

Wykorzystanie obrazów hiperspektralnych do klasyfikacji pokrycia terenu zlewni Bystrzanki

Using hyperspectral images for land cover classification in Bystrzanka basin

Dawid OLESIUK, Bogdan ZAGAJEWSKI

The new kind of available remote sensing data are hyperspectral images that characterize big amount of the tight spectral channels. They allow for distinguish the physico-chemical properties of the objects that are located on the earth area. In this paper are used hyperspectral images DAIS 7915 for develop the method of performing land cover maps by using artificial neural networks. The implemented neural network is multilayer one-way perceptron, the learning method is back-propagation. For learning the neural network were used particular layers of the land cover classes identified during land

research of the aircraft. Land research resorted also as the reference material for estimate the precision of the classification. Suitability of the hyperspectral data compression procedure by using Minimum Noise Fraction transformation and including for the classification the texture and objects neighbourhood information was evaluated. The best precision about 90% of the classification was achieved for set of data after MNF transformation with texture window 3x3 pixels. It allows to infer, that hyperspectral images and classification method can be very useful and accurate solution in land cover mapping.

Wstęp

Rozpowszechnienie i zintensyfikowanie prac dotyczących kartowania pokrycia terenu nierozzerwalnie wiąże się z wykorzystaniem metod teledetekcyjnych, które są kompleksowym źródłem informacji o powierzchni Ziemi. Nowym rodzajem danych są obrazy hiperspektralne, na których zarejestrowane jest odbite od powierzchni Ziemi promieniowanie elektromagnetyczne w dziesiątkach, a nawet setkach wąskich kanałów, tworzących ciągle profile spektralne (Vane i Goetz, 1993). Jest to główna cecha obrazów hiperspektralnych, dzięki której są one bogatszym nośnikiem informacji niż inne wcześniej dostępne zobrazowania.

Ciągłość krzywej odbicia spektralnego pozwala na wychwycenie specyficznych cech charakterystycznych dla poszczególnych elementów środowiska, z których każdy ma inne właściwości bio-fizyko-chemiczne określające zdolności do reflektancji konkretnych zakresów widma, a pochłaniania innych (Mohammed i in., 2005). Pozwala to identyfikować badane obiekty na podstawie różnic odpowiedzi spektralnej, możliwych do wyróżnienia w niektórych przypadkach tylko w bardzo wąskich

fragmentach spektrum. Sprawia to, iż zastosowanie obrazów hiperspektralnych w kartowaniu różnych formacji roślinnych jest o wiele bardziej dokładniejsze niż przy wykorzystaniu np. danych wielospektralnych (Elvidge i Chen, 1995; Richter, Müller, Heiden, 2002).

Do klasyfikacji danych hiperspektralnych dedykowane są specjalistyczne procedury takie jak *Spectral Angle Mapper* (SAM), *Spectral Unmixing*, *Linear Mixture Modelling*, *Matched Filtering* (MF), oraz drzewa decyzyjne (Decision Tree – DT), wektory wspierające (*Support Vector Machines* – SVM), czy metody nieparametrycznej klasyfikacji danych bazujące na sztucznych sieciach neuronowych (Artificial Neural Network – ANN) (Zagajewski i in., 2005; Mahesh i Mather, 2006). Dodatkowymi danymi pozwalającymi udoskonalić interpretację i klasyfikację obrazu jest tworzenie za pomocą spektrometrów nieobrazujących bibliotek spektralnych. Otrzymane w ten sposób krzywe interesujących badacza elementów środowiska są uznawane za czyste spektralnie (endmembers), gdyż odzwierciedlają charakterystykę tylko jednego obiektu i pozwalają jednoznacznie zidentyfikować obiekt na obrazie hiperspektralnym (Kruse i in., 1993).

Wykorzystanie obrazów hiperspektralnych w klasyfikacji pokrycia terenu w Polsce jest zagadnieniem nowatorskim i zajmowały się nim do tej pory nieliczne jednostki naukowe oraz poszczególni naukowcy. Zaawansowane prace z obrazami hiperspektralnymi wykonano w Katedrze Geoinformatyki i Teledetekcji Wydziału Geografii i Studiów Regionalnych Uniwersytetu Warszawskiego. Metody te stosowano w kartowaniu roślinności wysokogórskiej Tatr Wysokich z zastosowaniem wysokorozdzielczych lotniczych obrazów DAIS 7915 (3 m) oraz ROSIS (1 m) (Zagajewski i in., 2004; Zagajewski i in., 2005, Zagajewski i in., 2006). Stosując nowoczesne metody przygotowania i klasyfikacji obrazów hiperspektralnym wyróżniono 8 klas pokrycia terenu, natomiast wykorzystując nieparametryczną metodę sztucznych sieci neuronowych skartowano 5 zbiorowisk, określając dokładność na około 80%. Badania z wykorzystaniem danych hiperspektralnych prowadzone były także w Akademii Górniczo Hutniczej pod kierownictwem B. Hejmanowskiej. Prace te dotyczyły zanieczyszczenia gruntu siarką regionu Tarnobrzeskiego Zagłębia Siarkowego (Hejmanowska, Głowienka, 2004), oraz integracji obrazów satelitarnych Hyperion z naziemnymi pomiarami spektrometrycznymi w badaniu zbiornika Dobczyckiego (Hejmanowska i in., 2006). Zespół z Politechniki Warszawskiej i Uniwersytetu Warmińsko-Mazurskiego prowadził badania jezior mazurskich pod kątem koncentracji chlorofilu a, zawartości tlenu i stopnia eutrofizacji (Osińska-Skotak i in., 2005). Obiektem prac na podstawie danych ze skanera AISA rejestrującego 32 kanały spektralne o rozdzielczości 1 m były również ekosystemy leśne Puszczy Niepołomickiej. Podsumowując eksperyment stwierdzono, iż obrazy hiperspektralne są bardzo bogatym źródłem informacji przydatnych w leśnictwie; na ich podstawie możliwa jest pełna aktualizacja map leśnych, które zawierają błędy w informacji gatunkowej oraz obszarowej występowania poszczególnych formacji leśnych (Wężyk, 2005).

Prace autorów zagranicznych obejmują aspekty zastosowań obrazów hiperspektralnych w wielu dziedzinach, dlatego też zaprezentowane zostaną jedynie przykłady badań szczegółowo traktujących o pokryciu terenu nawiązując do problematyki podejmowanej w poniższej pracy. Satelitarne obrazy MERIS wykorzystane zostały w kartowaniu pokrycia terenu obszaru Portugalii (Carrão i in., 2006). Materiały te zostały wybrane ze względu na skalę badań obejmującą całą Portugalię. Wydzielając 19 klas charakterystycznych dla badanego obszaru, autorzy przetestowali metody klasyfikacji *k-Nearest Neighbor* (kNN) oraz algorytm sztucznych sieci neuronowych *Kohonen's Self-Organizing Map* (SOM). Lepsze wyniki dokładności całkowitej na poziomie 68% uzyskano metodą SOM, która pozwoliła wyekstrahować poszczególne względnie homogeniczne klasy z dokładnością około 80%. Rozpoznawanie upraw jest to szczególnym zagadnieniem ze względu na napotykaną trudności w rozróżnianiu poszczególnych formacji rolniczych, które charakteryzują się wysoką heterogenicznością. Jednak badania z wykorzystaniem

obrazów hiperspektralnych pozwalają z dużym prawdopodobieństwem poprawnie je sklasyfikować, co udowadniają naukowcy kartując uprawy w regionie Eifel w Niemczech (Mader i in., 2006). Wykorzystali dane z lotniczego skanera HyMap rejestrującego 126 kanałów spektralnych z rozdzielczością przestrzenną 2–10 m. Trzy zestawy danych hiperspektralnych poddano procesowi klasyfikacji największego prawdopodobieństwa (Maximum Likelihood – ML), w celu oceny różnych wariantów wyboru kanałów. Najlepszy rezultat (88,7%) osiągnięto dla zestawu zawierającego 67 kanałów wybranych metodą wizualną. Prace P. Mahesha i P. Mathera (2006) poświęcone są klasyfikacji pokrycia terenu obszaru średnio-suchych bagien podlegających osuszaniu, wykonanych na obrazach hiperspektralnych DAIS 7915. Opisowanymi metodami klasyfikacji są: ML, ANN, DT i SVM. Badacze poddali również ocenie procedury kompresji danych hiperspektralnych, czyli przygotowania obrazów do etapu klasyfikacji za pomocą metody Minimum Noise Fraction (MNF) oraz wyboru odpowiednich kanałów metodą DT. Rezultaty prac potwierdziły dużą zależność dokładności klasyfikacji od wyboru nieskorelowanej informacji zarejestrowanej na obrazie w poszczególnych kanałach. Wśród metod klasyfikacji najdokładniejsze wyniki uzyskano za pomocą SVM, jednak specyfika danych hiperspektralnych pozwoliła osiągnąć bardzo dobre rezultaty na poziomie > 85% we wszystkich próbach.

Uniwersalność sztucznych sieci neuronowych sprawia, iż mogą być stosowane do klasyfikacji każdego rodzaju obrazów, natomiast publikacje dotyczące przetwarzania obrazów hiperspektralnych są do tej pory bardzo nieliczne i przedstawiono je powyżej (Zagajewski, i in., 2006; Mahesh, Mather 2006). Prace dotyczące pokrycia terenu wykonane na innych danych niż hiperspektralne w kraju opublikowali Jerzy Chmiel (Chmiel, 2001), Adam Iwaniak i Witold Paluszyński (Iwaniak i in., 2002), Małgorzata Krówczyńska (Krówczyńska, 2004), a także Zbigniew Bochenek (Bochenek, 2006). W literaturze zagranicznej, badania nad zastosowaniem sieci neuronowych w teledetekcji prezentowane są od ponad 25 lat, i zagadnieniu temu poświęcono cały tom „International Journal of Remote Sensing” (JRS, 1997). Prace z tego zakresu podzielić można na szczegółowo przedstawiające metodykę i wyniki badań (Civco, 1993; Foody, 1995; Kanellopoulous i Wilkinson, 1997; Kavzoglu i Mather, 2003; Rocha, i in., 2007), a także opisujące różne aspekty zastosowania i ocenę podjętych prac przez wielu autorów klasyfikacji obrazów (Atkinson, Tatnall, 1997; Бельчанский, Коробков 1998).

Sztuczne sieci neuronowe określane są jako metoda nieparametryczna, ponieważ nie wymagają wyznaczenia kategoriycznych reguł statystycznych determinujących klasyfikację obrazu klasyfikacjami, co jest podstawą klasycznych metod klasyfikacji parametrycznych. Jako podstawowe wady drugich metod wymienia się to, iż definiując parametry odrębności zbiorów pikseli dla poszczególnych klas pokrycia terenu (średnia, odchylenie standardowe), zakłada się, iż odpowiadają one roz-

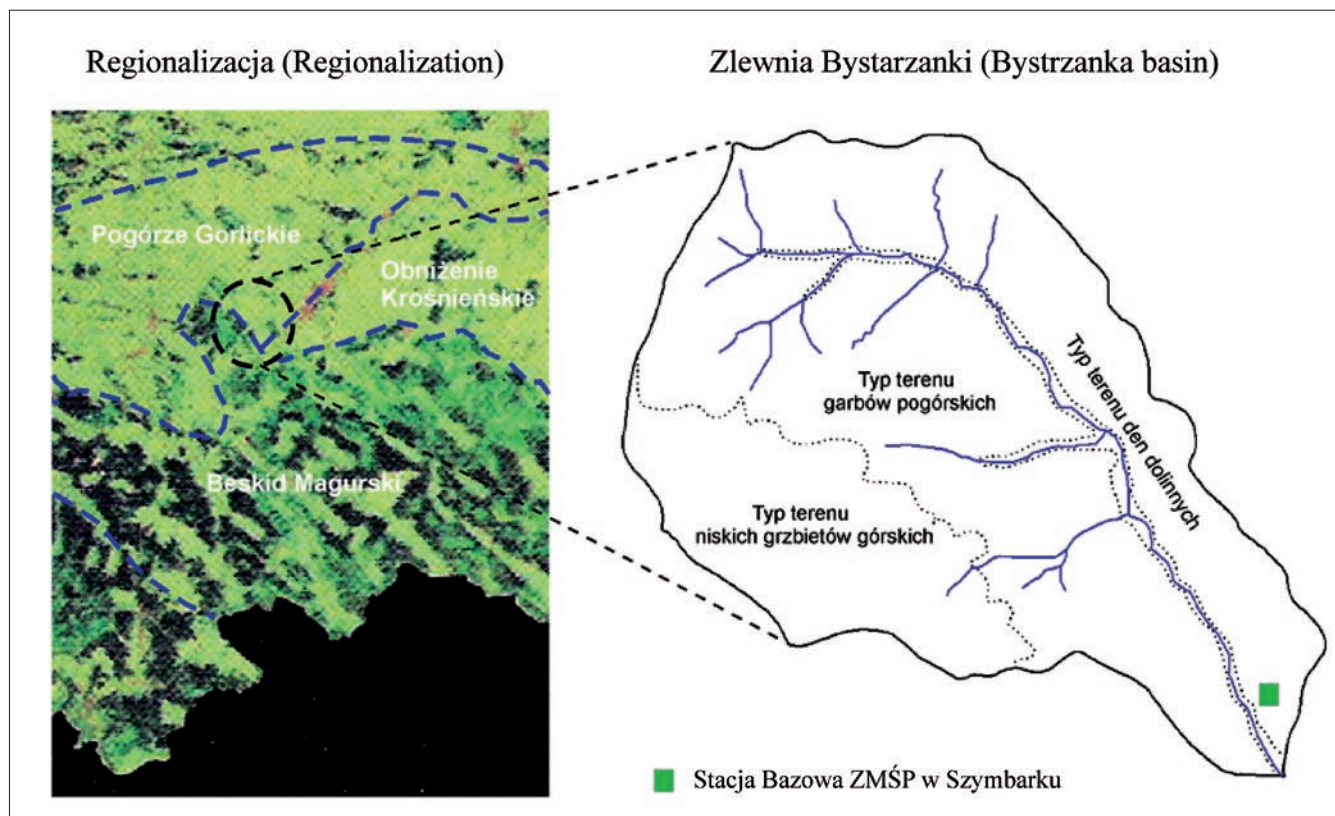
kładowi normalnemu Gaussa (Jakomulska, 1998). Metody te sprawdzają się w przypadku klasyfikacji jednorodnych spektralnie klas względem innych elementów środowiska, jednak na obszarach o złożonej charakterystyce pokrycia terenu nie zawsze możliwe jest zdefiniowanie niepowtarzalnych „czystych” pól treningowych dla wszystkich wymaganych klas. Typowym przykładem klasy o nienormalnym rozkładzie wartości są tereny miejskie, ponieważ składają się one z wielu odmiennych obiektów takich jak budynki, roślinność, drogi, a także ogródków działkowych w przypadku gospodarstw wiejskich. Dlatego też wzorzec spektralny utworzony dla tej klasy może zawierać sygnatury spektralne odpowiadające innym klasom pokrycia terenu, co powoduje błędy w klasyfikacji. Natomiast stosując sztuczne sieci neuronowe istnieje możliwość implementacji w procesie klasyfikacji informacji o sąsiedztwie i współwystępowaniu obiektów, co może rozwiązać wyżej opisany problem.

Na podstawie powyższego przeglądu literatury można stwierdzić, iż obrazy hiperspektralne są bardzo dobrym materiałem do tworzenia map pokrycia terenu. Pozwalają na szczegółowe kartowanie obiektów powierzchni terenu, z wyższą dokładnością odzwierciedlenia rzeczywistości niż za pomocą obrazów wielospektralnych. Ich efektywne wykorzystanie uzależnione jest od wciąż rozwijanych nowoczesnych metod automatycznej klasyfikacji. Jednym z głównych kierunków badań są sztuczne sieci neuronowe, dzięki którym uzyskuje się wyniki dokładności na wysokim poziomie.

Charakterystyka obszaru badań

Zlewnia Bystrzanki położona jest w obrębie Płaszczowiny Magurskiej. Zajmuje obszar o powierzchni 13,6 km² dzielący się na trzy typy terenu: niskich grzbietów górskich, garbów pogórskich oraz dno doliny Bystrzanki (ryc. 1). Najwyżej położonym punktem zlewni jest Maślana Góra 750 m n.p.m., natomiast ujście Bystrzanki leży na wysokości 300 m n.p.m.. Średnie nachylenie stoków w zlewni wynosi 10°. Najwyższe partie terenu budują piaskowce magurskie, a stanowiące bezpośrednie otoczenie zlewni pogórskie garby zbudowane są z warstw inoceramowych poprzedzielanych wąskimi wkładkami łupków pstrych (Gil, 1979).

Deniwelacje rzeźby terenu badanego obszaru są przyczyną piętrowości klimatycznej. Piętro umiarkowanie ciepłe występuje średnio do wysokości 570 m n.p.m., a powyżej piętro umiarkowanie chłodne. Na kształtowanie się termiki i wilgotności powietrza wpływają częste adwekcje ciepłych mas powietrza z południa wywołujących w Beskidzie Niskim efekty fenowe (Obrębska-Starkłowa, 1973). Szata roślinna i użytkowanie ziemi nawiązuje do pięter klimatycznych. Granica między piętrem pogórz a piętrem regła dolnego przebiega na wysokości 450–500 m n.p.m. Wyższe partie zlewni zajmuje buczyna karpacka *Dentario Glandulosae-Fagetum*, z dominacją jodły i buka, zaś pogórz zajmuje grąd *Tilio-Carpinetum* z grabem, lipą, jaworem i jesionem. W dnie doliny Bystrzanki występuje zespół olszyny karpackiej (Staszkievicz, 1977). Użytkowanie



Ryc. 1. Obszar badań. Regionalizacja (Olędzki, 2007) i typy terenu zlewni Bystrzanki (Gil, 1997).

Fig. 1. The study area. Regionalization (Olędzki, 2007) and terrain types of Bystrzanka basin (Gil, 1997).

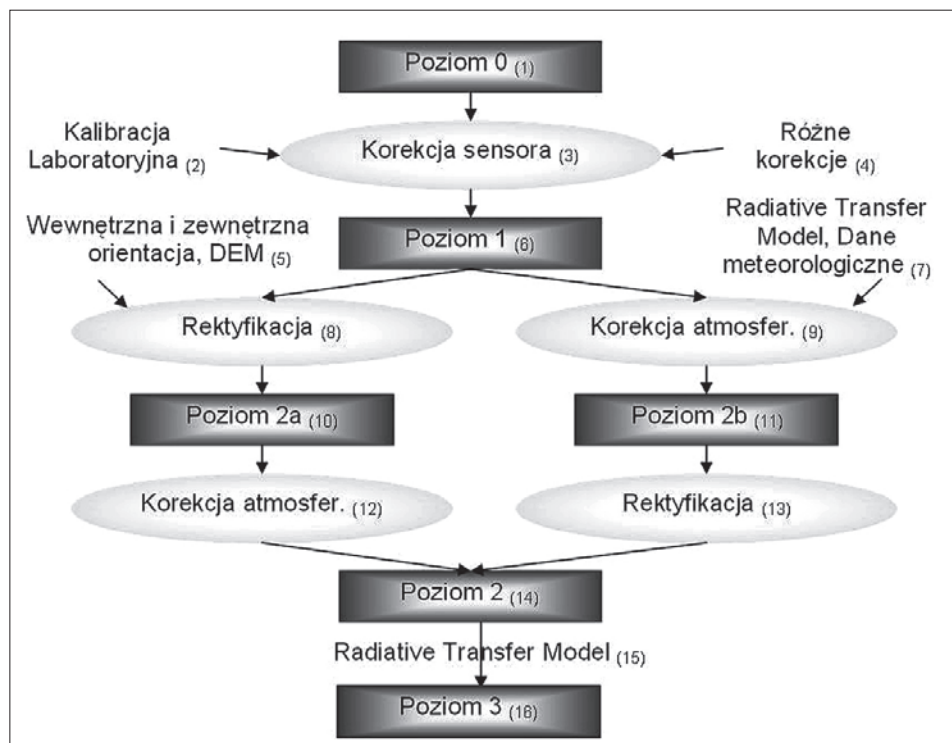
gruntów przedstawia się w następujący sposób: 46% – użytki rolne (w tym 19% – grunty orne, 27% – użytki zielone), 41% – lasy, 10% – powierzchnie zabudowane z sadami, 3% – inne.

Metodyka badań

Przeprowadzone prace polegały na wykonaniu mapy pokrycia terenu na podstawie obrazów hiperspektralnych z wykorzystaniem sztucznych sieci neuronowych. Główna idea badań, polegała na opracowaniu metodyki cyfrowej klasyfikacji obrazów, poprzez zastosowanie różnych zbiorów danych i struktury sieci neuronowych. Porównując uzyskane wyniki z poszczególnymi klasyfikacjami, dokonano oceny ich przydatności w kartowaniu pokrycia terenu. W rezultacie wskazano najlepsze rozwiązanie i algorytm postępowania, który może być punktem odniesienia dla przyszłych badań o podobnej tematyce.

Główną różnicą decydującą o sposobie przetwarzania danych oprócz liczby kanałów, jest mała szerokość zakresów spektralnych, dzięki którym możliwe jest rozważanie zestawu danych jako spektrum absorpcji (Habermeyer i in., 2005; Olesiuk, 2007). Analiza danych realizowana w taki sposób nazywana jest spektroskopią obrazową (Imaging Spectroscopy), powszechnie nazywaną także teledetekcją hiperspektralną.

Przystąpienie do interpretacji zdjęć hiperspektralnych wymaga odpowiedniego przetworzenia danych, których niedostateczna jakość bądź nadmiar informacji mogą fałszować lub utrudniać klasyfikację pokrycia terenu. Proces ten możemy podzielić na dwa etapy: przetwarzanie wstępne oraz wybór kanałów do klasyfikacji. Etap pierwszy polega na parametrycznej korekcji geometrycznej oraz atmosferycznej obrazów (Schlöpfer, Richter, 2002; Richter, Schlöpfer, 2002; Habermeyer i in., 2005), ponieważ cechują się one błędami wynikającymi z ruchu samolotu oraz obecności atmosfery (ryc. 2). Dane wykorzystywane w niniejszej pracy zostały przetworzone wraz z korekcją parametryczną, korekcją geometryczną oraz atmosferyczną w programie PARGE oraz ATCOR przez dr Bogdana Zagajewskiego i dr Rudolfa Richtera w Niemieckiej Agencji Kosmicznej (DLR Oberpfaffenhoffen), a terenowe pomiary referencyjne



Ryc. 2. Etapy przetwarzania obrazów hiperspektralnych (źródło: Habermeyer i in., 2005; Zagajewski, 2008).

Fig. 2. Stage of the hyperspectral image processing (source: Habermeyer i in., 2005; Zagajewski, 2008). 1 – Level 0. 2 – Laboratory calibration. 3 – System correction. 4 – Vicarious calibration. 5 – Attitude data, Position data, DEM. 6 – Level 1. 7 – Radiative Transfer Model, Meteorologic data. 8 – Parametric geocoding. 9 – Atmospheric correction. 10 – Level 2a. 11 – Level 2b. 12 – Atmospheric correction. 13 – Parametric geocoding. 14 – Level 2. 15 – Radiative Transfer Model. 16 – Level 3.

wykonała dr Uta Heiden z GeoForschungsZentrum w Poczdamie spektrometrem FieldSpec Pro (ryc. 3).

Po korekcji danych hiperspektralnych przechodzi się do ekstrakcji informacji w nich zawartych, które są dla najbardziej przydatne w pracy badawczej lub też niepotrzebne, ze względu na obciążenie błędami powstającymi podczas rejestracji obrazów. Polega to na wizualnej selekcji i wyborze kanałów spektralnych, lub automatycznych transformacji obrazu (*Principal Component Analysis – PCA*, *Minimum Noise Fraction – MNF*) mających na celu wyodrębnienie najmniej skorelowanych informacji.

Charakterystyka wykorzystanych obrazów hiperspektralnych i materiałów referencyjnych

Klasyfikowane obrazy pozyskane zostały 29.07.2002 roku we współpracy z Niemiecką Agencją Kosmiczną (DLR – Deutsches Centrum für Luft- und Raumfahrt) w ramach projektu EU HySens PL02_05 za pomocą skanera lotniczego DAIS 7915, rejestrującego 79 kanałów o rozdzielczościach spektralnych od 2 do 900 nm, przestrzennej 3 m i radiometrycznej 15 bitów. W trakcie nalotu wykonano trzy linie zobrazowania obszaru

badania, które nie objęły jednak całego terenu zlewni Bystrzanki (ryc. 4). Podział obrazów na dane treningowe i testowe był wymagany ze względu na wielkość plików oraz metodykę klasyfikacji za pomocą sieci neuronowych i został opisany poniżej.

Wykorzystano materiały referencyjne w postaci mapy pokrycia terenu zlewni Bystrzanki przedstawiającej 27 wydzieleni form pokrycia terenu, wykonanej w roku 2002 przez studentów w ramach praktyk terenowych. Kolejnym materiałem referencyjnym jest dokumentacja prac terenowych (zdjęcia fotograficzne, opisy, szkice sytuacyjne oraz film DVD nagrany w trakcie badań) przeprowadzonych w trakcie nalotu.

Przygotowanie danych do klasyfikacji

Przeprowadzenie klasyfikacji obrazów hyperspektralnych za pomocą sieci neuronowych wymagało wykonania szeregu prac przygotowawczych. Schemat poszczególnych etapów przedstawiony został na ryc. 5. Główne elementy przystąpienia do klasyfikacji to stworzenie mapy wzorcowej pokrycia terenu oraz wybór kanałów DAIS 7915 do klasyfikacji.

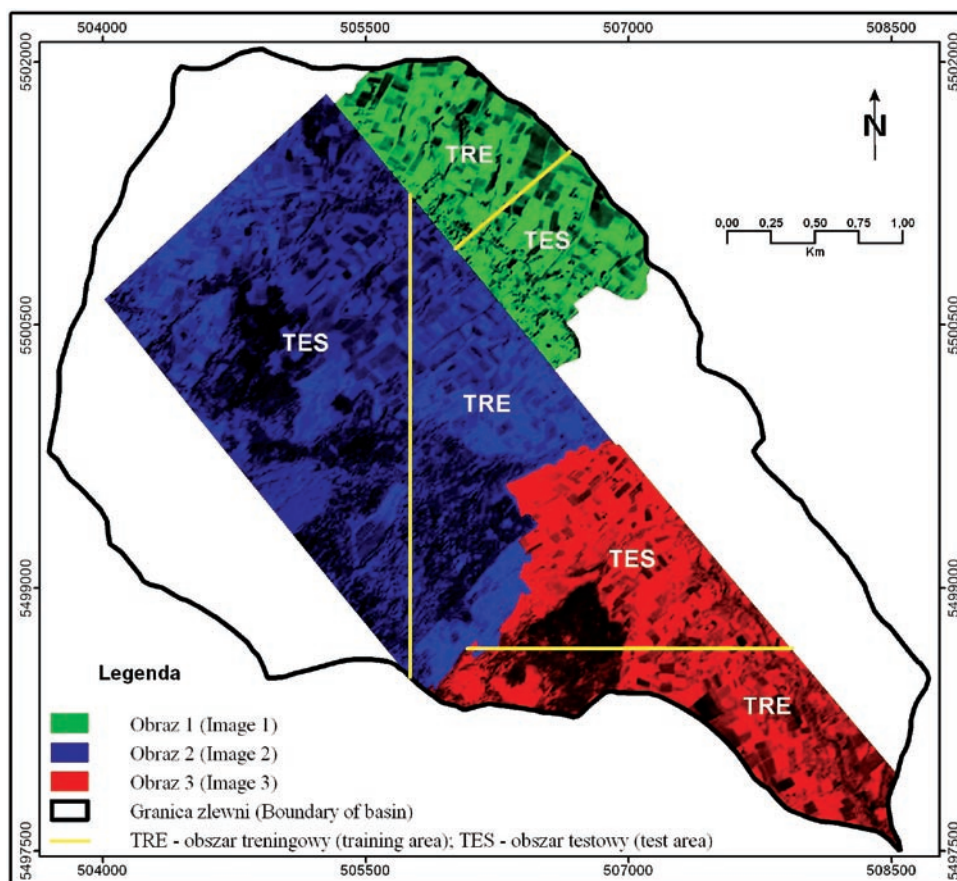
Wzorcowa mapa pokrycia terenu

Wzorcową mapę pokrycia terenu zlewni Bystrzanki wykonano metodą kameralną, ponieważ przeprowadzenie wywiadu terenowego nie było metodycznie uzasadnione ze względu na datę pozyskania obrazów oraz zebranie w trakcie badań wystarczającej ilości



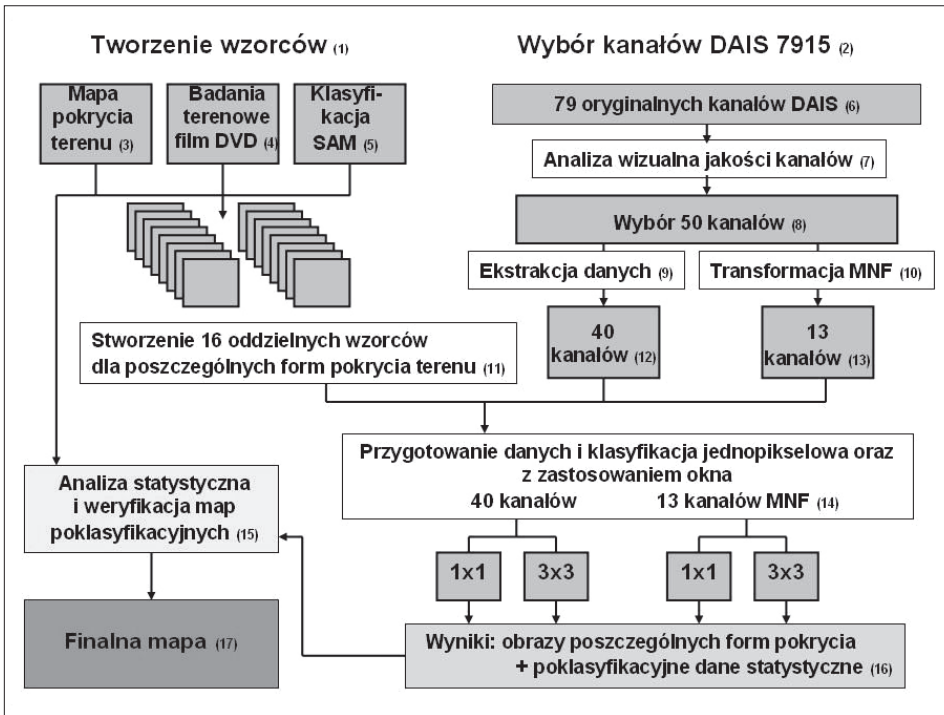
Ryc. 3. Pomiary kalibracyjne do korekcji atmosferycznych (Szymbark 2002 r.).

Fig. 3. Calibration measurements for the atmospheric correction (Szymbark 2002 r.).



Ryc. 4. Klasyfikowane obszary zlewni Bystrzanki na poszczególnych obrazach z podziałem na rejonny treningowe i testowe. Objasnienia: obraz 1 obejmuje Bieśnik Północny, obraz 2 – Bieśnik Południowy, obraz 3 pokrywa Wiatrówki.

Fig. 4. Classified regions of Bystrzanka basin with division on training and test area. Explanation: image 1 include North Bieśnik, image 2 include South Bieśnik, image 3 include Wiatrówki.



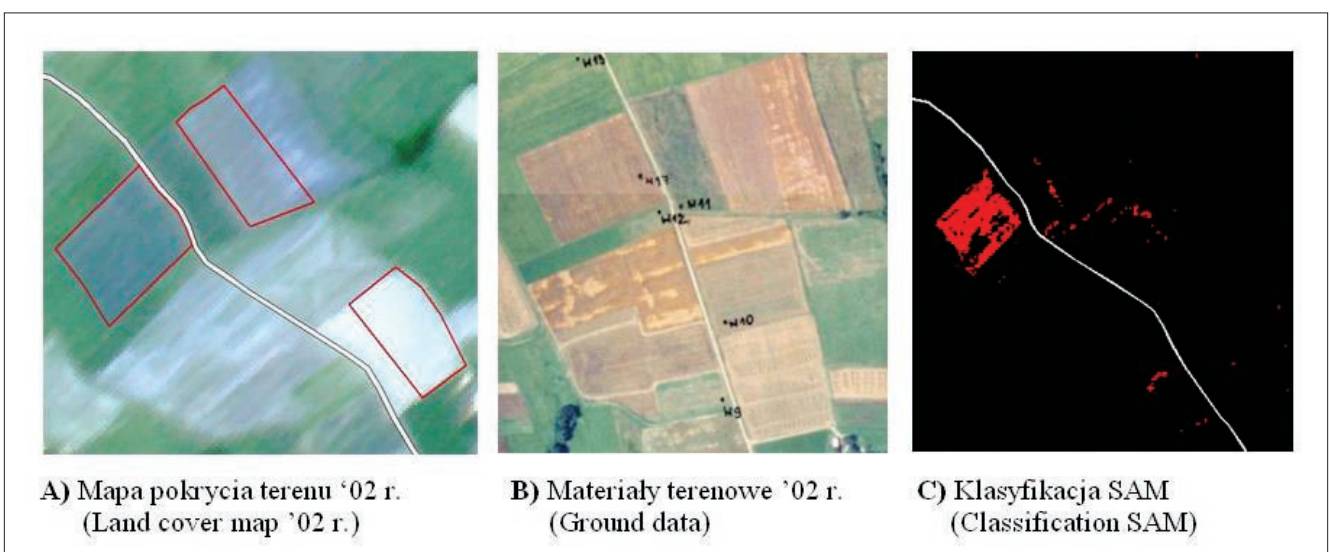
Ryc. 5. Przygotowanie i klasyfikacja obrazów hiperspektralnych.

Fig. 5. Preparation and classification hyperspectral images. 1 – Making pattern. 2 – DAIS 7915 bands selection. 3 – Land cover map. 4 – Ground reference data, film DVD. 5 – Classification SAM. 6 – 79 original DAIS 7917 bands. 7 – Visual quality bands analysis. 8 – Selected 50 bands. 9 – Feature extraction. 10 – Transformation MNF. 11 – Creating 16 land cover pattern. 12 – 40 bands. 13 – 13 bands. 14 – Preparing and classification data in pixel-by-pixel and utilizing a window. 15 – Accuracy assessment. 16 – Classification images. 17 – Final map.

danych. Mapa ta powstała na bazie wcześniej opisanych materiałów referencyjnych, z których poszczególne wydzielania zostały zweryfikowane za pomocą klasyfikacji *Spectral Angle Mapper*. Konieczność weryfikacji mapy pokrycia terenu z roku 2002 wynikała głównie z tego, iż obrazy hiperspektralne zostały

zarejestrowane w okresie żniw, tak więc areal upraw zbożowych ulegał dynamicznym zmianom w trakcie trwania 10-dniowej kampanii pomiarowej towarzyszącej zobrazowaniu lotniczemu. Ponadto wymagało to aktualizacji wcześniej wykonanej mapy. Wykorzystanie w tym celu klasyfikacji SAM było możliwe, dzięki szczegółowej dokumentacji badań terenowych przeprowadzanych w dniach nalu. Mimo, iż wywiad terenowy nie objął całego obszaru zlewni, a tylko poligony kluczowe, metodyczne założenia klasyfikacji SAM pozwoliły z wysoką pewnością zidentyfikować poszczególne klasy pokrycia terenu, aczkolwiek konieczne było zawężenie ilości wydzielanych klas do 16 względem 27 z pierwotnej mapy. Rycina 6 przedstawia zakres weryfikacji pierwotnej mapy pokrycia terenu na podstawie posiadanych materiałów referencyjnych.

Ryc. 6A, przedstawia przykład wydzielenia działek z uprawą owsa (czerwonym kolorem oznaczone są poligony tej uprawy z pierwotnej mapy), natomiast na ryc. 6B będącym fragmentem zdjęcia lotniczego, naniezione są punkty udokumentowane w trakcie badań terenowych. Analiza materiałów wskazała, iż w trakcie



Ryc. 6. Weryfikacja mapy pokrycia terenu z roku 2002. Objaśnienia w tekście.

Fig. 6. Verification land cover map from 2002 year. Explanation in text.

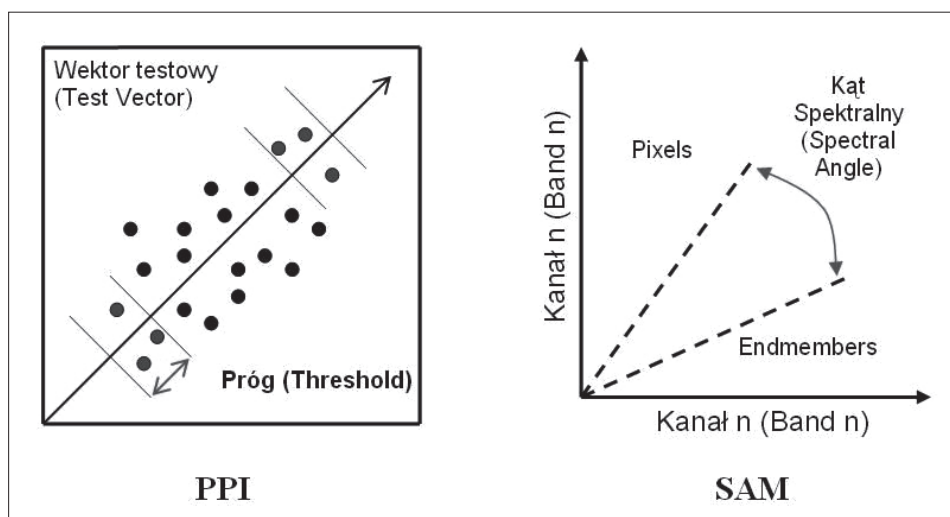
nalotu owies nie był skoszony jedynie na polu z lewej strony, co potwierdziła także klasyfikacja SAM, której rezultat w postaci czerwonych pikseli odpowiadających owsowi widoczny jest na ryc. 6C. Jak wcześniej wspomniano, ówczesne badania terenowe wykonywane w dniu nalotu nie objęły obszaru całej zlewni, przez co weryfikacja w tych rejonach podlegała jedynie klasyfikacji SAM, której nie można było wykonać dla innych klas pokrycia terenu niż tych opisanych w badaniach terenowych. Wynikało to z braku pewności co do prawidłowości wydzielenia na pierwotnej mapie, i zdecydowano się klasyfikować 16 klas pokrycia terenu takich jak: las liściasty, las mieszany, las iglasty, zadrzewienia i zakrzaczenia, sad, łąka, nieużytek, owies, ściernisko, buraki, ziemniaki, grunt zaorany, droga polna, droga asfaltowa, budynki, tereny zabudowane. Z uwagi na to, iż klasyfikowano trzy obrazy pokrywające teren badań wszystkie powyższe klasy pokrycia terenu znajdują się jedynie na obrazie 3, natomiast na pozostałych nie znalazły się grunty zorane. Na terenie obrazu 2 w obszarze treningowym nie występuje także droga asfaltowa, natomiast na obrazie 1 nie ma lasów iglastych, oraz mieszanych i nieużytków w obszarze testowym.

Ponieważ wykorzystywany symulator sztucznych sieci neuronowych nie obsługuje plików w formacie wektorowym oraz rastrowym, wymagane było utworzenie z każdej klasy pokrycia terenu osobnego pliku tekstowego w jednobitowym formacie zapisu danych (ASCII). W rezultacie tego działania, w poszczególnych plikach obszarom, gdzie występują poszczególne wydzielenia przypisane zostały 1, natomiast 0 odpowiadało pozostałym klasom.

Ponieważ wykorzystywany symulator sztucznych sieci neuronowych nie obsługuje plików w formacie wektorowym oraz rastrowym, wymagane było utworzenie z każdej klasy pokrycia terenu osobnego pliku tekstowego w jednobitowym formacie zapisu danych (ASCII). W rezultacie tego działania, w poszczególnych plikach obszarom, gdzie występują poszczególne wydzielenia przypisane zostały 1, natomiast 0 odpowiadało pozostałym klasom.

Klasyfikacja Spectral Angle Mapper (SAM)

Klasyfikacja SAM to automatyczna metoda polegająca na porównaniu profili spektralnych (wektorów spektralnych) każdego piksela na analizowanym obrazie z wektorami spektralnymi odpowiadającymi obiektom czystym spektralnie, które będą reprezentowały wynikowe klasy. Obliczany jest kąt spektralny (bądź też odległość spektralna) między każdą parą wektorów i na podstawie tego tworzone są obrazy, dla każdej klasy oddzielnie, przedstawiające ową odległość dla każdego piksela (Zagajewski i in., 2005). Piksele powstałych obrazów zawierają wartości z zakresu 0–1, które określają stopień podobieństwa do pikseli czystych spektralnie, czyli prawdopodobieństwa występowania danej



Ryc. 7. Wyznaczenie pikseli czystych spektralnie (PPI) oraz klasyfikacja SAM (źródło <http://www.microimages.com/>).

Fig. 7. Pixel Purity Index (PPI) and SAM classification (source: <http://www.microimages.com/>).

klasy pokrycia terenu, gdzie im bliżej 0 to prawdopodobieństwo wzrasta. Malejąca skala przynależności pikseli do danej klasy wynika z ustalania w klasyfikacji SAM maksymalnego kąta (w radianach) przynależności, tzn. wyższe wartości pikseli wynikowych klasyfikacji świadczą o dużej odległości (różnicy) spektralnej (ryc. 7). Powstałe obrazy prawdopodobieństwa podlegają następnie progowaniu, tzn. określeniu maksymalnego odchylenia od 0, czyli ustaleniu zakresu traktowania pikseli jako należących do poszczególnych klas. W przykładzie klasyfikacji owsa (ryc. 6) zastosowano próg kąta radialnego wynoszącego 0,05.

Piksele czyste spektralnie wykorzystywane w klasyfikacji SAM pobrano z obrazu, wyznaczając uprzednio indeks czystości pikseli (*Pixel Purity Index* – PPI). Proces ten służy do wskazania ze zbioru wszystkich pikseli zobrazowania hyperspektralnego pikseli czystych spektralnie, tzn. najbardziej reprezentatywnych. Piksele odwzorowywane są na niezależne n-wymiarowe wektory w celu znalezienia pikseli o ekstremalnym położeniu (ryc. 7). Krotność, z jaką dany piksel został zarejestrowany jako ekstremalny, określa jego „indeks czystości spektralnej”. Informacja ta jest wykorzystywana do wyznaczenia endmemberów dla poszczególnych klas pokrycia terenu. Poza wartością progu ekstremum, dla procesu PPI określa się liczbę iteracji przetwarzania obrazu, co determinuje dla pikseli krotność indeksu czystości.


Inną metodą pozyskania do klasyfikacji SAM pikseli czystych spektralnie z obrazu to N-wymiarowa wizualizacja danych w przestrzeni wielowymiarowej, która także umożliwia określenie ekstremalnych pikseli, jednak w mniej automatyczny sposób. Pozyskanie pikseli czystych spektralnie może odbyć się także w trakcie badań terenowych za pomocą spektrometrów nieobrazujących, z których uzyskane krzywe spektralne po dostosowaniu rozdzielczości spektralnej do obrazu. Pro-

wadzi to do stworzenia bibliotek spektralnych, z których krzywe mogą być wykorzystywane do klasyfikacji różnych obrazów.

Wybór kanałów DAIS 7915 do klasyfikacji

Ekstrakcji informacji tematycznej obrazów hiperpektralnych DAIS 7915 dokonano w pierwszej fazie metodą wizualną wybierając 50 najlepszych kanałów na podstawie oceny jasności zobrazowania oraz rozkładu histogramu dla każdego kanału zobrazowania. Najwięcej kanałów wykluczono w zakresie średniej podczerwieni, gdzie występuje absorpcja promieniowania przez parę wodną i CO_2 . W pracy założono wykonanie klasyfikacji na dwóch zestawach danych, tzn. oryginalnych kanałach spektralnych, a także danych skompresowanych za pomocą transformacji MNF. Miało to na celu porównanie uzyskanych dokładności klasyfikacji z użyciem sieci neuronowych, w odniesieniu do poświęconego temu czasu obliczeń, który jak się okazało liczony był nawet w tygodniach. Na podstawie konkluzji z artykułu P. Mahesha i P. Mathera (2006), dotyczącego klasyfikacji obrazów DAIS 7915, postanowiono ograniczyć liczbę klasyfikowanych oryginalnych kanałów do 40, ze względu na optymalny stosunek dokładności klasyfikacji do czasu jej wykonywania. Redukcję kanałów przeprowadzono eliminując co piąty kanał, tak aby nie zawęzić spektrum w żadnych zakresach, przez co ostatecznie do klasyfikacji przeznaczono kanały: 1, 2, 3, 4, 7, 9, 10, 11, 12, 14, 15, 16, 17, 19, 20, 21, 22, 24, 25, 26, 27, 29, 30, 31, 32, 34, 35, 36, 37, 38, 39, 40, 42, 46, 47, 50, 52, 53, 55, 56, 58.

Drugi zestaw danych przeznaczony do klasyfikacji określony został za pomocą transformacji MNF. Składa się ona z podwójnej transformacji składowych głównych (PCA). Pierwszy etap polega na dekorelacji szumu zawartego na obrazie, czego rezultatem jest oddzielenie zakłóceń od najbardziej istotnych informacji



Ryc. 8. Wykres transformacji MNF. Oś X – wartości pikseli, oś Y – kanały.

Fig. 8. MNF transformation graph. Axis X – pixel value, axis Y – bands.

w kontekście cyfrowej klasyfikacji. W następnym etapie przeprowadzana jest standardowa transformacja PCA, zmierzająca do wyznaczenia nowej osi głównej przebiegającej wzdłuż największej wariacji danych. Brak korelacji między nowymi kanałami zapewniają kolejne prostopadłe osie układu współrzędnych. W wyniku transformacji MNF powstają nowe kanały, zawierające kolejno najbardziej nieskorelowane wartości. Przydatność (zawartość nieskorelowanej informacji spektralnej) poszczególnych kanałów można ocenić analizując powstający w danym procesie wykres (ryc. 8), przedstawiający wartości własne kanałów, i na podstawie tego zdecydować o zakresie włączonych kanałów do późniejszej klasyfikacji.

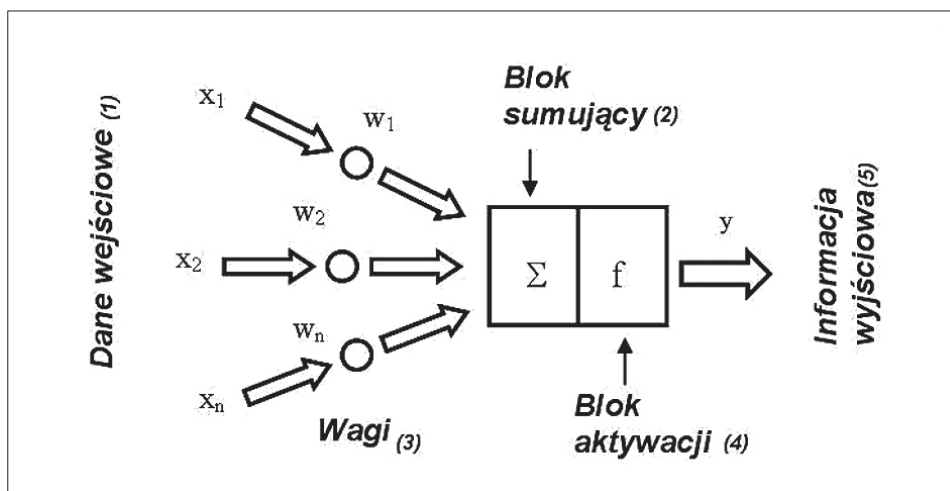
Na podstawie powyższego wykresu oraz przeglądu literatury zdecydowano wykorzystać do klasyfikacji pierwsze 13 kanałów zawierających najbardziej nieskorelowane informacje.

Klasyfikacja obrazów za pomocą sztucznych sieci neuronowych

Niezależnie od zastosowań podstawowy model sieci neuronowych składających się z określonej przez użytkownika liczbie neuronów jest niezmienny. Proces przetwarzania informacji przez poszczególne neurony zaprezentowano na ryc. 9.

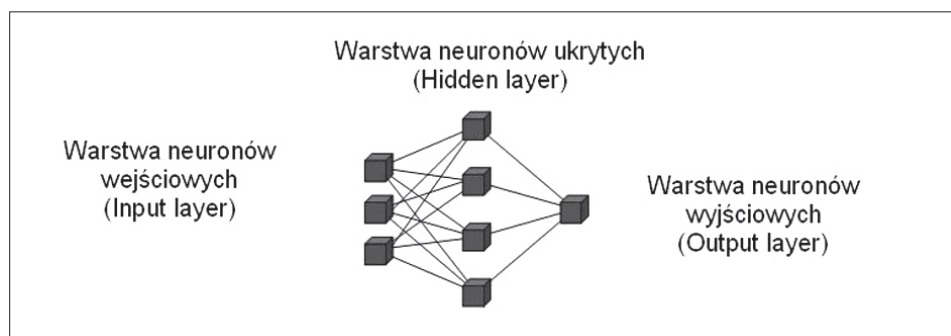
Przy klasyfikacji obrazów neurony wejściowe tworzone są przez kanały spektrum elektromagnetycznego włączonego do analizy, z których informacje za pomocą połączeń i ich wag są modyfikowane i przekazywane do kolejnych warstw. W warstwie wyjściowej przedstawia się wzór wartości odpowiadających poszczególnym formom pokrycia terenu. W trakcie procesu uczenia sieci neuronowych najważniejszą rolę odgrywają wagi połączeń neuronów, gdyż wszystko, czego sieć została nauczona, zapisane jest w tych wagach (Civco, 1993). Oceny przeprowadzonego treningu sieci neuronowych, na który decydujący wpływ mają cechy jakościowe wzorca oraz parametry i długość uczenia, dokonuje się testując działanie sieci na zbiorze danych, który nie był włączony do procesu treningu. Metoda ta pozwala opierać się nie tylko o analizę cech spektralnych poszczególnych pikseli, ale również dołączyć do procesu klasyfikacji informację o teksturze, poprzez zaprojektowanie struktury neuronów wejściowych w postaci kwadratu (np. o rozmiarach 3x3 piksele), z którego obliczana jest średnia wartość i przypisywana jedynie do piksela środkowego. Dlatego postanowiono wykonać klasyfikacje obrazów w standardowym podejściu jednopikselowym, a także z zastosowaniem okna teksturalnego 3x3 piksele, aby porównać wpływ informacji o teksturze na dokładność klasyfikacji. Miało to na celu uwzględnienie w klasyfikacji strukturalnych cech obiektów, takich jak współwystępowanie i analiza sąsiedztwa.

Oceny przeprowadzonego treningu sieci neuronowych, na który decydujący wpływ mają cechy jakościowe wzorca oraz parametry i długość uczenia, dokonuje



Ryc. 9. Elementy procesu działania sieci neuronowych (źródło: Foody, 1995). Objasnienia: x – wartości wejściowych, w – wagi, Σ – suma zmodyfikowanych wartości wejściowych, f – funkcja aktywacji, y – informacja wyjściowa.

Fig. 9. Artificial neural network processing element (source: Foody, 1995). Explanations: x – input values; w – weights; Σ – sum modified input values; f – activation functions; y – output values. 1 – Input path. 2 – Sum block. 3 – Weights. 4 – Activation block. 5 – Output path.



Ryc. 10. Topologia zastosowanej sieci neuronowej.

Fig. 10. Used neural network topology.

się prezentując nauczonej sieci zbiór danych, który nie był włączony do procesu treningu i porównując uzyskane wyniki przetworzenia przez sieć danych testowych z oczekiwanym rezultatem.

Struktura i parametry uczenia oraz testowania sieci neuronowych

Ze względu na długi czas obliczeń i ogromny zakres potrzebnej do wykonania analizy pamięci operacyjnej, nie było możliwe przetestowanie różnych rozwiązań struktury i parametrów uczenia. Dlatego też powyższe wartości określono na podstawie opracowania T. Kavzoglu i P. M. Mathera (2003). Opisali oni wiele eksperymentów klasyfikacji obrazów za pomocą sieci neuronowych, i zaprezentowali optymalne wartości struktury i parametrów uczenia dokonując podsumowania, iż są one konsensusem między czasem trwania procesów, a uzyskiwanymi dokładnościami.

Na potrzeby niniejszej pracy przyjęto, iż strukturą sieci będzie perceptron wielowarstwowy jednokierunkowy, gdzie liczba neuronów wejściowych wynosiła kolejno 40 i 13 neuronów, odpowiadających liczbie kanałów dwóch wejściowych zestawów danych (kanałów oryginalnych i po transformacji MNF). Struktura sieci jest to model układu kolejnych warstw neuronów, i istniejących połączeń między nimi. Schemat sieci wielowarstwowej jednokierunkowej przedstawiono na ryc. 10. Liczbę neuronów w warstwie ukrytej określono stosując wzór $3N_i+1$ (Kavzoglu, Mather, 2003), gdzie N_i oznacza liczbę neuronów wejściowych. Oznaczało to, iż w przypadku 40 kanałów wejściowych stosowano 121 neuronów ukrytych, natomiast przy 13 było ich 50.

Sieci neuronowe uczone były z wykorzystaniem algorytmu wstecznej propagacji błędów, w którym adekwatnie do nazwy modyfikacja wag połączeń między kolejnymi warstwami neuronów podlegała wartościom zaprezentowanym w ostatniej warstwie wyjściowej, tzn. na podstawie wzoru poszczególnych

warstw pokrycia terenu. Stosowanymi parametrami uczenia sieci była waga inicjacji, czyli nadanie początkowych wartości połączeniom neuronowym w przedziale $-0,25-0,25$, a także współczynnik uczenia wynoszący 0,2. Współczynnik uczenia określa możliwy zakres zmiany wag połączeń przy kolejnych iteracjach procesów, których dla każdego procesu treningu sieci wykonano 2500. Jakość uczenia sieci była oceniana na podstawie uzyskiwanego kumulowanego błędów kwadratowego sum-squared error (SSE). Wskaźnik ten, obliczany jest poprzez porównywanie otrzymanego wyniku uczenia z wartością docelową, a następnie podnoszenie tej wartości do kwadratu.

Test uczenia, czyli główna klasyfikacja obrazu, polegała na wykorzystaniu nauczonych plików sieci z każdego obrazu do przetworzenia części zdjęcia określonego na ryc. 4 jako testowe. Czas testu nie odbiegał od standardowych metod klasyfikacji, ponieważ nie wymagało to wykonania 2500 iteracji, a jedynie jednorazowego przetworzenia obrazu.

Wynikowe obrazy klasyfikacji

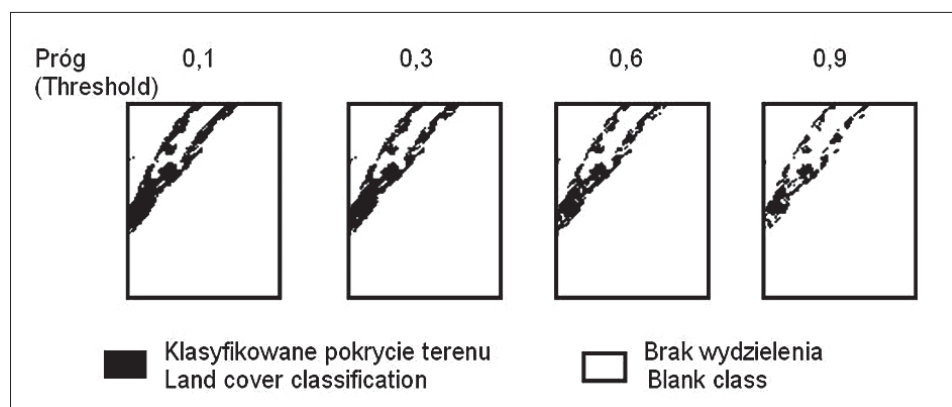
Rezultatem klasyfikacji obrazu za pomocą sieci neuronowych były pliki tekstowe, których liczba odpowiadała ilości wydzielanych klas pokrycia terenu na każdym obrazie. Zawierały one wartości odpowiadające kolejnym pikselom w przedziale 0–1, odpowiadając prawdopodobieństwu wystąpienia klasyfikowanego obiektu, przy czym im bliżej 1 (cyfrze tej odpowiadały kolejne klasy pokrycia w 1 bitowym zapisie wzorca uczącego) tym zakres wydzielenia na końcowym obrazie malał, gdyż zdecydowanie zawężone zostaje kryterium statystyczne poszukiwanej klasy (ze względu na zawężanie ekstrahowanych cech ze zbioru danych (przykład na ryc. 11)). Dla każdego obrazu próg został określony na podstawie wizualnego porównania ze wzorcem klasy, w taki sposób, aby możliwie zapobiegać wzajemnemu nakładaniu się wydzieleni, co mogło wystąpić po złożeniu ze sobą wszystkich klas pokrycia terenu. Nakładanie się wydzieleni dotyczyło w głównej mierze klas, których parametry spektralne są zbliżone, a ich rozdzielność spektrometryczna nie została w pełni uwzględniona przez sztuczną sieć neuronową, na co wpływ mogły mieć parametry uczenia oraz ilość iteracji. Przykład połączonych klas pokrycia terenu z nakładającymi się klasami zaprezentowano na ryc. 12 i jest to wynik treningu obrazu 1 (objaśnienie na ryc. 4)

Reguły poklasyfikacyjne

W celu sklasyfikowania obszarów wspólnych wydzieleni została z nich utworzona oddzielna warstwa, która podlegała następnie regułom poklasyfikacyjnym opracowanym po analizie obrazu wynikowego. Zastosowano automatyczne reguły: przydzielenie do dróg wydzieleni, które mają wspólną granicę z tymi klasami pokrycia terenu – wynikało to z tego, iż na obrazie 3 droga asfaltowa przysłonięta jest drzewami porastającymi dolinę rzeki

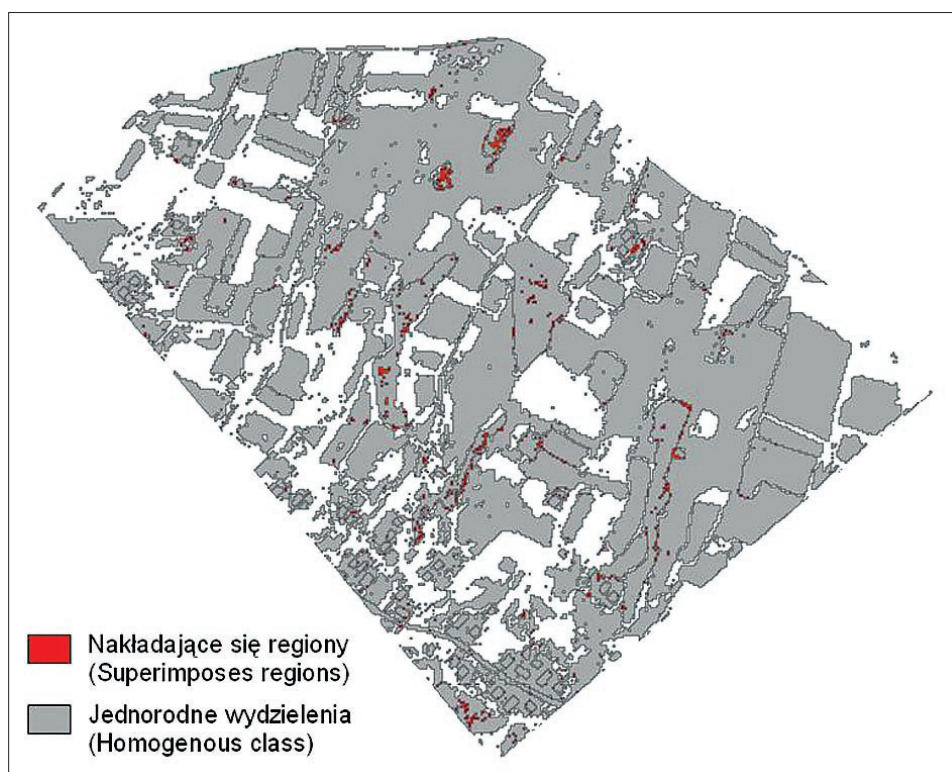
Bystrzanki, co spowodowało utworzenie w tych miejscach obu klas pokrycia terenu. Nadanie priorytetowego znaczenia wydzieleniom dróg, podyktowane było także tworzeniem na nich klas budynków i terenów zabudowanych, co nie występowało w odwrotnym kierunku. Wyższy status nadano także wydzieleniom, które powinny należeć do budynków, a które niekiedy pokrywały się z terenami zabudowanymi. Pozostałe wspólne poligony ostatecznie sklasyfikowane zostały pod względem zawierania się, bądź najdłuższej wspólnej granicy z przylegającymi.

Dla prezentacji map wynikowych przyjęto wartość skali 1:15000. Wymagało to generalizacji najmniejszych wydzieleni do poligonu 3x3 piksele, czyli 81 m².



Ryc. 11. Przykład progowania wynikowego obrazu klasyfikacji.

Fig. 11. Example of using threshold on output image.



Ryc. 12. Połączone obrazy klas pokrycia terenu z regionami nakładającymi się.

Fig. 12. Joint land cover classes with superimposes regions.

Zaprezentowane algorytmy pozwalają na klasyfikację każdej formy pokrycia terenu oddzielnie, uwzględniając możliwość korekty poszczególnych poligonów wzorcowych, co pomaga w odpowiednim nauczaniu sieci i wyborze lepszego zestawu danych (40 klas danych oryginalnych, bądź też 13 po transformacji MNF). Powyższy sposób postępowania gwarantuje uzyskanie wiarygodnych i powtarzalnych wyników dla każdego zestawu danych.

Wyniki klasyfikacji obrazów

Ocena dokładności

Ocenię dokładności klasyfikacji poddano wszystkie mapy poszczególnych form pokrycia terenu, na których przeprowadzono opisane reguły poklasyfikacyjne (przed generalizacją powierzchni mniejszych niż 81 m²). Dokładność klasyfikacji oceniono wykorzystując program ENVI za pomocą metody *Using Ground Truth*

Image, czyli na podstawie mapy poligonów wzorcowych (ocena wszystkich pikseli). Wskaźniki określające dokładność klasyfikacji to: dokładność całkowita – stosunek poprawnie sklasyfikowanych pikseli względem wszystkich wydzielonych dla każdej z klas; dokładność producenta – poprawnie sklasyfikowane piksele w danej klasie; dokładność użytkownika – obliczana jest poprzez porównanie pikseli dobrze sklasyfikowanych w danej klasie z wszystkimi pikselami, które zostały zaklasyfikowane do tej kategorii; wskaźnik Kappa – pokazuje prawdopodobieństwo błędów w czasie klasyfikacji w porównaniu z błędem klasyfikacji realizowanej przypadkowo.

Porównanie dokładności klasyfikacji obrazu

Wiatrówek w kontekście wykorzystania strukturalnych cech obiektów

Poligon badawczy Wiatrówki (obraz nr 3) stanowił poligon testowy, na którym wykonano klasyfikację

Tab. 1. Wyniki dokładności klasyfikacji danych treningowych obrazu 3.

Tab. 1. Classification accuracy for training area on image 3.

Pokrycie terenu (Land cover)	Dokładność (Accuracy)		13 k MNF 1x1		13 k MNF 3x3		40 k 1x1		40 k 3x3	
	Całk.: 80,1 % (Overall)		Całk.: 88,1 % (Overall)		Całk.: 85,3 % (Overall)		Całk.: 93,1 % (Overall)		Całk.: 93,1 % (Overall)	
	Kappa: 0,7563		Kappa: 0,8546		Kappa: 0,8204		Kappa: 0,9159		Kappa: 0,9159	
	Prod. [%] (Prod.)	Użyt. [%] (User)	Prod. [%] (Prod.)	Użyt. [%] (User)	Prod. [%] (Prod.)	Użyt. [%] (User)	Prod. [%] (Prod.)	Użyt. [%] (User)	Prod. [%] (Prod.)	Użyt. [%] (User)
Łąki (Meadow)	87,6	91,2	94,3	92,4	93,1	92,2	96,6	95,1		
Nieuzytki (Wastelands)	81,5	53,9	81,7	89,3	83,9	75,6	91,7	90,1		
Las iglasty (Coniferous forest)	81,6	89,6	87,3	92,0	84,8	89,2	90,7	94,2		
Las mieszany (Mixed forest)	80,7	83,0	91,3	88,1	86,3	84,2	94,1	91,5		
Las liściasty (Deciduous forest)	83,6	74,3	84,9	88,3	85,8	80,6	92,0	92,7		
Zadrzewienia (Woodeds)	33,9	33,9	60,4	53,0	43,6	39,8	67,2	72,5		
Sad (Orchard)	37,1	28,4	70,2	76,9	44,3	56,9	86,0	91,0		
Buraki (Beets)	19,8	70,3	74,0	85,2	75,0	84,5	96,7	100,0		
Ziemniaki (Potatoes)	61,0	40,6	64,1	88,7	81,7	75,3	91,6	91,9		
Owies (Oats)	97,2	93,8	99,2	98,3	98,9	96,6	99,6	99,3		
Ściernisko (Stubble)	97,3	96,9	97,5	97,7	98,8	94,8	98,7	98,6		
Grunt zaor. (Plough soil)	93,9	99,3	100,0	99,9	98,7	100,0	100,0	100,0		
Droga asfalt. (Asphalt road)	38,9	23,3	39,5	42,2	4,6	40,6	70,8	72,4		
Droga polna (Dirt road)	60,5	27,3	95,6	67,4	55,5	72,6	98,6	91,2		
Tereny zabud. (Built-up area)	0,6	46,0	63,0	65,0	43,2	57,5	72,6	83,6		
Budynki (Buildings)	69,8	61,7	68,8	75,1	75,3	68,4	94,4	86,3		

dwóch zestawów danych, tzn. 40 kanałów oryginalnych oraz 13 kanałów po transformacji MNF. Oba zestawy poddano klasyfikacji opierającej się jedynie o wartości spektralne pojedynczych pikseli. W drugiej klasyfikacji dołączono cechy strukturalne obiektów stosując okno klasyfikacyjne 3x3 piksele. Wykonanie powyższych klasyfikacji miało na celu porównanie i wybór najlepszej metodyki klasyfikacji zastosowanej do dwóch pozostałych obrazów. Wyniki wykonanych prób dla danych treningowych i testowych znajdują się odpowiednio w tabeli 2 oraz 3.

Analiza całkowitej dokładności klasyfikacji obrazu 3 nie pozwoliła jednoznacznie wnioskować o lepszej przydatności w cyfrowej klasyfikacji pokrycia terenu obrazów składających się oryginalnych kanałów hiperpektralnych bądź kanałów MNF. Wynikało to z rozbieżności lepszych wyników uzyskanych z kanałów oryginalnych dla danych treningowych, względem wyższej dokładności klasyfikacji obrazu MNF w przypadku zbioru testowego.

Porównanie wpływu na dokładność klasyfikacji dołączenia cech strukturalnych obiektów poprzez wykorzystanie okna 3x3 piksele wskazało, iż w każdym przypadku dla danych treningowych dokładność producenta, użytkownika oraz całkowita dla poszczególnych klas pokrycia terenu była wyższa. Natomiast wyniki dokładności całkowitej zbioru testowego okazały się bardzo zbliżone, uzyskując najlepszy rezultat w klasyfikacji 13 kanałów MNF w oknie 3x3 piksele, aczkolwiek nie wszystkie klasy pokrycia terenu zostały sklasyfikowane lepiej niż w podejściu jednopikselowym. Zauważono jednak, iż w przypadku klasyfikacji niejednorodnych klas, jak np. terenów zabudowanych, reprezentowanych na obszarze zlewni Bystrzanki przez zagrody gospodarcze, uzyskano lepsze wyniki stosując okno teksturalne.

Na podstawie powyższych wniosków zdecydowano przeprowadzić klasyfikację obrazu 1 i 2 ponownie wykorzystując dwa zestawy danych, jednak stosując już wyłącznie proces uwzględniający teksturę obiektów, czyli okno klasyfikacyjne 3x3 piksele.

Tab. 2. Dokładność klasyfikacji danych testowych obrazu 3.

Tab. 2. Classification accuracy for test area on image 3.

Dokładność (Accuracy) Pokrycie terenu (Land cover)	13 k MNF 1x1		13 k MNF 3x3		40 k 1x1		40 k 3x3	
	Całk.: 74,9 % (Overall)		Całk.: 75,9 % (Overall)		Całk.: 74,5 % (Overall)		Całk.: 73,7% (Overall)	
	Kappa: 0,6813		Kappa: 0,6942		Kappa: 0,6635		Kappa: 0,6480	
	Prod. [%] (Prod.)	Użyt. [%] (User)	Prod. [%] (Prod.)	Użyt. [%] (User)	Prod. [%] (Prod.)	Użyt. [%] (User)	Prod. [%] (Prod.)	Użyt. [%] (User)
Łąki (Meadow)	89,4	85,1	93,4	78,6	89,9	78,7	89,1	78,3
Nieuzytki (Wastelands)	38,1	29,3	8,4	33,3	31,8	45,1	7,1	37,5
Las iglasty (Coniferous forest)	85,0	93,6	96,2	93,4	94,7	94,0	97,4	93,2
Las miesz. (Mixed forest)	59,2	70,7	66,5	86,2	65,0	75,7	76,1	85,0
Las liściasty (Deciduous forest)	78,4	62,1	70,3	70,4	75,2	64,4	65,2	81,3
Zadrzewienia (Woodeds)	4,8	30,9	18,7	21,9	10,9	20,2	25,1	24,8
Sad (Orchard)	12,5	7,6	38,4	19,6	1,9	25,6	17,6	25,0
Buraki (Beets)	33,3	64,3	49,0	77,4	27,1	82,9	7,6	26,2
Ziemniaki (Potatoes)	52,1	59,7	43,5	47,6	80,9	61,5	79,3	63,5
Owies (Oats)	63,4	82,5	38,7	99,1	76,5	77,7	74,4	96,4
Ściernisko (Stubble)	98,1	87,8	98,1	95,3	94,5	89,0	91,2	98,4
Grunt zaor. (Plough soil)	66,3	93,3	87,8	93,7	89,1	90,8	73,7	94,2
Droga asfalt. (Asphalt road)	26,3	39,1	52,9	31,9	32,4	29,0	23,7	35,1
Droga polna (Dirt road)	15,4	17,4	63,0	49,2	25,6	38,1	26,7	46,8
Tereny zabud. (Built-up area)	6,0	34,8	41,4	50,4	16,4	22,5	22,6	20,7
Budynki (Buildings)	70,8	53,0	73,1	54,5	65,3	49,3	84,8	30,3

Tab. 3. Wyniki dokładności klasyfikacji obszarów treningowych i testowych obrazu 1.

Tab. 3. Classification accuracy for training and test area on image 1.

Dokładność (Accuracy)	13 k MNF 3x3				40 k 3x3			
	TRENING		TEST		TRENING		TEST	
	Całk.: 93,8 % (Overall)		Całk.: 89,1 % (Overall)		Całk.: 96,8 % (Overall)		Całk.: 86,1 % (Overall)	
	Kappa: 0,9071		Kappa: 0,8308		Kappa: 0,9567		Kappa: 0,7913	
	Prod. [%] (Prod.)	Użyt. [%] (User)	Prod. [%] (Prod.)	Użyt. [%] (User)	Prod. [%] (Prod.)	Użyt. [%] (User)	Prod. [%] (Prod.)	Użyt. [%] (User)
Łąki (Meadow)	97,2	91,2	94,8	95,8	98,3	97,8	92,7	94,6
Nieuzytki (Wastelands)	63,1	53,9	-	-	61,3	95,7	-	-
Las iglasty (Coniferous forest)	-	-	-	-	-	-	-	-
Las miesz. (Mixed forest)	76,5	97,4	-	-	99,7	99,4	-	-
Las liściasty (Deciduous forest)	92,2	90,4	93,7	85,4	90,8	95,0	86,1	81,7
Zadrzewienia (Woodeds)	70,4	60,3	38,8	59,5	81,7	93,4	53,2	40,7
Sad (Orchard)	57,5	66,7	44,6	83,0	95,9	96,8	43,9	69,5
Buraki (Beets)	99,8	99,5	86,1	93,2	99,7	99,4	73,2	86,2
Ziemniaki (Potatoes)	94,3	87,6	63,6	81,6	97,0	96,8	47,3	77,1
Owies (Oats)	99,1	98,4	99,8	94,7	99,5	99,6	98,9	90,6
Ściernisko (Stubble)	97,8	97,7	96,5	97,6	99,3	98,2	95,5	89,8
Grunt zaor. (Plough soil)	-	-	-	-	-	-	-	-
Droga asfalt. (Asphalt road)	88,5	90,7	61,3	76,6	97,7	96,7	73,8	78,5
Droga polna (Dirt road)	86,1	76,8	56,1	69,6	94,5	93,5	44,4	64,6
Tereny zabud. (Built-up area)	82,11	79,3	66,7	52,3	91,8	96,8	61,1	56,0
Budynki (Buildings)	64,3	86,4	77,3	72,2	96,7	98,5	77,1	65,8

Wyniki dokładności klasyfikacji
obrazu poligonów Bieśnik Północny
i Bieśnik Południowy

Wyniki klasyfikacji pokrycia terenu poligonu Bieśnik Północny (tab. 3) zawierają dla części treningowej 14 klas, natomiast w teście uwzględniono 12 wydzieleni, ponieważ tylko te formy występowały na analizowanym fragmencie obszaru zlewni. Oprócz lasu iglastego i gruntu zaoranego zestaw testowy był uboższy o klasę nieużytków i lasu mieszanego. Mimo to wykonano test uczenia sieci dla danego fragmentu nie uzyskując pozytywnego obrazu, co potwierdziło, iż dane klasy w tym obszarze nie występują. W opisywanej klasyfikacji obrazu 1 tak samo jak w przypadku obrazu 3 najwyższą dokładność treningu sieci na poziomie 96,8% uzyskano w klasyfikacji 40 oryginalnych kanałów, natomiast najlepszą dokładność testu otrzymano

dla 13 kanałów MNF i wyniosła ona 89,1%, pomimo iż wynik treningu był niższy niż dla 40 kanałów (93,8%).

Tabela 5 przedstawia wyniki klasyfikacji form pokrycia poligonu kluczowego Bieśnik Południowy (obraz 2). Badany teren również nie obejmował gruntów zaoranych, a także wystąpiła rozbieżność w klasie drogi asfaltowej, której nie wydzielono w obszarze treningowym, choć znajdowała się we fragmencie testowym. Aby uzupełnić klasyfikację obrazu testowego o daną klasę, postanowiono wykorzystać sieci neuronowe trenowane na podstawie obrazu 3 (Wiatrówki). Wyniki dokładności klasyfikacji obrazu 2 okazały się najgorsze wśród wszystkich analizowanych zdjęć, jednak potwierdziły tendencję uzyskiwania najlepszych wyników dla 40 kanałów oryginalnych w zestawie treningowym oraz 13 kanałów MNF dla danych testowych, gdzie uzyskano 63,7% zgodności z mapą wzorcową.

Tab. 4. Wyniki dokładności klasyfikacji obszarów treningowych i testowych obrazu 2.

Tab. 4. Classification accuracy for training and test area on image 2.

Dokładność (Accuracy)	13 k MNF 3x3				40 k 3x3			
	TRENING		TEST		TRENING		TEST	
	Całk.: 80,7 % (Overall)		Całk.: 63,7 % (Overall)		Całk.: 86,6 % (Overall)		Całk.: 59,6 % (Overall)	
	Kappa: 0,7492		Kappa: 0,4909		Kappa: 0,8310		Kappa: 0,4586	
Pokrycie terenu (Land cover)	Prod. [%] (Prod.)	Użyt. [%] (User)	Prod. [%] (Prod.)	Użyt. [%] (User)	Prod. [%] (Prod.)	Użyt. [%] (User)	Prod. [%] (Prod.)	Użyt. [%] (User)
Łąki (Meadow)	91,2	93,0	59,7	87,5	93,7	96,2	76,4	87,8
Nieużytki (Wastelands)	78,6	89,2	17,7	42,7	88,3	93,3	33,4	70,2
Las iglasty (Coniferous forest)	56,1	68,6	42,7	68,5	72,3	83,1	41,4	45,7
Las miesz. (Mixed forest)	85,9	77,6	88,8	56,5	83,1	87,2	70,3	57,5
Las liściasty (Deciduous forest)	56,7	81,0	2,5	4,7	89,6	59,3	24,8	39,2
Zadrzewienia (Woodeds)	75,1	49,5	31,3	18,4	83,4	78,6	10,6	4,4
Sad (Orchard)	25,1	53,5	36,1	79,5	61,1	91,6	2,32	4,1
Buraki (Beets)	39,5	46,1	48,6	51,0	96,4	72,7	44,5	77,8
Ziemniaki (Potatoes)	37,7	41,2	7,2	14,9	75,9	71,2	33,5	58,6
Owies (Oats)	95,7	94,6	64,5	81,1	99,3	95,7	68,6	79,5
Ściernisko (Stubble)	98,5	85,3	95,5	90,5	99,0	88,9	93,8	90,2
Grunt zaor. (Plough soil)	-	-	-	-	-	-	-	-
Droga asfalt. (Asphalt road)	-	-	8,1	12,7	-	-	30,6	58,3
Droga polna (Dirt road)	80,6	82,4	15,3	9,8	93,7	88,2	45,6	61,7
Tereny zabud. (Built-up area)	53,4	68,1	66,5	64,9	80,3	90,4	61,6	53,4
Budynki (Buildings)	75,1	58,2	57,2	49,7	93,5	89,1	69,7	43,5

Szczegółowa analiza statystyczna wyników klasyfikacji

Najwyższą dokładność całkowitą klasyfikacji danych treningowych oraz testowych, uzyskano dla obrazu 1, stosując okno teksturalne 3x3 piksele. Trenowanie sieci neuronowych na obrazach składających się z 40 oryginalnych kanałów i 13 po transformacji MNF wskazało kolejno 96,8% i 93,8% zgodności pokrycia terenu względem mapy wzorcowej. Jednak test uczenia sieci wykazał odpowiednio 86,1% oraz 89,1% dokładności klasyfikacji, a więc, mimo iż wynik trenowania obrazu MNF był niższy niż oryginalnego, to osiągnięto lepsze rezultaty przetwarzania wyuczonymi sieciami obszaru testowego. Zależność ta występuje także na pozostałych klasyfikowanych obrazach. Jako że o poprawności i jakości wykonywanej klasyfikacji obrazu za pomocą sztucznych sieci neuronowych świadczy dokładność testu nauczonej sieci, to poniższy opis poszczególnych klas

pokrycia terenu będzie dotyczył klasyfikacji obszaru testowego obrazu 1 po transformacji MNF.

Najwyższe wartości klasyfikacji pod względem dokładności producenta uzyskały klasy: owies (99,8%), ścierniska, łąki, oraz las liściasty. Jako że na danym obszarze nie występował las iglasty i mieszany, uzasadnione wydaje się podanie, iż dla obrazu 3 uzyskały one odpowiednio 96,2% i 66,5%. Także nie zawartą na danym obrazie klasę gruntów zoranych sklasyfikowano na obrazie 3 z dokładnością 87,8% (100% w treningu), a test nieużytków najlepszy okazał się na obrazie 2 i dla 40 kanałów w oknie 3x3 wyniósł 33,4%. Kolejnymi pod względem uzyskanej dokładności klasami na obrazie 1 były buraki, budynki, tereny zabudowane, ziemniaki, droga asfaltowa, droga polna. Natomiast klasy: sadu oraz zadrzewień, zostały sklasyfikowane poniżej 50% zgodności, kolejno 44,6% oraz 38,8%.

Macierz błędów (tab. 5 i 6) pokazuje rozkład sklasyfikowanych warstw na poligonach wzorcowych. Wśród

najczęściej nieprawidłowo wyróżnionych klas znajdują się budynki, tereny zabudowane, łąki, zadrzewienia i drogi polne, natomiast najbardziej jednoznacznie wyróżnione formy to owies oraz buraki.

Macierz błędów

Macierz błędów (*Confusion matrix*) prezentuje statystykę rozkładu sklasyfikowanych wydzieleni względem wzorcowej mapy pokrycia terenu. Przedstawia procentowy udział poszczególnych klas zawartych w powierzchniach poligonów mapy utworzonej wizualnie. W tabeli 5

bieżnością spektralną między obydwoma zestawami danych.

Analiza przydatności obrazów hiperspektralnych i algorytmów sztucznych sieci neuronowych do klasyfikacji form pokrycia terenu zlewni Bystrzanki

Wynikiem przeprowadzonych badań nad klasyfikacją pokrycia terenu z wykorzystaniem obrazów hiperspektralnych, są mapy dołączone do pracy w formie załączników: Załącznik nr 1 – Bieśnik Północny (obraz 1), Załącznik nr 2 – Bieśnik Południowy (obraz 2),

Tab. 5. Macierz błędów klasyfikacji testowej obraz 1. Objaśnienia: Łąk – łąki, Lli – las liściasty, Zad – zadrzewienia i zakrzaczenia, Sad – sady, Bur – buraki, Zie – ziemniaki, Owi – owies, Ści – ściernisko, Das – droga asfaltowa, Dpo – droga polna, Tza – tereny zabudowane, Bud – budynki.

Tab. 5. *Confusion matrix for test on image 1. Expanation: Łąk – meadow, Lli – decidous forest, Zad – Woodeds, Sad – orchard, Bur – beets, Zie – potatoes, Owi – oats, Ści – stubble, Das – asphalt road, Dpo – dirt road, Tza – built-up area, Bud – buildings.*

Wzór (Pat.) \ Wynik (Res.)	Łąk	Lli	Zad	Sad	Bur	Zie	Owi	Ści	Das	Dpo	Tza	Bud
Łąk	94,8	1,2	18,4	11,2	1,4	17,7	0,0	1,4	0,0	11,2	14,3	0,3
Lli	0,7	93,9	23,0	6,8	0,0	0,0	0,0	0,0	3,8	0,2	0,2	0,0
Zad	0,3	0,6	38,8	5,5	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Sad	0,1	0,1	5,2	44,7	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,1
Bur	0,0	0,0	0,0	0,0	86,0	0,2	0,0	0,0	0,0	0,0	0,1	0,3
Zie	0,1	0,0	0,0	0,0	0,0	63,6	0,0	0,6	0,0	0,0	0,0	0,0
Owi	0,0	0,0	0,0	0,0	0,0	0,0	100,0	0,1	0,3	0,0	0,0	0,0
Ści	0,0	0,0	1,2	0,0	12,6	15,4	0,0	96,6	0,0	6,0	0,0	0,3
Da	0,0	0,4	0,0	0,0	0,0	0,0	0,0	0,0	61,3	3,7	1,9	1,7
Dpo	0,5	0,0	0,9	0,0	0,0	3,2	0,0	0,4	0,3	56,1	1,2	1,3
Tza	3,3	3,8	12,6	31,9	0,0	0,0	0,0	0,8	31,0	22,1	66,8	18,7
Bud	0,2	0,1	0,0	0,0	0,0	0,0	0,0	0,1	3,4	0,7	15,5	77,3

przedstawiono macierz błędów dla zestawu testowego obrazu 1, dla którego uzyskano najwyższą całkowitą dokładność, czyli 89,1%, oraz macierz zestawu testowego obrazu 3 w tabeli 6, na którym znajdowało się 16 analizowanych klas pokrycia terenu.

Rozbieżności otrzymanych wyników klasyfikacji dla poszczególnych obrazów mogą być spowodowane przez różnice w charakterystyce spektralnej poligonów treningowych względem testowych, które zaprezentowano w tabeli 7. Klasyfikacja za pomocą sztucznych sieci neuronowych nazywana jest nieparametryczną, ponieważ nie wymaga od użytkownika określenia na początku procesu ścisłych i niepowtarzalnych wartości statystycznych detekcji klas pokrycia terenu. Jednak w trakcie testowania nauczonych sieci, ekstrahują one z obrazu najbliższe położone spektralnie obiekty względem poligonów treningowych. Jak widać w tabeli 7 najwyższą dokładność klasyfikacji otrzymano dla obrazu 1, który charakteryzuje się najmniejszą roz-

Załącznik nr 3 – Wiatrówki (obraz 3). W efekcie realizacji prac badawczych dokonano oceny użyteczności zastosowanej metody i szczegółowości automatycznej klasyfikacji obrazu za pomocą sztucznych sieci neuronowych. Analiza wyników wykazała, iż zastosowane materiały oraz metodyka ich przetwarzania może być efektywnym narzędziem sporządzania map pokrycia terenu. Głównymi czynnikami decydującymi o powodzeniu klasyfikacji obrazu z wykorzystaniem sieci neuronowych są: precyzyjne wyznaczenie poligonów treningowych i testowych; odpowiednio dobrana struktura i parametry uczenia sieci; zakres skali i szczegółowości klasyfikowanych wydzieleni.

Pierwszy przypadek odnośnie wykonanej mapy wzorcowej można uznać za spełniony, ze względu na zweryfikowane za pomocą klasyfikacji SAM materiały referencyjne. Należy także zaznaczyć, iż w przypadku pominięcia lub przeszacowania poligonów treningowych wykorzystywanych do uczenia sieci zostałyby one wska-

Tab. 6. Macierz błędów klasyfikacji testowej obrazu 3. Objasnienia: Łąk – łąki, Nie – nieużytki, Lig – las iglasty, Lmi – las mieszany, Lli – las liściasty, Zad – zadrzewienia i zakrzaczenia, Sad – sady, Bur – buraki, Zie – ziemniaki, Owi – owies, Ści – ściernisko, Gza – grunt zaorany, Das – droga asfaltowa, Dpo – droga polna, Tza – tereny zabudowane, Bud – budynki.

Tab. 6. Confusion matrix for test on image 3. Expanation: Łąk – meadow, Nie – wastelands, Lig – coniferous forest, Lmi – mixed forest, Lli – decidous forest, Zad – Woodeds, Sad – orchard, Bur – beets, Zie – potatoes, Owi – oats, Ści – stubble, Gza – plough soil, Das – asphalt road, Dpo – dirt road, Tza – built-up area, Bud – buildings.

Wzór (Pat.) \ Wynik (Res.)	Łąk	Nie	Lig	Lmi	Lli	Zad	Sad	Bur	Zie	Owi	Ści	Gza	Das	Dpo	Tza	Bud
Łąk	93,4	83,8	0,0	0,0	3,1	8,4	34,3	51,0	30,4	4,0	0,4	0,0	0,2	0,0	26,5	0,6
Nie	1,7	8,4	0,0	0,6	0,3	5,0	3,6	0,0	0,0	57,2	0,1	0,0	1,8	1,1	1,1	0,6
Lig	0,0	0,0	96,2	9,5	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Lmi	0,3	0,6	3,8	66,5	1,4	13,5	0,0	0,0	0,0	0,0	0,0	0,0	0,0	1,3	0,3	0,1
Lli	0,2	0,5	0,0	13,8	70,3	26,2	0,4	0,0	0,0	0,0	0,0	0,0	9,3	0,0	0,2	0,2
Zad	0,5	0,9	0,0	1,7	12,2	18,7	9,5	0,0	0,0	0,0	0,0	0,0	0,2	0,0	2,7	0,2
Sad	1,9	4,3	0,0	7,8	6,2	16,1	38,4	0,0	0,0	0,0	0,0	0,0	0,0	2,4	4,3	0,5
Bur	0,0	0,0	0,0	0,0	0,0	0,0	0,0	49,0	0,0	0,0	0,0	0,0	0,0	0,3	0,1	0,1
Zie	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	43,5	0,0	0,2	0,0	0,0	0,0	0,0	0,0
Owi	0,0	0,0	0,0	0,0	0,0	0,1	0,0	0,0	0,0	38,7	0,0	0,0	0,0	0,0	0,0	0,1
Ści	0,6	0,0	0,0	0,0	0,0	0,0	0,0	0,0	21,7	0,0	98,1	0,0	0,0	9,1	1,2	0,6
Gza	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,3	87,8	0,0	0,0	0,0	0,0
Das	0,2	0,6	0,0	0,0	5,4	9,8	0,0	0,0	0,0	0,0	0,0	0,0	52,9	0,3	1,2	0,8
Dpo	0,3	0,1	0,0	0,0	0,0	0,1	2,8	0,0	4,4	0,0	0,6	12,2	0,0	63,0	1,4	1,7
Tza	0,4	0,4	0,0	0,0	1,0	1,7	9,1	0,0	0,0	0,0	0,2	0,0	22,2	13,4	41,4	21,5
Bud	0,3	0,5	0,0	0,0	0,1	0,5	1,9	0,0	0,0	0,0	0,2	0,0	13,6	9,1	19,6	73,1

zane dzięki generalizacyjnym właściwościom sieci neuronowych, co nie miało miejsca.

W przypadku punktu drugiego nie jest możliwe dokonanie obiektywnej oceny zastosowanej struktury i parametrów, ponieważ nie wykonywano procedury poszukiwania optymalnych wartości, tylko zostały one przyjęte na podstawie literatury. Wskazane w pracy T. Kavzoglu i P. M. Mathera (2003) parametry jako optymalne, nie były opracowane na podstawie obrazów hiperspektralnych DAIS 7915. Jednak P. Mahesh i P. M. Mather (2006), którzy klasyfikowali za pomocą sieci neuronowych obraz DAIS 7915 nie zamieścili w swojej pracy opisu zastosowanej struktury i parametrów, wskazując jako źródło pracę T. Kavzogla i P. M. Mathera, czyli też współautora późniejszych badań. Na podstawie pracy P. Mahesha i P. M. Mathera określono natomiast klasyfikowane dwa zbiory danych, czyli 40 kanałów oryginalnych i 13 po transformacji MNF. Wynikało to z tego, iż klasyfikując obraz DAIS 7915 stwierdzili, że uwzględnienie 40 oryginalnych kanałów jest rozwiązaniem optymalnym, ze względu na jakość i czas klasyfikacji, aczkolwiek najwyższą dokładność około 92% otrzymali dla maksymalnej liczby 65 oryginalnych kanałów. Klasyfikując 13 kanałów MNF uzyskali 87,1% dokładności, na podstawie czego stwierdzili, iż ta transformacja wpłynęła negatywnie na wyniki klasyfikacji.

Należy jednak pamiętać o czasie trwania procesów treningu, które w danej pracy trwały około dwóch tygodni dla 40 oryginalnych kanałów, i około pięciu dni dla 13 kanałów MNF. Tak więc, mając na uwadze długi czas wykonywania klasyfikacji obrazów hiperspektralnych za pomocą sieci neuronowych, należy rozważać kompromis między jej jakością, a poświęconym na nią czasem. Dodatkowo uzyskano wyższą dokładność testowej klasyfikacji zestawu po transformacji MNF względem kanałów oryginalnych (odpowiednio 89,1% i 86,1%) co nie koresponduje pozytywnie z wnioskami prezentowanymi przez P. Mahesha i P. M. Mathera. Może być to wynikiem wyłączenia z zestawu danych najbardziej skorelowanych informacji, co doprowadziło do wyższej reprezentatywności spektralnej poszczególnych form pokrycia terenu, a także zniwelowania możliwych różnic między obszarem treningowym i testowym. Analizując obszar badań zlewni Bystrzanki, który jest bioróżnorodnym ekosystemem z małoobszarowym ekstensywnym rolnictwem, można przypuszczać, iż transformacja MNF poprzez redukcję wymiarów przestrzeni spektralnej pozwoliła nadać poszczególnym klasom pokrycia terenu wyższą homogeniczność (jednorodność spektralną), co mogło być powodem uzyskania wyższej dokładności klasyfikacji dla danego zestawu danych. Powyższe stwierdzenie można także skonfrontować z wynikami prac

S. Madera i in. (2006), w których uzyskano lepsze wyniki klasyfikacji oryginalnego zestawu kanałów, niż po transformacji PCA. Autorzy wnioskują, iż było to wynikiem wysokiej kultury agrarnej stosowanej na terenie badań, gdzie klasyfikacji podlegały uprawy rolne. Według badaczy, cechy spektralne dużych i jednorodnych pól uprawnych były na tyle reprezentatywne, iż wyznaczenie nowych osi składowych głównych w procesie PCA nie przyniosło lepszych rezultatów.

Materiał referencyjny prac P. Mahesha i P. M. Mathera (2006) przedstawia rycina 13. Autorzy nie zamieścili szczegółowych statystyk klasyfikacji poszczególnych wydzieleni, przez co nie jest możliwe dokonanie porównania z wynikami uzyskanymi w niniejszej pracy. Aczkolwiek można zauważyć, iż z antropogenicznej grupy klas pokrycia terenu, analizowali jedynie tereny zabudowane, bez podziału na budynki i drogi, które podlegały klasyfikacji w wykonanym opracowaniu. Ponieważ w ujęciu całościowym wymienione klasy, a tak-


że bardzo zbliżone spektralnie formy sadów i zadrzewień uzyskały najniższe wyniki dokładności w prezentowanej pracy można założyć, iż poprzez ich wyłączenie, dokładność całkowita powstałych map byłaby wyższa niż najlepszy uzyskany wynik na poziomie 89,1%. Powyższa teza odnosi się do wymienionego trzeciego punktu głównych czynników decydujących o powodzeniu klasyfikacji, gdyż rozdzielczość geometryczna obrazów DAIS wynosi 3 m. Zatem rozmiar piksela mógł być czynnikiem ograniczającym w przypadku określania poligonów budynków i dróg polnych, w trakcie wizualnego tworzenia mapy wzorcowej, choć niewątpliwie uwzględnienie tych klas podniosło walory powstałych map pokrycia terenu.

Innym przykładem klasyfikacji danych hiperspektralnych z wykorzystaniem sieci neuronowych są wspomniane badania S. Madera i in. (2006). Ocena dokładności wykonanych klasyfikacji wykazała zbliżony poziom dokładności 88,7% (dla 67 kanałów wybranych metodą

Tab. 7. Porównanie spektralne obszarów treningowych i testowych (średnia z 40 kanałów). Objasnienia kolorów: biały – różnica < 10; szary – różnica > 10.

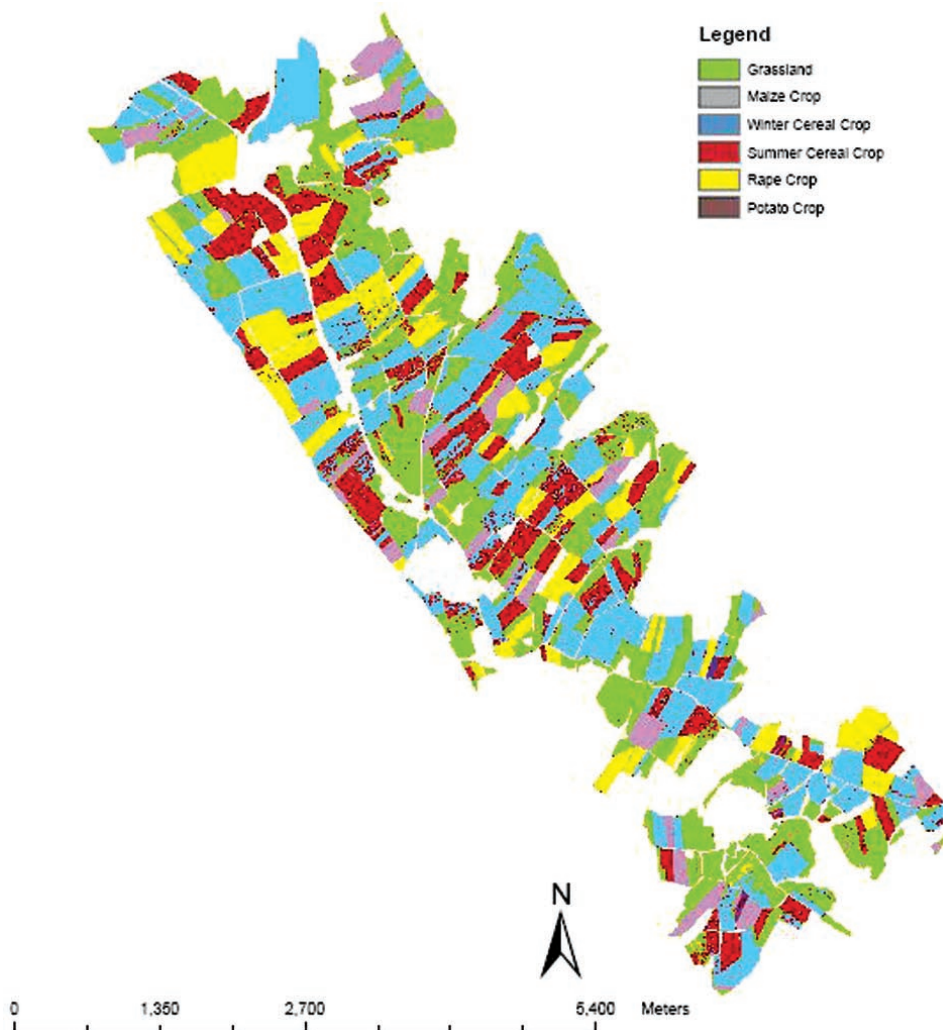
Tab. 7. Spectral comparison between training and test area (mean of 40 bands). Explanation colors: white – difference < 10; grey – difference > 10.

Parametry (Parametr)	Średnia z obrazu 1 (Mean of image 1)		Średnia z obrazu 2 (Mean of image 1)		Średnia z obrazu 3 (Mean of image 1)	
	TRENING	TEST	TRENING	TEST	TRENING	TEST
Pokrycie terenu (Land cover)						
Łąki (Meadow)	258,9	260,5	130,3	107,1	130,7	150,4
Nieużytki (Wastelands)	274,6	–	112,0	107,9	108,8	135,6
Las iglasty (Coniferous forest)	–	–	62,8	50,8	69	60,7
Las miesz. (Mixed forest)	177,1	187,0	75,3	71,0	95,9	96,7
Las liściasty (Deciduous forest)	220,5	–	99,3	86,4	103,1	110,2
Zadrzewienia (Woodeds)	196,8	191,6	115,8	92,2	112,1	122,8
Sad (Orchard)	229,3	213,6	120,2	89,6	114,8	129,5
Buraki (Beets)	246,1	236,4	123,6	124,1	134,4	142,2
Ziemniaki (Potatoes)	238,6	233,6	119,1	109,2	119,8	127,7
Owies (Oats)	177,4	157,6	90,4	91,8	87	101,3
Ściernisko (Stubble)	249,6	252,5	122,1	109,0	115,4	133,8
Grunt zaor. (Plough soil)	–	–	–	–	122,5	122,7
Droga asfalt. (Asphalt road)	246,5	243,7	118,8	112,3	127,4	142,4
Droga polna (Dirt road)	228,3	243,7	–	90,7	89,8	114,1
Tereny zabud. (Built-up area)	226,2	236,6	111,6	96,5	112,5	134,7
Budynki (Buildings)	256,4	257,7	130,8	114,7	122,4	141,8



Ryc. 13. Materiał referencyjny terenu badań (Mahesh i Mather, 2006). Objaśnienia: Unknown – nieznanne, Water – woda, Salt – sól, Hydrophytic vegetation – roślinność wilgociolubna, Wheat – pszenica, Vineyards – winorośla, Bare soil – odkryta gleba, Pasture land – pastwiska, Built-up area – tereny zabudowane.

Fig. 13. Reference image of the study area (Mahesh i Mather, 2006).



Ryc. 14. Wynikowa mapa użytkowania terenu po klasyfikacji bazującej na nieskompresowanych danych HyMap (Resulting land use map of the classification based on the untransformed optimal subset of the HyMap data; Mader i in., 2006). Oznaczenia: Grassland – łąki; Maize Crop – kukurydza; Winter Cereal Crop – zboże ozime; Summer Cereal Crop – zboże jare; Rape Crop – rzepak; Potato Crop – ziemniaki.

Ryc. 14. Resulting land use map of the classification based on the untransformed optimal subset of the HyMap data (Mader i in., 2006).

wizualną i nie poddaną żadnej kompresji), natomiast w przypadku tychże samych danych skompresowanych metodą PCA poziom dokładności oscylował w granicach 84,6 – 84,3%. Autorzy artykułu tłumaczą zaistniałą sytuację dużymi oraz jednorodnymi poligonami treningowymi, które dostatecznie prawidłowo określiły przestrzeń spektralną dla każdego wydzielenia. Na ryc. 14 przedstawiono efekt końcowy tych prac w postaci mapy upraw.

Z powodu przeprowadzenia badań z wykorzystaniem wyłącznie klasyfikacji za pomocą sieci neuronowych analiza jakościowa uzyskanych wyników może być porównywana jedynie z opublikowanymi pracami innych badaczy, które w większości opisane zostały w przeglądzie literatury we „Wstępie”. Na podstawie przeglądu literatury należy stwierdzić, iż otrzymane dokładności klasyfikacji w granicach 90% w przypadku obrazu 1, jest bardzo dobrym rezultatem. Pozwala to także wnioskować o poprawności metodycznej wykonanej klasyfikacji, a także świadczy o wysokim stopniu przydatności sieci neuronowych w kartowaniu pokrycia terenu. Ponadto udowodniono pozytywny wpływ wykorzystania cech strukturalnych obiektów w procesie klasyfikacji, poprzez porównanie wyników podejścia jednopikselowego oraz zastosowania okna 3x3 piksele. Powyższy wniosek odnosi się szczególnie do klasyfikacji form heterogenicznych, jak na przykład terenów zabudowanych.

Podsumowanie i wnioski

W trakcie badań przeprowadzone zostały kompleksowe prace dotyczące metod przygotowania i klasyfikacji obrazów hyperspektralnych za pomocą sztucznych sieci neuronowych. Wykonane analizy doprowadziły do wskazania najbardziej przydatnych algorytmów w kontekście postawionego zadania, jakim była analiza środowiska przyrodniczego obszaru pogórzy i niskich grzbietów górskich zlewni Bystrzanki. W pracy podkreślono znaczenie ekstrakcji informacji tematycznej zawartej na obrazie hyperspektralnym, co w przypadku klasyfikacji badanego terenu z wykorzystaniem sieci neuronowych prowadziło do uzyskiwania lepszych wyników i skrócenia czasu klasyfikacji. Udowodniono także pozytywny wpływ włączenia do procesu klasyfikacji informacji o strukturze obiektów poprzez wykorzystanie okna pikselowego, co nie jest możliwe w przypadku stosowania tradycyjnych metod klasyfikacji.

Uzyskane w toku badań wyniki automatycznej klasyfikacji obrazów prezentują ogromne możliwości wykorzystania sztucznych sieci neuronowych w sporządzaniu map pokrycia terenu. Zaprezentowana metodyka powinna umożliwić przyszłym badaczom bardziej efektywne kontynuowanie prac nad zastosowaniem sieci neuronowych w klasyfikacji pokrycia terenu. Głównym kierunkiem kontynuowania badań powinno być poszukiwanie optymalnego typu architektury i parametrów

uczenia sieci, dla których punktem wyjścia mogą być wartości opisane w tej pracy. Badania mogą także dotyczyć zastosowania innych rodzajów oraz algorytmów uczenia sztucznych sieci neuronowych, a także udoskonalania metod korekcji zobrazowań hyperspektralnych.

Reasumując całość prac związanych z wykorzystaniem sztucznych sieci neuronowych w klasyfikacji form pokrycia zlewni Bystrzanki należy stwierdzić, iż założony cel badań został zrealizowany z sukcesem.

W wyniku przeprowadzonych prac powstały 3 mapy form pokrycia terenu dla każdego badanego poligonu kluczowego. Mapy te są dobrze udokumentowane danymi statystycznymi.

Opracowano szczegółowe mapy dla 16 kategorii form pokrycia (wszystkie które można było rozpoznać na badanym obszarze, z uwzględnieniem skali opracowania). Dla każdej badanej formy pokrycia terenu wykonana została szczegółowa analiza statystyczna.

Wykorzystanie szczegółowej informacji zawartej w kilkudziesięciu kanałach o wąskich zakresach spektralnych pozwoliło na identyfikację form pokrycia, które na obrazach wielospektralnych byłyby trudne do rozpoznania, np. owies, buraki, ziemniaki.

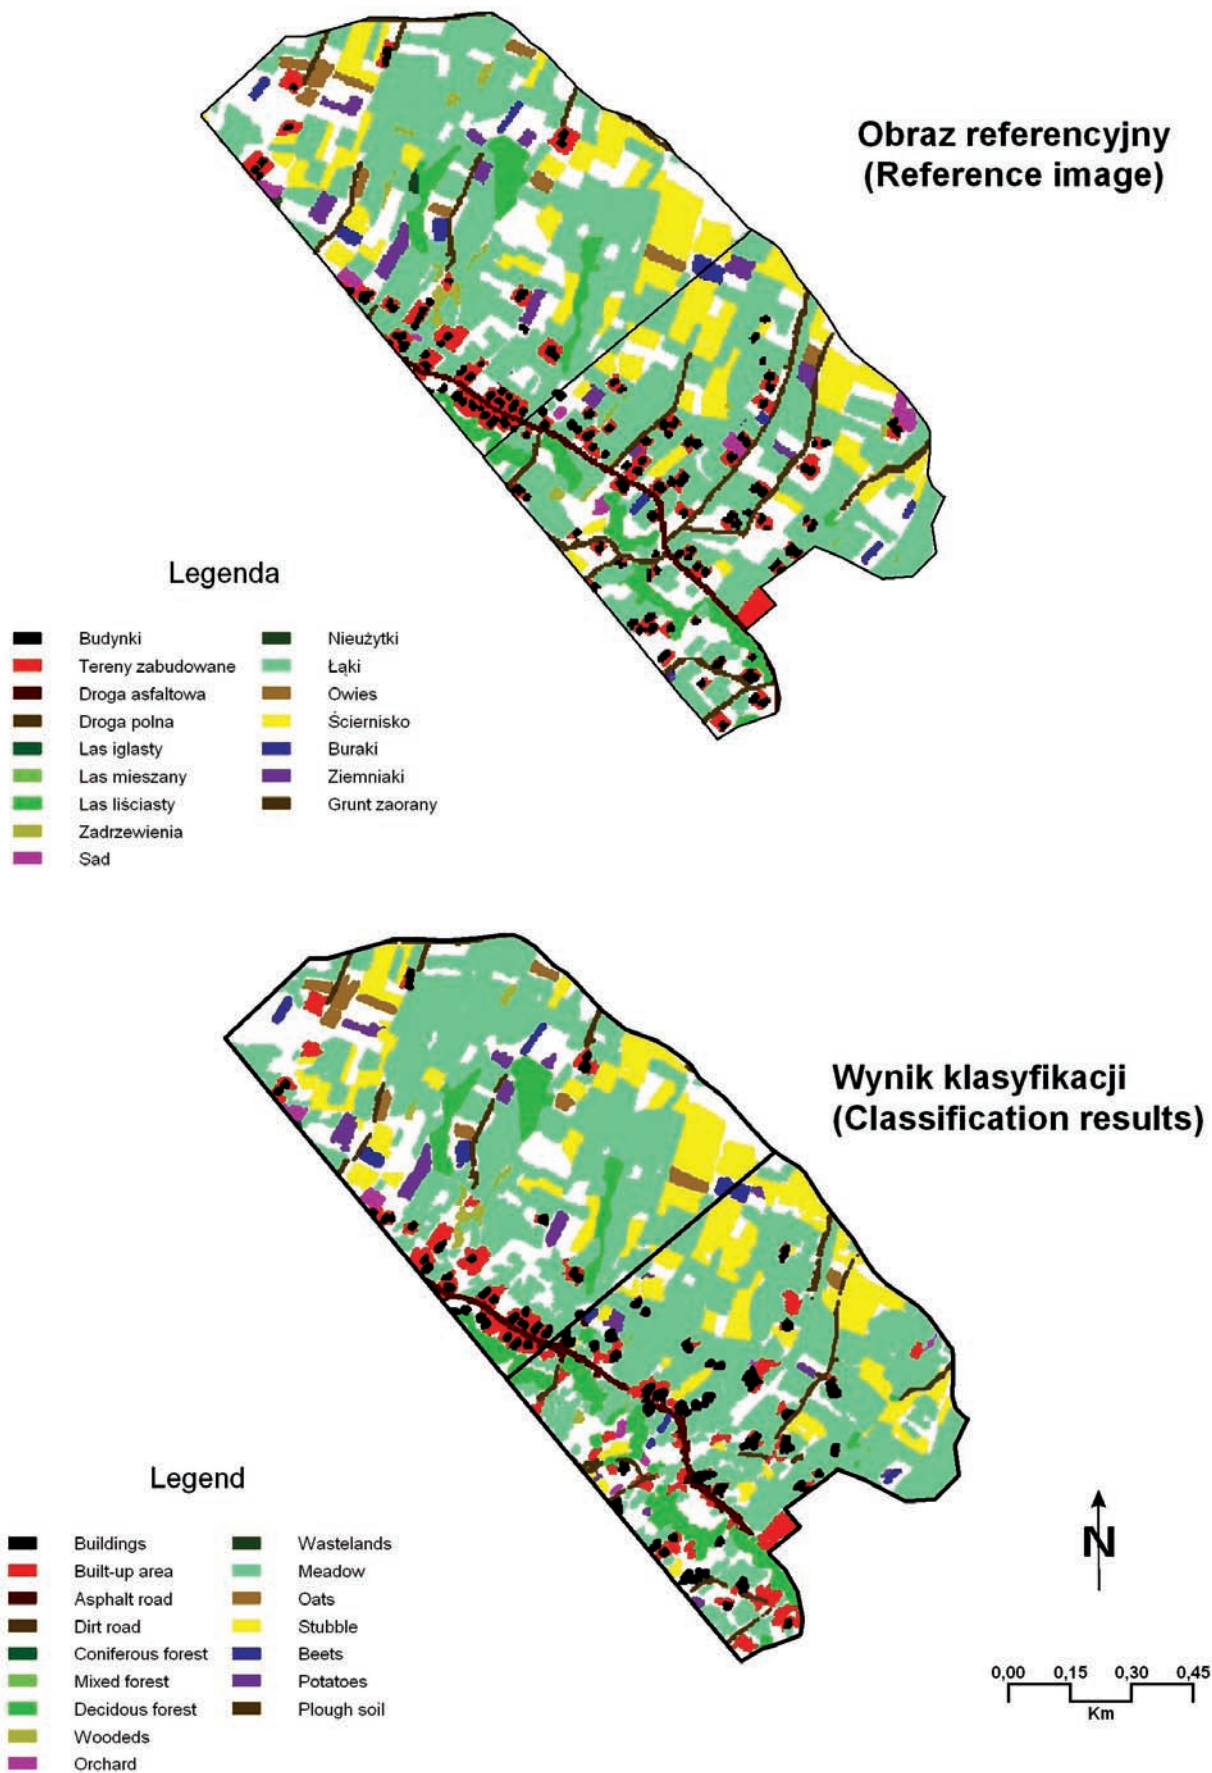
Opracowana została metodyka klasyfikacji danych 15 bitowych z wykorzystaniem sztucznych sieci neuronowych obszarów rolniczych. Większość dotychczasowych prac wykonywana była w Polsce na danych 8 lub 10 bitowych, co wymagało innych systemów zapisu i klasyfikacji danych. Dane 15 bitowe ze względu na zwiększoną rozdzielczość radiometryczną wymagają bardziej zaawansowanych algorytmów i są one bardziej czasochłonne.

Opracowane algorytmy zostały zweryfikowane na zestawach danych dla kolejnych obrazów poligonów kluczowych potwierdzając ich powtarzalność (przy niewielkich modyfikacjach adaptacyjnych).

Autorzy pracy dziękują Interdyscyplinarnemu Centrum Modelowania Matematycznego i Komputerowego Uniwersytetu Warszawskiego za przyznanie grantu obliczeniowego nr G33-4 „Klasyfikacja obrazów hyperspektralnych za pomocą sztucznych sieci neuronowych”.

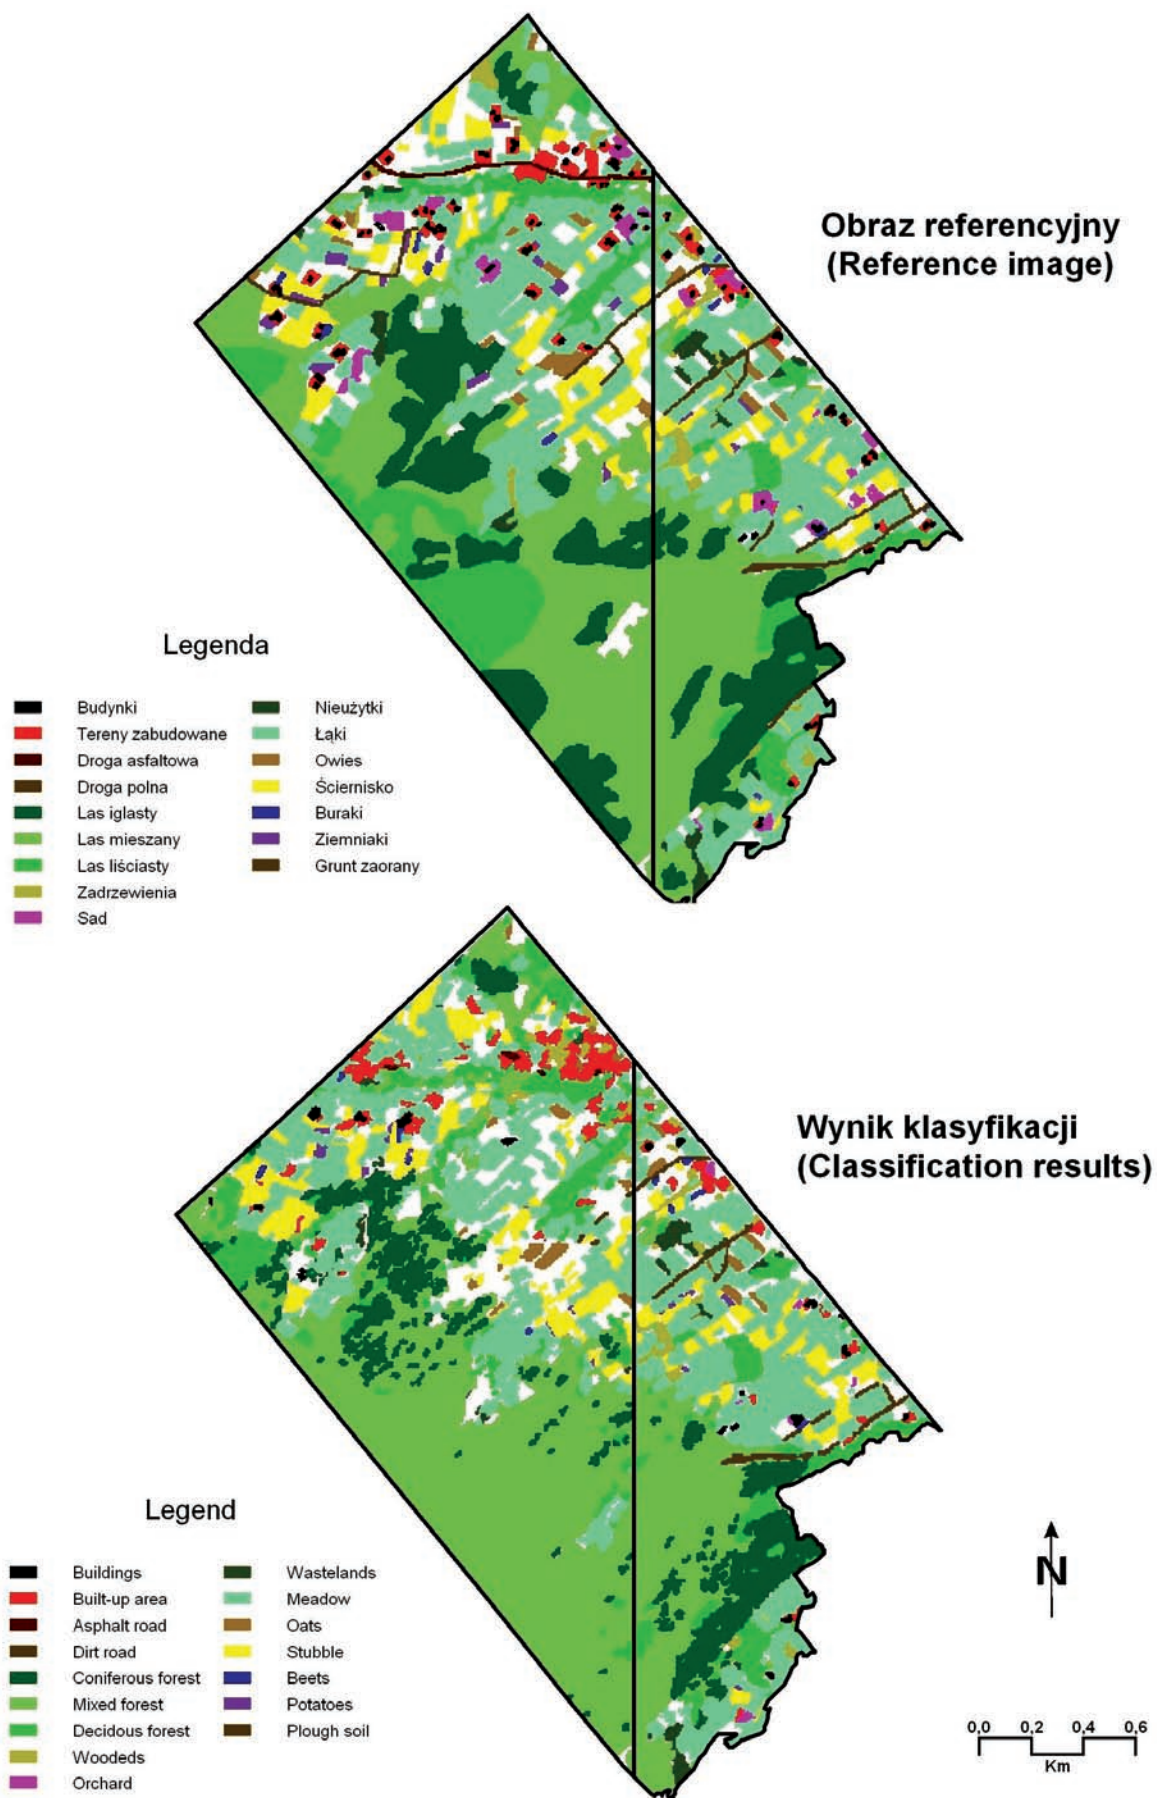
Literatura

- Atkinson P. M., Tatnall A. R. L., 1997, *Neural Networks in remote sensing. International Journal of Remote Sensing*, tom 18, nr 4.
- Бельчанский Г. И., Коробков Н.В., 1998, Использование искусственных нейронных сетей для анализа спутниковых данных дистанционно зондирования. *Исследование земли из космоса*, nr 4.
- Belluco E., Camuffo M., Ferrari S., Modenese L., Silvestri S., Marani A., Marani M., 2006, *Mapping salt-marsh vegetation by multispectral and hyperspectral remote sensing*, *Remote Sensing of Environment*, nr 105, s. 54–67.
- Bochenek Z., 2006, *Analiza metod klasyfikacji obszarów miejskich zobrazowanych na wysokorozdzielczych zdjęciach*



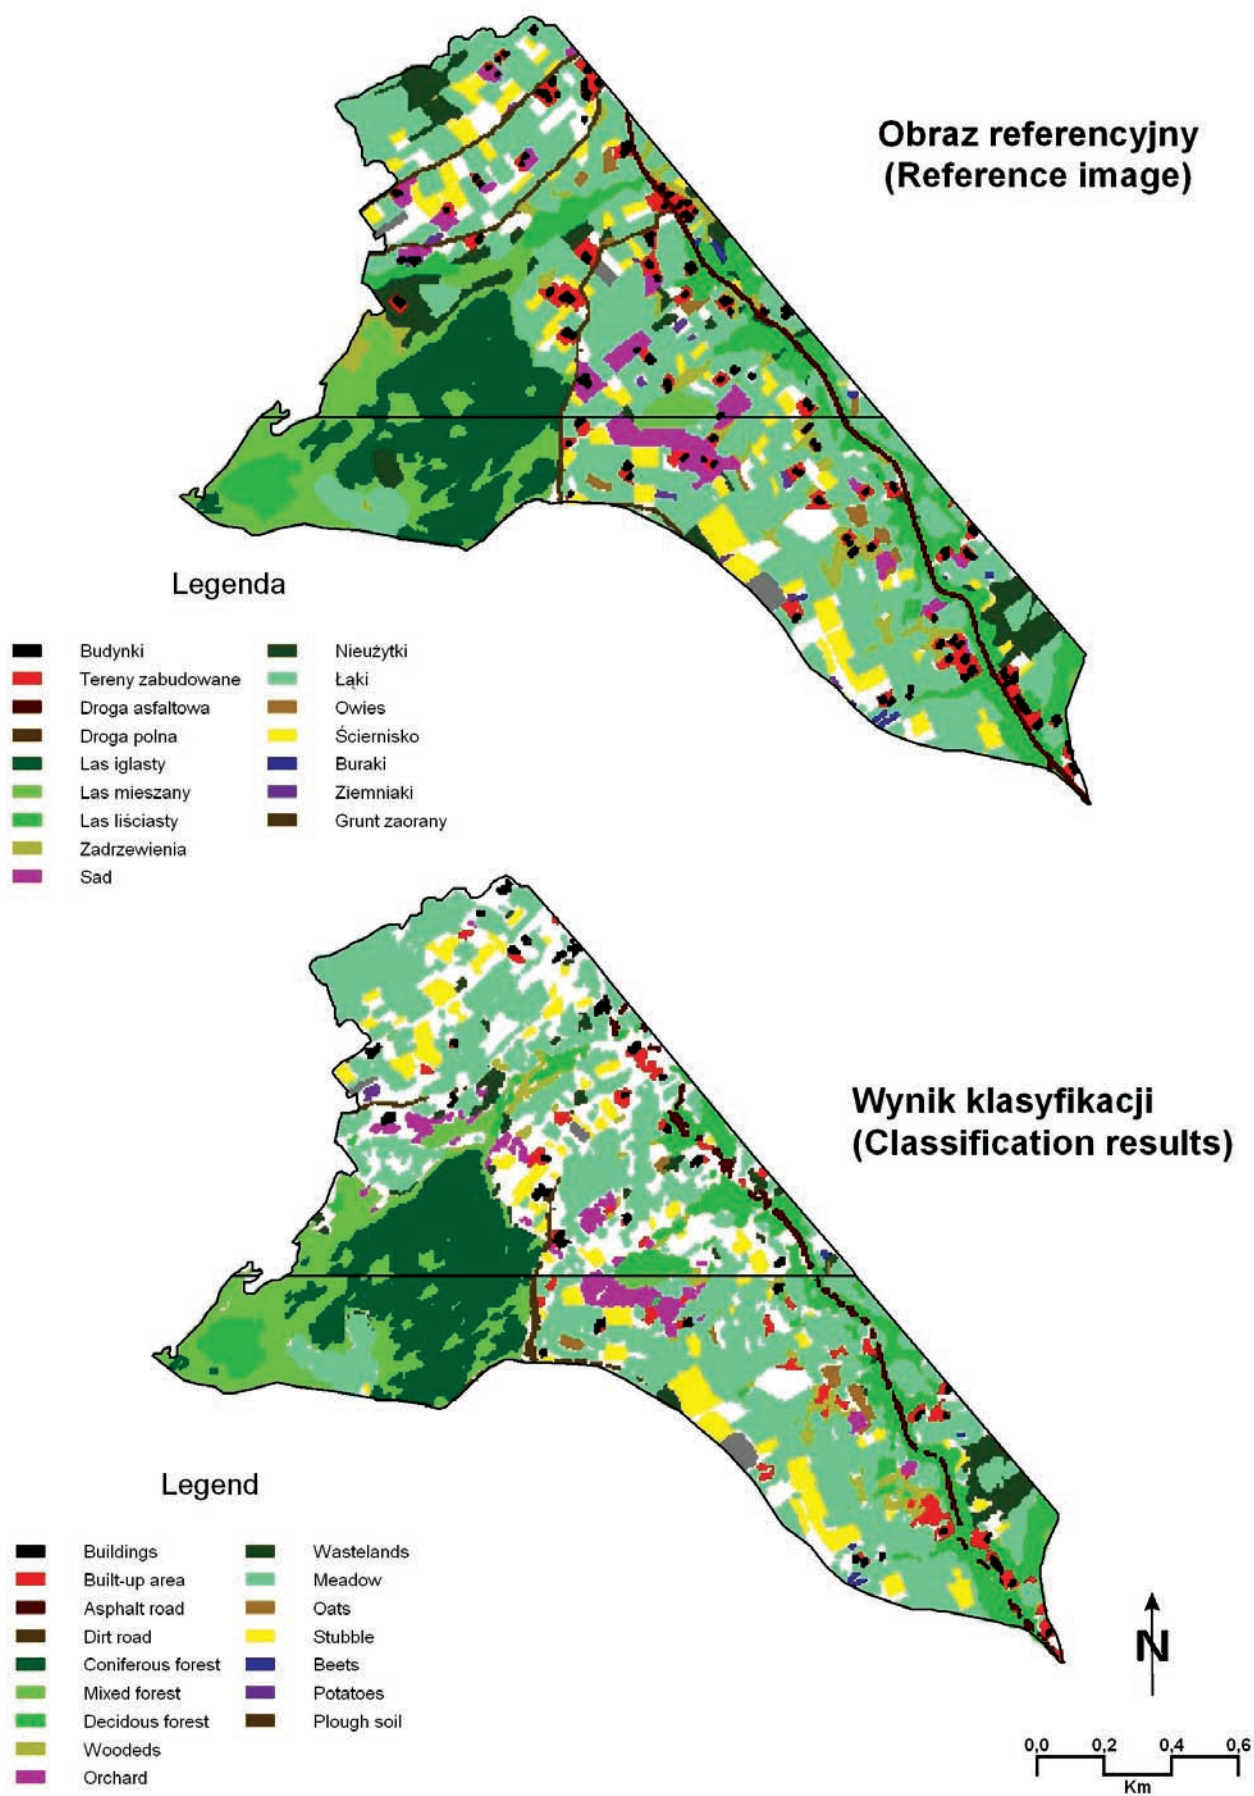
Ryc. 15. Wyniki klasyfikacji poligonu kluczowego Bieśnik Północny

Fig. 15. Classification results of the Bieśnik N key polygon



Ryc. 16. Wyniki klasyfikacji poligonu kluczowego Bieśnik Południowego

Fig. 16. Classification results of the Bieśnik S key polygon



Ryc. 17. Wyniki klasyfikacji poligonu kluczowego Wiatrówki
 Fig. 17. Classification results of the Wiatrówki key polygon

- satelitarnych, Prace Instytutu Geodezji i Kartografii, tom LII, zeszyt 110, s. 5–33
- Carrão H., Capão L., Bação F., Caetano M., 2006, *MERIS based land cover classification with Self-Organizing maps: preliminary results*, 2nd Workshop of the EARSeL SIG on Remote Sensing of Land Use & Land Cover, Bonn, s. 16–25.
- Chmiel J., 2001, *Przykłady wykorzystania sieci neuronowych w cyfrowej klasyfikacji pokrycia terenu*, Archiwum fotogrametrii, kartografii i teledetekcji, nr 12, Warszawa.
- Civco D. L., 1993, *Artificial neural networks for land-cover classification and mapping*, International Journal of Geographical Information System, tom 17, nr 2, s. 173–186.
- Eldvige C. D., Chen Z., 1995, *Comparison of broadband and narrowband red and near-infrared vegetation indices*, Remote Sensing of Environment, nr 54, s. 38–48.
- Foody G. M., 1995, *Land cover classifications by artificial neural networks*, International Journal of Geographics Information Systems, vol. 9, no 5.
- Gil E., 1979, *Typologia i ocena środowiska naturalnego okolic Szymbarku*, Dokumentacja Geograficzna, z. 5.
- Habermeyer M., Müller A., Holzwarth S., Richter R., Müller R., Bachmann M., Seitz K. H., Seifert P., Strobl P., 2005, *Implementation of the automatic processing chain for ares*, 2005, W: Zagajewski B., Sobczak M., Wrzesień M., (red.) Proceedings of 4th EARSeL Workshop on Imaging Spectroscopy, New quality in environmental studies, Warszawa 2005, s. 67–75.
- Hejmanowska B., Głowienka E., 2004, Wstępne wyniki pomiarów spektrometrycznych i klasyfikacji obrazów hiperspektralnych rekultywowanego obszaru Tarnobrzeskiego Zagłębia Siarkowego. *Geoinformatica Polonica*, t. 6, Kraków.
- Hejmanowska B., Drzewiecki W., Głowienka E., Mularz S., Zagajewski B., Sanecki J., 2006, *Próba integracji satelitarnych obrazów hiperspektralnych z nieobrazowymi naziemnymi danymi spektrometrycznymi na przykładzie Zbiornika Dobczyckiego*, Archiwum Fotogrametrii, Kartografii i Teledetekcji, Vol. 16. Ss. 207–216.
- <http://www.microimages.com/> (26.03.2008)
- Iwaniak A., Króczyńska M., Paluszyński W., 2002, *Użycie sieci neuronowych do klasyfikacji obszarów miejskich na zdjęciach satelitarnych*, Acta Scientiarum Polonorum, Geodezja i Kartografia, 1 (1–2), Wrocław.
- Jakomulska A., 1998, *Zastosowanie logiki rozmytej w klasyfikacji nadzorowanej*, Fotointerpretacja w Geografii, Warszawa.
- Kanellopoulos I., Wilkinson G. G., *Strategies and best practice for neural network image classification*, International Journal of Remote Sensing, tom 18, nr 4.
- Kavzoglu T., Mather P. M., 2003, *The use of backpropagating artificial neural networks in land cover classification*, International Journal of Remote Sensing, tom 24, nr 23.
- Króczyńska M., 2004, Wykorzystanie spektralnych i strukturalnych cech obiektów odwzorowanych na zdjęciach satelitarnych w kartowaniu użytkowania ziemi, Rozprawa doktorska, Uniwersytet Warszawski WGiSR, Warszawa.
- Kruse F. A., Lefkoff A. B., Boardman J. B., Heidebrecht K. B., Shapiro A. T., Barloon P. J., Goetz A. F. H., 1993, *The Spectral Image Processing System (SIPS) – Interactive Visualization and Analysis of Imaging spectrometer Data*, Remote Sensing of Environment, nr 44, s. 145–163.
- Lunetta R. S., Johnson D. M., Lyon J. G., Crotwell J., 2004, *Impacts of imagery temporal frequency on land-cover change detection monitoring*, Remote Sensing of Environment, nr 89, s. 444–454.
- Mader S., Vohland M., Jarmer T., Casper M., 2006, *Crop classification with hyperspectral data of the HyMap sensor using different feature extraction techniques*, 2nd Workshop of the EARSeL SIG on Remote Sensing of Land Use & Land Cover, Bonn, s. 96–101.
- Mahesh P., Mather P. M., 2006, *Some issues in the classification of DAIS hyperspectral data*, International Journal of Remote Sensing, nr 27, s. 2895–2916.
- Mohammed A., Dorigo W., Habermeyer M., Müller A., Schneider T., 2005, *Characterization of landcover types by classification and parameter retrieval using HyMap imagery*, W: Zagajewski B., Sobczak M., Wrzesień M., (red.) Proceedings of 4th EARSeL Workshop on Imaging Spectroscopy, New quality in environmental studies, Warszawa 2005, s. 257–270
- Neural networks in remote sensing*, 1997, International Journal of Remote Sensing (Special issue), tom 18, nr 4.
- Obrebska-Starkłowa B., 1973, *Stosunki mezo- i mikroklimatyczne Szymbarku*, Dokumentacja Geograficzna, z. 5.
- Olesiuk D., 2007, *Istota i metodyczne podstawy wykorzystania obrazów hiperspektralnych*, Okólnik TD, nr 129.
- Olędzki J.R., 2007, *Regiony geograficzne Polski, „Teledetekcja Środowiska”*, nr 38.
- Osińska-Skotak K., Kruk M., Mróz M., Szumiało M., 2005., *CHRIS/PROBA superspectral data for inland water quality studies*, W: Zagajewski B., Sobczak M., Wrzesień M., (red.) Proceedings of 4th EARSeL Workshop on Imaging Spectroscopy, New quality in environmental studies, Warszawa 2005, s. 317–325
- Richter R., Müller A., Heiden U., 2002, *Aspects of operational atmospheric correction of hyperspectral imagery*, International Journal of Remote Sensing, tom 23, nr 1, s. 145–157
- Richter R., Schläpfer D., 2002, *Geo-atmospheric processing of airborne imaging spectroscopy data. Part 2: Atmospheric/Topographic correction*, International Journal of Remote Sensing, nr 23 (13), s. 2631–2649
- Rocha J., Tenedório J. A., Encarnação S., Estanqueiro R., 2007, *Land use/cover classification using orbital and ancillary data, neural networks and multiresolution segmentation*, New Developments and Challenges in Remote Sensing.
- Schläpfer D., Richter R., 2002, *Geo-atmospheric processing of airborne imaging spectroscopy data. Part 1: Parametric Orto-Rectification Process*, International Journal of Remote Sensing, nr 23 (13), s. 2609–2630
- Schmid T., Koch M., Gumuzzio J., Mather P. M., 2004, *A spectral library for a semi-arid wetland and its application to studies of wetland degradation using hyperspectral and multispectral data*, International Journal of Remote Sensing, t. 25, nr 13, s. 2485–2496.
- Staszkiwicz J., 1973, *Zbiorowiska leśne okolic Szymbarku (Beskid Niski)*, Dokumentacja Geograficzna, z. 1.
- Vane G., Goetz A. F. H., 1993, *Terrestrial Imaging Spectroscopy: Current Status, Future Trends*, Remote Sensing of Environment, nr 44, s. 117–126.
- Wężyk P., Wertz B., 2005, *Forest map revision using the hyperspectral scanner AISA images*, W: Zagajewski B., Sobczak M., Wrzesień M., (red.) Proceedings of 4th EARSeL Workshop on Imaging Spectroscopy, New quality in environmental studies, Warszawa 2005, s. 617–629
- Zagajewski B., Sobczak M., Wrzesień M. 2004, *Badania górskich zbiorowisk roślinnych z użyciem technik hiperspektralnych*, Przegląd Geofizyczny, Tom XLIX, WN PWN, Warszawa. Ss. 115–129.

Zagajewski B., Wrzesień M., Sobczak M., Krówczyńska M., 2005, *Cyfrowe przetwarzanie zdjęć hiperspektralnych*, Teledetekcja Środowiska, nr 36, s. 79–95.

Zagajewski B., Sobczak M., Wrzesień M., Kozłowska A., Krówczyńska M., 2006, *Kartowanie górskich zbiorowisk roślinnych z użyciem obrazów hiperspektralnych DAIS*

7915, W: Mirek Z., Godzik B., (red.). *Tatrzański Park Narodowy na tle innych górskich terenów chronionych*, Tom II, Nauki biologiczne, TPN, PTPNoZ – Oddział Krakowski. Zakopane, s. 137–150.

Zagajewski B., 2008 (w druku), *Badania hiperspektralne zlewni Bystrzanki*, IGiPZ PAN.



Mgr Dawid Olesiuk, absolwent Wydziału Geografii i Studiów Regionalnych UW. Swoje zainteresowania koncentruje wokół zastosowań teledetekcji, głównie metod hiperspektralnych, i narzędzi GIS w badaniach środowiskowych. E-mail: dolesiuk@gmail.com



Bogdan Zagajewski, adiunkt w Katedrze Geoinformatyki i Teledetekcji (wcześniej Zakład Teledetekcji Środowiska) Wydziału Geografii i Studiów Regionalnych Uniwersytetu Warszawskiego. Zainteresowania naukowe koncentrują się wokół teledetekcji i SIG i ich zastosowań w badaniach środowiska. Od roku 2002 zajmuje się technikami hiperspektralnymi w badaniach nad roślinnością. Dane kontaktowe: e-mail: bogdan@uw.edu.pl, tel. 022 5521507, fax 022 5521521, http://telegeo.wgsr.uw.edu.pl/bz/bz_pl.html