

ZBIGNIEW BOCHENEK

Instytut Geodezji i Kartografii

ANALIZA METOD KLASYFIKACJI OBSZARÓW MIEJSKICH ZOBRAZOWANYCH NA WYSKOROZDZIELCZYCH ZDJĘCIACH SATELITRANYCH*

ZARYS TREŚCI: W artykule zostały przedstawione wyniki prac nad utworzeniem metody cyfrowego klasyfikowania obszarów miejskich z wykorzystaniem wyskorozdzielczych obrazów satelitarnych. Przebadano różne sposoby cyfrowej klasyfikacji obrazów: metodę spektralnego zmieszania, metodę wykorzystującą miary tekstury obiektu, klasyfikację obiektową oraz metodę bazującą na zastosowaniu sieci neuronowych. Przedmiotem badań był fragment aglomeracji warszawskiej zobrazony na 3 typach obrazów satelitarnych: Landsat ETM+, Terra ASTER oraz QuickBird. W wyniku analiz sformułowano wnioski dotyczące optymalnego sposobu klasyfikowania obszarów miejskich pod względem zróżnicowania struktury miasta; w prezentowanej pracy była to metoda hybrydowa łącząca w sobie elementy analizy obiektowej oraz wykorzystania sieci neuronowych. Realizacja projektu badawczego (nr 4 T12E 043 26) została sfinansowana ze środków KBN.

1. WPROWADZENIE

Szczegółowa informacja dotycząca pokrycia terenu i użytkowania ziemi na obszarach miejskich stanowi podstawę do prawidłowego zarządzania tymi obszarami i sporządzania planów zagospodarowania przestrzennego. Środowisko miejskie jest dynamicznie rozwijającym się organizmem, podlegającym szybkim przeobrażeniom wywołanym rozwojem terenów zabudowanych i zmianami struktury miasta. Stąd też w celu charakterystyki obszarów miejskich oraz określania ich zmian optymalne staje się wykorzystanie danych teledetekcyjnych. Od dziesiątków lat stosuje się wielkoskalowe zdjęcia lotnicze do interpretacji miejskiego użytkowania ziemi i pokrycia terenu, wykorzystując w tym celu klasyczne metody analizy

* Praca wykonana w ramach projektu badawczego Komitetu Badań Naukowych nr 4 T12E 043 26

wizualnej treści zdjęć. Dotychczasowe zdjęcia satelitarne o rozdzielczości terenowej 20–30 metrów mają dość ograniczone zastosowanie w tych pracach ze względu na agregację niektórych charakterystycznych elementów środowiska miejskiego, aczkolwiek są stosowane do określania generalnych zmian na obszarach aglomeracji miejskich. Dopiero wprowadzenie na orbitę satelitów ze skanerami o bardzo wysokiej, metrowej rozdzielczości terenowej stwarza nowe możliwości otrzymywania szczegółowej informacji na temat pokrycia terenu i użytkowania ziemi na obszarach miejskich.

Obrazy z satelitów typu QuickBird czy Ikonos mogą być analizowane w sposób analogowy, poprzez interpretację obiektów terenowych na podstawie ich tonu, barwy, tekstury i wzajemnego usytuowania. Jednakże prawidłowa interpretacja miejskiego pokrycia terenu, jako proces w dużej mierze subiektywny, wymaga dużej wiedzy interpretatora. Dlatego też w ostatniej dekadzie podjęto działania służące opracowaniu metod klasyfikacji cyfrowej wysokorozdzielczych zdjęć satelitarnych. Podstawowym zagadnieniem w tego typu pracach jest utworzenie metodyki uwzględniającej w procesie klasyfikacji zdjęć oprócz informacji spektralnej również informacje przestrzenne, charakteryzujące kształt, wymiary, teksturę i wzajemne usytuowanie obiektów terenowych. W ostatnich latach w zachodnich ośrodkach naukowo-badawczych przeprowadzono wiele badań nad utworzeniem optymalnych algorytmów do numerycznej klasyfikacji środowiska miejskiego (Gong i in., 1992; Hung i in., 2002; Pesaresi i in.; 2001, Thomas i in., 2003; Wu i in., 2003). Dotychczasowe badania wykazują dużą zależność pomiędzy charakterem obszarów miejskich a typem stosowanych metod analizy i klasyfikacji obrazu.

Dlatego też w niniejszym projekcie podjęto próbę opracowania metodyki numerycznej klasyfikacji wysokorozdzielczych zdjęć satelitarnych w warunkach środowiska zurbanizowanego w Polsce, charakteryzującego się dużą różnorodnością form zabudowy na terenach nowych osiedli mieszkaniowych, występowaniem rozproszonego budownictwa wielokondygnacyjnego z dużą ilością zieleni miejskiej oraz stosunkowo niewielkimi obszarami zwartej zabudowy miejskiej zawierającej kompleksy przemysłowo-handlowe w granicach dzielnic centralnych. Przebadano różne typy danych satelitarnych oraz różne metody numerycznej analizy i klasyfikacji zdjęć, bazujące na najnowszych kierunkach badań, wykorzystujących m.in. analizę spektralnego zmieszania, klasyfikacji obiektowej i wielopoziomowej segmentacji obrazu. W efekcie tych prac sformułowano wnioski dotyczące przydatności poszczególnych metod dla potrzeb określania struktury miejskiego pokrycia terenu.

2. OPIS OBIEKTU BADAWCZEGO

Jako obiekt prac badawczych w niniejszym projekcie został wybrany fragment aglomeracji warszawskiej. Obejmuje on obszary północnej

i środkowej części aglomeracji: w całości dzielnicę Śródmieście oraz fragmenty dzielnic Żoliborz, Bielany, Wola, Bemowo, Mokotów, Ochota, Włochy i Praga Północ. Obiekt badawczy jest usytuowany południkowo pomiędzy 20° 54' 44'' i 21° 02' 00'' długości geograficznej wschodniej oraz równoleżnikowo pomiędzy 52° 12' 10'' i 52° 16' 50'' szerokości geograficznej północnej. Obejmuje obszar o wymiarach ok. 8 x 8 km. Szczegółowy zasięg wybranego do badań fragmentu Warszawy został podyktowany dostępnością wysokorozdzielczych obrazów satelitarnych dla obszaru aglomeracji warszawskiej.

Wybrany obiekt charakteryzuje się dużą różnorodnością form pokrycia terenu i użytkowania ziemi. W granicach obiektu występują różne typy zespołów urbanistycznych: obszary zwartej zabudowy wielkomiejskiej, zespoły regularnej, wielokondygnacyjnej zabudowy mieszkaniowej reprezentowanej przez starsze dzielnice mieszkaniowe, tereny z luźną zabudową wielokondygnacyjną reprezentowane przez nowe osiedla mieszkaniowe oraz obszary luźnej niskiej zabudowy jednorodzinnej typu miejskiego. W ramach obiektu badawczego znajdują się duże obiekty przemysłowe i handlowe oraz tereny związane z infrastrukturą drogową i kolejową. Część obiektu pokrywają zantropogenizowane tereny zielone: parki miejskie, skwery, zieleńce, ogrody działkowe oraz cmentarze; występują także tereny nieużytkowane gospodarczo. W granicach obiektu znajdują się naturalne obszary trawiaste i zakrzaczone oraz rzeki i zbiorniki wodne.

Występowanie różnorodnych form miejskiego pokrycia terenu, podlegających w przypadku aglomeracji warszawskiej dynamicznym przekształceniom na skutek rozwoju nowych osiedli mieszkaniowych i zmianom struktury miasta, uzasadnia wybór opisanego fragmentu Warszawy jako obiektu badawczego. Dodatkowym atutem tego obiektu jest także możliwość szybkiej kontroli terenowej wyników analiz i klasyfikacji zdjęć satelitarnych w przypadkach wymagających ich bezpośredniego sprawdzenia.

3. MATERIAŁY WYKORZYSTYWANE W PRACACH BADAWCZYCH

W ramach niniejszego projektu postanowiono przebadать przydatność kilku typów danych satelitarnych do klasyfikacji miejskiego pokrycia terenu, charakteryzujących się różną rozdzielczością przestrzenną i spektralną. Do badań wybrano trzy rodzaje danych pochodzących z satelitów środowiskowych Landsat, Terra i QuickBird. Dane techniczne dotyczące charakterystyk spektralnych radiometrów umieszczonych na pokładach tych satelitów oraz daty rejestracji obrazów wykorzystywanych w pracach badawczych zostały podane w tabeli 1.

Tabela 1. Charakterystyka i daty rejestracji obrazów satelitarnych wykorzystywanych w pracach badawczych

Satelita	Radiometr	Daty rejestracji	Zakres spektralny μm	Rozdzielczość m
Landsat	ETM+	7.05.2000	0.45–0.52	30
			0.52–0.60	30
			0.63–0.69	30
			0.76–0.90	30
			1.55–1.75	30
			2.08–2.35	30
			10.4–12.5	60
			0.52–0.90 (PAN)	15
Terra	ASTER	4.05.2002	0.52–0.60	15
			0.63–0.69	15
			0.76–0.86	15
			1.600–1.700	30
			2.145–2.185	30
			2.185–2.225	30
			2.235–2.285	30
			2.295–2.365	30
			2.360–2.430	30
			8.125–8.475	90
			8.475–8.825	90
			8.925–9.275	90
			10.25–10.95	90
			10.95–11.65	90
QuickBird	QuickBird	9.05.2002	0.45–0.52	2.8
			0.52–0.60	2.8
			0.63–0.69	2.8
			0.76–0.90	2.8
			0.45–0.90 (PAN)	0.7

W pierwszej fazie prac wszystkie trzy typy danych satelitarnych zostały poddane korekcji geometrycznej. Transformację oryginalnych obrazów przeprowadzono poprzez dostosowanie ich do mapy topograficznej w skali 1:25 000, opracowanej w odwzorowaniu Gaussa-Krügera układ 1942. Wykorzystywano afiniczny model transformacji, osiągając średni błąd dostosowania rzędu 0.5 piksela. Proces korekcji geometrycznej został przeprowadzony w środowisku oprogramowania Intergraph, umożliwiającego współpracę ze stołem digitalizacyjnym oraz w środowisku oprogramowania ENVI, zapewniającego transformację metodą „obraz do obrazu”.

Następnie przeprowadzono korekcję radiometryczną wykorzystywanych obrazów satelitarnych Landsat ETM+, ASTER i QuickBird. Wykorzystano w tym celu procedury kalibracji dla tych typów danych satelitarnych, zawarte w module oprogramowania ENVI 4.1. Tak przygotowane obrazy satelitarne posłużyły do dalszych prac w ramach niniejszego projektu, zmierzających do utworzenia optymalnej metody numerycznej klasyfikacji obszarów miejskich.

Metody bazujące na numerycznej analizie obrazów satelitarnych wymagają w procesie klasyfikowania wykorzystywania informacji o pokryciu terenu i użytkowaniu ziemi, które stanowiłyby materiał referencyjny do przeprowadzania etapów tzw. treningu i oceny wyników klasyfikacji. Aby taki materiał był wiarygodnym źródłem informacji, powinien być sporządzony na podstawie szczegółowej analizy zdjęć lotniczych i wiedzy o typach pokrycia terenu występujących na obszarze obiektu badawczego. Dlatego też w ramach niniejszego projektu zdecydowano się na opracowanie mapy pokrycia terenu i użytkowania ziemi na podstawie barwnych zdjęć lotniczych w skali 1:26 000, zarejestrowanych w maju 2001 roku dla obszaru Warszawy. Zdjęcia te zostały skorygowane do układu współrzędnych 1992 w Biurze Geodety Województwa Mazowieckiego. W Instytucie Geodezji i Kartografii dokonano połączenia zdjęć pokrywających obszar badawczy, tworząc jednorodny obraz będący podstawą procesu interpretacji. Tak przygotowany obraz został poddany analizie wizualnej w celu sporządzenia szczegółowej mapy pokrycia terenu i użytkowania ziemi. Tworząc legendę mapy, przyjęto założenie, że będzie ona odpowiadać szczegółowością czwartemu poziomowi legendy stosowanej w programie CORINE Land Cover, z uwzględnieniem specyfiki obszaru badań.

W wyniku interpretacji zdjęć lotniczych wyróżniono następujące kategorie pokrycia terenu/użytkowania ziemi:

- zabudowa zwarta miejska,
- stara wielorodzinna zabudowa mieszkaniowa,
- nowa wielorodzinna zabudowa mieszkaniowa,
- zabudowa jednorodzinna,
- tereny komunikacyjne,
- tereny przemysłowe i handlowe,
- drzewostany iglaste,
- drzewostany mieszane,
- drzewostany liściaste,
- obszary trawiaste,
- tereny rolnicze,
- obszary odkrytej gleby,
- ogrody działkowe,
- cmentarze,

- nieużytki,
- rzeki i zbiorniki wodne.

Łącznie wyróżniono 16 klas zgrupowanych w czterech głównych kategoriach: terenów zantropogenizowanych, terenów rolnych, drzewostanów i ekosystemów naturalnych oraz wód.

4. ANALIZA METOD CYFROWEJ KLASYFIKACJI MIEJSKIEGO POKRYCIA TERENU

4.1. Metoda spektralnego zmieszania

Dynamiczny rozwój aglomeracji miejskich, przejawiający się m.in. w zmianach w pokryciu terenu – z obszarów naturalnych do terenów antropogenicznych, wymaga szybkiej i dokładnej informacji o ewolucji tych terenów. Rozmieszczenie pokrycia powierzchni ziemi obiektami antropogenicznymi (budynki, tereny komunikacyjne, obiekty przemysłowe) ma istotne znaczenie dla oceny czynników społeczno-gospodarczych i tworzenia planów zagospodarowania przestrzennego. Istotne staje się także określanie dynamiki zmian obszarów aglomeracji miejskich. Największym archiwalnym zbiorem danych satelitarnych, mogących służyć do tego celu, są dane pochodzące z satelitów serii Landsat, charakteryzujące się 20-letnim okresem pozyskiwania oraz dobrą rozdzielczością spektralną. Dane z satelitów Landsat były w ostatnich latach wykorzystywane do studiów zmian miejskiego pokrycia terenu w kilku zachodnich ośrodkach naukowo-badawczych (Chen i in., 2002; Rashed T. i in., 2005; Small, 2003; Yang i in., 2003). Dlatego też w pierwszej fazie prac postanowiono wykorzystać tego typu dane do przebadania ich przydatności do klasyfikacji miejskiego pokrycia terenu.

Podstawowym problemem, jaki występuje przy wykorzystaniu obrazów satelitarnych Landsat ETM do klasyfikacji miejskiego pokrycia terenu jest ich rozdzielczość przestrzenna, wynosząca (dla danych wielospektralnych) 30 metrów. Powoduje ona zmieszanie sygnałów spektralnych pochodzących od niewielkich powierzchniowo obiektów infrastruktury miejskiej. Stąd też od połowy lat dziewięćdziesiątych poszukiwano metod i modeli, które mogłyby posłużyć do rozwiązania problemu. Ridd (1995) zaproponował parametryczny model charakteryzujący kompozycję elementów środowiska miejskiego, znany jako model V-I-S (*vegetation – impervious surface – soil*). W tym modelu każdy zobrazowany element środowiska miejskiego (np. piksel) składa się z trzech składowych – roślinności, powierzchni antropogenicznej i gleby. Do zważowania udziału tych składowych w powierzchni piksela i ich wpływu na sygnał spektralny stosuje się analizę spektralnego zmieszania (*spectral mixture analysis – SMA*). Analiza ta zakłada, iż wypadkowy sygnał spektralny jest kombinacją (liniową lub nieliniową) sygnałów elementarnych

reprezentantów pokrycia terenu, reprezentujących „czystą” charakterystykę spektralną, tzw. *endmembers* (Dennison i in., 2003; Roberts i in., 1998). Proces wyznaczania tych reprezentantów na podstawie danych wielospektralnych (lub hipspektralnych, czyli zarejestrowanych w kilkudziesięciu wąskich zakresach spektrum) składa się z następujących etapów:

1. Transformacja oryginalnych wielokanałowych danych spektralnych w celu redukcji wymiarów przestrzeni spektralnej (*Minimum Noise Fraction* – MNF)
Procedura ta jest stosowana w celu określenia wewnętrznej wymiarowości danych spektralnych, wykrycia w nich tzw. szumu i zredukowania wymagań obliczeniowych dotyczących dalszych etapów prac. Transformacja MNF wykorzystuje w tym celu dwa kaskadowe przetworzenia metodą składowych głównych (*Principal Component Analysis* – PCA). Pierwsze przetworzenie, oparte na macierzy kowariancji, dekoreluje szum w wyjściowych danych. W rezultacie otrzymujemy dane, w których szum ma jednostkową wariancję i nie występują korelacje międzykanałowe. Drugie przetworzenie to standardowa transformacja PCA dla danych po redukcji szumów. Wynikowe kanały po transformacji MNF są uszeregowane od największej do najmniejszej wariancji. W dalszych pracach wykorzystuje się kanały o największej wariancji.
2. Wyznaczenie indeksu czystości piksela (*Pixel Purity Index* – PPI)
Indeks czystości piksela służy do określania elementarnych reprezentantów klas pokrycia terenu, tzw. *endmembers*, lub ekstremalnych pikseli w danych wielospektralnych. Wyznacza się go poprzez iteracyjne nakładanie n-wymiarowych skaterogramów na losowy jednostkowy wektor. W wyniku tej procedury powstaje obraz rozkładu wskaźnika, w którym wartość piksela odpowiada liczbie zarejestrowanych przypadków ekstremalnych. Wartości te są wykorzystywane na następnym etapie prac.
3. Wizualizacja n-wymiarowa w celu wyboru „czystych” reprezentantów klas, tzw. *endmembers*.
N-wymiarowy wizualizer jest narzędziem interaktywnym służącym do znajdowania *endmembers* poprzez lokalizację „najczystszych” pikseli w przestrzeni n-wymiarowej. Współrzędne punktu w tej przestrzeni to wartości spektralne w poszczególnych kanałach. Wizualizer jest stosowany do obracania „chmury” pikseli i znajdowania jej narożników, które według założeń powinny reprezentować „najczystsze” piksele, czyli *endmembers*.

Po wykonaniu powyższej procedury i wyborze właściwych elementarnych reprezentantów klas pokrycia terenu wykorzystuje się jedną z trzech metod kartowania obrazu:

1. Kartowanie na podstawie kąta spektralnego (*Spectral Angle Mapper* – SAM)

W tej metodzie dopasowuje się charakterystyki spektralne obrazu do charakterystyk referencyjnych w przestrzeni n -wymiarowej, porównując kąty pomiędzy wektorami *endmembers* a wektorami poszczególnych pikseli. Małe kąty oznaczają dobre dopasowanie, czyli sklasyfikowanie piksela. Ta technika, stosowana do danych skalibrowanych, jest względnie niewrażliwa na efekty wywołane zmiennością oświetlenia.

2. Dopasowana filtracja (*Mixture-Tuned Matched Filtering* – MTMF)

W tej metodzie znajduje się skupienia *endmembers*, stosując odpowiedni filtr w celu zwiększenia odpowiedzi spektralnej znanych reprezentantów klas i zmniejszenia sygnału tła. Metoda ta pozwala na szybkie wykrycie głównych typów pokrycia i nie wymaga znajomości wszystkich *endmembers* na podstawie obrazu.

3. Liniowe rozmiksowanie spektralne (*Linear Spectral Unmixing*)

W metodzie tej znajduje się skupienia klas w obrazie, zakładając, że wartość radiometryczna piksela jest liniową kombinacją wartości elementarnych reprezentantów klas pokrycia terenu, obecnych w ramach tego piksela. Metoda ta bada liczebność każdego *endmember* w charakterystyce spektralnej piksela. Jakość wyników zastosowania metody zależy w dużym stopniu od jakości referencyjnych reprezentantów klas pokrycia terenu.

Opisana metoda została wykorzystana do analizy obrazu satelitarnego Landsat ETM. W analizie zastosowano zmodyfikowany model Ridda V-I-S, zakładając, iż każdy piksel obrazu jest wypadkową 4 elementarnych typów pokrycia terenu (*endmembers*), a mianowicie:

- typ pokrycia antropogenicznego o niskim albedo (np. asfalt, ciemne pokrycia dachów) + obszary wodne,
- typ pokrycia antropogenicznego o wysokim albedo (np. powierzchnie betonowe),
- typ pokrycia roślinnego (trawy, drzewostany),
- obszary odkrytej gleby.

Na badanym obszarze zostały wybrane pola reprezentujące poszczególne typy pokrycia terenu. We wstępnej fazie na podstawie tych pól przeprowadzono analizę rozdzielczości spektralnej klas, otrzymując wysokie wartości rozdzielczości (*Transformed Divergence*). Następnie wykonano pełną analizę spektralnego zmieszania, zgodnie z wymienionymi kolejnymi etapami procesu. W efekcie tych prac otrzymano trzy podstawowe typy obrazów klasyfikujących badany obszar według przyjętego podziału na 4 kategorie pokrycia terenu.

1. Obraz klasyfikujący teren według kryterium kąta spektralnego – SAM uzupełniony obrazami prawdopodobieństwa występowania poszczególnych typów pokrycia terenu.
2. Obrazy częstości występowania poszczególnych typów pokrycia terenu po wykonaniu dopasowanej filtracji – MTMF.
3. Obrazy częstości występowania poszczególnych typów pokrycia terenu po przeprowadzeniu liniowego spektralnego rozmiksowania – LSU.

Pierwsza metoda klasyfikacji nie dała zadowalających wyników: część obiektu badawczego nie została przydzielona do żadnej z 4 kategorii pokrycia terenu. Także druga metoda – dopasowanej filtracji – MTMF dostarczyła obrazów częstości występowania poszczególnych typów pokrycia terenu charakteryzujących się we fragmentach obrazu małym zróżnicowaniem względem tła. Stosunkowo najlepsze wyniki osiągnięto przy zastosowaniu metody liniowego spektralnego rozmiksowania – LSU. Efektem końcowym wykorzystania tej metody były obrazy częstości występowania poszczególnych elementarnych typów pokrycia terenu (*endmembers*). W celu scharakteryzowania gęstości zabudowy postanowiono wykorzystać obraz przedstawiający częstość występowania terenów zielonych w ramach pikseli obrazu Landsat ETM. Obraz ten podzielono na 5 klas częstości, odpowiadających następującym poziomom gęstości zabudowy:

- klasa 1 — gęstość zabudowy 80–100% (częstość występowania terenów zielonych 0–20%),
- klasa 2 — gęstość zabudowy 60–80% (częstość występowania terenów zielonych 20–40%),
- klasa 3 — gęstość zabudowy 40–60% (częstość występowania terenów zielonych 40–60%),
- klasa 4 — gęstość zabudowy 20–40% (częstość występowania terenów zielonych 60–80%),
- klasa 5 — gęstość zabudowy 0–20% (częstość występowania terenów zielonych 80–100%).

W celu określenia dokładności utworzonego obrazu klasyfikacyjnego dla wyżej wymienionych 5 klas gęstości zabudowy wybrano pola testowe. Do wyznaczenia tych pól wykorzystano zdjęcia lotnicze oraz wysokorozdzielczy obraz satelitarny QuickBird. Wybrano charakterystyczne fragmenty pokrycia terenu na obszarze Warszawy wyróżniające się odpowiednim procentowym udziałem terenów „czystej” zabudowy. Następnie dokonano oceny dokładności obrazu klasyfikacyjnego poprzez nałożenie pól testowych i wyznaczenie macierzy błędów. W efekcie tej oceny otrzymano stosunkowo wysoką dokładność przyporządkowania do 2 klas charakteryzujących się najwyższą gęstością zabudowy (klasa 1 – 80–100% i klasa 2 – 60–80%). Jednak w przypadku klas o niższej gęstości zabudowy dokładność rozpoznania była niska. Tak więc metoda spektralnego rozmiksowania oraz wykorzystanie obrazu częstości występowania terenów zielonych do

scharakteryzowania gęstości zabudowy ma zastosowanie ograniczone do obszarów ścisłej zabudowy śródmiejskiej i przemysłowej.

4.2. Metoda określania struktury obszarów miejskich za pomocą miar tekstury obiektu

W kolejnej fazie prac postanowiono zastosować metodę charakteryzującą obszar miejski za pomocą miar tekstury obiektu. Do przeprowadzenia analiz wykorzystano obraz ze skanera ASTER, charakteryzujący się w kanałach widzialnych i bliskiej podczerwieni rozdzielczością terenową 15 metrów oraz dużą rozdzielczością spektralną w zakresie średniej podczerwieni. Do wyznaczenia miar tekstury obiektu wykorzystano kanał bliskiej podczerwieni, zapewniający największe zróżnicowanie wartości odbicia na obszarach miejskich o różnej gęstości zabudowy.

Istnieje wiele metod określania tekstury obiektu (Herold i in., 2003); w niniejszej pracy postanowiono zastosować metodę macierzy *Gray-level Co-occurrence* (GLCM). Metoda GLCM jest aproksymacją funkcji gęstości probabilistycznej par pikseli; wykazuje małą wrażliwość na nietypowe wartości odbicia. Nadaje się dobrze do charakteryzowania tekstury obrazu, w którym występują nieregularne kształty elementów składowych. Na potrzeby niniejszych badań wyznaczono 7 miar tekstury obiektu: średnią, wariancję, jednorodność, kontrast, odmienność, entropię, korelację. Krótka charakterystyka tych miar została przedstawiona w tabeli 2.

Tabela 2. Charakterystyka miar tekstury obiektu

Miara tekstury	Charakterystyka
Średnia	Miara jednolitości obiektu; duże wartości występują dla obszarów o stałych lub powtarzalnych wartościach odbicia
Wariancja	Miara zróżnicowania; wariancja wzrasta, gdy wartości odbicia różnią się znacznie od średniej
Jednorodność	Miara ujednolicenia obrazu; wrażliwa na występowanie elementów wzdłuż przekątnej macierzy GLCM
Kontrast	Miara różnicy pomiędzy najwyższymi i najniższymi wartościami ciągłego zbioru pikseli. Niski kontrast cechuje obrazy o niewielkiej częstotliwości przestrzennej
Odmienność	Miara podobna do kontrastu; zamiast wagowania przekątnej wykładniczo wagi wzrastają liniowo
Entropia	Miara skorelowana ze średnią. Określa nieregularność w obrazie. Entropia jest wysoka, gdy obraz jest niejednorodny pod względem tekstury
Korelacja	Miara zależności pomiędzy elementami składowymi obrazu – pikselami

Aby określić przydatność metody określania struktury miasta za pomocą miar tekstury, na obszarze obiektu badawczego wybrano zestaw pól testowych reprezentujących 7 klas miejskiego pokrycia terenu. Były to następujące klasy:

- zabudowa zwarta miejska,
- stara wielorodzinna zabudowa mieszkaniowa,
- nowa wielorodzinna zabudowa mieszkaniowa,
- zabudowa jednorodzinna,
- tereny komunikacyjne,
- tereny przemysłowe i handlowe,
- obszary odkrytej gleby.

Następnie przeanalizowano rozdzielczość spektralną tych klas w obrazie, składającym się z 7 miar tekstury, wykorzystując w tym celu stosowaną uprzednio funkcję *Transformed Divergence*. W rezultacie tej analizy stwierdzono, że wysoką rozdzielczością spektralną charakteryzują się następujące klasy miejskiego pokrycia terenu:

- zabudowa zwarta miejska – zabudowa jednorodzinna,
- zabudowa zwarta miejska – nowa wielorodzinna zabudowa mieszkaniowa,
- tereny przemysłowe i handlowe – obszary odkrytej gleby,
- zabudowa zwarta miejska – obszary odkrytej gleby.

W trakcie prac badawczych przeanalizowano także przydatność drugiej metody analizy tekstury obiektu, tzw. macierzy zdarzeń (*occurrence matrix*). Ta metoda charakteryzuje się 5 miarami tekstury. Są to: średnia, wariancja, entropia, skośność i przedział danych. Zbadano przydatność tej metody, stosując ten sam zestaw pól testowych, który wykorzystano w metodzie GLCM. W wyniku analizy rozdzielczości spektralnej 7 klas miejskiego pokrycia terenu stwierdzono, iż metoda analizy tekstury obiektu za pomocą macierzy zdarzeń w porównaniu z metodą GLCM daje znacznie niższe wartości rozdzielczości. W dalszych pracach postanowiono zatem poddać szczegółowej analizie metodę GCLM. Ponieważ w przypadku wykorzystania obrazu satelitarnego ze skanera ASTER nie wszystkie klasy miejskiego pokrycia terenu charakteryzowały się w obrazie tekstury wysoką rozdzielczością spektralną, na kolejnym etapie prac postanowiono wykorzystać do badań obraz satelitarny o bardzo wysokiej rozdzielczości pochodzący z satelity QuickBird. Obraz ten został poddany takiej samej procedurze jak w przypadku zastosowania danych satelitarnych ASTER. Wykorzystując kanał bliskiej podczerwieni obrazu QuickBird, metodą GCLM utworzono zbiór składający się z 7 miar tekstury, na podstawie którego przeanalizowano rozdzielczość spektralną uprzednio badanych 7 klas miejskiego pokrycia terenu. Wyniki tej analizy przedstawia tabela 3.

Tabela 3. Rozdzielczość spektralna klas pokrycia terenu dla obrazów tekstury (obraz satelitarny QuickBird)

Pary klas pokrycia terenu	Współczynnik rozdzielczości
Zabudowa zwarta miejska – tereny przemysłowe i handlowe	0.52
Nowa zabudowa mieszkaniowa – stara zabudowa mieszkaniowa	1.10
Stara zabudowa mieszkaniowa – zabudowa jednorodzinna	1.27
Zabudowa zwarta miejska – stara zabudowa mieszkaniowa	1.28
Zabudowa zwarta miejska – nowa zabudowa mieszkaniowa	1.51
Tereny komunikacyjne – tereny przemysłowe i handlowe	1.57
Nowa zabudowa mieszkaniowa – obszary odkrytej gleby	1.58
Stara zabudowa mieszkaniowa – tereny przemysłowe i handlowe	1.67
Nowa zabudowa mieszkaniowa – tereny przemysłowe i handlowe	1.73
Nowa zabudowa mieszkaniowa – zabudowa jednorodzinna	1.73
Zabudowa zwarta miejska – tereny komunikacyjne	1.76
Tereny komunikacyjne – obszary odkrytej gleby	1.77
Zabudowa zwarta miejska – zabudowa jednorodzinna	1.85
Nowa zabudowa mieszkaniowa – tereny komunikacyjne	1.86
Stara zabudowa mieszkaniowa – obszary odkrytej gleby	1.92
Zabudowa jednorodzinna – tereny przemysłowe i handlowe	1.92
Stara zabudowa mieszkaniowa – tereny komunikacyjne	1.94
Zabudowa jednorodzinna – obszary odkrytej gleby	1.95
Tereny przemysłowe i handlowe – obszary odkrytej gleby	1.95
Zabudowa zwarta miejska – obszary odkrytej gleby	1.96
Zabudowa jednorodzinna – tereny komunikacyjne	1.98

W rezultacie tej analizy uzyskano wysoką rozdzielczość spektralną następujących klas miejskiego pokrycia terenu:

- zabudowa zwarta miejska – zabudowa jednorodzinna,
- zabudowa zwarta miejska – obszary odkrytej gleby,
- stara wielorodzinna zabudowa mieszkaniowa – tereny komunikacyjne,
- stara wielorodzinna zabudowa mieszkaniowa – obszary odkrytej gleby,
- nowa wielorodzinna zabudowa mieszkaniowa – tereny komunikacyjne,

- zabudowa jednorodzinna – tereny przemysłowe i handlowe,
- zabudowa jednorodzinna – obszary odkrytej gleby,
- zabudowa jednorodzinna – tereny komunikacyjne.
- tereny przemysłowe i handlowe – obszary odkrytej gleby.

W przypadku wykorzystania kanału bliskiej podczerwieni obrazu QuickBird otrzymano zatem lepsze wyniki niż przy zastosowaniu analogicznego kanału obrazu ze skanera ASTER. Niemniej niektóre z kategorii miejskiego pokrycia terenu, takie jak:

- zabudowa zwarta miejska – tereny przemysłowe i handlowe,
- nowa wielorodzinna zabudowa mieszkaniowa – stara wielorodzinna zabudowa mieszkaniowa,
- stara wielorodzinna zabudowa mieszkaniowa – zabudowa jednorodzinna,
- zabudowa zwarta miejska – stara wielorodzinna zabudowa mieszkaniowa.

nie dały dobrych wyników rozdzielczości spektralnej w obrazie tekstury sporządzonym metodą GCLM. Postanowiono zatem przebadać, czy pozostałe kanały spektralne nie wnoszą dodatkowych informacji odnośnie tekstury obiektu, umożliwiając analizę miejskiego pokrycia terenu z wyższą wiarygodnością. Na podstawie kanałów 1, 3 i 4 obrazu QuickBird utworzono zbiór składający się z 21 miar tekstury (7 miar dla każdego kanału). Analiza tego zbioru wykazała, że kanały widzialne QuickBird dostarczają informacji na temat tekstury różniącej się od informacji uzyskanej na podstawie kanału bliskiej podczerwieni. Wniosek ten potwierdziła analiza rozdzielczości 7 klas miejskiego pokrycia terenu; wszystkie kategorie charakteryzowały się wysoką rozdzielczością, przebadaną za pomocą funkcji *Transformed Divergence*. Na kolejnym etapie prac podjęto więc próbę sklasyfikowania obszaru badawczego na podstawie obrazu tekstury. Na badanym obszarze wybrano pola treningowe reprezentujące 7 klas miejskiego pokrycia terenu:

- zabudowę zwartą miejską,
- starą wielorodzinną zabudowę mieszkaniową,
- nową wielorodzinną zabudowę mieszkaniową,
- zabudowę jednorodzinną,
- tereny komunikacyjne,
- tereny przemysłowe i handlowe,
- obszary odkrytej gleby

oraz 5 klas nieantropogenicznego pokrycia terenu:

- drzewostany iglaste,
- drzewostany liściaste i mieszane,
- tereny trawiaste,

- ogrody działkowe,
- wody.

Następnie przeprowadzono klasyfikację nadzorowaną całego obszaru badań, stosując metodę największego prawdopodobieństwa.

Ocena jakościowa obrazu klasyfikacyjnego wykazuje generalnie dobre przypisanie elementów obrazu głównym klasom pokrycia terenu. Wniosek ten potwierdza analiza ilościowa wykonana za pomocą pól kontrolnych – dla niektórych klas charakteryzujących się wyrazistą i względnie jednorodną teksturą obrazu, takich jak wody, tereny trawiaste, obszary odkrytej gleby czy drzewostany iglaste, osiągnięto dokładność rozpoznania (dokładność producenta) przewyższającą 90%. Jednakże obszary miejskiego pokrycia terenu charakteryzujące się dużą heterogenicznością w przypadku wykorzystania do klasyfikacji obrazu rastrowego o strukturze pikselowej nie dały zadowalających wyników rozpoznania. Postanowiono zatem w dalszych pracach zastosować metodę tzw. klasyfikacji obiektowej, która pozwala w procesie klasyfikacyjnym wykorzystywać również pozaspektralne cechy obrazu.

4.3. Metoda kartowania obszarów miejskich za pomocą klasyfikacji obiektowej

Metoda klasyfikacji obiektowej umożliwia włączenie do procesu klasyfikacyjnego, poza wartościami odbicia spektralnego, również innych cech obrazu, związanych z kształtem, położeniem i teksturą obiektów, a także z wzajemnymi relacjami pomiędzy poszczególnymi klasami pokrycia terenu. Została ona opracowana w postaci pakietu oprogramowania eCognition firmy Definiens Imaging. Pakiet ten umożliwia analizowanie informacji pochodzących nie tylko z pojedynczych pikseli obrazu, lecz także z grup pikseli (obiektów) wyróżnionych w trakcie procesu segmentacji obrazu. Zastosowanie w tym pakiecie klasyfikacji metodą logiki rozmytej pozwala na integrację różnych atrybutów obiektu, takich jak wartości spektralne i ich przetworzenia oraz cechy dotyczące kształtu, tekstury i usytuowania względem innych obiektów terenowych. Pakiet eCognition daje także możliwości jednoczesnej analizy różnych typów danych, tym samym wzmacniając wiarygodność wyników klasyfikacji.

W tej części prac postanowiono poddać klasyfikacji obiektowej obraz satelitarny QuickBird, charakteryzujący się rozdzielczością terenową kanałów wielospektralnych (2.8 metra) zapewniającą duże zróżnicowanie struktury miejskiego pokrycia terenu. W pierwszej fazie tego etapu prac utworzono wyjściowe zbiory wielospektralne do wykonania klasyfikacji, zawierające 4 zakresy promieniowania: 3 pasma w zakresie widzialnym oraz pasmo w zakresie bliskiej podczerwieni. Następnie przeprowadzono proces segmentacji obrazu. Oprogramowanie eCognition umożliwia wykonanie

segmentacji wielopoziomowej. Pozwala ona na wyróżnienie homogenicznych elementów obrazu, które na dalszych etapach klasyfikacji mogą stanowić obiekty poddawane procesowi klasyfikacji (zamiast pojedynczych pikseli obrazu). Segmentacja może być wykonywana z różnym stopniem agregacji, uzależnionym od charakteru obiektu badawczego. O stopniu agregacji decyduje kilka parametrów wejściowych, takich jak skala, jednorodność, wygładzenie kształtów i zwartość segmentów. W ramach niniejszych prac przeprowadzono analizy w celu określenia optymalnych wartości tych parametrów dla miejskiego pokrycia terenu.

Parametr skali określa maksymalną heterogeniczność wyznaczanych segmentów. Przeanalizowano kilka poziomów skalowych – od tych, które pozwalają wyróżnić pojedyncze, małe elementy pokrycia terenu (skala 10), do poziomów agregujących te elementy, wyróżniających zespoły miejskiego użytkowania ziemi (skala 50–80).

Jednorodność segmentów determinuje tzw. *Shape factor* – im wyższy ten wskaźnik, tym większa jednorodność w granicach segmentu. Przeanalizowano kilka poziomów tego wskaźnika, wybierając taki, przy którym zespoły miejskiego pokrycia terenu tworzą większe powierzchnie (wartość wskaźnika rzędu 0.4).

Dodatkowo, oprócz agregacji według informacji spektralnej oprogramowanie eCognition umożliwia optymalizację jednorodności wyznaczanych segmentów według ich kształtu. W tym przypadku są stosowane dwa kryteria:

1. Wygładzenia (*smoothness*) – kryterium umożliwiające wygładzenie granic segmentów (szczególnie korzystne przy bardzo heterogenicznych obrazach, np. radarowych).
2. Zwartości (*compactness*) – kryterium pozwalające na optymalizację kształtu segmentu przy zachowaniu jego maksymalnej zwartości.

Kryteria te są stosowane zwłaszcza wówczas, gdy obiekty są zwarte, lecz oddzielone od siebie niewielkimi powierzchniami o małym kontraście.

Przeanalizowano różne wartości wskaźników wygładzenia i zwartości, wybierając takie, przy których zespoły miejskiego pokrycia terenu tworzą większe powierzchnie (wartość wskaźnika wygładzenia rzędu 0.1, wartość wskaźnika zwartości rzędu 0.9).

W wyniku tych prac postanowiono przeprowadzić segmentację na trzech poziomach szczegółowości (z różnymi parametrami skali), wybierając dla każdego poziomu odpowiednie wartości parametrów wejściowych dotyczących jednorodności, kształtu i zwartości segmentów.

Kolejnym etapem prac było wykonanie podstawowej klasyfikacji obrazu wielospektralnego. W tym celu na obszarze badawczym założono zespół pól treningowych reprezentujących 9 klas pokrycia terenu i użytkowania ziemi.

Były to następujące klasy:

- zabudowa zwarta miejska i przemysłowa,
- zabudowa stara z udziałem zieleni miejskiej,
- zabudowa rozproszona (tereny nowych osiedli mieszkaniowych typu blokowego i jednorodzinnego),
- drzewostany iglaste,
- drzewostany liściaste i mieszane,
- ogrody działkowe,
- tereny zielone (rolnicze i łakowe),
- tereny glebowe,
- wody.

Na podstawie wybranych pól treningowych dla wymienionych klas wykonano klasyfikację obrazu, wykorzystując do tego celu proponowaną w ramach pakietu eCognition metodę *standard nearest neighbour*. Metoda ta w odróżnieniu od klasycznej metody „najbliższego sąsiada” umożliwia wykorzystywanie jednej przestrzeni spektralnej dla wszystkich analizowanych klas, zapewniając tym samym ich lepsze rozdzielanie. Oprogramowanie eCognition wykorzystuje w procesie klasyfikowania obiektów zasadę logiki rozmytej, bazującą na stosowaniu dla poszczególnych wyznaczanych klas tzw. funkcji przynależności, charakteryzujących stopień przynależności do danej klasy w zależności od warunków określonych przez operatora. Ten typ klasyfikowania, zwany „miękkim”, pozwala na wykorzystanie w większym stopniu niż w przypadku klasyfikatorów „twardych” (np. metodą prostopadłościaków) informacji o obiekcie badawczym.

Obraz klasyfikacyjny otrzymany na tym etapie prac stanowił podstawę do rozpoczęcia kolejnego etapu – podziału obszarów miejskich na różne poziomy gęstości zabudowy, charakteryzujące zróżnicowaną strukturę przestrzenną pokrycia terenu na obszarze Warszawy. W tym celu postanowiono wykorzystać możliwości oprogramowania eCognition, pozwalające na stosowanie w procesie klasyfikowania hierarchii wyznaczanych klas, segmentacji wielopoziomowej oraz informacji pozaspektralnej.


Oprogramowanie eCognition umożliwia założenie hierarchii wyznaczanych klas, czyli ich wzajemnych zależności, co stanowi podstawę do wykorzystania funkcji systemu, pozwalających na korzystanie z wzajemnych relacji pomiędzy klasami i poziomami szczegółowości. W niniejszej pracy zgrupowano wymienione klasy w trzy główne kategorie pokrycia terenu: obszary zabudowane, tereny niezurbanizowane oraz wody. To zgrupowanie umożliwiło przeprowadzenie dalszych etapów klasyfikacji obrazów satelitarnych, zmierzających do zróżnicowania struktury przestrzennej miejskiego pokrycia terenu.

Na pierwszym etapie połączono klasy uzyskane w wyniku pierwotnej klasyfikacji, tworząc nową mapę klasyfikacyjną z podziałem na trzy wyżej wymienione generalne typy pokrycia terenu (obszary zabudowane, tereny niezurbanizowane, wody). Mapa ta stanowiła najbardziej zagregowany poziom szczegółowości – tzw. superinformację służącą do wydzielenia generalnych zasięgów tych klas. Następnie wykonano segmentację obrazów ze współczynnikami skalowymi umożliwiającymi podział obrazu na elementy bardzo drobne oraz średniej wielkości (subobiekty oraz obiekty). Poziom szczegółowości w przypadku subobiektów został za pomocą współczynnika skali tak dobrany, aby wyróżnić pojedyncze elementy zabudowy. W kolejnej fazie prac dokonano klasyfikację obrazu podzielonego na subobiekty w taki sposób, aby wyróżnić jedynie obszary „czystej” zabudowy. W tym celu wykorzystano zarówno informację spektralną charakteryzującą zakres odbicia dla zabudowy w zakresach widzialnych i bliskiej podczerwieni, jak i kombinacje kanałów spektralnych oraz ich przetworzenia. Były to: współczynnik jasności (średnia wartości współczynników odbicia ze wszystkich kanałów spektralnych), znormalizowany wskaźnik zieleni NDVI oraz stosunek wartości odbicia w kanale bliskiej podczerwieni do współczynnika jasności. Zastosowanie takiej wieloczynnikowej informacji pozwoliło na wyodrębnienie obszarów „czystej” zabudowy z dużym stopniem wiarygodności.

Na finalnym etapie prac przeprowadzono klasyfikację obrazów, wykorzystując informacje zawarte w warstwie o małym poziomie szczegółowości (superinformację) oraz w warstwie o dużym poziomie szczegółowości (subinformację). Postanowiono dokonać podziału obszarów zabudowanych na 4 klasy, charakteryzujące się różnym stopniem gęstości zabudowy:

- klasa 1: zabudowa rozproszona z bardzo dużym udziałem zieleni (1–25% „czystej” zabudowy),
- klasa 2: zabudowa z dużym udziałem zieleni (26–50 % „czystej” zabudowy),
- klasa 3: zabudowa o średniej gęstości elementów antropogenicznych (51–75% „czystej” zabudowy),
- klasa 4: zabudowa o dużej gęstości elementów antropogenicznych (76–100% „czystej” zabudowy).

W wyniku przeprowadzenia klasyfikacji utworzono obraz klasyfikacyjny przedstawiający zróżnicowanie struktury miejskiego pokrycia terenu na 4 wymienione kategorie gęstości zabudowy. Został on przedstawiony na rysunku 1.



LEGENDA

■	75 - 100 % zabudowy
■	50 - 75 % zabudowy
■	25 - 50 % zabudowy
■	1 - 25 % zabudowy
■	Tereny zielone
■	Wody

Rys.1. Mapa gęstości zabudowy wykonana za pomocą klasyfikacji obiektowej

Obraz ten poddano analizie dokładności wyznaczenia klas poprzez oszacowanie dokładności producenta i użytkownika za pomocą pól kontrolnych, utworzonych na podstawie mapy pokrycia terenu sporządzonej ze zdjęć lotniczych. W wyniku oceny dokładności klasyfikacji za pomocą tych pól otrzymano następujące rezultaty, przedstawione w tabeli 4.

Tabela 4. Analiza dokładności wyznaczenia klas gęstości zabudowy

Klasa gęstości zabudowy	Dokładność producenta	Dokładność użytkownika
1–25% zabudowy	87.4%	61.2%
26–50% zabudowy	70.8%	93.5%
51–75% zabudowy	77.8%	81.9%
76–100% zabudowy	94.2%	77.8%
Dokładność całkowita 79.8%		
Współczynnik Kappa 0.7262		

Z tabeli 4 wynika, że generalnie osiągnięto zadowalającą precyzję rozpoznania, wyrażoną dokładnością całkowitą i współczynnikiem Kappa. Jednakże w przypadku szczegółowego rozpoznania klas pośredniej gęstości zabudowy (dokładność producenta), a także klas małej i dużej gęstości zabudowy (dokładność użytkownika) precyzja wyznaczenia tych klas nie jest wysoka. Postanowiono zatem włączyć do procesu klasyfikacji obiektowej oprócz cech spektralnych obiektów i ich wzajemnych zależności również cechy związane z teksturą obiektów.

W tym celu w pierwszej fazie prac przeanalizowano zróżnicowanie podstawowych miar tekstury obiektu: średniej, jednorodności, odmienności i entropii dla 4 typów zabudowy:

- zabudowy zwartej (miejskiej i przemysłowej),
- zabudowy o średniej gęstości (z niewielkim udziałem zieleni miejskiej),
- zabudowy o małej gęstości (z udziałem zieleni miejskiej),
- zabudowy rozproszonej (z dużym udziałem zieleni miejskiej).

Wyniki analizy zostały zawarte w tabeli 5.

Tabela 5. Zróżnicowanie miar tekstury klas miejskiego pokrycia terenu

Klasa pokrycia terenu	Średnia	Jednorodność	Odmiennosc	Entropia
Zabudowa zwarta	min. 127.05 maks. 128.81	min. 0.054 maks. 0.082	min. 16.41 maks. 22.82	min. 8.093 maks. 8.844
Zabudowa o średniej gęstości	min. 126.13 maks. 127.31	min. 0.060 maks. 0.068	min. 17.36 maks. 18.84	min. 8.496 maks. 8.752
Zabudowa o małej gęstości	min. 126.70 maks. 127.88	min. 0.070 maks. 0.085	min. 15.70 maks. 18.91	min. 8.268 maks. 8.820
Zabudowa rozproszona	min. 126.82 maks. 127.14	min. 0.052 maks. 0.085	min. 16.09 maks. 19.35	min. 8.335 maks. 8.808

Z tabeli 5 wynika, że przeanalizowane miary tekstury obiektu nie dają podstawy do dobrego zróżnicowania 4 badanych typów gęstości zabudowy; ich włączenie do procesu klasyfikacji obiektowej nie podnosi dokładności wyznaczenia szczegółowych kategorii miejskiego pokrycia terenu.

4.4. Metoda klasyfikacji obszarów miejskich z wykorzystaniem sieci neuronowych

Na kolejnym etapie prac postanowiono wykorzystać nowe podejście do klasyfikacji, bazujące na zastosowaniu metody sieci neuronowych. Ta metoda cieszy się w ostatnich latach dużym zainteresowaniem ze względu na nowe możliwości związane z predykcją i klasyfikacją danych (Paola i in., 1995; Kavzoglu i in., 2003; Keramitsoglou i in., 2005; Stankiewicz, 2004). Główne zalety metody sieci neuronowych można scharakteryzować następująco:

1. Zdolność do precyzyjnego modelowania zjawisk poprzez odwzorowywanie złożonych, nieliniowych zależności pomiędzy analizowanymi parametrami.
2. Kontrola nad problemem wielowymiarowości przy modelowaniu funkcji nieliniowych.
3. Ułatwienie budowy modelu w porównaniu z tradycyjnymi metodami statystycznymi dzięki zastosowaniu zasady naśladowania działania ludzkiego umysłu.
4. Łatwość zastosowania dzięki procesowi „uczenia się” sieci na podstawie reprezentatywnych danych określających badaną zależność.


Ta ostatnia cecha stanowi podstawę wykorzystywania metody sieci neuronowych. Istnieją dwa typy algorytmów służących do uczenia sieci neuronowych, stosowane w zależności od rodzaju używanej sieci: tzw. uczenie z nauczycielem i bez nauczyciela. Pierwsza metoda jest częściej stosowana i polega na uprzednim zgromadzeniu odpowiednich zestawów danych wejściowych i odpowiadającym im wartości wyjściowych. Na tej podstawie sieć uczy się wnioskować odnośnie sposobów rozwiązań zadania, dokonując analizy danych wejściowych i wyjściowych w celu określenia występujących między nimi zależności. Sieć neuronowa jest uczona w ten sposób, że jej parametry (współczynniki wag i progi neuronów) są w celowy sposób zmieniane przy użyciu wybranego algorytmu uczenia. Najbardziej znanym przykładem takiego algorytmu jest metoda wstecznej propagacji błędów (tzw. *backpropagation*). Algorytm ten modyfikuje wagi i wartości progowe sieci w sposób zapewniający minimalizację błędu popełnianego przez sieć w trakcie realizacji zadania. Poprawnie nauczona sieć potrafi modelować nieznaną uprzednio użytkownikowi funkcję, także w przypadkach, gdy ma ona charakter silnie nieliniowy.

Istnieje wiele typów sieci neuronowych, różniących się między sobą strukturą i mechanizmem działania. Najczęściej są stosowane następujące architektury sieciowe:


- perceptron wielowarstwowy (MLP),
- sieci o radialnych funkcjach bazowych (RBF),
- sieci probabilistyczne (PNN),
- sieci realizujące regresję uogólnioną (GRNN),
- sieci liniowe,
- sieci Kohonena.

W szczególności dwa pierwsze typy sieci cieszą się największą popularnością przy rozwiązywaniu zagadnień, w których występują złożone, nieliniowe zależności pomiędzy licznymi zmiennymi wejścia i wyjścia. Schematy ideowe tych typów zostały przedstawione na rysunku 2.

Perceptron wielowarstwowy



Sieć o radialnych funkcjach bazowych



Rys. 2. Schematy ideowe sieci neuronowych

Wybór optymalnej architektury sieciowej jest skomplikowanym zadaniem, dlatego też w oprogramowaniach realizujących prace związane z wykorzystaniem sieci neuronowych stosuje się najczęściej rozwiązania ułatwiające użytkownikowi wyselekcjonowanie najkorzystniejszej sieci. Takie rozwiązanie, zwane automatycznym projektantem sieci, zostało zastosowane w oprogramowaniu *Statistica Neural Networks*, które było wykorzystywane w tej części prac badawczych. Automatyczny projektant sieci, po otwarciu zbioru danych oraz wskazaniu zmiennych wejściowych i wyjściowych, analizuje różne kombinacje parametrów dla poszczególnych typów sieci, wybierając w finalnej fazie te rozwiązania sieciowe, które charakteryzują się najwyższą jakością procesów uczenia, walidacji i testowania oraz najniższymi błędami. Ostateczny wybór rodzaju sieci do przeprowadzenia klasyfikacji całego zbioru danych jest dokonywany na podstawie oceny dokładności klasyfikacji zbioru służącego do budowy sieci i analizy wrażliwości poszczególnych parametrów będących podstawą klasyfikacji.

W tej części prac postanowiono przebadать użyteczność klasyfikacji z wykorzystaniem metody sieci neuronowych dla wybranego obiektu badawczego – fragmentu aglomeracji warszawskiej. W pierwszej fazie

postanowiono dokonać klasyfikacji obrazu satelitarnego QuickBird z wyróżnieniem 8 kategorii pokrycia terenu. Były to następujące klasy:

- zabudowa zwarta,
- zabudowa o średniej gęstości,
- zabudowa o małej gęstości,
- drzewostany,
- ogrody działkowe,
- tereny zielone (trawiaste),
- tereny odkrytej gleby,
- wody.

Dla wymienionych klas wybrano na podstawie obrazu satelitarnego QuickBird, poddanemu uprzednio procesowi segmentacji, pola treningowe reprezentujące poszczególne kategorie pokrycia terenu. W ramach oprogramowania eCognition dla każdego pola zostały określone wartości następujących parametrów charakteryzujących wybrane segmenty:

- wartość odbicia w zakresie bliskiej podczerwieni,
- odchylenie standardowe wartości odbicia w zakresie bliskiej podczerwieni,
- stosunek wartości odbicia w zakresie bliskiej podczerwieni do sumy odbicia w 4 kanałach skanera QuickBird,
- wartość znormalizowanego wskaźnika roślinności – NDVI,
- jasność (suma wartości odbicia w poszczególnych kanałach podzielona przez liczbę kanałów),
- miara tekstury obiektu – średnia,
- miara tekstury obiektu – entropia,
- miara tekstury obiektu – jednorodność,
- miara tekstury obiektu – odmienność.

Po utworzeniu tabeli atrybutów pól treningowych, zawierającej wymienione parametry, wykorzystano zestaw zawartych w niej danych do przeprowadzenia procesu projektowania sieci neuronowej. Zastosowano metodę automatycznego projektanta sieci w celu zoptymalizowania wyboru najlepszych rozwiązań dla analizowanego zestawu danych wejściowych. W pierwszej fazie prac przeanalizowano budowę sieci neuronowej dla pełnego zestawu 9 zmiennych wejściowych, charakteryzujących pod względem spektralnym i tekstury poszczególne kategorie pokrycia terenu, stosując 3 główne typy sieci:

- perceptron wielowarstwowy (MLP),
- sieci o radialnych funkcjach bazowych (RBF),
- sieci liniowe.

Po wykonaniu procesu projektowania dokonano oceny jakości uczenia, walidacji i testowania, podawanych na zakończenie fazy modelowania. Przeprowadzono także analizę wrażliwości poszczególnych parametrów charakteryzujących dane wejściowe. Zestawienie wyników uczenia sieci przedstawia tabela 6.

Tabela 6. Wyniki uczenia sieci dla zestawu 9 zmiennych wejściowych i 8 klas pokrycia terenu

Nr	Typ sieci	Jakość uczenia	Jakość walidacji	Jakość testowania	Błąd uczenia	Błąd walidacji	Błąd testowania
1	Perceptron wielowarstwowy 9:9-12-8:1	1.00	0.97	0.98	0.04	0.29	0.22
2	Sieć o radialnych funkcjach bazowych 9:9-49-8:1	0.99	1.00	0.95	0.06	0.10	0.10
3	Sieć liniowa	0.72	0.68	0.65	0.25	0.29	0.27


Analiza wrażliwości uzyskanych wyników na usunięcie każdej ze zmiennych wejściowych, informująca o tym, które ze zmiennych są kluczowe w procesie klasyfikacji, wykazała następującą kolejność ważności stosowanych parametrów opisujących klasy pokrycia terenu:

- w przypadku typu sieci perceptron wielowarstwowy:
 - wskaźnik roślinności NDVI,
 - albedo w kanale 4 (bliska podczerwień – IR),
 - miara tekstury odmienność (*dissimilarity*),
 - miara tekstury entropia (*entropy*),
 - odchylenie standardowe odbicia w kanale 4 (IR);
- w przypadku radialnej sieci bazowej:
 - wskaźnik roślinności NDVI,
 - albedo w kanale 4 (bliska podczerwień),
 - odchylenie standardowe odbicia w kanale 4 (IR),
 - miara tekstury odmienność (*dissimilarity*),
 - stosunek wartości odbicia w kanale 4 (IR) do sumy odbicia w 4 kanałach.

Wykorzystując wyniki uczenia sieci przeprowadzono klasyfikację pełnego zestawu poligonów obejmującego cały obszar badawczy, stosując

dwie najlepsze sieci: perceptron wielowarstwowy i sieć o radialnych funkcjach bazowych.

Sporządzono 2 mapy klasyfikacyjne, bazujące na obu wybranych sieciach: perceptronie wielowarstwowym i sieci o radialnych funkcjach bazowych. Przykładowa mapa sporządzona z wykorzystaniem sieci typu perceptron wielowarstwowy została przedstawiona na rysunku 3.



LEGENDA

- wody
- zabudowa o dużej gęstości
- zabudowa o średniej gęstości
- zabudowa o małej gęstości
- tereny nie pokryte roślinnością
- drzewostany
- tereny trawiaste
- ogrody działkowe

Rys. 3. Klasyfikacja pokrycia terenu metodą sieci neuronowych

Następnie dokonano oceny klasyfikacji obrazu z wykorzystaniem obu rodzajów sieci, stosując w tym celu zespół pól kontrolnych. Wyniki tej oceny, charakteryzujące dokładność klasyfikacji klas pokrycia terenu, zostały przedstawione w tabeli 7.

Tabela 7. Wyniki oceny dokładności klasyfikacji z wykorzystaniem sieci neuronowych (w %)

Nazwa klasy pokrycia terenu	Perceptron wielowarstwowy		Sieć o radialnych funkcjach bazowych	
	dokładność producenta	dokładność użytkownika	dokładność producenta	dokładność użytkownika
Zabudowa zwarta	93	100	63	100
Zabudowa o średniej gęstości	97	97	87	70
Zabudowa o małej gęstości	75	93	75	93
Drzewostany	85	96	81	81
Tereny zielone (trawiaste)	93	96	76	96
Ogrody działkowe	78	67	83	70
Tereny glebowe	100	100	87	100
Wody	96	100	92	100

Analiza wyników klasyfikacji przedstawionych w tabeli 7 pozwala na wyciągnięcie następujących wniosków:

1. Zabudowa zwarta – miejska, przemysłowa i handlowa – z punktu widzenia producenta została sklasyfikowana z dużą dokładnością tylko przy wykorzystaniu sieci perceptron wielowarstwowy. W przypadku sieci o radialnych funkcjach bazowych występuje niedoszacowanie tego typu pokrycia terenu na skutek zaliczenia części pól kontrolnych do klasy zabudowy o średniej gęstości.
2. Zabudowa o średniej gęstości z punktu widzenia producenta została sklasyfikowana z dużą dokładnością, lecz z punktu widzenia użytkownika dokładność nie była wysoka w przypadku sieci o radialnych funkcjach bazowych ze względu na „mieszanie się” z klasą zabudowy zwartej.
3. Dla klasy zabudowy o małej gęstości z punktu widzenia producenta osiągnięto niezbyt wysoką dokładność rozpoznania, wywołaną w głównej mierze zaliczeniem części pól kontrolnych do terenów

zielonych, jednakże z punktu widzenia użytkownika dokładność dla obu typów sieci była zadowalająca.

4. W przypadku drzewostanów osiągnięto dość dobrą dokładność klasyfikacji dla obu typów sieci, aczkolwiek w przypadku parków miejskich niewykazujących zwartej struktury drzew obserwowano zaliczanie pól kontrolnych do klasy ogrody działkowe.
5. Tereny zielone o niskiej roślinności – skwery miejskie, obszary trawiaste, murawy na boiskach sportowych – zostały sklasyfikowane z dużą dokładnością z wykorzystaniem sieci perceptron wielowarstwowy, zaś niższą dokładnością przy użyciu sieci o radialnych funkcjach bazowych.
6. Tereny ogrodów działkowych sklasyfikowano z niezbyt wysoką dokładnością – z punktu widzenia producenta rzędu 80%, z punktu widzenia użytkownika rzędu 70%. Było to głównie spowodowane „mieszaniem się” z klasą terenów o małej gęstości zabudowy oraz z klasą drzewostanów o rozluźnionej strukturze drzew.
7. Dla klasy terenów odkrytej gleby oraz klasy wód osiągnięto wysoką dokładność rozpoznania, zarówno z punktu widzenia producenta, jak i użytkownika.

Z punktu widzenia producenta dla 8 klas pokrycia terenu otrzymano następujące średnie wartości dokładności klasyfikacji:

- dla sieci perceptron wielowarstwowy – 89.6%,
- dla sieci o radialnych funkcjach bazowych – 80.5%.

Z punktu widzenia użytkownika średnie wartości dokładności klasyfikacji kształtują się następująco:

- dla sieci perceptron wielowarstwowy – 93.6 %,
- dla sieci o radialnych funkcjach bazowych – 88.8 %.

Porównując klasyfikacje oparte na 2 typach sieci uczących, można zatem stwierdzić, że klasyfikacja bazująca na wynikach uczenia metodą perceptronu wielowarstwowego dała lepsze wyniki rozpoznania 8 klas pokrycia terenu, zapewniając wysoką średnią dokładność rozpoznania, zarówno z punktu widzenia producenta, jak i użytkownika. Nieco niższą dokładność osiągnięto jedynie dla kategorii ogrody działkowe, co skłania do włączenia tej klasy pokrycia terenu do kategorii terenów zielonych.

5. PODSUMOWANIE

W trakcie realizacji prac w ramach projektu badawczego nr 4 T12E 043 26 zostały przeprowadzone kompleksowe badania zmierzające do utworzenia optymalnej metody klasyfikowania obszarów miejskich z użyciem wysokorozdzielczych obrazów satelitarnych nowej generacji. Wykorzystano dane obrazowe charakteryzujące się różną rozdzielczością przestrzenną i spektralną, pochodzące z trzech typów systemów satelitarnych służących do

obrazowania powierzchni Ziemi: Landsat ETM+, Terra ASTER oraz QuickBird. W pierwszej fazie dla wybranego obiektu badań – fragmentu aglomeracji warszawskiej – zgromadzono wymienione obrazy satelitarne oraz materiały referencyjne w postaci map tematycznych, niezbędne w procesie klasyfikacji zdjęć. Poszczególne obrazy satelitarne zostały poddane odpowiednim przetworzeniom geometrycznym i radiometrycznym w celu ich odpowiedniego przygotowania do głównej fazy prac.

W drugiej fazie prac przebadano różne metody cyfrowej analizy i klasyfikacji wysokorozdzielczych zdjęć satelitarnych. Przedmiotem prac były następujące metody:

- metoda analizy spektralnego zmieszania,
- metoda określania struktury obszarów miejskich za pomocą miar tekstury obiektów,
- metoda kartowania obszarów miejskich za pomocą klasyfikacji obiektowej z wykorzystaniem wielorozdzielczej segmentacji oraz logiki rozmytej i funkcji przynależności,
- metoda klasyfikacji za pomocą sieci neuronowych.

W efekcie wykonanych prac badawczych dokonano oceny użyteczności wyżej wymienionych metod pod względem dokładności i szczegółowości klasyfikacji pokrycia terenu na obszarach miejskich. Okazało się, iż najbardziej przydatna do całościowego sklasyfikowania pokrycia terenu na wysokorozdzielczym obrazie satelitarnym jest metoda hybrydowa, łącząca elementy klasyfikacji obiektowej oraz wykorzystania sieci neuronowych. Zastosowanie elementów klasyfikacji obiektowej w procesie wielorozdzielczej segmentacji pozwala na wydzielenie obiektów jednorodnych pod względem zróżnicowania spektralnego oraz zmienności geometrycznej, optymalizując te cechy poprzez wybór odpowiednich parametrów służących do wykonania segmentacji – współczynnika skalowego oraz wskaźników kształtu i zwartości. Analiza obrazu metodą obiektową za pomocą oprogramowania eCognition umożliwia również określenie dla każdego obiektu wydzielonego w trakcie segmentacji wielu charakterystyk, zarówno spektralnych, jak i pozaspektralnych, m.in. dotyczących kształtu i tekstury obiektów oraz relacji zachodzących pomiędzy poszczególnymi obiektami. Zostało to wykorzystane do utworzenia metody hybrydowej. W procesie analizy obrazu metodą obiektową dla zespołu pól treningowych reprezentujących poszczególne klasy pokrycia terenu wyznaczono wiele parametrów określających wielkość odbicia spektralnego, znormalizowany wskaźnik roślinności oraz miary tekstury obiektów. Tabela z wartościami tych parametrów stanowiła zestaw danych będących podstawą analizy i klasyfikacji z wykorzystaniem sieci neuronowych. Dobór odpowiednich parametrów wejściowych oraz typów i sposobów uczenia sieci neuronowej pozwolił na osiągnięcie wysokiej jakości uczenia, walidacji i testowania sieci, a w efekcie uzyskanie dobrej dokładności klasyfikacji wykonanej za pomocą

optymalnego typu sieci. Analiza dokładności klasyfikacji, przeprowadzona za pomocą zespołu pól kontrolnych, wykazała, iż obszary zabudowane w ramach aglomeracji miejskiej można podzielić na trzy kategorie gęstości zabudowy ze średnią precyzją rozpoznania 88%. Również dla terenów zielonych występujących w ramach aglomeracji można wyróżnić trzy kategorie pokrycia terenu ze średnią dokładnością klasyfikacji 85%. Wyniki uzyskane w niniejszej pracy wykazują, że metoda hybrydowej klasyfikacji wysokorozdzielczego obrazu satelitarnego, wykorzystująca elementy analizy obiektowej i sieci neuronowych, może być efektywnym narzędziem sporządzania map pokrycia terenu dla obszarów aglomeracji miejskich. Mapy sporządzane tą metodą mogą służyć planistom przestrzennym do szybkiej, generalnej oceny struktury obszarów miejskich oraz określania zmian wywoływanych procesami urbanizacyjnymi w obrębie dużych aglomeracji.

6. LITERATURA

- [1] Chen J., Gong P., He C., Luo W., Tamural M., Shi P., 2002, *Assessment of the urban development plan of Beijing by using a CA-based urban growth model*. Photogrammetric Engineering & Remote Sensing, Vol. 68, No. 10, pp. 1063-1071.
- [2] Dennison P.E., Roberts D.A., 2003, *Endmember selection for multiple endmember spectral mixture analysis using endmember average RSME*. Remote Sensing of Environment, Vol. 87, pp. 123-135.
- [3] Gong P.D., Marceau J., Howarth P.J., 1992, *A comparison of spatial feature extraction algorithms for land use classification with SPOT HRV data*. Remote Sensing of Environment, Vol. 40, pp. 137-151.
- [4] Herold M., Liu X., Clarke K.C., 2003, *Spatial metrics and image texture for mapping urban land use*. Photogrammetric Engineering & Remote Sensing, Vol. 69, No. 9, pp. 991-1001.
- [5] Hung M., Ridd M.K., 2002, *A subpixel classifier for urban land cover mapping based on maximum likelihood approach and expert system rules*. Photogrammetric Engineering & Remote Sensing, Vol. 68, No. 11, pp. 1173-1180.
- [6] Kavzoglu T., Mather P.M., 2003, *The use of backpropagating artificial neural networks in land cover classification*. International Journal of Remote Sensing, Vol. 24, No. 23, pp. 4907-4938.
- [7] Keramitsoglou I., Sarimveis H., Kiranoudis C.T., Sifakis N., 2005, *Radial basis function neural networks classification using very high spatial resolution satellite imagery: an application to the habitat area of Lake Kerkini (Greece)*. International Journal of Remote Sensing, Vol. 26, No. 9, pp. 1861-1880.
- [8] Paola J.D., Schowengerdt R.A., 1995, *A review and analysis of backpropagation neural networks for classification of remotely sensed*

- multispectral imagery*. International Journal of Remote Sensing, Vol. 16, No. 16, pp. 3033-3058.
- [9] Pesaresi M., Benediktsson J.A., 2001, *A new approach for the morphological segmentation of high-resolution satellite imagery*. IEEE Transactions on Geoscience and Remote Sensing, Vol. 39, No. 2, pp. 309-319.
- [10] Rashed T., Weeks R.J., Stow D., Fugate D., 2005, *Measuring temporal compositions of urban morphology through spectral mixture analysis: toward a soft approach to change analysis in crowded cities*. International Journal of Remote Sensing, Vol. 26, No. 4, pp. 699-718.
- [11] Ridd M.K., 1995, *Exploring a V-I-S (Vegetation-Impervious Surface-Soil) model for urban ecosystem analysis through remote sensing: comparative anatomy of cities*. International Journal of Remote Sensing, Vol. 16, No. 12, pp. 2165-2185.
- [12] Roberts D.A., Gardner M., Church R., Ustin S., Scheer G., Green R.O., 1998, *Mapping chaparral in the Santa Monica mountains using multiple endmember spectral mixture models*. Remote Sensing of Environment, Vol. 65, pp. 267-279.
- [13] Small C., 2003, *High spatial resolution spectral mixture analysis of urban reflectance*. Remote Sensing of Environment, Vol. 88, pp. 170-186.
- [14] Stankiewicz K., 2004, *Zastosowanie sieci neuronowych do klasyfikacji zdjęć mikrofalowych pozyskanych z satelitów ENVISAT i ERS*. Prace Instytutu Geodezji i Kartografii, Tom L, zeszyt 106, str. 63-71.
- [15] Thomas N., Hendrix C., Congalton R.G., 2003, *A comparison of urban mapping methods using high-resolution digital imagery*. Photogrammetric Engineering & Remote Sensing, Vol. 69, No. 9, pp. 963-972.
- [16] Wu C., Murray A.T., 2003, *Estimating impervious surface distribution by spectral mixture analysis*. Remote Sensing of Environment, Vol. 84, pp. 493-505.
- [17] Yang L., Xian G., Klaver J.M., Deal B., 2003, *Urban land cover change detection through sub-pixel imperviousness mapping using remotely sensed data*. Photogrammetric Engineering & Remote Sensing, Vol. 69, No. 9, pp. 1003-1010.

ZBIGNIEW BOCHENEK

Institute of Geodesy and Cartography

ANALYSIS OF CLASSIFICATION METHODS OF URBAN AREAS REGISTERED ON HIGH-RESOLUTION SATELLITE IMAGES

Summary

Results of the research works aimed at preparation of the optimal method for classifying urban areas on the basis of digital analysis of high-resolution satellite images were presented in the article. Data from three different satellite systems: Landsat ETM+, ASTER and QuickBird were used these works. The following methods of digital analysis and classification of satellite images were investigated in the course of the works:

- Spectral mixture analysis,
- Classification of urban areas with inclusion of texture measures,
- Object-oriented analysis with the use of multi-resolution segmentation, fuzzy logic and membership functions,
- Neural networks.

As a results of the conducted works it was found, that hybrid method, combining elements of object-oriented analysis and neural networks, is optimal for classifying urban areas with adequate accuracy. Application of multi-resolution segmentation enables to distinguish homogeneous objects within urban areas and to determine their several spectral and non-spectral parameters. Neural Networks analysis allows to find optimal solution concerning type of network for classification and importance of various parameters used in the classification process. The mean accuracy of classification with the use of this method, with division of urban areas into 3 levels of built-up land density, reaches 85 %. The crucial for obtaining high accuracy, while classifying high-resolution satellite image, is to select properly parameters of segmentation and a set of features characterizing land cover classes, used in neural network analysis.