symbole	44
Skróty	44
Spis rysunków	45
Spis tabel	47
Spis załączników	48
Załączniki	49

Wstęp

Skutki transformacji ustrojowej w Polsce w latach 90-tych XX wieku oraz zmianami gospodarczymi z nią związanymi można było zauważyć nie tylko w ekonomicznych czy politycznych dziedzinach życia, lecz także w przestrzeni miejskiej. W ustroju komunistycznym miasta stanowiły główne ośrodki przemysłowe i przyciągały znaczne liczby ludności robotniczej, poszukującej pracy. Skupienie całej uwagi na przemyśle oraz silny związek władz miast z władzami centralnymi kraju doprowadziły do zaniedbania pozostałych sfer życia miejskiego, zaczynając od nieracjonalnego gospodarowania ziemią, a kończąc na aspektach ekologicznych. Pomimo znacznego przyrostu ludności w tamtym czasie, rozwój miast był związany jedynie ze wzrostem liczby ludności i powiększaniem się terenów mieszkalnych. Po zmianie ustroju tempo wzrostu liczby ludności miejskiej znacznie zwolniło, mimo ciągłej migracji ze wsi do miast. Było to spowodowane spadkiem przyrostu naturalnego. W efekcie tempo urbanizacji miast zmalało, a obszary wiejskie ulegają wyludnieniu (Węclawowicz, Łotocka, Baucz, 2010). Powrót gospodarki rynkowej wpłynął na zmianę charakteru urbanizacji w miastach, które stały się centrum usługowym i inwestycyjnym. Zmieniono funkcje wielu terenów miejskich, zintensyfikowano użytkowanie ziem, które powracały do swoich właścicieli, a ośrodki przemysłowe stopniowo przenoszono na tereny podmiejskie. Poprzez większą konkurencyjność pod względem inwestycyjnym miast zachodniej Polski, proces urbanizacji na tych terenach polegał przede wszystkim na suburbanizacji wraz z rozwojem średnich miejscowości i migracją pomiędzy miastami.

W badaniach nad rozwojem miast, zwłaszcza pod względem przestrzennym, dużą rolę odgrywają metody teledetekcyjne. Na podstawie danych satelitarnych analizują zmiany zachodzące w pokryciu terenu i użytkowaniu gruntów zarówno w miastach, jak i terenach wokół nich. Informacje uzyskane w ten sposób tworzą podkład i ilustrację do badań oraz pomagają lepiej zrozumieć zachodzące procesy.

Celem prezentowanego opracowania było ukazanie i analiza trendów zmian, jakie nastąpiły w sposobie użytkowania terenu aglomeracji wrocławskiej w przeciągu ostatnich 20 lat, zwracając szczególną uwagę na rozwój obszarów zabudowanych. Analizy wykonano na podstawie teledetekcyjnych danych obrazowych pozyskanych przez system satelitarny Landsat przy wykorzystaniu klasyfikacji spektralnej i spektralno-teksturowej.

1. Wykorzystanie teledetekcji do analiz pokrycia terenu

1.1. Podstawy teledetekcji

Teledetekcja oznacza zdalne pozyskanie danych obrazowych oraz przetwarzanie tych danych w informacje o obiektach i zjawiskach, zachodzących na powierzchni ziemi (Mularz, 2004). Obejmuje to również dane pozyskiwane za pomocą satelitów. Metody otrzymywania danych satelitarnych polegają przede wszystkim na wykorzystaniu promieniowania elektromagnetycznego, które, odbijając się od powierzchni ziemi, zostaje zarejestrowane przez specjalne detektory, znajdujące się na satelitach. Podstawowym źródłem promieniowania elektromagnetycznego jest Słońce, które emituje energię we wszystkich zakresach fal elektromagnetycznych. Ze względu na występowanie atmosfery ziemskiej, nie wszystkie długości fal docierają do powierzchni ziemi. Z tego powodu w teledetekcji wykorzystuje się tylko te zakresy, które bez przeszkód przechodzą przez atmosferę, tzw. okna atmosferyczne. Do tych fal zaliczamy: światło widzialne, krótkofalowe promieniowanie podczerwone, promieniowanie termalnej podczerwieni oraz mikrofałe (Ciołkosz, 2005). Obiekt znajdujący się na powierzchni ziemi w różny sposób reaguje na promieniowanie elektromagnetyczne. Może je transmitować, absorbować, rozpraszać lub też odbijać. Może także sam emitować niektóre zakresy promieniowania. Każdy obiekt, ze względu na swoje charakterystyczne właściwości fizyczne, w różnym stopniu odpowiada na różne zakresy promieniowania. Skutkuje to odmiennym dla każdego rodzaju obiektu natężeniem odbieranego przez detektory promieniowania, co przekłada się na różne odcienie i barwy na danych obrazowych. Dzięki temu, analizując zdjęcie, można rozróżnić między sobą poszczególne rodzaje pokrycia terenu.

Dane pozyskane przez satelity znalazły wszechstronne zastosowanie w wielu dziedzinach nauki, takich jak geologia, meteorologia czy rolnictwo. Na ich podstawie bada się także wody w morzach i oceanach, lodowce i lądolody, kondycję drzewostanów. Informacje z danych teledetekcyjnych wspomagają działania ratunkowe i zabezpieczające na obszarach zagrożonych katastrofami naturalnymi. Wykorzystuje się je również do tworzenia baz danych pokrycia terenu i kartowania map, użytecznych do dalszych analiz zmian użytkowania ziemi oraz badania ich wpływu na środowisko.

1.2. Przykłady zastosowań teledetekcji w analizach pokrycia terenu

Określenie pokrycia terenu, oznaczające cechy fizyczne środowiska, oraz użytkowanie ziemi, odnoszące się do przeznaczenia i funkcji, jaką dany obszar pełni (np. tereny rekreacyjne, rolnicze itd.), są ściśle ze sobą powiązane, pomimo swoich różnic. Dane teledetekcyjne dostarczają bezpośrednich informacji jedynie o pokryciu terenu, natomiast obszary użytkowania gruntów określa się dopiero podczas analiz tego pokrycia (www.nrcan.gc.ca/node/9373).

Zmiany w pokryciu terenu oraz w użytkowaniu gruntów są, obok klimatu, jednym z ważniejszych czynników zmieniających środowisko, a zmiany środowiska, zarówno lokalne jak i globalne, coraz częściej interesują nie tylko naukowców, lecz także instytucje rządowe. Aby przewidzieć przyszłe zmiany w otoczeniu, wykorzystują oni dane o środowisku biofizycznym oraz badają procesy naturalne i antropogeniczne, wpływające na zmiany środowiska (Ciołkosz, 2005). Z tego powodu analiza pokrycia terenu jest obecnie najpowszechniejszym zastosowaniem teledetekcji.

Jednym z większych projektów, w których uczestniczy Polska, mających na celu pozyskanie i przetworzenie danych o pokryciu terenu, jest projekt CORINE Land Cover przygotowany przez Unię Europejską. Od 1990 roku, w cyklach co 6-10 lat, zbierane są i dostarczane aktualne dane o pokryciu i użytkowaniu terenu Europy, w tym także Polski, oraz, jako wyniki analiz, prezentowane są zmiany, jakie zaszły pomiędzy cyklami. Początkowo do pozyskania zdjęć wykorzystano amerykański system satelitarny Landsat. W kolejnych edycjach projektu dołączono także inne systemy. Dane do aktualnego projektu pozyskały satelity systemu Landsat oraz Sentinel. W ramach programu na najniższym poziomie szczegółowości wyodrębniono 44 klasy pokrycia terenu, z czego występujących w Polsce jest 31. Minimalna powierzchnia wyróżnionego obszaru to 25 ha, przy czym najmniejsza możliwa szerokość wynosi 100 m, co w przypadku niektórych rejonów Polski, charakteryzujących się dużym rozdrobnieniem użytkowania terenu, nie wystarcza do szczegółowego przedstawienia sytuacji przestrzennej (Jucha, Kroczak). Dlatego Polska wraz z kilkoma innymi państwami, w ramach programu PHARE, uzupełniła bazę danych o czwarty poziom szczegółowości, odpowiadający mapom o skali 1:50000. Niewątpliwym atutem projektu CORINE Land Cover są uniwersalne kryteria podziału na klasy, jednolite dla całej Europy (Jucha, Kroczak). Najnowsze statystyki tego programu, dotyczące pokrycia i użytkowania terenu w Polsce, wskazują, że wciąż jest ona państwem typowo rolniczym (<http://clc.gios.gov.pl/index.php/clc-2018/statystyki>). Tereny rolne stanowią niemal 60% powierzchni kraju, podczas gdy lasy - 33%, tereny antropogeniczne około 6%, natomiast pozostałą część powierzchni zajmują wody i obszary podmokłe. Jednak w ciągu ostatnich 15 lat liczba gruntów użytkowanych rolniczo zmniejszyła się o ponad 6,5% na rzecz lasów i terenów antropogenicznych (oba wzrosły o 3 punkty procentowe, co w przypadku obszarów zabudowanych odpowiada dwukrotnemu wzrostowi wartości) (Ciółkosz, 2005). Można zatem stwierdzić, że w skali kraju tereny antropogeniczne, których znaczącą większość stanowi zabudowa miejska, silnie się rozwijają.

Jednym z projektów wykorzystującym bazę danych CORINE Land Cover był projekt o nazwie MOLAND mający na celu monitorowanie procesów towarzyszących rozwojowi miast i analizowanie kierunków tych rozwojów w skali regionalnej i lokalnej (Drzewiecki, 2008). Projekt był realizowany przez Centrum badań Wspólnotowych UE na zlecenie i pod opieką Komisji Europejskiej, jako kontynuacja wcześniejszego projektu MURBANDY. Składał się z trzech głównych części, których produktami finalnymi było: utworzenie baz danych użytkowania gruntów i sieci transportowych dla wybranych obszarów, wyznaczenie wskaźników rozwoju obszarów miejskich przy uwzględnieniu procesów socjo-ekonomicznych i zmian regulacji prawnych oraz utworzenie modeli, pozwalających sprawdzić skutki różnych wariantów zmian w użytkowaniu gruntów (Borsa, Zagajewski, Kulawik, 2017). Klasyfikacje użytkowania gruntów wykonano w oparciu o rozszerzoną klasyfikację bazy danych CORINE Land Cover, która składała się z trzech poziomów szczegółowości, z czego najniższy poziom obejmował 99 klas. Projekt obejmował wykonanie analiz dla 4 okresów: lat 50-tych, 60-tych, 80-tych i 90-tych. Dodanie do projektu danych archiwalnych, zachowujących jednolite kryteria klasyfikacyjne, poszerzyło możliwości wykonywania analiz i polepszyło prognozy przyszłych zmian.

Względnie nową inicjatywą służącą badaniu zmian w pokryciu i użytkowaniu terenu jest projekt Copernicus zapoczątkowany w latach 90-tych przez Unię Europejską i Europejską Agencją Kosmiczną, noszący do 2012 roku nazwę GMES (Global Monitoring for Environment and Security). Przy tworzeniu programu wykorzystano doświadczenie zebrane z prowadzenia projektu MOLAND. Głównym celem projektu Copernicus jest opracowanie metod zdalnego monitorowania stanu środowiska, na podstawie danych satelitarnych systemu Sentinel i danych z pomiarów in-situ (www.geoserwis.pl). Produktem projektu są serwisy informacyjne prezentujące informacje uzyskane poprzez analizę

danych obrazowych z uwzględnieniem danych statystycznych i ekonomicznych. Podzielono je na kilka kategorii tematycznych: monitorowanie atmosfery, monitorowanie środowiska morskiego, monitorowanie obszarów lądowych, zmiana klimatu, zarządzanie kryzysowe oraz bezpieczeństwo. Serwisy mają być powszechnie dostępne i mają pomóc w zarządzaniu zasobami środowiska oraz usprawnić działania w sytuacjach kryzysowych. Z tego powodu projekt stanowi wsparcie dla wprowadzania polityki zrównoważonego rozwoju.


2. Charakterystyka systemów satelitarnych Landsat

W powszechnym rozumieniu teledetekcja jest ściśle związana z satelitami, jednak w ogólnej definicji oznacza pozyskiwanie danych bez fizycznego kontaktu z obiektem (Mularz, 2004). Można zatem powiedzieć, że początki teledetekcji sięgają połowy XIX wieku, gdy wykonano pierwsze zdjęcia powierzchni ziemi podczas lotu balonem. Później następowały kolejne, pojedyncze próby fotografowania terenu z powietrza, wykorzystując latawce lub gołębie pocztowe, jednak faktyczny rozwój dziedziny nastąpił w okresie I wojny światowej, gdy zaczęto wykorzystywać na szeroką skalę zdjęcia robione z pokładów samolotów. Zdjęcia lotnicze pokazały nowe możliwości pozyskiwania danych o środowisku, niemożliwych do otrzymania znanymi dotychczas metodami.

Za symboliczną datę powstania teledetekcji satelitarnej przyjmuje się rok 1960, gdy ZSRR zestrzeliło amerykański samolot rozpoznawczy, co spowodowało, że Stany Zjednoczone zaczęły szukać innych sposobów na pozyskanie danych o podejmowanych działaniach na terenie wroga. Wówczas USA zaczęło wyposażać satelity w kamery fotograficzne (Gabinecka, 2017). Wyprowadzenie na orbitę satelitów teledetekcyjnych zintensyfikowało i poszerzyło rozwój teledetekcji, a kolejne, coraz dokładniejsze systemy satelitarne doprowadziły do stanu, który znamy obecnie – dokładnej, aktualnej i powszechnie dostępnej informacji o powierzchni ziemi.

2.1. Misja Landsat

Przełomem w teledetekcji było wystrzelenie na orbitę satelity systemu Landsat, utworzonego przez NASA i ministerstwo Spraw Wewnętrznych USA. W pierwszej, roboczej fazie swojego istnienia nosił nazwę ERTS (Earth Resources Technology Satellite). Gdy misja zakończyła się sukcesem, w 1972 roku wypuszczono kolejnego satelitę, nadając mu nową nazwę - Landsat, mającą oznaczać, że jest przeznaczony do badania lądów. Od tamtej pory satelity Landsat nieustannie zbierają spektralne dane o powierzchni ziemi. Do chwili obecnej wypuszczono 8 generacji satelitów, z których wciąż aktywne są satelity generacji 7 i 8. W przygotowaniu jest kolejny sputnik, Landsat 9, którego wystrzelenie na orbitę planowane jest na rok 2020/2021. W Tabeli 1 zaprezentowano szczegółową charakterystykę systemów, natomiast Rysunek 1 pokazuje zestawienie kanałów spektralnych dla poszczególnych sensorów satelitów w odniesieniu do zakresów promieniowania elektromagnetycznego.



Rysunek 1. Wizualne porównanie kanałów spektralnych systemu Landsat (źródło: <http://landsat.gsfc.nasa.gov/about/technical-information>)

Tabela 1. Charakterystyka poszczególnych generacji satelitów Landsat (<https://www.usgs.gov/land-resources/nli/landsat>)

Generacja satelity	Lata działalności	Sensory	Wysokość orbity	Rozmiar sceny	Rozmiar piksela		
					Panchromatyczne	Spektralne	Termalne
Landsat 1	1972-1978	RBV MSS	900 km	170 km x 185 km	-	80 m	-
Landsat 2	1975-1982	RBV MSS	900 km	170 km x 185 km	-	80 m	-
Landsat 3	1978-1983	RBV MSS	900 km	170 km x 185 km	-	80 m	-
Landsat 4	1982-1993	TM MSS	705 km	185 km x 185 km	-	30 m	120 m
Landsat 5	1984-2013	TM MSS	705 km	185 km x 185 km	-	30 m	120 m
Landsat 6	1993	ETM	nie osiągnął orbity	-	-	-	-
Landsat 7	od 1999	ETM+	705 km	185 km x 185 km	15 m	30 m	60 m
Landsat 8	od 2013	OLI TIRS	705 km	170 km x 185 km	15 m	30 m	100 m

Rozdzielczość przestrzenną obecnych satelitów Landsat można określić jako mierną, lecz odpowiednio dostosowaną do celów misji. Dzięki niej można opracowywać obszary o zasięgu globalnym, a jednocześnie jest wystarczająco szczegółowa, by badać lokalne zmiany w terenie, takie jak na przykład rozwój zabudowy.

3. Podstawy teoretyczne klasyfikacji

Automatyzacja przetwarzania danych teledetekcyjnych w użyteczne informacje wymaga wykonywania na obrazie operacji, pozwalających zdefiniować i uporządkować cechy, które dany obraz zawiera. Podstawową operacją, którą wykonuje się przy analizach pokrycia i użytkowania terenu, jest klasyfikacja. W ogólnym rozumieniu pojęcie to oznacza podział osób, rzeczy lub zjawisk na poszczególne grupy według określonej zasady (internetowy Słownik Języka Polskiego). Rozważając to pojęcie w kontekście teledetekcji, można je uszczegółowić i uznać, że klasyfikacja jest podziałem obrazu cyfrowego na wybrane klasy, poprzez cyfrowe przetworzenie tego obrazu w sposób automatyczny lub półautomatyczny. Klasyfikacji podlegają piksele obrazu, które zostają przypisane do odpowiednich klas, na podstawie swoich indywidualnych cech.

3.1. Rodzaje klasyfikacji ze względu na proces uczenia maszynowego

Wyróżnia się dwa podstawowe rodzaje klasyfikacji podzielone ze względu na sposób uczenia maszynowego. Pierwszym z nich jest klasyfikacja nadzorowana, budująca model podziału na klasy na podstawie wzorcowych danych przygotowanych przez operatora. Drugim, rzadziej stosowanym rodzajem klasyfikacji, jest klasyfikacja nienadzorowana, która sama tworzy podział na klasy, na podstawie podobieństwa cech obrazu we wszystkich kanałach. Jest ona mniej dokładna, przez co stosuje się ją do badania terenów trudno dostępnych i mało znanych (Mularz, 2004). W przeciwieństwie do klasyfikacji nienadzorowanej, w której wzorce klas są opracowywane automatycznie, w klasyfikacji nadzorowanej podejmowanie wielu decyzji zostawia się operatorowi. Ma on znacznie większy wpływ na proces klasyfikacji i może ten proces dostosować do charakterystyki badanego obiektu. Charakterystycznym elementem klasyfikacji nadzorowanej jest określanie przez interpretatora niewielkich fragmentów obrazu, tzw. „pól treningowych”, które mają reprezentować poszczególne klasy, przez co stanowią wzorce do wykonania klasyfikacji. Pola, będące zazwyczaj różnymi typami pokrycia lub użytkowania terenu, są wyznaczane przez interpretatora, biorąc pod uwagę nie tylko podobieństwo spektralne sąsiadujących ze sobą pikseli, ale także wiedzę na temat opracowywanego terenu zdobytą z innych źródeł. W ten sposób operator ma wpływ na proces klasyfikacji, zwiększając dokładność jej wyników. W celu uzyskania wiarygodnych wyników, wyznaczone pola treningowe powinny zawierać odpowiednio dużą liczbę typowych dla danej klasy pikseli oraz nie zawierać pikseli należących do innych klas. Na podstawie zdefiniowanych pól treningowych system określa charakterystyki każdego pola, zwane sygnaturami, poprzez analizę jasności składających się na dane pole pikseli. Poprzez porównanie wartości każdego piksela obrazu z wyznaczonymi sygnaturami, komputer przyporządkowuje go do najlepiej odpowiadającej mu klasy. Przyporządkowanie pikseli do odpowiednich klas może zostać wykonane z wykorzystaniem różnych kryteriów. Wśród najbardziej znanych reguł decyzyjnych można wymienić metodę największego prawdopodobieństwa, najmniejszej odległości od średniej, metodę równoległości, metodę wektorów nośnych (SVM), metodę drzewa decyzyjnego i lasów losowych oraz metody hybrydowe. Dokładność klasyfikacji nadzorowanej zależy przede wszystkim od precyzyjnego określenia pól treningowych oraz wyboru odpowiedniej reguły decyzyjnej, dostosowanej do badanego obiektu i dostępnych danych.

3.2. Rodzaje klasyfikacji ze względu na wykorzystane cechy obrazu

W zależności od cechy, na podstawie której następuje rozróżnienie pikseli, metody klasyfikacji można podzielić na:

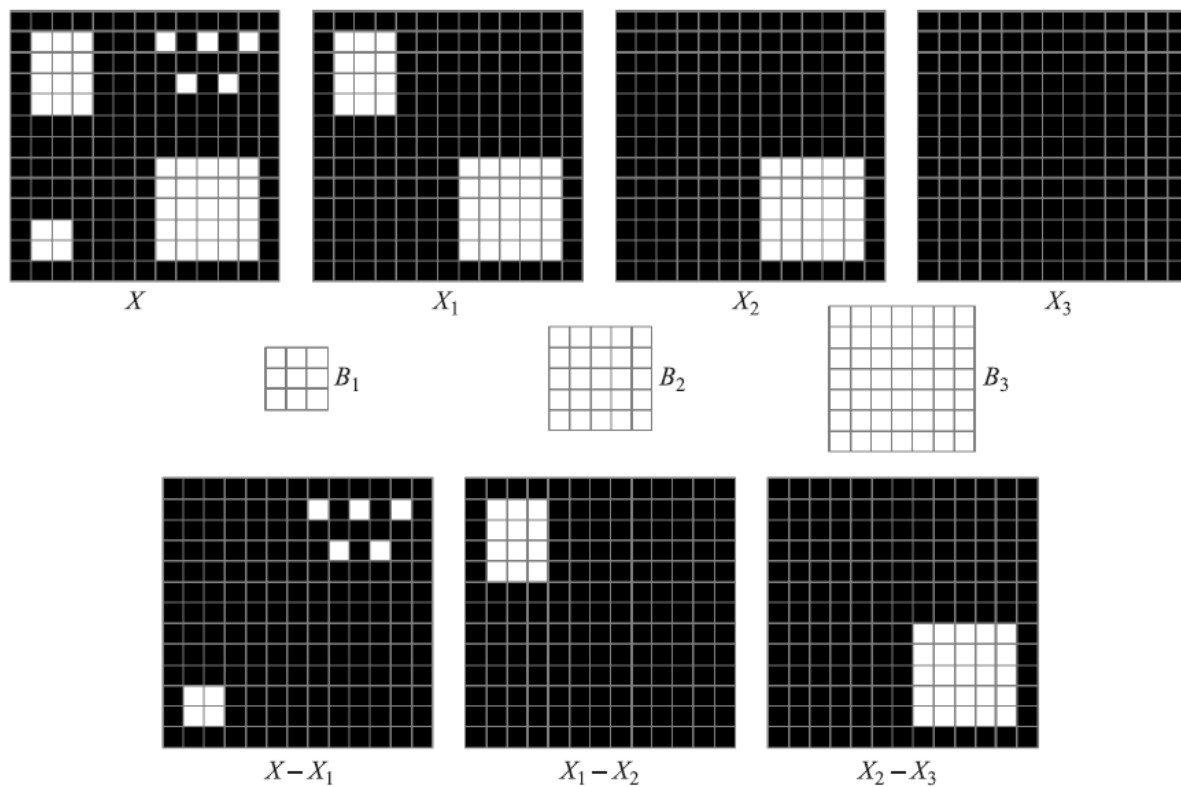
- klasyfikację spektralną;
- klasyfikację wielocechową;
- klasyfikację kontekstualną;
- klasyfikację obiektową.

W klasyfikacji spektralnej cechą rozróżniającą piksele jest ich wartość spektralna, dla klasyfikacji wielocechowej podstawą są pozostałe (niespektralne) cechy obrazu, takie jak tekstura czy kształt. Klasyfikacja kontekstualna wykorzystuje rozróżnienie na podstawie wartości spektralnej poszczególnych pikseli, a także wartości pikseli sąsiednich, natomiast klasyfikacja obiektowa klasyfikuje całe obiekty, wyodrębnione we wcześniejszych etapach opracowania (Kupidura, 2015).

Najbardziej znaną i powszechnie używaną metodą klasyfikacji jest klasyfikacja spektralna, polegająca na analizie każdego piksela jedynie pod względem jego wartości radiometrycznej oraz przyporządkowaniu go do konkretnej klasy na podstawie porównania tych wartości z wyznaczonymi wcześniej sygnaturami. Powszechność tej metody bierze się z faktu, że jest ona stosunkowo prosta do wykonania. Ponadto istnieje obecnie szeroki wybór programów obsługujących funkcje tej klasyfikacji, także darmowych, opartych na wolnych licencjach. Klasyfikacja spektralna jest szybka i stosunkowo łatwa do wykonania. Jej ograniczenie polega na tym, że nie uwzględnia innych cech obrazu (Kupidura, 2015). Z tego względu opracowane zostały inne metody klasyfikacji, uzupełniające klasyfikację spektralną o dodatkowe cechy. Metody te nazwano ogólnym pojęciem klasyfikacji wielocechowej. Pozwalają one na dodanie do spektralnego przyporządkowania dodatkowych informacji, zawartych w obrazie. Informacje mogą odnosić się do cech takich jak kształt, wielkość czy tekstura obrazu. Uwzględnienie ich w klasyfikacji zbliża automatyczny proces przyporządkowania pikseli do możliwości interpretacyjnych ludzkiego operatora.

Szczególnym przypadkiem klasyfikacji wielocechowej jest klasyfikacja spektralno-teksturowa, łącząca informacje spektralne z teksturowymi. Wykorzystuje dodatkowo cechę obrazu, jaką jest tekstura, czyli charakterystyczną fakturę obrazu powstałą na skutek wzajemnego położenia części składowych oraz ich rozmiaru (Kupidura, 2015). Jest to jedna z podstawowych cech interpretacyjnych obrazu, na podstawie której obserwator może wyszczególnić występujące elementy pokrycia i użytkowania terenu. Rozróżnienie poszczególnych klas jest możliwe dzięki różnym rodzajom i różnej wyrazistości tekstury, która ich cechuje. Aby zautomatyzować proces klasyfikacji obrazu na podstawie tekstury, należy uprzednio zapisać ją w postaci matematycznej, zrozumiałej dla komputera. W tym celu istniejące metody klasyfikacji teksturowej w pierwszym etapie przetwarzają obraz tak, by każdemu pikselowi przypisać wartości określające rodzaj i stopień tekstury (Kupidura, 2015). Właściwy etap klasyfikacji przeprowadza się w sposób analogiczny, jak w przypadku klasyfikacji spektralnej.

Jedną z metod wykonania klasyfikacji teksturowej są mapy granulometryczne. Stanowią one produkt wykonywanych analiz granulometrycznych na obrazie. Analizy wykonuje się przy użyciu operacji morfologicznych otwarcia i domknięcia. Sama granulometria obrazowa ma za zadanie zbadanie struktury obrazu poprzez wykonanie operacji usuwających obiekty na obrazie, stosując większe „sito” w każdym kolejnym kroku, i obliczenie różnic pomiędzy powstającymi obrazami (Kupidura, 2015). Ogólny schemat działania granulometrii obrazowej przedstawia Rysunek 2.



Rysunek 2. Sposób działania granulometrii obrazowej z wykorzystaniem operacji otwarcia (Kupidura, 2015)

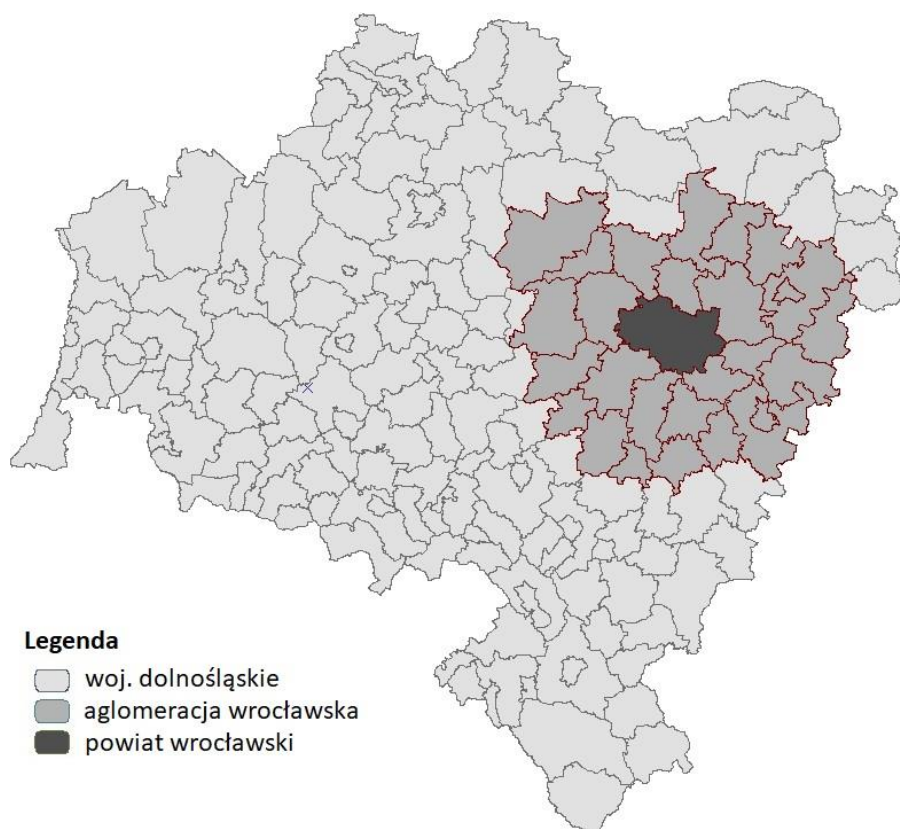
Obrazy rastrowe powstałe w wyniku wykonania operacji morfologicznych, czyli mapy granulometryczne, zostają bezpośrednio wykorzystane w klasyfikacji, uzupełniając ją o cechy teksturowe obrazu.

4. Metodyka pracy

Niniejszy rozdział stanowi zasadniczą część omawianego projektu. Prezentuje obszar, który podlegał badaniu, przedstawia dane źródłowe, na podstawie których wykonano analizy, oraz wyjaśnia samą metodykę opracowania wraz z otrzymanymi wynikami. W podrozdziale poświęconym metodyce opracowania opisano kolejne etapy projektu.

4.1. Ogólna charakterystyka aglomeracji wrocławskiej

Obszar badań obejmuje granice aglomeracji wrocławskiej, położonej w południowo-zachodniej Polsce w województwie dolnośląskim (Rys. 3.). Miastem centralnym jest Wrocław, który wraz z sąsiednimi miastami tworzy monocentryczną aglomerację. Zajmuje ona obszar 4 117,25 km², obejmujący teren 30 gmin, które w sposób gospodarczy są powiązane z Wrocławiem. Całą aglomerację zamieszkuje ponad milion ludzi, z czego ponad 60% mieszka w stolicy województwa (www.wroclaw.stat.gov.pl).



Rysunek 3. Mapa, przedstawiająca położenie aglomeracji wrocławskiej w województwie dolnośląskim


Obserwując rozwój miast w Polsce w przeciągu ostatnich 20 lat, można zauważyć tendencję poszerzania się głównych miast z jednoczesnym intensywnym rozwojem okolicznych miejscowości. Związane jest to z przenoszeniem się mieszkańców poza granice miasta, pozostającego dla nich jednocześnie centrum realizacji zawodowej. Na tereny podmiejskie zostają również przenoszone ośrodki przemysłowe (Zakrzewska-Póttorak, Mempel-Śnieżyk, Miszczak, 2010). Powoduje to rozbudowę infrastruktury i sieci komunikacyjnych na tych terenach, wspólną gospodarkę z okolicznymi miejscowościami, dzięki czemu tworzą wraz z miastem centralnym jeden organizm. Zaobserwowane

w skali kraju procesy pozwalają założyć, że wybranie na obszar badań całej aglomeracji pozwoli na szersze spojrzenie na rozwój samego miasta Wrocławia oraz umożliwi określenie jego wpływu na okoliczne miejscowości.

4.2. Charakterystyka danych źródłowych

Do badań wykorzystano zdjęcia satelitarne systemu Landsat, udostępnione nieodpłatnie przez USGS poprzez stronę <https://earthexplorer.usgs.gov>. Zdjęcia przedstawiają obszar opracowania w miesiącach między kwietniem a wrześniem, w latach 1999-2018, w cztero- i pięcioletnich odstępach czasowych. Wybór padł na te konkretne miesiące uwagi na to, że wtedy obszary zabudowy mocniej wyróżniają się spośród pozostałych form pokrycia terenu, co zwiększa dokładność klasyfikacji. Idealną sytuacją byłoby operowanie na zdjęciach wykonanych dokładnie w tym samym czasie i tych samych warunkach dla każdego z badanych okresów. Niestety przy kompletowaniu danych wiele obrazów należało odrzucić ze względu na znaczne zachmurzenie, uniemożliwiające otrzymanie wiarygodnych wyników. Z tego powodu zdjęcia pochodzą z różnych miesięcy, co jednak nie wpływa znacząco na dokładność wyników.

Wykonanie analizy całej aglomeracji wrocławskiej, wymagało posłużenia się zdjęciami z pasa 190 i dwóch rzędów 24 i 25 (wg oznaczeń Landsata) (Rys. 4.).



Rysunek 4. Przykładowe dane wyjściowe wykorzystane do opracowania: zdjęcie z rzędu 24 (a) i z rzędu 25 (b) (źródło: <http://earthexplorer.usgs.gov/>)

Początkowo wszystkie dane miały pochodzić wyłącznie z 7 i 8 generacji Landsata, jednak okazało się, że z powodu uszkodzonego czujnika na pokładzie satelity Landsat 7, użyteczność zdjęć wykonanych w maju 2003 r. i później, jest znacznie ograniczona (Rys. 5.). Z tego powodu dla lat 2003 oraz 2008 wybrano obrazy z satelity Landsat 5.




Rysunek 5. Fragment sceny satelitarnej satelity Landsat 7 z uszkodzonym czujnikiem z roku 2008 (źródło: <http://earthexplorer.usgs.gov/>)

Analizy wykonano na obrazach wielospektralnych złożonych z sześciu kanałów (niebieskiego, zielonego, czerwonego, bliskiej podczerwieni oraz dwóch średnich podczerwieni) o rozmiarze piksela wynoszącym 30 m. Dodatkowo dla lat 2013 oraz 2018 posłużono się obrazami panchromatycznymi o wielkości piksela terenowego równej 15 m, na podstawie których wygenerowano mapy granulometryczne, dołączone w kolejnych etapach do klasyfikacji. Szczegółowe zestawienie informacji o każdym wykorzystanym zdjęciu przedstawia Tabela 2, natomiast same zdjęcia, przycięte do obszaru opracowania, zaprezentowano na Rysunku 6.

Tabela 2. Szczegółowe informacje o wykorzystanych w projekcie danych obrazowych

Nr zdjęcia	Rok	Rząd	Data wykonania zdjęcia	System satelitarny	Rozdzielczość radiometryczna
1	1999	24	7 sierpnia	Landsat 7	8 b
2		25	24 września		8 b
3	2003	24	23 czerwca	Landsat 5	8 b
4		25	23 czerwca		8 b
5	2008	24	1 kwietnia	Landsat 5	8 b
6		25	1 kwietnia		8 b
7	2013	24	15 kwietnia	Landsat 8	12 b
8		25	18 czerwca		12 b
9	2018	24	2 maja	Landsat 8	12 b
10		25	29 kwietnia		12 b



Rysunek 6. Zdjęcia źródłowe w kompozycji RGB 453 (654) przycięte do obszaru opracowania dla lat: 1999 rząd 24 (a), i rząd 25 (b), 2003 rząd 24 (c) i rząd 25 (d), 2008 rząd 24 (e) i rząd 25 (f), 2013 rząd 24 (g) i rząd 25 (h) oraz 2018 rząd 24 (i) i rząd 25 (j)

4.3. Wykorzystane oprogramowanie

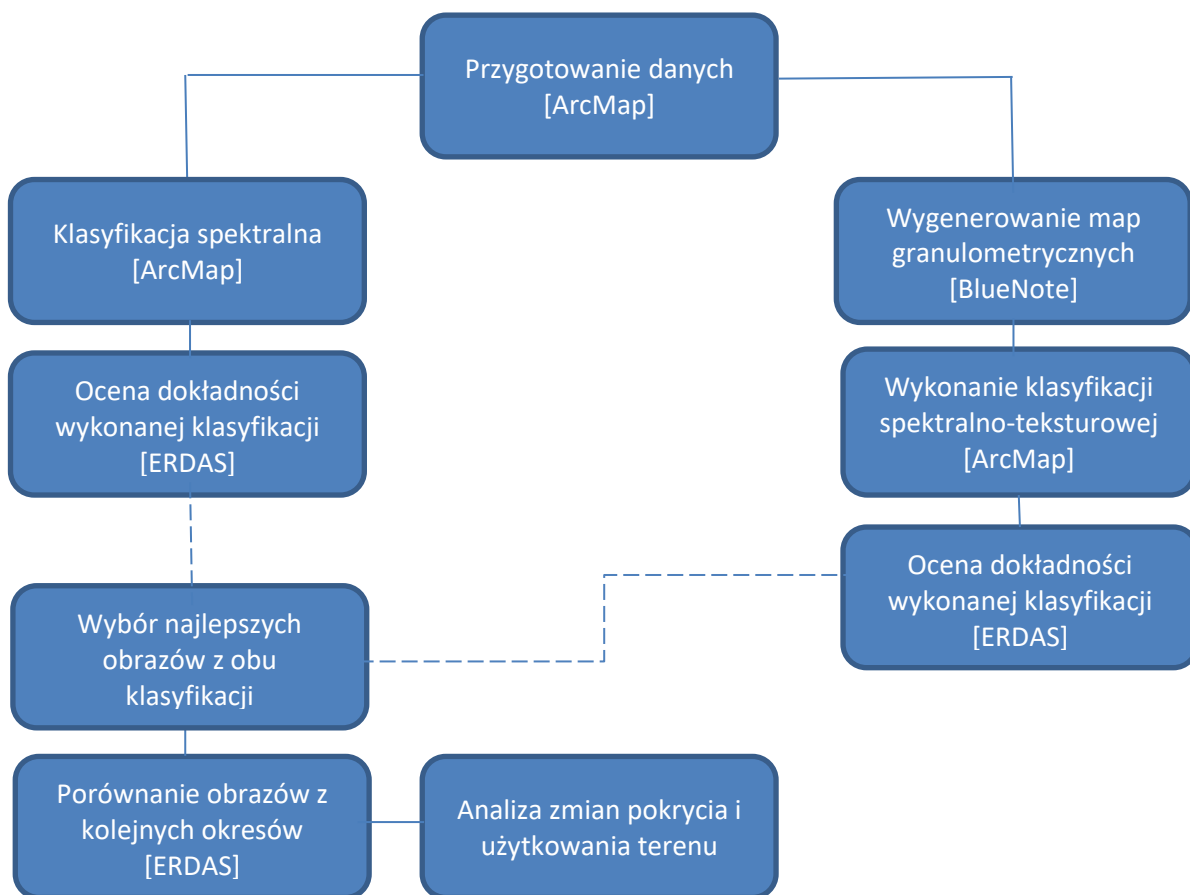
Do opracowania projektu posłużono się trzema programami:

- ArcMap 10.1.6 – jeden z głównych modułów oprogramowania ArcGis. Służy przede wszystkim do wyświetlania, edytowania i przetwarzania zbiorów danych GIS oraz generowania kompozycji mapowych.
- ERDAS IMAGINE 15.1 – specjalistyczne oprogramowanie przeznaczone do przetwarzania danych teledetekcyjnych, fotogrametrycznych i GIS oraz wykonywania na nich analiz przestrzennych
- BlueNote 1.1.5 – program stworzony do wykonywania operacji na danych obrazowych wykorzystując funkcje morfologii matematycznej

W ArcMapie wykonano większość operacji związanych z klasyfikacją, od przygotowania danych po same klasyfikacje. Przycięto w niej zdjęcia źródłowe do obszaru opracowania, wybrano pola treningowe, wykonano przyporządkowanie pikseli do klas metodą spektralną i spektralno-tekstурową oraz wskazano pola testowe. Samo określenie dokładności, poprzez wygenerowanie macierzy błędów, zostało przeprowadzone w programie ERDAS IMAGINE. W tym programie dokonano także porównania wynikowych obrazów, stanowiącego element analiz zmian pokrycia/użytkowania terenu. Natomiast w programie BlueNote utworzono mapy granulometryczne potrzebne do wykonania klasyfikacji spektralno-tekstурowej.

4.4. Metodyka analizy rozwoju aglomeracji wrocławskiej

Podstawowym elementem analizy rozwoju aglomeracji jest wskazanie zmian, jakie zaszły w pokryciu i użytkowaniu badanego obszaru, skupiając uwagę przede wszystkim na terenach zabudowanych. Określenie zmian stanowi produkt wzajemnego porównania obrazów, reprezentujących stan pokrycia terenu w pięciu wybranych momentach badanego okresu. Wspomniane obrazy powstały w wyniku klasyfikacji danych źródłowych.



Rysunek 7. Schemat, ilustrujący proces opracowania projektu; w nawiasach podano użyte na danych etapie oprogramowanie

Jak można zauważyć na powyższym schemacie (Rys. 7.), głównym etapem pracy było wykonanie klasyfikacji obrazów. Przeprowadzono ją dwiema metodami: spektralną i spektralno-teksturową. Do ostatecznego procesu badania zmian pokrycia terenu wykorzystano najlepsze wyniki wybrane z obu metod – charakteryzujące się najwyższą dokładnością.

Przed przystąpieniem do klasyfikacji, należało przygotować dane źródłowe – zdjęcia satelitarne systemu Landsat. Przygotowanie obejmowało selekcję odpowiednich zdjęć, połączenie obrazów z sześciu kanałów spektralnych w jedną warstwę oraz przycięcie powstałej warstwy do obszaru opracowania. Nie wykonano mozaikowania odpowiadających sobie zdjęć z dwóch rzędów ze względu na różne terminy ich powstania. Czynności przygotowawcze wykonano w programie ArcMap. Posiadając tak dostosowane dane, można było przystąpić do procesu klasyfikacji. Jako algorytm uczenia maszynowego wybrano metodę nadzorowaną. Postanowiono wyodrębnić 5 klas pokrycia i użytkowania gruntów:


- obszary zabudowane – tereny, na których występują zabudowania miejskie, wiejskie, przemysłowe lub inne tereny wykorzystywane przez człowieka posiadające zabudowę;
- wody – obszary wód powierzchniowych, takich jak rzeki, jeziora czy mokradła;
- lasy – klasa zawierająca w sobie zarówno lasy liściaste jak i iglaste oraz wszelkie tereny zalesione;
- roślinność - obejmuje tereny zarośnięte roślinnością niską, głównie uprawy i łąki;
- gleby odkryte – obszary, na których nie występuje żaden rodzaj roślinności ani infrastruktury, bezpośrednio ukazujące glebę.

W teorii wystarczyłby podział na tereny zabudowane i niezabudowane, jednak decyzja o podziale na większą liczbę klas, miała na celu lepsze zrozumienie procesów zachodzących na badanym terenie. Klasa roślinności oraz gleb odkrytych stanowią jeden rodzaj użytkowania terenu – grunty rolne, będąc jednocześnie dwoma różnymi rodzajami pokrycia terenu. Z tego względu w projekcie postanowiono rozdzielić je na dwie odrębne klasy.

4.4.1. Klasyfikacja spektralna

Jako pierwszą wykonano klasyfikację spektralną. Posłużono się do tego programem ArcMap. Proces wykonano dla wszystkich zdjęć, pomimo że w kolejnych etapach poddano je klasyfikacji spektralno-teksturowej. Zdecydowano się na ten krok, aby zwiększyć bazę potencjalnych danych do wykorzystania w analizach zmian pokrycia terenu i wybrać bardziej dokładne wyniki.

Proces klasyfikacji rozpoczęto od utworzenia pól treningowych. Należało to zrobić precyzyjnie, gdyż od poprawnego zdefiniowania pól zależy jakość otrzymanych wyników. Operacje te wykonywano na obrazach w kompozycji barwnej, przypisującej kanał czerwony kolorowi niebieskiemu, kanał bliskiej podczerwieni – czerwonemu i kanał średniej podczerwieni – zielonemu, czyli RGB 564 (dla zdjęć z Landsata 8) (Rys. 8.) oraz RGB 453 (dla zdjęć z Landsata 5 i 7). Taka kompozycja barwna w najlepszy sposób uwydatnia różnice między obszarem miejskim a terenami niezabudowanymi.



Rysunek 8. Kompozycja barwna RGB 564 zdjęcia z Landsata 8 z roku 2018 z rzędu 24 wykorzystana w procesie klasyfikacji

Ze względu na to, że docelowe klasy obejmowały obszary różnorodnie spektralnie, na czas definiowania pól treningowych podzielono je na podklasy, które później zgrupowano w klasy docelowe. Po wyznaczeniu pól treningowych sprawdzono poprawność ich wskazania poprzez ocenę histogramów. Częstość występowania pikseli o danych wartościach radiometrycznych powinna mieć rozkład Gaussa.

W następnej kolejności zajęto się wyborem reguły decyzyjnej. Postanowiono wykonać klasyfikację metodą wektorów nośnych (SVM – Support Vector machine), zaliczaną do metod nieparametrycznych. SVM jest uważane za jedną z dokładniejszych metod klasyfikacji, radzącą sobie nawet z trudnymi, zaszumionymi danymi (Marcinkowska-Ochytra, 2016), chociaż przeznaczoną przede wszystkim do danych hiperspektralnych (Benediktsson, Ghamisi, 2015). Dla potwierdzenia tej opinii wykonano porównanie metody wektorów nośnych z metodą największego prawdopodobieństwa, uznawaną za najdokładniejszą spośród metod parametrycznych (Mularz, 2004). Przy klasyfikacji wykorzystano tę samą bazę pól treningowych dla obu metod, a do oceny użyto tych samych pól testowych. Dla zwiększenia wiarygodności wyników, porównanie wykonano także dla klasyfikacji spektralno-teksturowej.

Właściwą klasyfikację wykonano przy użyciu funkcji Classify Raster programu ArcMap, wprowadzając wspomniane parametry, a po zakończeniu tej operacji obraz zreklasyfikowano za pomocą funkcji Reclassify, łącząc go w klasy docelowe.

4.4.2. Klasyfikacja spektralno-teksturowa

Drugim rodzajem klasyfikacji, jaki wykonano, była klasyfikacja spektralno-teksturowa. Jak wspomniano, badania rozwoju aglomeracji wrocławskiej sprowadzają się do przeanalizowania zmian jakie zaszły w położeniu i zasięgu obszarów zabudowanych. Oprócz cech spektralnych, wyróżniających zabudowę od innych rodzajów pokrycia i użytkowania terenu, inną cechą charakterystyczną tej klasy jest tekstura. Tekstura obszarów zabudowanych powstaje w wyniku złożenia części składowych, będących poszczególnymi elementami infrastruktury. Dzięki temu tereny zabudowane, szczególnie miejskie, wyraźnie odznaczają się od pozostałego terenu. Z tego powodu postanowiono wykorzystać tę cechę w przeprowadzonych badaniach. W praktyce oznaczało to dołączenie do danych spektralnych danych określających teksturę obrazu. Do tego celu posłużono się mapami granulometrycznymi, które wygenerowano w programie BlueNote. Utworzono je na podstawie obrazów panchromatycznych o wielkości piksela równej 15 m (dla danych z Landstata 7 i 8) oraz obrazów powstałych w wyniku przeprowadzenia analizy składowych głównych (PCA), z pikselem wielkości 30 m.

Dla każdego obrazu panchromatycznego i obrazów z PCA wykonano procesy otwarcia i domknięcia, skąd powstały po dwie mapy granulometryczne. Parametry do wykonania tych operacji wybrano tak, aby mapy, możliwie jak najdokładniej, uwydatniły obszary zabudowy. Osiągnięto to poprzez ustalenie wartości promienia elementu strukturującego jako 2 px. Ze względu na to, że program BlueNote obsługuje jedynie obrazy w formacie 8 b, zdjęcia pochodzące z Landsata 8 należało, przez przystąpieniem do wykonywania działań, przekonwertować. Podczas wykonywania operacji w programie, obrazy straciły georeferencję, którą przywrócono za pośrednictwem programu ERDAS.

Następnie mapy granulometryczne połączono z obrazami spektralnymi. Powstałe zestawy danych stanowiły bazę do wykonania klasyfikacji. Wykorzystano w niej te same pola treningowe, co w przypadku klasyfikacji spektralnej, a sam proces klasyfikacji przebiegał analogicznie.

4.4.3. Ocena dokładności i analiza zmian pokrycia i użytkowania terenu

Po wykonaniu klasyfikacji należało sprawdzić jej dokładność, które polegało na przyrównaniu sklasyfikowanego obrazu do wskazanych wzorców, reprezentujących każdą z klas, zwanych polami testowymi. Są to niewielkie fragmenty obrazu, zdefiniowanymi przez operatora na podstawie jego wiedzy o terenie, które określają rzeczywiste położenie danego rodzaju pokrycia terenu. Pola testowe należy rozmieszczać proporcjonalnie do występowania każdej klasy, równomiernie na całym zdjęciu (na ile pozwala charakterystyka badanego obszaru). Ważne jest, aby były wskazane z dużą precyzją, aby ocenę można było uznać za wiarygodną.


Sklasyfikowane obrazy oraz zdefiniowane pola testowe zapisano w postaci rastrów o rozszerzeniu .tiff. Z tak przygotowanych rastrów wygenerowano, również w programie ERDAS, macierze błędów. Ze względu na to, że program nie ukazuje bezpośrednio błędów pominięcia i niedomiaru oraz współczynnika Kappa, wyznaczono je samodzielnie w programie obliczeniowym. Wartości błędów i współczynnika Kappa określiły dokładność wykonanych klasyfikacji.

Ostatnim etapem pracy było wykonanie analizy pokrycia i użytkowania terenu. Wykonano ją w programie ERDAS, przy użyciu tej samej funkcji, którą posłużono się do wygenerowania macierzy błędów. Porównano ze sobą zdjęcia sąsiadujące ze sobą czasowo (np. zdjęcia z roku 2003 i 2008) oraz obrazy ze skrajnych dat (1999 i 2018), dla każdego rzędu oddzielnie. Jako obrazy bazowe do porównania przyjęto obrazy ze wcześniejszych okresów. Otrzymane raporty pokazały w sposób ilościowy, jak zmieniły się poszczególne klasy. Należało je odpowiednio zinterpretować, wykorzystując dodatkowo dane obrazowe. Wnioski z dokonanych analiz stanowiły cel niniejszej pracy i zostały szczegółowo opisane w kolejnym rozdziale.


5. Przebieg opracowania i wyniki

5.1. Przygotowanie danych

W etapie przygotowania danych, utworzono obrazy wielospektralne i przycięto je do granic obszaru opracowania. Przykładowe produkty tych operacji ilustrują Rysunki 9 i 10, na których pokazano granice aglomeracji wrocławskiej nałożone na warstwę przyciętego obrazu. Dzięki wykorzystaniu zdjęć z rzędów 24 i 25, możliwe było zbadanie całego obszaru opracowania, wraz z niewielkim fragmentem na południu aglomeracji, którego nie objęło zdjęcie z rzędu 24.




Rysunek 9. Zdjęcie z roku 2018 z rzędu 24 w kompozycji RGB 321, przycięte do obszaru opracowania



Rysunek 10. Zdjęcie z roku 2018 z rzędu 25 w kompozycji RGB 321, przycięte do obszaru opracowania

5.2. Klasyfikacja spektralna

Proces klasyfikacji spektralnej rozpoczyna wyznaczenie pól treningowych (Rys. 11.) dla każdego zestawu danych, w takiej liczbie, jaka odzwierciedlała rodzaje pokrycia terenu, które można było wyróżnić. Nadano im robocze nazwy (Rys. 12.), nawiązujące do docelowej klasy, do której miały być ostatecznie zaliczone.




Rysunek 11. Pola treningowe na przykładzie zdjęcia z 1999 roku z rzędu 24

Legenda

■ Zabudowa1	■ Woda1	■ Las1	■ Roslinnosc1	■ Gleba1	■ Gleba10	■ Gleba19
■ Zabudowa2	■ Woda2	■ Las2	■ Roslinnosc2	■ Gleba2	■ Gleba11	■ Gleba20
■ Zabudowa3	■ Woda3	■ Las3	■ Roslinnosc3	■ Gleba3	■ Gleba12	■ Gleba21
■ Zabudowa4		■ Las4	■ Roslinnosc4	■ Gleba4	■ Gleba13	■ Gleba22
■ Zabudowa5		■ Las5	■ Roslinnosc5	■ Gleba5	■ Gleba14	■ Gleba23
■ Zabudowa6		■ Las6	■ Roslinnosc6	■ Gleba6	■ Gleba15	
■ Zabudowa7			■ Roslinnosc7	■ Gleba7	■ Gleba16	
■ Zabudowa8			■ Roslinnosc8	■ Gleba8	■ Gleba17	
			■ Roslinnosc9	■ Gleba9	■ Gleba18	

Rysunek 12. Legenda do wyznaczonych pól treningowych, ukazująca podział na podklasy

Utworzonym polom treningowym sprawdzono histogramy, które wyszły poprawnie (Rys. 13.). Powstałe nieciągłości w rozkładzie Gaussa w klasach lasów, roślinności oraz gleb odkrytych były spowodowane dużą rozciągłością spektralną tych klas. było to związane z dużą generalizacją klas, która skutkowałą m.in. połączeniem lasów iglastych z liściastymi czy gleb suchych z wilgotnymi.



Rysunek 13. Przykładowe histogramy pól treningowych zdjęcia nr 1 zgrupowane w 5 klas: zabudowę (a), wody (b), lasy (c), roślinność (d) i gleby odkryte (e)


W następnej kolejności wybrano regułę decyzyjną. Zdecydowano się na metodę wektorów nośnych, upewniając się uprzednio, że daje lepsze rezultaty od pozostałych metod. Porównanie sprawdzało dokładność SVM oraz metody największego prawdopodobieństwa i miało na celu jedynie potwierdzenie prawdziwości tej opinii. Stąd wykonano je tylko na jednym zdjęciu z 2013 roku z rzędu 24. Już wizualna ocena wyników (Rys.14.) pokazuje, że dokładność metody SVM nieznacznie przewyższa metodę największego prawdopodobieństwa, a dane liczbowe (Tab. 3.) to potwierdzają.

Tabela 3. Porównanie wyników klasyfikacji spektralnej i spektralno-teksturowej z wykorzystaniem metody SVM i metody największego prawdopodobieństwa wykonane na zdjęciu z 2013 roku z rzędu 24





Metoda decyzyjna	Błąd pominięcia klasy zabudowy	Błąd nadmiaru klasy zabudowy	Współczynnik Kappa	Ogólna dokładność
Klasyfikacja spektralna				
SVM	0,050	0,186	0,960	0,971
Największego prawdopodobieństwa	0,450	0,045	0,898	0,926
Klasyfikacja spektralno-teksturowa				
SVM	0,014	0,000	0,991	0,993
Największego prawdopodobieństwa	0,396	0,000	0,921	0,942

Legenda

-  Zabudowa
-  Wody
-  Lasy
-  Roslinność
-  Gleby odkryte



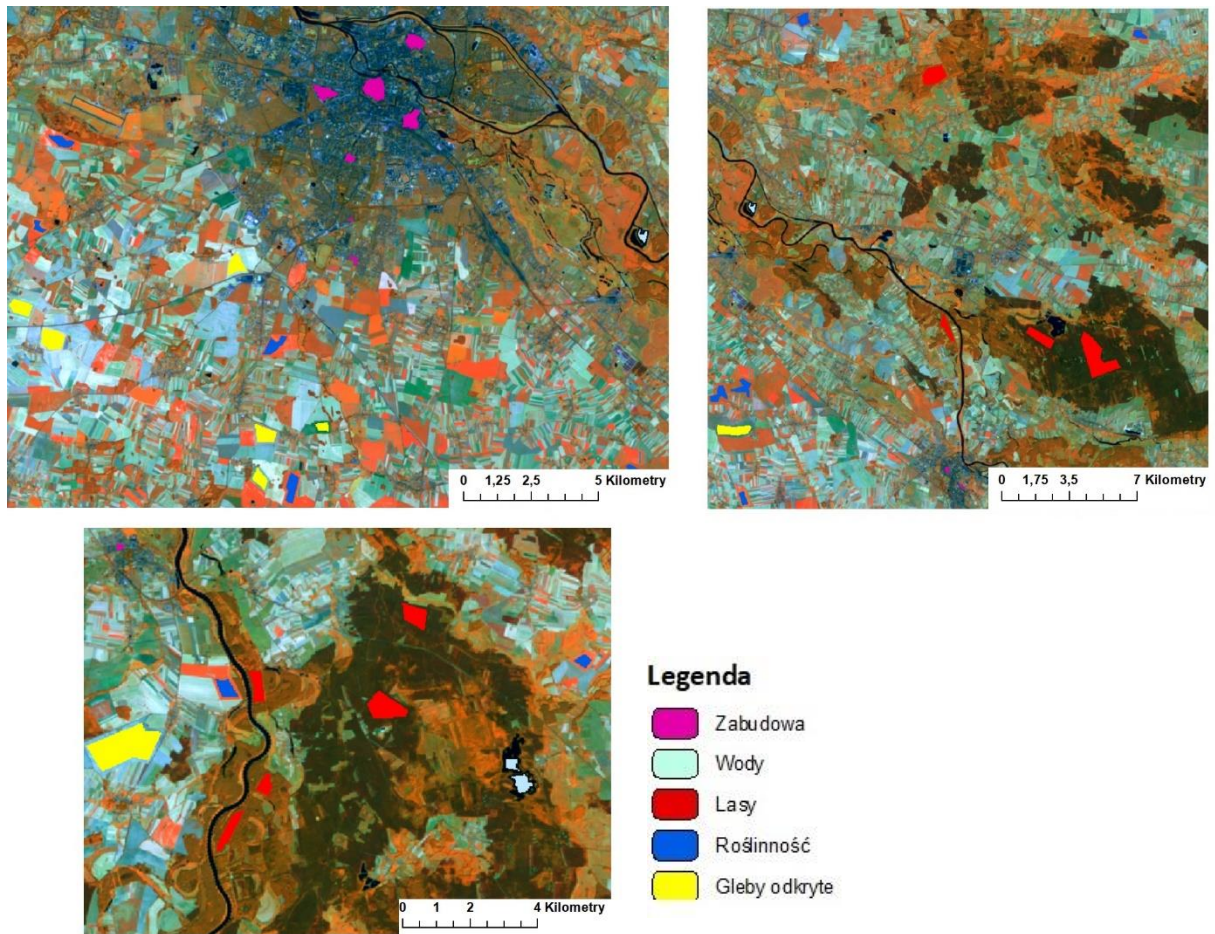
0 5 10 20 Kilometry



Rysunek 14. Wyniki klasyfikacji spektralnej zdjęcia z roku 2013 z rzędu 24 (a) przy użyciu: SVM (b) i metody największego prawdopodobieństwa (c) oraz klasyfikacji spektralno-teksturalnej metodą SVM (d) i metodą największego prawdopodobieństwa (e)

Posiadając zdefiniowane pola treningowe oraz wybraną regułę decyzyjną wykonano klasyfikację. Po tej operacji, zreklasyfikowano powstałe obrazy w 5 głównych klas.

W celu sprawdzenia dokładności wykonanego procesu, dla każdego zdjęcia utworzono pola testowe (Rys. 15.). Umieszczono je na obrazie na tyle równomiernie, na ile to było możliwe, starając się zachować proporcje między liczebnością pól a wielkością obszaru zajmowanego przez daną klasę.



Rysunek 15. Zdefiniowane pola testowe na zdjęciu z 1999 roku z rzędu 24

Ostatecznie wygenerowano macierze błędów i policzono charakterystyki dokładnościowe, które przedstawiono w poniższych tabelach (Tab. 4. – 13.).

Tabela 4. Macierz błędów klasyfikacji spektralnej dla zdjęcia z 1999 roku z rzędu 24

		Klasy pól testowych							
Wyznaczone klasy	Rok 1999	Zabudowa [px]	Wody [px]	Lasy [px]	Roślinność [px]	Gleby odkryte [px]	Σ [px]	Błąd pominięcia	
	Zabudowa	3063	1	0	0	167	3231	0,052	
	Wody	1	2991	0	0	0	2992	0,000	
	Lasy	6	0	25520	1	0	25527	0,000	
	Roślinność	27	0	14	8137	263	8441	0,036	
	Gleby odkryte	224	0	0	0	17433	17657	0,013	
Σ	3321	2992	25534	8138	17863	57848	Ogólna dokładność	Wsp. Kappa	
Błąd nadmiaru	0,077	0,000	0,001	0,000	0,024	-	0,988	0,982	

Tabela 5. Macierz błędów klasyfikacji spektralnej dla zdjęcia z 1999 roku z rzędu 25

		Klasy pól testowych							
Wyznaczone klasy	Rok 1999	Zabudowa [px]	Wody [px]	Lasy [px]	Roślinność [px]	Gleby odkryte [px]	Σ [px]	Błąd pominięcia	
	Zabudowa	327	0	1	0	1	329	0,003	
	Wody	0	4592	0	0	0	4592	0,000	
	Lasy	8	0	11673	89	2	11772	0,008	
	Roślinność	1	0	3	4963	0	4967	0,001	
	Gleby odkryte	411	3	0	0	15818	16232	0,026	
Σ	747	4595	11677	5052	15821	37892	Ogólna dokładność	Wsp. Kappa	
Błąd nadmiaru	0,562	0,001	0,000	0,018	0,000	-	0,986	0,980	

Tabela 6. Macierz błędów klasyfikacji spektralnej dla zdjęcia z 2003 roku z rzędu 24

		Klasy pól testowych							
Wyznaczone klasy	Rok 2003	Zabudowa [px]	Wody [px]	Lasy [px]	Roślinność [px]	Gleby odkryte [px]	Σ [px]	Błąd pominięcia	
	Zabudowa	3206	1	1	0	49	3257	0,015	
	Wody	0	2654	0	0	0	2654	0,000	
	Lasy	4	3	13952	65	0	14024	0,005	
	Roślinność	35	0	1230	5468	75	6808	0,197	
	Gleby odkryte	177	0	0	0	5180	5357	0,033	
Σ	3422	2658	15183	5533	5304	32100	Ogólna dokładność	Wsp. Kappa	
Błąd nadmiaru	0,063	0,000	0,081	0,012	0,023	-	0,949	0,928	

Tabela 7. Macierz błędów klasyfikacji spektralnej dla zdjęcia z 2003 roku z rzędu 25

		Klasy pól testowych							
Wyznaczone klasy	Rok 2003	Zabudowa [px]	Wody [px]	Lasy [px]	Roślinność [px]	Gleby odkryte [px]	Σ [px]	Błąd pominięcia	
	Zabudowa	2362	0	0	0	473	2835	0,167	
	Wody	1	5377	0	0	0	5378	0,000	
	Lasy	7	36	7112	1	0	7156	0,001	
	Roślinność	170	1	376	8067	3657	12271	0,343	
	Gleby odkryte	29	3	0	0	1654	1686	0,019	
Σ	207	5417	7488	8068	5311	29326	Ogólna dokładność	Wsp. Kappa	
Błąd nadmiaru	0,995	0,001	0,050	0,000	0,778	-	0,838	0,792	

Tabela 8. Macierz błędów klasyfikacji spektralnej dla zdjęcia z 2008 roku z rzędu 24

		Klasy pól testowych							
Wyznaczone klasy	Rok 2008	Zabudowa [px]	Wody [px]	Lasy [px]	Roślinność [px]	Gleby odkryte [px]	Σ [px]	Błąd pominięcia	
	Zabudowa	1733	0	0	0	0	1733	0,000	
	Wody	0	2361	0	0	0	2361	0,000	
	Lasy	28	0	15546	1	0	15575	0,000	
	Roślinność	1	0	0	10655	0	10656	0,000	
	Gleby odkryte	428	0	0	0	6390	6818	0,063	
Σ	2190	2361	15546	10656	6390	37143	Ogólna dokładność	Wsp. Kappa	
Błąd nadmiaru	0,209	0,000	0,000	0,000	0,000	-	0,988	0,982	

Tabela 9. Macierz błędów klasyfikacji spektralnej dla zdjęcia z 2008 roku z rzędu 25

		Klasy pól testowych							
Wyznaczone klasy	Rok 2008	Zabudowa [px]	Wody [px]	Lasy [px]	Roślinność [px]	Gleby odkryte [px]	Σ [px]	Błąd pominięcia	
	Zabudowa	2114	9	42	0	472	2637	0,182	
	Wody	3	3732	0	0	0	3735	0,000	
	Lasy	122	21	9444	0	0	9587	0,002	
	Roślinność	2	0	1	7282	98	7383	0,013	
	Gleby odkryte	47	0	0	0	13501	13548	0,003	
Σ	2288	3762	9487	7282	14071	36890	Ogólna dokładność	Wsp. Kappa	
Błąd nadmiaru	0,075	0,008	0,000	0,000	0,041	-	0,978	0,970	

Tabela 10. Macierz błędów klasyfikacji spektralnej dla zdjęcia z 2013 roku z rzędu 24

		Klasy pól testowych							
Wyznaczone klasy	Rok 2013	Zabudowa [px]	Wody [px]	Lasy [px]	Roślinność [px]	Gleby odkryte [px]	Σ [px]	Błąd pominięcia	
	Zabudowa	1284	0	0	0	68	1352	0,050	
	Wody	0	948	0	0	0	948	0,000	
	Lasy	3	0	4743	101	83	4930	0,038	
	Roślinność	9	0	0	6450	0	6459	0,001	
	Gleby odkryte	282	0	4	0	5186	5472	0,052	
Σ	1578	948	4747	6551	5337	19161	Ogólna dokładność	Wsp. Kappa	
Błąd nadmiaru	0,186	0,000	0,001	0,015	0,028	-	0,971	0,961	

Tabela 11. Macierz błędów klasyfikacji spektralnej dla zdjęcia z 2013 roku z rzędu 25

		Klasy pól testowych							
Wyznaczone klasy	Rok 2013	Zabudowa [px]	Wody [px]	Lasy [px]	Roślinność [px]	Gleby odkryte [px]	Σ [px]	Błąd pominięcia	
	Zabudowa	791	0	0	0	80	871	0,092	
	Wody	0	6048	0	0	0	6048	0,000	
	Lasy	0	1	6301	41	0	6343	0,007	
	Roślinność	21	0	96	9249	18	9384	0,014	
	Gleby odkryte	30	0	0	28	5391	5449	0,011	
Σ	842	6049	6397	9318	5489	28095	Ogólna dokładność	Wsp. Kappa	
Błąd nadmiaru	0,061	0,000	0,015	0,007	0,018	-	0,989	0,985	

Tabela 12. Macierz błędów klasyfikacji spektralnej dla zdjęcia z 2018 roku z rzędu 24


		Klasy pól testowych							
Wyznaczone klasy	Rok 2018	Zabudowa [px]	Wody [px]	Lasy [px]	Roślinność [px]	Gleby odkryte [px]	Σ [px]	Błąd pominięcia	
	Zabudowa	2407	0	0	0	1	2408	0,000	
	Wody	146	2892	0	0	0	3038	0,048	
	Lasy	4	0	15456	73	0	15533	0,005	
	Roślinność	52	0	360	12198	0	12610	0,033	
	Gleby odkryte	261	0	0	0	14731	14992	0,000	
Σ	2870	2892	15816	12271	14732	48581	Ogólna dokładność	Wsp. Kappa	
Błąd nadmiaru	0,161	0,000	0,023	0,006	0,000	-	0,982	0,975	

Tabela 13. Macierz błędów klasyfikacji spektralnej dla zdjęcia z 2018 roku z rzędu 25

		Klasy pól testowych							
Wyznaczone klasy	Rok 2018	Zabudowa [px]	Wody [px]	Lasy [px]	Roślinność [px]	Gleby odkryte [px]	Σ [px]	Błąd pominięcia	
	Zabudowa	913	0	0	0	11	924	0,012	
	Wody	0	3525	0	0	0	3525	0,000	
	Lasy	0	0	3764	16	0	3780	0,004	
	Roślinność	2	0	0	10116	0	10118	0,000	
	Gleby odkryte	41	0	0	0	13364	13405	0,000	
Σ	956	3525	3764	10132	13375	31752	Ogólna dokładność	Wsp. Kappa	
Błąd nadmiaru	0,045	0,000	0,000	0,002	0,001	-	0,998	0,997	

5.3. Klasyfikacja spektralno-teksturowa

Do przeprowadzenia klasyfikacji spektralno-teksturowej należało na początku utworzyć dane zawierające informacje o teksturze obrazu. W tym celu wygenerowano po dwie mapy granulometryczne dla każdego zdjęcia, powstałe w wyniku operacji otwarcia i domknięcia (Rys. 16.). Zestawienie wszystkich utworzonych map przedstawiono w Załączniku 1.



Rysunek 16. Mapy granulometryczne zdjęcia z 2008 roku z rzędu 24 utworzone z funkcji otwarcia (a) i domknięcia (b)

Połączone mapy granulometryczne z obrazami spektralnymi każdego okresu stanowiły bazę do wykonania kolejnej klasyfikacji. Wykorzystano do niej utworzone poprzednio pola treningowe.

Tak jak w przypadku klasyfikacji spektralnej, na koniec utworzono macierze błędów i policzono charakterystyki dokładnościowe (Tab. 14. – 23.).

Tabela 14. Macierz błędów klasyfikacji spektralno-teksturowej dla zdjęcia z 1999 roku z rzędu 24

		Klasy pól testowych							
Wyznaczone klasy	Rok 1999	Zabudowa [px]	Wody [px]	Lasy [px]	Roślinność [px]	Gleby odkryte [px]	Σ [px]	Błąd pominięcia	
	Zabudowa	3254	4	0	0	260	3518	0,075	
	Wody	16	2988	0	0	0	3004	0,005	
	Lasy	11	0	25520	1	0	25532	0,000	
	Roślinność	11	0	14	8137	273	8435	0,035	
	Gleby odkryte	29	0	0	0	17330	17359	0,000	
Σ	3321	2992	25534	8138	17863	57848	Ogólna dokładność	Wsp. Kappa	
Błąd nadmiaru	0,020	0,001	0,001	0,000	0,030	-	0,989	0,984	

Tabela 15. Macierz błędów klasyfikacji spektralno-teksturowej dla zdjęcia z 1999 roku z rzędu 25

		Klasy pól testowych							
Wyznaczone klasy	Rok 1999	Zabudowa [px]	Wody [px]	Lasy [px]	Roślinność [px]	Gleby odkryte [px]	Σ [px]	Błąd pominięcia	
	Zabudowa	815	2	0	0	45	862	0,055	
	Wody	0	4695	0	0	0	4695	0,000	
	Lasy	6	1	11662	9	0	11678	0,001	
	Roślinność	1	0	15	5043	1827	6886	0,268	
	Gleby odkryte	4	0	0	0	13950	13954	0,000	
Σ	826	4698	11677	5052	15822	38075	Ogólna dokładność	Wsp. Kappa	
Błąd nadmiaru	0,013	0,000	0,001	0,002	0,118	-	0,950	0,930	

Tabela 16. Macierz błędów klasyfikacji spektralno-teksturowej dla zdjęcia z 2003 roku z rzędu 24

		Klasy pól testowych							
Wyznaczone klasy	Rok 2003	Zabudowa [px]	Wody [px]	Lasy [px]	Roślinność [px]	Gleby odkryte [px]	Σ [px]	Błąd pominięcia	
	Zabudowa	3359	42	0	8	62	3471	0,030	
	Wody	0	2606	0	0	0	2606	0,000	
	Lasy	9	10	14601	9	0	14629	0,001	
	Roślinność	7	0	582	5516	82	6187	0,108	
	Gleby odkryte	47	0	0	0	5160	5207	0,009	
Σ	3422	2658	15183	5533	5304	32100	Ogólna dokładność	Wsp. Kappa	
Błąd nadmiaru	0,018	0,016	0,038	0,002	0,027	-	0,973	0,962	

Tabela 17. Macierz błędów klasyfikacji spektralno-teksturowej dla zdjęcia z 2003 roku z rzędu 25

		Klasy pól testowych						Σ [px]	Błąd pominięcia	
		Rok 2003	Zabudowa [px]	Wody [px]	Lasy [px]	Roślinność [px]	Gleby odkryte [px]			
Wyznaczone klasy	Zabudowa	2461	5	0	0	61	2527	0,026		
	Wody	0	5323	0	0	0	5323	0,000		
	Lasy	1	24	7181	1	1	7208	0,000		
	Roślinność	73	0	307	8067	3983	12430	0,351		
	Gleby odkryte	34	65	0	0	1739	1838	0,054		
	Σ	2569	5417	7488	8068	5784	29326	Ogólna dokładność	Wsp. Kappa	
	Błąd nadmiaru	0,042	0,013	0,041	0,000	0,699	-	0,845	0,798	

Tabela 18. Macierz błędów klasyfikacji spektralno-teksturowej dla zdjęcia z 2008 roku z rzędu 24

		Klasy pól testowych						Σ [px]	Błąd pominięcia	
		Rok 2008	Zabudowa [px]	Wody [px]	Lasy [px]	Roślinność [px]	Gleby odkryte [px]			
Wyznaczone klasy	Zabudowa	1469	1	0	0	0	1470	0,001		
	Wody	59	2359	0	0	0	2418	0,000		
	Lasy	66	1	15517	0	0	15584	0,000		
	Roślinność	0	0	0	10656	0	10656	0,000		
	Gleby odkryte	596	0	29	0	6390	7015	0,085		
	Σ	2190	2361	15546	10656	6390	37143	Ogólna dokładność	Wsp. Kappa	
	Błąd nadmiaru	0,302	0,001	0,002	0,000	0,000	-	0,980	0,971	

Tabela 19. Macierz błędów klasyfikacji spektralno-teksturowej dla zdjęcia z 2008 roku z rzędu 25

		Klasy pól testowych						Σ [px]	Błąd pominięcia	
		Rok 2008	Zabudowa [px]	Wody [px]	Lasy [px]	Roślinność [px]	Gleby odkryte [px]			
Wyznaczone klasy	Zabudowa	2175	33	2328	0	37	4573	0,015		
	Wody	18	3691	0	0	2	3711	0,001		
	Lasy	42	38	7157	0	64	7301	0,014		
	Roślinność	0	0	2	7282	162	7446	0,022		
	Gleby odkryte	53	0	0	0	13806	13859	0,004		
	Σ	2288	3762	9487	7282	14071	36890	Ogólna dokładność	Wsp. Kappa	
	Błąd nadmiaru	0,042	0,019	0,000	0,000	0,019	-	0,925	0,899	

Tabela 20. Macierz błędów klasyfikacji spektralno-teksturowej dla zdjęcia z 2013 roku z rzędu 24

		Klasy pól testowych							
Wyznaczone klasy	Rok 2013	Zabudowa [px]	Wody [px]	Lasy [px]	Roślinność [px]	Gleby odkryte [px]	Σ [px]	Błąd pominięcia	
	Zabudowa	1578	21	0	0	1	1600	0,014	
	Wody	0	927	0	0	0	927	0,000	
	Lasy	0	0	4745	44	58	4847	0,021	
	Roślinność	0	0	0	6507	0	6507	0,000	
	Gleby odkryte	0	0	2	0	5278	5280	0,000	
Σ	1578	948	4747	6551	5337	19161	Ogólna dokładność	Wsp. Kappa	
Błąd nadmiaru	0,000	0,022	0,000	0,007	0,011	-	0,993	0,991	

Tabela 21. Macierz błędów klasyfikacji spektralno-teksturowej dla zdjęcia z 2013 roku z rzędu 25

		Klasy pól testowych							
Wyznaczone klasy	Rok 2013	Zabudowa [px]	Wody [px]	Lasy [px]	Roślinność [px]	Gleby odkryte [px]	Σ [px]	Błąd pominięcia	
	Zabudowa	783	1	0	0	91	875	0,105	
	Wody	0	6047	0	0	0	6047	0,000	
	Lasy	0	1	6244	9	0	6254	0,002	
	Roślinność	43	0	153	9285	31	9512	0,024	
	Gleby odkryte	16	0	0	24	5367	5407	0,007	
Σ	842	6049	6397	9318	5489	28095	Ogólna dokładność	Wsp. Kappa	
Błąd nadmiaru	0,070	0,000	0,024	0,004	0,022	-	0,987	0,983	

Tabela 22. Macierz błędów klasyfikacji spektralno-teksturowej dla zdjęcia z 2018 roku z rzędu 24

		Klasy pól testowych							
Wyznaczone klasy	Rok 2018	Zabudowa [px]	Wody [px]	Lasy [px]	Roślinność [px]	Gleby odkryte [px]	Σ [px]	Błąd pominięcia	
	Zabudowa	2845	0	0	0	5	2850	0,002	
	Wody	0	2887	0	0	0	2887	0,000	
	Lasy	0	0	15539	53	0	15592	0,003	
	Roślinność	2	0	277	12218	0	12497	0,022	
	Gleby odkryte	23	5	0	0	14727	14755	0,000	
Σ	2870	2892	15816	12271	14732	48581	Ogólna dokładność	Wsp. Kappa	
Błąd nadmiaru	0,009	0,002	0,018	0,004	0,000	-	0,992	0,990	

Tabela 23. Macierz błędów klasyfikacji spektralno-teksturowej dla zdjęcia z 2018 roku z rzędu 25

		Klasy pól testowych							
Wyznaczone klasy	Rok 2018	Zabudowa [px]	Wody [px]	Lasy [px]	Roślinność [px]	Gleby odkryte [px]	Σ [px]	Błąd pominięcia	
	Zabudowa	940	0	0	0	0	940	0,000	
	Wody	0	3525	0	0	0	3525	0,000	
	Lasy	3	0	3760	715	0	4478	0,160	
	Roślinność	0	0	4	9417	0	9421	0,000	
	Gleby odkryte	13	0	0	0	13375	13388	0,000	
	Σ	956	3525	3764	10132	13375	31752	Ogólna dokładność	Wsp. Kappa
	Błąd nadmiaru	0,017	0,000	0,001	0,071	0,000	-	0,977	0,967

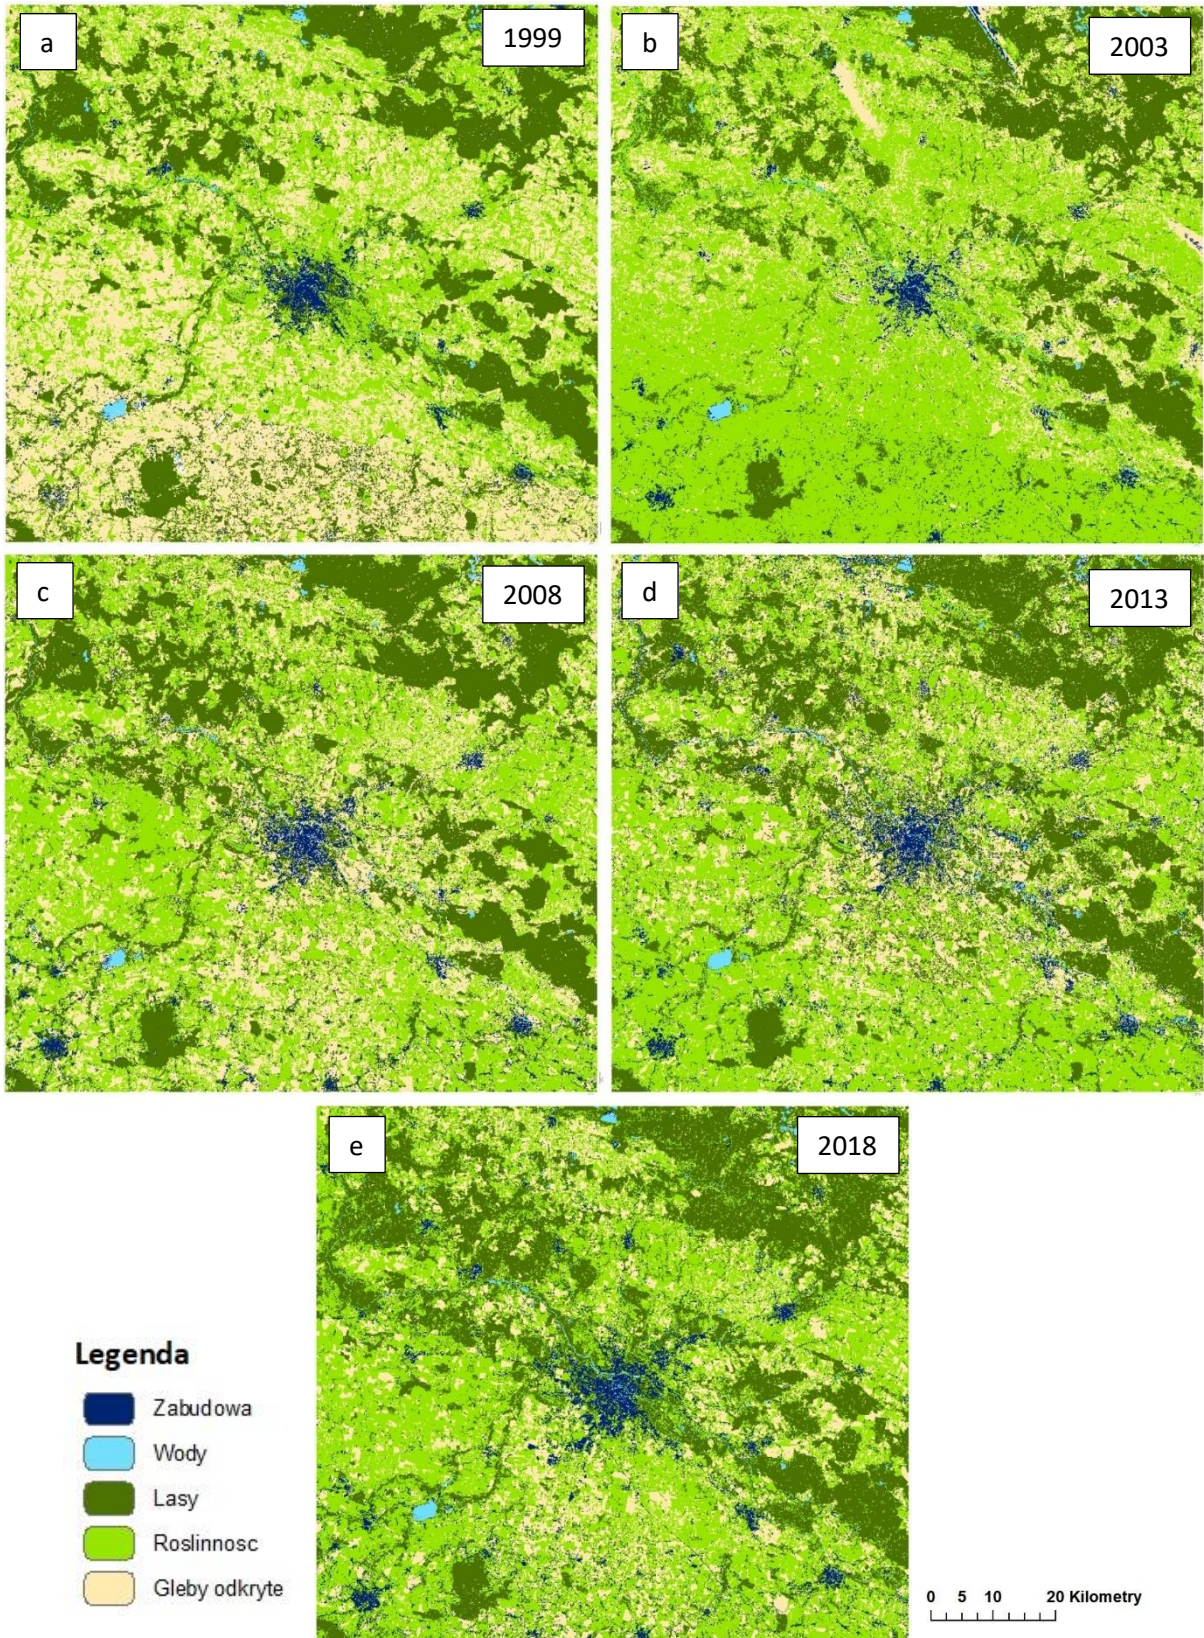
5.4. Zestawienie wyników klasyfikacji

Przed przystąpieniem do tworzenia analiz rozwoju zabudowy porównano wyniki obu klasyfikacji dla każdego zdjęcia. Ogólne dokładności i współczynniki Kappa dla połowy obrazów (zdjęć nr 2, 5, 6, 8 i 10) miały wyższe wartości dla klasyfikacji spektralnej. Jednocześnie wszystkie zdjęcia, z wyjątkiem zdjęcia z 2013 roku (nr 8), wykazały wyższą dokładność przyporządkowania terenów zabudowanych dla klasyfikacji spektralno-teksturowej. Jest to spowodowane uwzględnieniem tekstury w procesie klasyfikacji, istotnej dla identyfikacji tego rodzaju klas, które charakteryzują się nie tylko cechami spektralnymi, ale również teksturowymi. Z tego powodu do końcowych analiz użyto wszystkie obrazy pochodzące z klasyfikacji spektralno-teksturowej, także wspomniane zdjęcie z 2013 r., którego różnice dokładności między klasyfikacjami nie są znaczące, a pozwoliło to na ujednolicenie wykonania badań.

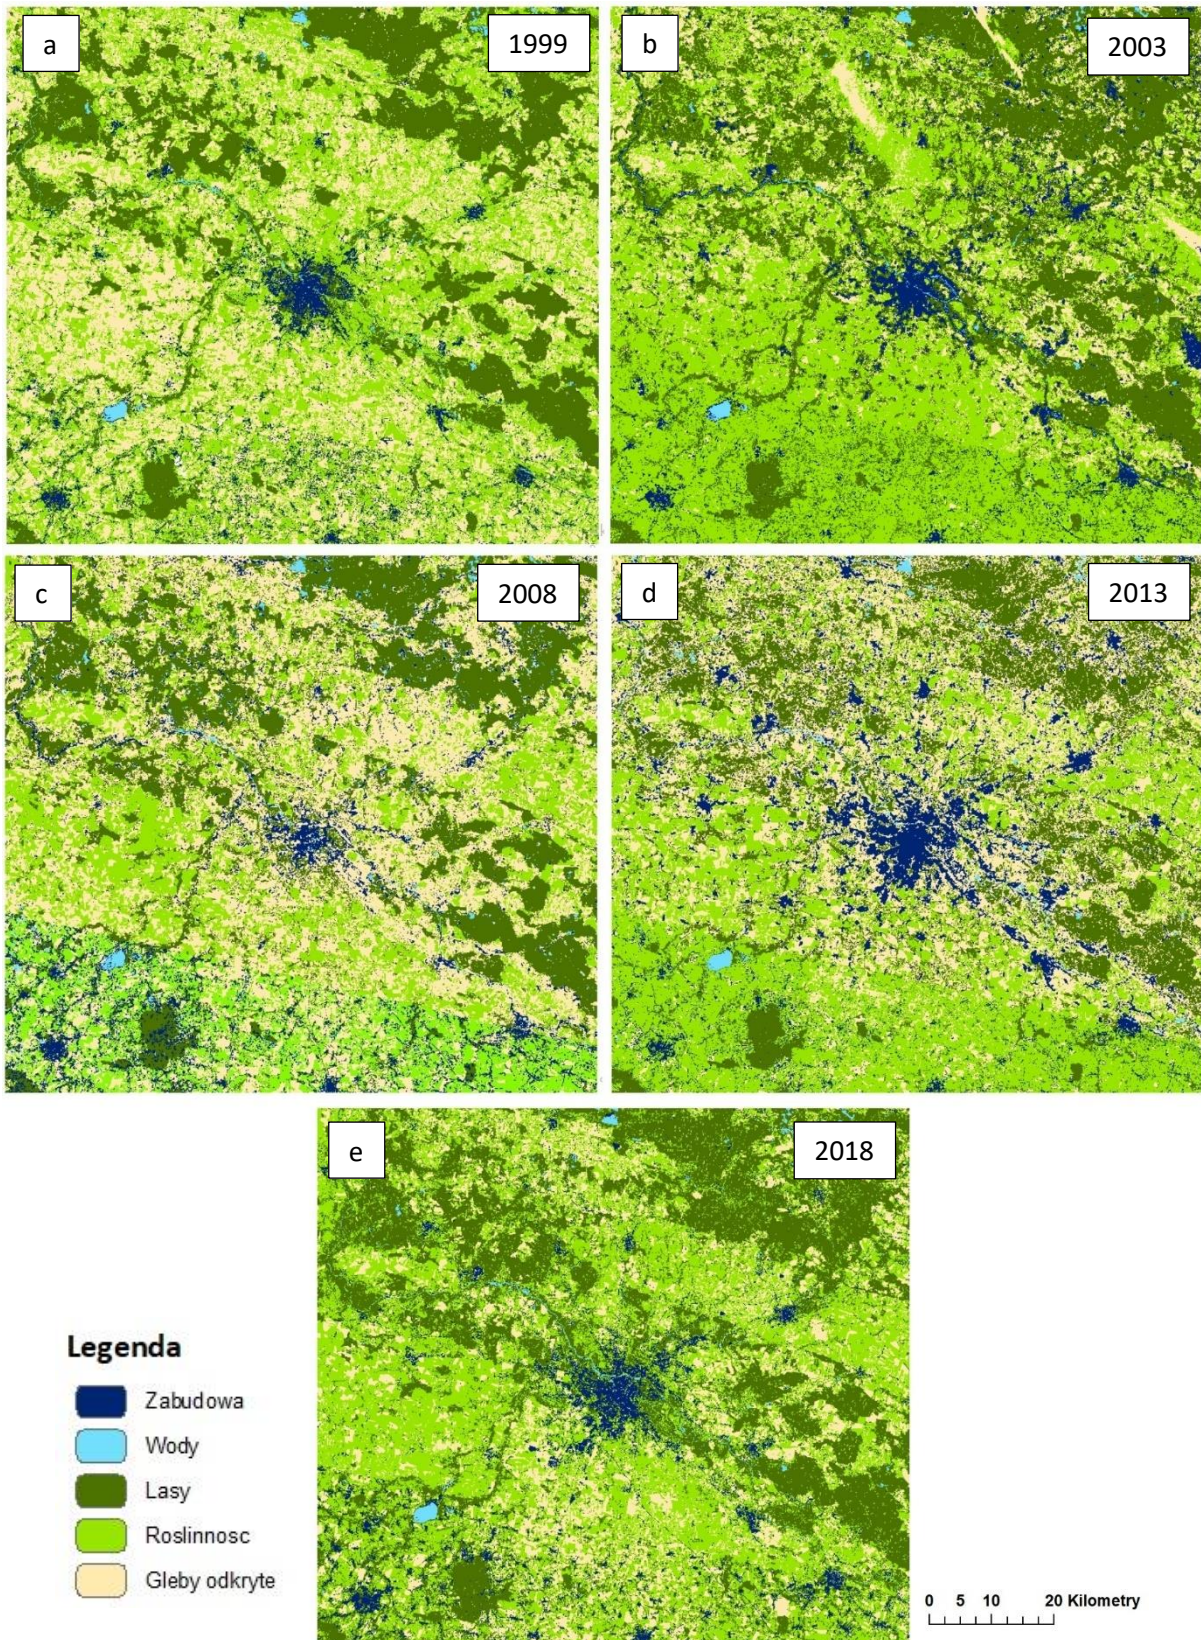
Wyniki klasyfikacji spektralnej i spektralno-teksturowej (Tab. 9.) wraz z prezentacją wizualną (Rys. 17. i 18.):

Tabela 24. Zestawienie wyników klasyfikacji spektralnej i spektralno-teksturowej

Zdjęcie	Rok	Błąd pominięcia klasy zabudowy	Błąd nadmiaru klasy zabudowy	Współczynnik Kappa	Ogólna dokładność
Klasyfikacja spektralna					
1	1999	0,052	0,077	0,982	0,988
2		0,003	0,562	0,980	0,986
3	2003	0,015	0,063	0,928	0,949
4		0,167	0,080	0,789	0,838
5	2008	0,000	0,209	0,982	0,988
6		0,182	0,075	0,970	0,978
7	2013	0,050	0,186	0,961	0,971
8		0,092	0,061	0,985	0,989
9	2018	0,000	0,161	0,975	0,982
10		0,012	0,045	0,997	0,998
Klasyfikacja spektralno-teksturowa					
1	1999	0,075	0,020	0,984	0,989
2		0,055	0,013	0,930	0,950
3	2003	0,030	0,018	0,962	0,973
4		0,026	0,042	0,798	0,845
5	2008	0,001	0,302	0,971	0,980
6		0,015	0,042	0,899	0,925
7	2013	0,014	0,000	0,991	0,993
8		0,105	0,070	0,983	0,987
9	2018	0,002	0,009	0,990	0,992
10		0,000	0,017	0,967	0,977



Rysunek 17. Zestawienie połączonych wyników obrazów klasyfikacji spektralnej dla lat: 1999 (a), 2003 (b), 2008 (c), 2013 (d), 2018 (e)



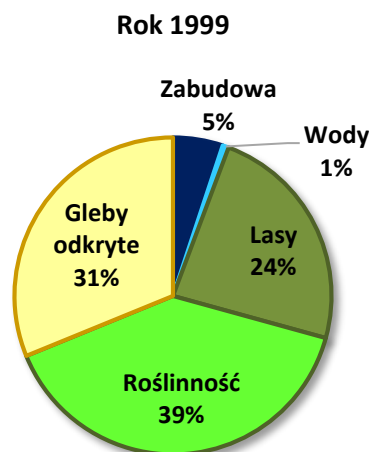
Rysunek 18. Zestawienie połączonych wynikowych obrazów klasyfikacji spektralno-teksturowej dla lat: 1999 (a), 2003 (b), 2008 (c), 2013 (d), 2018 (e)

6. Analiza otrzymanych wyników

Ostatecznym etapem projektu było wzajemne porównanie sklasyfikowanych zdjęć z każdego okresu. Jak wspomniano, do dalszego opracowania wykorzystano obrazy z klasyfikacji spektralno-teksturowej, ze względu na lepsze dokładności. Poniżej przedstawiono zestawienie informacji uzyskanych z tych obrazów (Tab. 10.). Mniejszy obszar w roku 1999 jest spowodowany częściowym zachmurzeniem obszaru, a terenów zachmurzonych nie uwzględniono w zestawieniach.


Tabela 25. Zestawienie powierzchni klas w poszczególnych latach, na podstawie obrazów klasyfikacji spektralno-teksturowej

Lata	Zabudowa [ha]	Wody [ha]	Lasy [ha]	Roślinność [ha]	Gleby [ha]	Powierzchnia całkowita [ha]
1999	35196	4329	163156	273771	215796	692248
2003	42306	4218	246644	298891	101120	693177
2008	47495	8538	186035	192639	258471	693177
2013	68895	4886	175927	215156	228313	693177
2018	74398	4034	248940	246325	119480	693177




Rysunek 19. Udział procentowy powierzchni każdej klasy w obszarze aglomeracji wrocławskiej w 1999 roku

Rok 2003



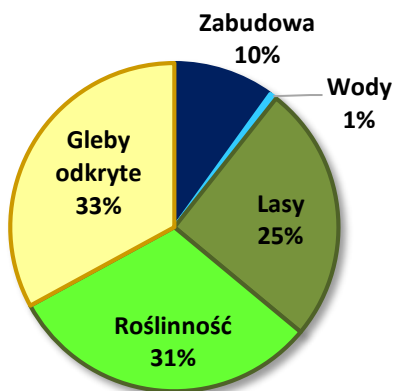
Rysunek 20. Udział procentowy powierzchni każdej klasy w obszarze aglomeracji wrocławskiej w 2003 roku

Rok 2008




Rysunek 21. Udział procentowy powierzchni każdej klasy w obszarze aglomeracji wrocławskiej w 2008 roku

Rok 2013

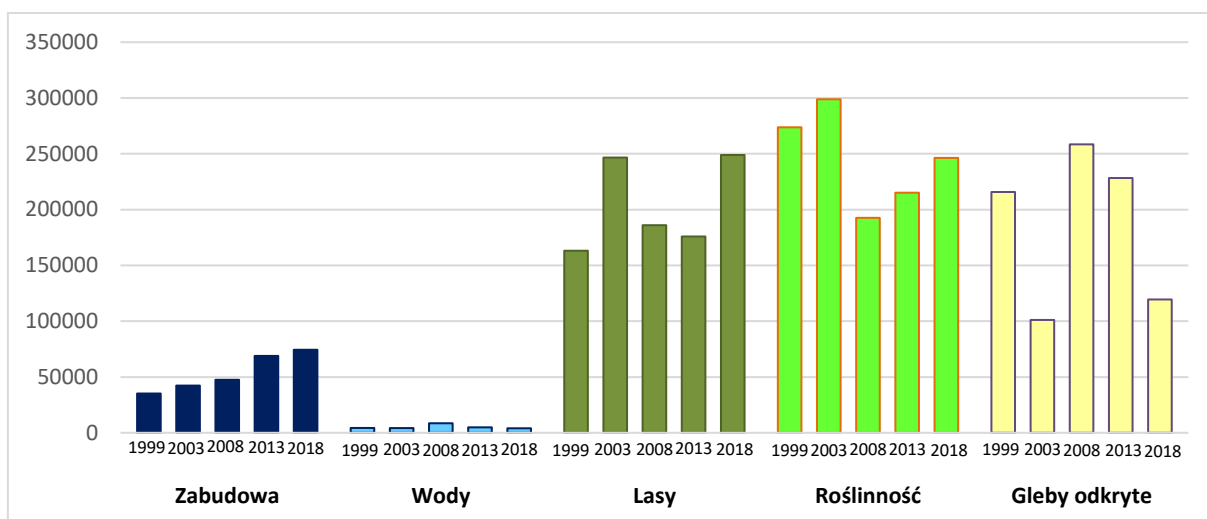


Rysunek 22. Udział procentowy powierzchni każdej klasy w obszarze aglomeracji wrocławskiej w 2013 roku

Rok 2018



Rysunek 23. Udział procentowy powierzchni każdej klasy w obszarze aglomeracji wrocławskiej w 2018 roku



Rysunek 24. Porównanie powierzchni każdej klasy w danych latach

Analizując podane wyniki można stwierdzić, że:

- na podstawie wyników ze skrajnych dat, tj. z roku 1999 i 2018, obszary zabudowane pomiędzy tymi latami ponad dwukrotnie powiększyły pole powierzchni. Oznacza powiększenie się miast o ponad 100% w ciągu ostatnich 19 lat.
- największy rozwój obszarów miejskich zaobserwowano w latach 2008-2013, natomiast najmniejszy, choć wciąż wyraźny, w ostatnich latach (2013-2018).
- ze względu na to, że obszary leśne nie zmniejszyły swojej powierzchni, a wręcz wyniki wskazują na jej wzrost, można wywnioskować, że obszary zabudowy w największym stopniu powiększyły się kosztem gruntów rolnych
- niewielkie wahania wielkości powierzchni wód, poza przyczyną niewystarczającej dokładności klasyfikacji, mogą być spowodowane częstymi powodziąmi w tamtych rejonach

7. Podsumowanie i wnioski

Opracowany projekt miał na celu analizę rozwoju aglomeracji wrocławskiej, na podstawie danych satelitarnych systemu Landsat, w okresie 1999-2018, wykorzystując metody klasyfikacji spektralnej oraz spektralno-teksturowej. Sprawdzono, która metoda klasyfikacji daje korzystniejsze wyniki i ustalono, że uwzględnienie dodatkowej cechy obrazu jaką jest tekstura, wspomaga proces odpowiedniego przyporządkowania pikseli do ustalonych klas, choć w niewielkim stopniu, ze względu na małą rozdzielczość przestrzenną obrazu.

Dodatkowo potwierdzono większą dokładność metody wektorów nośnych nad metodą największego prawdopodobieństwa, uznawaną za jedną z dokładniejszych reguł decyzyjnych.

Ostatecznie porównano obrazy, stanowiące produkt klasyfikacji spektralno-teksturowej, ukazujące stan pokrycia i użytkowania terenu dla wybranych pięciu lat w badanym okresie. Na podstawie wyników ilościowych porównania oraz wizualnej oceny obrazów stwierdzono znaczne powiększenie się obszarów miejskich. Z wyjątkiem intensywnej zmiany powierzchni między rokiem 2008 a 2013, procesy urbanizacji na terenie aglomeracji przebiegały w sposób jednostajny. Nie zauważono spadku powierzchni lasów, co potwierdza prowadzenie przez władze miejscowości wchodzących w skład aglomeracji wrocławskiej polityki zrównoważonego rozwoju uwzględniającej dbanie o środowisko naturalne. Zwrócono uwagę na zróżnicowane w różnych latach pola powierzchni terenów zajmowanych przez wody powierzchniowe. Może mieć to związek z częstymi powodziąmi, które mają miejsce na tamtych terenach.

Pozyskane w analizach informacje pozwoliły na zaobserwowanie zmian w sytuacji przestrzennej aglomeracji wrocławskiej i pozwoliły lepiej zrozumieć procesy zachodzące na tym obszarze.

8. Bibliografia

Materiały drukowane:

1. Benediktsson J. A., Ghamisi P., Spectral-Spatial Classification of Hyperspectral Remote Sensing Images, Artech House, Boston; London, 2015, s. 34-35 i 37.
2. Borsa M., Zagajewski B., Kulawik B., Teledetekcja w planowaniu przestrzennym, Warszawa, 2017, s. 114-117.
3. Ciołkosz A., Teledetekcja satelitarna źródłem informacji o obiektach, zjawiskach i procesach zachodzących na Ziemi, Nauka 4/2005.
4. Drzewiecki W., Monitoring zmian pokrycia i użytkowania terenu na podstawie wieloczasowych obrazów teledetekcyjnych, Roczniki Geomatyki, T. VI, zeszyt 3, 2008, s. 131-134.
5. Gabinecka M., Od aerofotografii do teledetekcji – czyli jak sięgnąć po kosmiczne informacje, Tutoring Gedanensis 2(1), 2017, s. 47-49.
6. Jucha W., Krocak R., Porównanie danych o użytkowaniu terenu z programu CORINE Land Cover z danymi uzyskanymi z ortofotomap, s. 123-125.
7. Kośnik P., Porównanie klasyfikacji zdjęć satelitarnych metodą kontekstualną „high-low” z metodą pikselową jako narzędzia do tworzenia map pokrycia terenu na potrzeby planowania przestrzennego., Praca dyplomowa magisterska, Warszawa, 2011.
8. Kupidura P., Morfologia matematyczna w teledetekcji, Wydawnictwo Naukowe PWN, Warszawa, 2010, s. 16-28.
9. Kupidura P., Wykorzystanie granulometrii obrazowej w klasyfikacji treści zdjęć satelitarnych, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa, 2015, s. 3-16.
10. Marcinkowska-Ochytra A., Ocena przydatności obrazów hiperspektralnych APEX oraz maszyn wektorów nośnych (SVM) do klasyfikacji roślinności subalpejskiej i alpejskiej Karkonoszy, Rozprawa doktorska w zakresie nauk o Ziemi, Warszawa, 2016, s. 37.
11. Mularz S., Podstawy teledetekcji, Wydawnictwo PK, Kraków, 2004, s. 7-10 i 52.
12. Zakrzewska-Półtorak A., Mempel-Śnieżyk A., Miszczak K., Analiza stanu i procesów integracji społeczno-gospodarczej, instytucjonalnej i przestrzennej regionu, Dokonanie analizy dotyczącej koegzystencji funkcji ochronnych oraz rozwoju systemów komunikacji i sieci infrastruktury w województwie dolnośląskim, Wrocław, 2010, s. 110-111.
13. Węclawowicz G., Łotocka M., Baucz A., Rozwój miast w Polsce, Raport wprowadzający ministerstwa Rozwoju Regionalnego, Warszawa, 2010, s. 1-14.

Strony internetowe:

1. Ludność, s. 79, źródło:
http://wroclaw.stat.gov.pl/files/gfx/wroclaw/pl/defaultstronaopisowa/1880/1/2/dzial_05_ludnosc.pdf
2. Copernicus (GMES), źródło: <http://geoserwisy.pl/vademecum/Vademecum-1/C/Copernicus-%28GMES%29-3/>
3. <https://sjp.pl/klasyfikacja>, dostęp: 22.10.2018
4. <https://www.nrcan.gc.ca/node/9373>, dostęp: 29.12.2018
5. <http://clc.gios.gov.pl/index.php/clc-2018/statystyki>, dostęp: 29.12.2018
6. <https://www.usgs.gov/land-resources/nli/landsat>, dostęp: 29.12.2018
7. <https://landsat.gsfc.nasa.gov>, dostęp: 29.12.2018

Wykaz symboli i skrótów

Symbole

m	metr
km	kilometr
b	bit
px	piksel
ha	hektar
Σ	suma

Skróty

ZSRR	Związek Socjalistycznych Republik Radzieckich
USA	Stany Zjednoczone Ameryki (United States of America)
RBV	zestaw kamer widikonowych umieszczonych na satelitach (Return-Beam Vidicon)
MSS	skaner wielospektralny (Multi-Spectral Scanner)
ETM	skaner wielospektralny (Enhanced Thematic Mapper)
OLI	operacyjny skaner wielospektralny (Operational Land Imager)
TIRS	skaner średniej podczerwieni (termalnej) (Thermal InfraRed Sensor)
SVM	Metoda Wektorów Nośnych (Support Vector Machine)
RGB	model przestrzeni barw (Red, Green, Blue)
PCA	analiza składowych głównych (Principal Component Analysis)

Spis rysunków

Rysunek 1. Wizualne porównanie kanałów spektralnych systemu Landsat (źródło: http://landsat.gsfc.nasa.gov/about/technical-information).....	9
Rysunek 2. Sposób działania granulometrii obrazowej z wykorzystaniem operacji otwarcia (Kupidura, 2015)...	13
Rysunek 3. Mapa, przedstawiająca położenie aglomeracji wrocławskiej w województwie dolnośląskim	14
Rysunek 4. Przykładowe dane wyjściowe wykorzystane do opracowania: zdjęcie z rzędu 24 (a) i z rzędu 25 (b) (źródło: http://earthexplorer.usgs.gov/).....	15
Rysunek 5. Fragment sceny satelitarnej satelity Landsat 7 z uszkodzonym czujnikiem z roku 2008 (źródło: http://earthexplorer.usgs.gov/)	16
Rysunek 6. Zdjęcia źródłowe w kompozycji RGB 453 (654) przycięte do obszaru opracowania dla lat: 1999 rząd 24 (a), i rząd 25 (b), 2003 rząd 24 (c) i rząd 25 (d), 2008 rząd 24 (e) i rząd 25 (f), 2013 rząd 24 (g) i rząd 25 (h) oraz 2018 rząd 24 (i) i rząd 25 (j)	17
Rysunek 7. Schemat, ilustrujący proces opracowania projektu; w nawiasach podano użyte na danych etapie oprogramowanie	19
Rysunek 8. Kompozycja barwna RGB 564 zdjęcia z Landsata 8 z roku 2018 z rzędu 24 wykorzystana w procesie klasyfikacji	20
Rysunek 9. Zdjęcie z roku 2018 z rzędu 24 w kompozycji RGB 321, przycięte do obszaru opracowania	23
Rysunek 10. Zdjęcie z roku 2018 z rzędu 25 w kompozycji RGB 321, przycięte do obszaru opracowania	23
Rysunek 11. Pola treningowe na przykładzie zdjęcia z 1999 roku z rzędu 24	24
Rysunek 12. Legenda do wyznaczonych pól treningowych, ukazująca podział na podklasy	24
Rysunek 13. Przykładowe histogramy pól treningowych zdjęcia nr 1 zgrupowane w 5 klas: zabudowę (a), wody (b), lasy (c), roślinność (d) i gleby odkryte (e).....	25
Rysunek 14. Wyniki klasyfikacji spektralnej zdjęcia z roku 2013 z rzędu 24 (a) przy użyciu: SVM (b) i metody największego prawdopodobieństwa (c) oraz klasyfikacji spektralno-teksturowej metodą SVM (d) i metodą największego prawdopodobieństwa (e).....	26
Rysunek 15. Zdefiniowane pola testowe na zdjęciu z 1999 roku z rzędu 24.....	27
Rysunek 16. Mapy granulometryczne zdjęcia z 2008 roku z rzędu 24 utworzone z funkcji otwarcia (a) i domknięcia (b).....	31
Rysunek 17. Zestawienie połączonych wynikowych obrazów klasyfikacji spektralnej dla lat: 1999 (a), 2003 (b), 2008 (c), 2013 (d), 2018 (e)	37
Rysunek 18. Zestawienie połączonych wynikowych obrazów klasyfikacji spektralno-teksturowej dla lat: 1999 (a), 2003 (b), 2008 (c), 2013 (d), 2018 (e).....	38
Rysunek 19. Udział procentowy powierzchni każdej klasy w obszarze aglomeracji wrocławskiej w 1999 roku... 39	39
Rysunek 20. Udział procentowy powierzchni każdej klasy w obszarze aglomeracji wrocławskiej w 2003 roku... 40	40
Rysunek 21. Udział procentowy powierzchni każdej klasy w obszarze aglomeracji wrocławskiej w 2008 roku... 40	40
Rysunek 22. Udział procentowy powierzchni każdej klasy w obszarze aglomeracji wrocławskiej w 2013 roku... 40	40
Rysunek 23. Udział procentowy powierzchni każdej klasy w obszarze aglomeracji wrocławskiej w 2018 roku... 41	41
Rysunek 24. Porównanie powierzchni każdej klasy w danych latach.....	41
Rysunek 25. Mapy granulometryczne zdjęcia z 1999 roku z rzędu 24 utworzone z funkcji otwarcia (a) i domknięcia (b).....	49
Rysunek 26. Mapy granulometryczne zdjęcia z 1999 roku z rzędu 25 utworzone z funkcji otwarcia (a) i domknięcia (b).....	49
Rysunek 27. Mapy granulometryczne zdjęcia z 2003 roku z rzędu 24 utworzone z funkcji otwarcia (a) i domknięcia (b).....	49
Rysunek 28. Mapy granulometryczne zdjęcia z 2003 roku z rzędu 25 utworzone z funkcji otwarcia (a) i domknięcia (b).....	50
Rysunek 29. Mapy granulometryczne zdjęcia z 2008 roku z rzędu 24 utworzone z funkcji otwarcia (a) i domknięcia (b).....	50

Rysunek 30. Mapy granulometryczne zdjęcia z 2008 roku z rzędu 25 utworzone z funkcji otwarcia (a) i domknięcia (b)	50
Rysunek 31. Mapy granulometryczne zdjęcia z 2013 roku z rzędu 24 utworzone z funkcji otwarcia (a) i domknięcia (b)	51
Rysunek 32. Mapy granulometryczne zdjęcia z 2013 roku z rzędu 25 utworzone z funkcji otwarcia (a) i domknięcia (b)	51
Rysunek 33. Mapy granulometryczne zdjęcia z 2018 roku z rzędu 24 utworzone z funkcji otwarcia (a) i domknięcia (b)	51
Rysunek 34. Mapy granulometryczne zdjęcia z 2018 roku z rzędu 25 utworzone z funkcji otwarcia (a) i domknięcia (b)	52

Spis tabel


Tabela 1. Charakterystyka poszczególnych generacji satelitów Landsat	10
Tabela 2. Szczegółowe informacje o wykorzystanych w projekcie danych obrazowych	16
Tabela 3. Porównanie wyników klasyfikacji spektralnej i spektralno-teksturowej z wykorzystaniem metody SVM i metody największego prawdopodobieństwa	25
Tabela 4. Macierz błędów klasyfikacji spektralnej dla zdjęcia z 1999 roku z rzędu 24	28
Tabela 5. Macierz błędów klasyfikacji spektralnej dla zdjęcia z 1999 roku z rzędu 25	28
Tabela 6. Macierz błędów klasyfikacji spektralnej dla zdjęcia z 2003 roku z rzędu 24	28
Tabela 7. Macierz błędów klasyfikacji spektralnej dla zdjęcia z 2003 roku z rzędu 25	29
Tabela 8. Macierz błędów klasyfikacji spektralnej dla zdjęcia z 2008 roku z rzędu 24	29
Tabela 9. Macierz błędów klasyfikacji spektralnej dla zdjęcia z 2008 roku z rzędu 25	29
Tabela 10. Macierz błędów klasyfikacji spektralnej dla zdjęcia z 2013 roku z rzędu 24	30
Tabela 11. Macierz błędów klasyfikacji spektralnej dla zdjęcia z 2013 roku z rzędu 25	30
Tabela 12. Macierz błędów klasyfikacji spektralnej dla zdjęcia z 2018 roku z rzędu 24	30
Tabela 13. Macierz błędów klasyfikacji spektralnej dla zdjęcia z 2018 roku z rzędu 25	31
Tabela 14. Macierz błędów klasyfikacji spektralno-teksturowej dla zdjęcia z 1999 roku z rzędu 24	32
Tabela 15. Macierz błędów klasyfikacji spektralno-teksturowej dla zdjęcia z 1999 roku z rzędu 25	32
Tabela 16. Macierz błędów klasyfikacji spektralno-teksturowej dla zdjęcia z 2003 roku z rzędu 24	32
Tabela 17. Macierz błędów klasyfikacji spektralno-teksturowej dla zdjęcia z 2003 roku z rzędu 25	33
Tabela 18. Macierz błędów klasyfikacji spektralno-teksturowej dla zdjęcia z 2008 roku z rzędu 24	33
Tabela 19. Macierz błędów klasyfikacji spektralno-teksturowej dla zdjęcia z 2008 roku z rzędu 25	33
Tabela 20. Macierz błędów klasyfikacji spektralno-teksturowej dla zdjęcia z 2013 roku z rzędu 24	34
Tabela 21. Macierz błędów klasyfikacji spektralno-teksturowej dla zdjęcia z 2013 roku z rzędu 25	34
Tabela 22. Macierz błędów klasyfikacji spektralno-teksturowej dla zdjęcia z 2018 roku z rzędu 24	34
Tabela 23. Macierz błędów klasyfikacji spektralno-teksturowej dla zdjęcia z 2018 roku z rzędu 25	35
Tabela 9. Zestawienie wyników klasyfikacji spektralnej i spektralno-teksturowej	36
Tabela 10. Zestawienie powierzchni klas w poszczególnych latach, na podstawie obrazów klasyfikacji spektralno-teksturowej	39

Spis załączników


Załącznik 1 _____ 49

Załączniki


Załącznik 1




Rysunek 25. Mapy granulometryczne zdjęcia z 1999 roku z rzędu 24 utworzone z funkcji otwarcia (a) i domknięcia (b)




Rysunek 26. Mapy granulometryczne zdjęcia z 1999 roku z rzędu 25 utworzone z funkcji otwarcia (a) i domknięcia (b)




Rysunek 27. Mapy granulometryczne zdjęcia z 2003 roku z rzędu 24 utworzone z funkcji otwarcia (a) i domknięcia (b)




Rysunek 28. Mapy granulometryczne zdjęcia z 2003 roku z rzędu 25 utworzone z funkcji otwarcia (a) i domknięcia (b)




Rysunek 29. Mapy granulometryczne zdjęcia z 2008 roku z rzędu 24 utworzone z funkcji otwarcia (a) i domknięcia (b)




Rysunek 30. Mapy granulometryczne zdjęcia z 2008 roku z rzędu 25 utworzone z funkcji otwarcia (a) i domknięcia (b)




Rysunek 31. Mapy granulometryczne zdjęcia z 2013 roku z rzędu 24 utworzone z funkcji otwarcia (a) i domknięcia (b)



Rysunek 32. Mapy granulometryczne zdjęcia z 2013 roku z rzędu 25 utworzone z funkcji otwarcia (a) i domknięcia (b)



Rysunek 33. Mapy granulometryczne zdjęcia z 2018 roku z rzędu 24 utworzone z funkcji otwarcia (a) i domknięcia (b)



Rysunek 34. Mapy granulometryczne zdjęcia z 2018 roku z rzędu 25 utworzone z funkcji otwarcia (a) i domknięcia (b)