

MARTYNA GOLENIA, BOGDAN ZAGAJEWSKI, ADRIAN OCHTYRA
Zakład Geoinformatyki, Kartografii i Teledetekcji
Wydział Geografii i Studiów Regionalnych Uniwersytetu Warszawskiego
martyna.golenia@student.uw.edu.pl; bogdan@uw.edu.pl; adrian.ochtyra@uw.edu.pl
AGATA HOŚCIŁO
Centrum Teledetekcji, Instytut Geodezji i Kartografii
agata.hoscilo@igik.edu.pl

Zastosowanie sztucznych sieci neuronowych do aktualizacji map pokrycia terenu Corine

Zarys treści. Aktualne mapy pokrycia terenu są podstawą wielu dyscyplin nauki oraz mają szerokie zastosowanie aplikacyjne. Jednym z problemów aktualizacji map jest proces aktualizacji danych. Teledetekcja dostarcza codziennie nowych obrazów satelitarnych, które mogą zaspokoić potrzeby aktualizacji baz danych. W niniejszym artykule autorzy przedstawiają metodę klasyfikacji pokrycia terenu sztucznymi sieciami neuronowymi fuzji ARTMAP zgodnie z założeniami i legendą Corine Land Cover na podstawie danych satelitarnych Landsat, które wykorzystywane są do opracowania map pokrycia terenu. W artykule użyto jako danych referencyjnych

i weryfikacyjnych najnowszą mapę Corine Land Cover (CLC) 2012. Do przeprowadzenia klasyfikacji symulatorem wykorzystano trzy zdjęcia satelitarne Landsat TM (21.04.2011, 05.06.2010, 27.08.2011). Obszarem badań były okolice Warszawy. Wynikami pracy symulatora są mapy klasyfikacji pokrycia terenu oraz macierze błędów klasyfikacji. Uzyskane wyniki potwierdzają, że sztuczne sieci neuronowe mogą z powodzeniem być wykorzystywane do aktualizacji map pokrycia terenu.

Słowa kluczowe: klasyfikacja, Corine Land Cover, Landsat, sztuczne sieci neuronowe, Warszawa

1. Wprowadzenie

Opracowanie aktualnej mapy pokrycia terenu to czasochłonna procedura, gdyż z uwagi na wzrost i rozwój roślinności oraz szybkie procesy urbanizacji mapy te muszą być często aktualizowane. Jednym ze źródeł danych wykorzystywanych do aktualizacji map pokrycia terenu są zdjęcia satelitarne, pozyskiwane codziennie lub w kilkudniowych odstępach. Dotychczas bazy danych Corine Land Cover dla Polski powstawały w wyniku eksperckiej wizualnej interpretacji obrazów satelitarnych. Wizualna interpretacja jest procesem czasochłonnym, w przypadku CLC2012 obejmujących Polskę trwającym prawie półtora roku (A. Hościło, M. Tomaszewska 2015), kosztownym i subiektywnym. Dlatego istotne jest wypracowanie metodologii automatycznej lub półautomatycznej klasyfikacji pokrycia terenu. Taka metoda jest bardziej obiektywna i tańsza, a proces klasyfikacji zajmuje mniej czasu niż w przypadku interpretacji wizualnej. Wykorzystanie symulatora sztucznych sieci neuronowych


o logice rozmytej fuzji ARTMAP (G.A. Carpenter i in. 1992) w celu wygenerowania map pokrycia terenu dają duże możliwości zautomatyzowania procesu klasyfikacji.

Zadaniem postawionym w niniejszym artykule jest ocena metodyki procesu klasyfikacji pokrycia terenu według legendy Corine Land Cover z wykorzystaniem zdjęć Landsat¹ oraz symulatora fuzji ARTMAP. Badania zostały przeprowadzone na obszarze Warszawy i terenach znajdujących się na południe od miasta (ryc. 1). Landsat to nazwa programu pozyskującego zdjęcia satelitarne Ziemi nieprzerwanie od 1972 roku, w ramach którego wystrzelono osiem satelitów. W artykule poddano analizie zdjęcia z satelity Landsat 5, o rozdzielczości przestrzennej 30 m. Od 1995 zdjęcia Landsat zaczęto wykorzystywać przy opracowaniu mapy Corine Land Cover (E. Bielecka, A. Ciołkosz 2004). Parametry tych satelitów przedstawia tabela 1.

¹ Landsat Science, landsat.gsfc.nasa.gov

Projekt CLC powstał z inicjatywy Europejskiej Agencji Środowiska (EEA) w latach 1990 w celu koordynacji przedsięwzięć zmierzających do gromadzenia danych na temat środowiska – ujednoczenia jakości pozyskiwanych informacji oraz śledzenia dynamiki zmian

pokrycia terenu w krajach Unii Europejskiej (Commission of the European Communities 1995). Legenda Corine zawiera 44 klasy form pokrycia terenu i podzielona jest na trzy hierarchiczne poziomy szczegółowości. Pierwszy poziom zawiera 5 klas, drugi 15, trzeci 44 klasy



Ryc. 1. Obszar badań widziany z satelity Landsat 5 w kompozycji RGB z dnia 5 czerwca 2011 r.

Tab. 1. Misje satelitarne Landsat

Satelita	Okres działania	Rozdzielczość spektralna (μm)	Rozdzielczość przestrzenna (m)
Landsat 5	1984–2013	TM: 0.45–2.35 liczba kanałów: 7	MSS: 80 m (MS); TM: 30 m (MS) i 120 m (IR)
Landsat 6	1993 (awaria, nie osiągnął orbity)		
Landsat 7	od 15.04.1999 wciąż obrazuje	ETM+: 0.45–12.5 liczba kanałów: 8	ETM+: 15 m (PAN), 30 m (MS) i 60 m (IR)
Landsat 8	od 11.02.2013 wciąż obrazuje	OLI: 0.433–12.5 liczba kanałów: 11	OLI: 15 m (PAN), 30 m (MS, IR), TIRS: 100 m

form pokrycia terenu. Baza danych CLC w Polsce zawiera 33 klasy pokrycia terenu według trzeciego poziomu². Mapy CLC co kilka lat są aktualizowane, a najnowsza mapa pokrycia terenu Polski pochodzi z 2012 roku. Dzięki tym aktualizacjom można dokonywać porównania dwóch map CLC, aby otrzymać zmienność pokrycia terenu w wybranym okresie (J. Feranec i in. 2007). Mapy CLC 2012 wykorzystano do narysowania poligonów treningowych i weryfikacyjnych (J.B. Campbell, R.H. Wynne 2011) w celu przeprowadzenia klasyfikacji, czyli podzielenia pikseli o podobnym odbiciu spektralnym do określonego klastra, który odpowiada określonej grupie obiektów (J.R. Anderson 1976).

Klasyfikacja metodą sztucznych sieci neuronowych bazuje na parametrach spektralnych obrazu i na składowych nieparametrycznych, czyli powtarzających się układach pikseli (R. Tadeusiewicz 2007). Opiera się na fizjologii ludzkiego postrzegania obiektów, która wykorzystuje zarówno barwy, jak i struktury i tekstury obiektów (R. Lula, R. Tadeusiewicz 2001). Człowiek ma możliwość rozpoznawania obiektów z wykorzystaniem tych cech (B. Zagajewski 2010). Sztuczna sieć neuronowa również korzysta z tych cech i dzięki nim z użyciem danych wejściowych wytwarza nową informację. Główne badania nad sieciami neuronowymi prowadzone były w latach 1960–1980 i nabierały rozmachu wraz z rozwojem technik komputerowych. Przełomowym odkryciem była pamięć asocjacyjna oraz stworzenie sieci typu ART (G.A. Carpenter i in. 1992). Wraz z rozwojem sztucznych sieci neuronowych rosło ich zastosowanie w procesie klasyfikacji (J.F. Mas 2004, H. Yuan i in. 2009, J. Olczyk 2014). Porównując klasyfikację sztucznymi sieciami neuronowymi (dokładność całkowita 86%) z metodą największego prawdopodobieństwa (dokładność całkowita 75%) lub metodą analizy dyskryminacyjnej (dokładność całkowita 75%), widać wyraźną przewagę tej pierwszej (M. Heini i in. 2009). Warto zwrócić uwagę na rosnące znaczenie sztucznych sieci neuronowych przy klasyfikacji pokrycia terenu obszarów zurbanizowanych, ze względu na dużą rozpiętość odbicia spektralnego zabudowy (M.J. Aitkenhead, I.H. Aalders 2008; Iwaniak i in. 2002; M. Krówczyńska 2004). Sieci neuronowe dają nowe

możliwości klasyfikacji tego rodzaju pokrycia terenu dzięki zastosowaniu dodatkowych czynników. M.J. Aitkenhead, I.H. Aalders (2008) podjęli próbę sklasyfikowania pokrycia terenu szkockiego miasta Aberdeen metodą sztucznych sieci neuronowych (metoda propagacji wstecznej) z pozytywnym skutkiem – uzyskano dokładność na poziomie 84,7%.

Wykorzystywany przez autorów symulator fuzji ARTMAP został przygotowany przez zespół prof. Paolo Gamba z Uniwersytetu w Pawii. Jest to sieć nadzorowana, w przypadku której do klasyfikacji wykorzystywany jest wcześniej przygotowany schemat wzorcowy, czyli pliki z oddzielnie przygotowanymi poligonami treningowymi i weryfikacyjnymi. Ważne, aby tworząc poligony, piksele treningowe i wzorcowe nie pokrywały się, gdyż może to negatywnie wpływać na wynik klasyfikacji. Do sieci wprowadzane są te dwa wzorce: pierwszy – uczący, drugi – weryfikujący. Definiowane są również parametry dotyczące wyboru sygnałów neuronów, szybkości uczenia się sieci, wskaźnika prawdopodobieństwa i liczby iteracji. Sieć ma za zadanie nauczyć się jak najlepiej relacji między wyżej wspomnianymi plikami (B. Zagajewski 2010). Symulator fuzji ARTMAP to również sieć współzawodnicząca. Wewnątrz sieci działają dwa symulatory, które równolegle klasyfikują dane. Obraz lepiej sklasyfikowany podawany jest jako wynik końcowy działania sieci (B. Zagajewski 2010). B. Zagajewski (2010), U. Pytlak (2013) oraz M. Kacprzyk (2013) w swoich pracach klasyfikowali zdjęcia satelitarne z wykorzystaniem symulatora fuzji ARTMAP. B. Zagajewski pracował na danych hiperspektralnych DAIS 7915 (dokładność producenta 86%, dokładność użytkownika 75,1%), zaś U. Pytlak (dokładność całkowita 90,9%) i M. Kacprzyk (dokładność całkowita 68%) na danych wielospektralnych Landsat. Można zauważyć lepsze wyniki klasyfikacji danych o dokładniejszej rozdzielczości spektralnej i przestrzennej.

2. Metodyka pracy

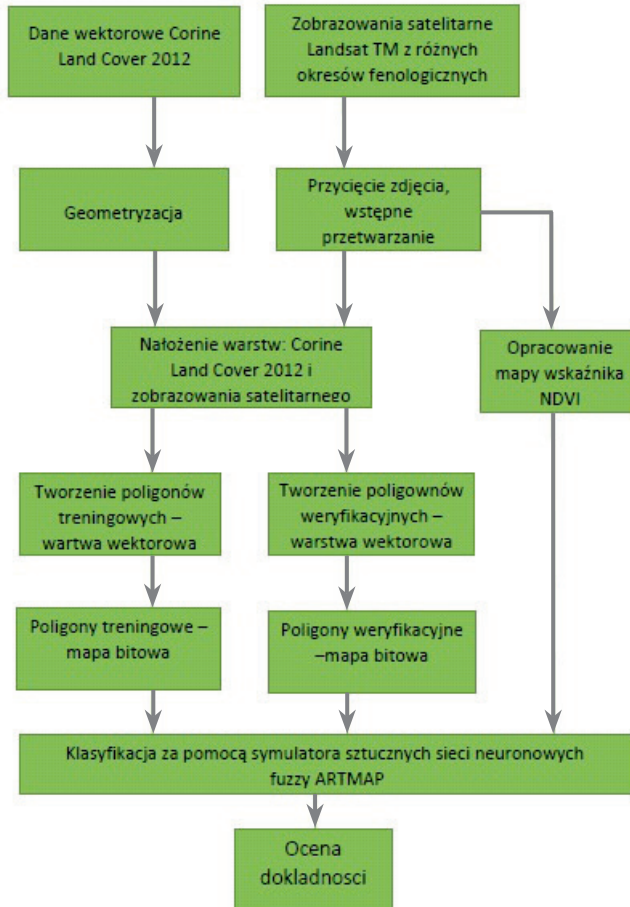
Klasyfikację przeprowadzono dla drugiego poziomu legendy Corine Land Cover 2012 (CLC12) z wykorzystaniem dziesięciu klas. Klasyfikacja i ocena jej dokładności wykonywane były według schematu przedstawionego na rycinie 2.

² Projekt Corine Land Cover, www.igik.edu.pl/pl/corine-projekt

Pierwszym etapem pracy było przygotowanie mapy bazowej Corine Land Cover 2012 i zdjęć satelitarnych do dalszego przetwarzania (wykonano transformację z PUVG 1992 do WGS-84 w programie ArcMap ESRI 10.2. oraz przycięto do analizowanego obszaru). Obrazy satelitarne Landsat 5 zostały pozyskane ze strony earthexplorer.usgs.gov kolejno 21 kwietnia 2011 r., 5 czerwca 2010 r. i 27 sierpnia 2011 roku.

W drugim etapie do przeprowadzenia klasyfikacji narysowano poligony treningowe i weryfikacyjne na podstawie legendy Corine Land Cover. Na analizowanym obszarze wyznaczono 10 form pokrycia terenu według drugiego poziomu legendy CLC: 1.1 zabudowa miejska, 1.2 tereny przemysłowe, handlowe i komuni-

kacyjne, 1.4 miejskie tereny zielone i wypoczynkowe, 2.1 grunty orne, 2.2 uprawy trwałe, 2.3 łąki i pastwiska, 2.4 obszary upraw mieszaných, 3.1 lasy, 3.2 zespoły roślinności drzewiastej i krzewiastej, 5.1 wody śródlądowe. Korzystając ze zdjęć Landsat na podstawie różnicy między najwyższym odbiciem w paśmie bliskiej podczerwieni a absorpcją w paśmie czerwonym obliczono znormalizowany wskaźnik zieleni NDVI (ang. Normalized Difference Vegetation Index), który pomógł rozróżnić formy terenu związane z roślinnością. Do przeprowadzenia klasyfikacji za pomocą symulatora fuzzy ARTMAP wykorzystano sześć kanałów zobrazowania Landsat (pominięto kanał termalny), poligony treningowe i weryfikacyjne w postaci bitmap oraz wskaźnik NDVI. W wyniku pracy



Ryc. 2. Metodyka pracy

sztucznej sieci neuronowej otrzymano obraz poklasyfikacyjny i tabelę dokładności.

Na koniec dokonano oceny dokładności całkowitej, która określa stosunek liczby pikseli prawidłowo sklasyfikowanych do wszystkich pikseli. W tym celu wykorzystano macierz błędów zbudowaną z wierszy zawierających wydzielenia wzorca oraz z kolumn, w których zapisane są wyniki poszczególnych wydziałów pochodzące z klasyfikacji (B. Zagajewski 2010). Macierz ta informuje w jaki sposób (z jakim wynikiem dokładności) zostały sklasyfikowane piksele w poszczególnych polach weryfikacyjnych (J.R. Jensen 2005).

3. Wyniki klasyfikacji

W wyniku klasyfikacji z użyciem poligonów narysowanych na podstawie mapy pokrycia terenu Corine Land Cover 2012 otrzymano obrazy poklasyfikacyjne. Uzyskano również macierze błędów informujące o dokładnościach.

Dokładności całkowite, otrzymane dla wszystkich obrazów poklasyfikacyjnych, są zbliżone i oscylują wokół 70%. Najlepszy wynik (76%) uzyskano dla zdjęcia z sierpnia, zaś najgorszy wynik dla zdjęcia wykonanego w czerwcu (68,6%).

Analizując wyniki (tab. 2) stwierdzono, że cztery z dziesięciu form pokrycia terenu klasyfikują się bardzo dobrze (dokładności użytkownika i producenta 80–100%). Są to kolejno: 5.1 wody śródlądowe, 3.1 lasy, 1.1 zabudowa miejska, 2.1 grunty orne. Forma 2.4 obszary upraw mieszanych nie klasyfikuje się poprawnie – wyniki sięgają poniżej 30%. Pozostałe klasy dopasowywane są z dokładnością na poziomie 50–70%. W celu przybliżenia relacji zachodzących w macierzy błędów przedstawiono wynik na przykładzie klasy 3.1 lasy. Prawidłowo zaklasyfikowały się 7084 piksele. Najwięcej niepoprawnie przyporządkowanych pikseli klasy 3.1 lasy zostało przypisanych kolejno do klas: 3.2 zespoły roślinności drzewiastej i krzewiastej

Tab. 2. Macierz błędów klasyfikacji zobrazowania z 21 kwietnia 2011 r.

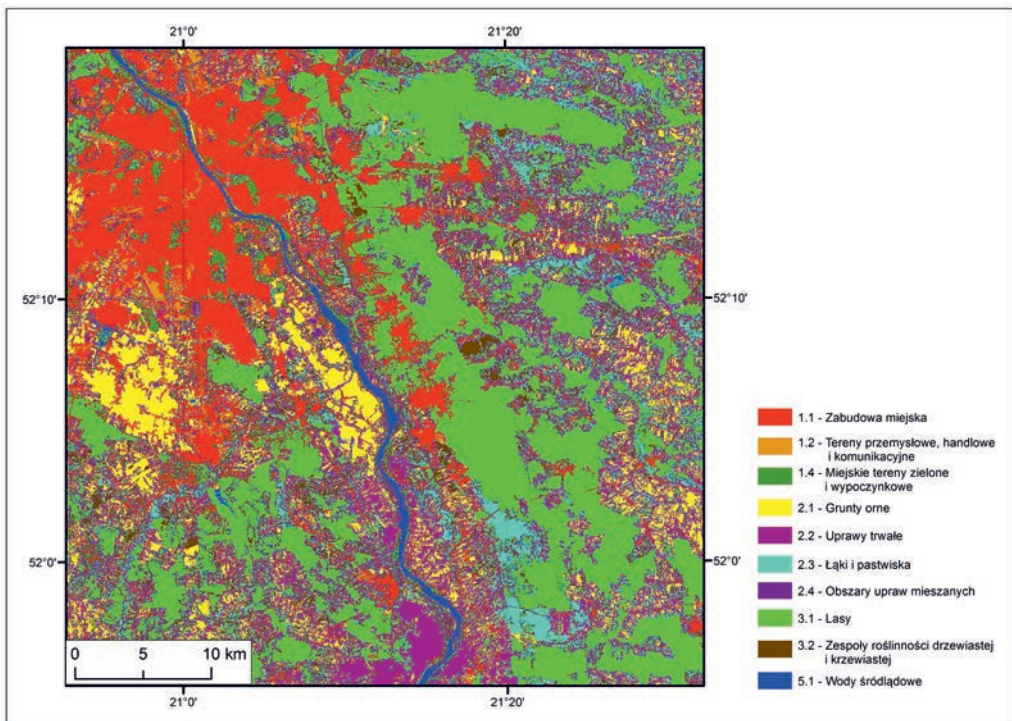
Formy pokrycia terenu	D.U.	Liczba sklasyfikowanych pikseli									
		3.1	1.1	2.1	2.3	5.1	2.2	3.2	2.4	1.4	1.2
3.1. Lasy	92.13%	7084	0	0	67	0	9	458	71	0	0
1.1. Zabudowa miejska	86.93%	15	4424	33	36	15	17	6	56	192	295
2.1. Grunty orne	77.30%	0	146	3653	98	15	299	215	201	29	70
2.3. Łąki i pastwiska	68.50%	324	0	57	2460	0	156	347	202	30	15
5.1. Wody śródlądowe	96.41%	3	41	39	4	3300	0	0	4	0	32
2.2. Uprawy trwałe	74.15%	50	78	197	145	0	2389	25	160	85	93
3.2. Zespoły roślinności drzewiastej i krzewiastej	51.66%	49	3	93	477	0	142	1245	348	44	9
2.4. Obszary upraw mieszanych	18.33%	58	132	500	214	0	388	448	428	133	34
1.4. Miejskie tereny zielone i wypoczynkowe	65.83%	15	220	12	66	0	188	3	169	1308	6
1.2. Tereny przemysłowe, handlowe i komunikacyjne	50.03%	0	698	27	0	58	2	0	17	4	807
	D.P.	93.24%	77.05%	79.22%	68.97%	97.40%	66.55%	45.32%	25.85%	71.67%	59.29%

D.U. – dokładność użytkownika, D.P. – dokładność producenta

(458 pikseli), 2.4 obszary upraw mieszanych (71 pikseli), 2.3 łąki i pastwiska (67 pikseli) oraz 2.2 uprawy trwałe (9 pikseli). Natomiast żaden piksel nie sklasyfikował się jako klasy: 1.1 zabudowa miejska, 1.2 tereny przemysłowe, 1.4 miejskie tereny zielone i wypoczynkowe, 2.1 grunty orne, 2.2 uprawy trwałe, 2.3 łąki i pastwiska, 2.4 obszary upraw mieszanych, 3.1 lasy, 3.2 zespoły roślinności drzewiastej i krzewiastej, 5.1 wody śródlądowe. Aby lepiej zobrazować wynik pracy symulatora, opracowano mapę poklasyfikacyjną na podstawie zdjęcia z 21 kwietnia 2011 r., gdzie 75,1% pikseli zostało sklasyfikowanych poprawnie. Wynik klasyfikacji przedstawia rycina 3.

torów artykułu dokładność 76,6% jest zadowalającym wynikiem. Dokładność zależy od analizowanego obszaru (jego heterogeniczności) i metody, jaką sklasyfikowane są zdjęcia.

Formami z najwyższymi wartościami dokładności producenta i użytkownika są wody śródlądowe (dokładność producenta 97,31%, dokładność użytkownika 98,14%) i lasy (99,09% i 94,58%). Najgorzej klasyfikują się obszary upraw mieszanych (13,45% i 23,29%). Podobne wyniki klasyfikacji otrzymali inni badacze wykorzystujący sieci neuronowe. J.F. Mas i in.



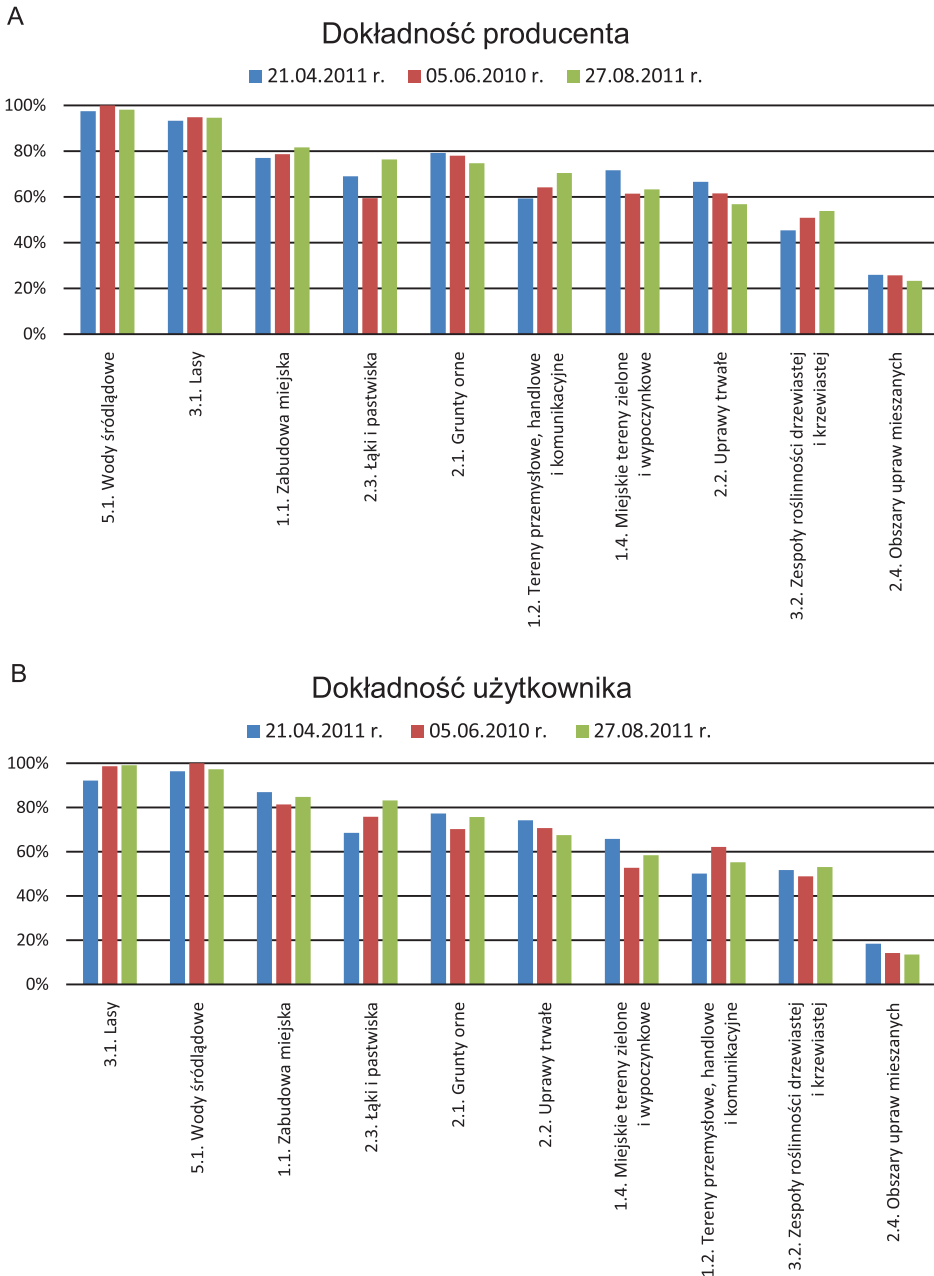
Ryc. 3. Obraz poklasyfikacyjny zdjęcia z 21 kwietnia 2011 r.

Porównując wszystkie wykonane klasyfikacje stwierdzono, że najlepsze wyniki uzyskano dla zdjęcia z sierpnia – otrzymano dokładność całkowitą na poziomie 76,6%. Odnosząc otrzymane wyniki do rezultatów M. Łyko w 2012 r. (dokładność całkowita 62%), J.F. Masa i in. w 2004 (74%), H. Yuana i in. z 2009 (88,1%) czy M.J. Aitkenheada i I.H. Aaldersa w 2008 r. (84,7%) stwierdzono, że uzyskana przez au-

(2004) otrzymali najwyższe wartości dokładności dla wód (dokładność użytkownika 98%, dokładność producenta 98%), zaś H. Yuan i in. (2009) stosując metodę nadzorowaną uzyskali dokładności użytkownika i producenta dla klas woda 100% i 98,3% oraz lasy 100% i 74,1%. U. Pytlak (2013) otrzymała najwyższe dokładności dla klas: wody śródlądowe (99,9%, 98,1%), grunty orne (94,9%; 96,3%), lasy (97,4%;

89,9%), a najgorsze dla obszarów upraw mieszanych (65,7%; 92,8%). Podobne wyniki uzyskała M. Kacprzyk w 2013 roku. Z powyższego

zestawienia wynika, że formami najlepiej klasyfikującymi się metodą sztucznych sieci neuronowych są wody i las.



Ryc. 4. A – dokładność producenta dla drugiego poziomu CLC2012, B – dokładność użytkownika dla drugiego poziomu CLC2012

4. Zależność wegetacyjna pokrycia terenu

Okres wegetacyjny to część roku, podczas którego roślinność ma najlepsze warunki, aby się rozwijać ze względu na dostateczną wilgotność i ilość ciepła (E. Żmudzka 2012).

Analizując dokładności klasyfikacji (ryc. 4) najlepsze wyniki dla form związanych z roślinnością (lasy, łąki i pastwiska oraz zespoły roślinności drzewiastej i krzewiastej) uzyskano dla klasyfikacji zdjęcia pochodzącego z sierpnia. Może to wynikać z dobrej kondycji roślin w tym czasie. Patrząc na rycinę można stwierdzić, która forma klasyfikuje się najlepiej w danym okresie. Dzięki temu możemy określić, które typy pokrycia terenu należy klasyfikować w określonym miesiącu.

5. Podsumowanie

Po przeprowadzeniu analiz otrzymano mapy poklasyfikacyjne wraz z tabelami informującymi o dokładnościach. Na podstawie otrzymanych wyników (dokładności na poziomie 70%) stwierdzono, że zaproponowana metoda klasyfikacji jest przydatnym narzędziem do aktualizacji map pokrycia terenu. Dzięki działaniu sztucznych sieci neuronowych znacznie uproszczył się proces klasyfikacji i tworzenia map pokrycia terenu. Klasyfikacje metodami nieautomatycznymi dają podobne wyniki dokładności, jednakże nakład czasu i pracy jaką trzeba włożyć jest większy. Zaletą metody sztucznych sieci neuronowych jest pozbycie się wpływu człowieka na wynik, ponieważ nie musi on posiadać informacji o analizowanym terenie. Dodatkowo, dzięki metodom automatycznym, proces klasyfikacji pokrycia terenu zostaje ujednoczony. Mapy pokrycia terenu w różnych państwach opracowywane są według tych samych wzorców i parametrów. Należy jednak pamiętać, że obrazy wygenerowane za pomocą sztucznych sieci neuronowych pod względem kartograficznym są niepoprawne i mogą być publikowane po odpowiednim zredagowaniu.

6. Wnioski

- Najwyższą dokładność całkowitą otrzymano klasyfikując zdjęcie Landsat TM pozyskane 27 sierpnia 2011 r. – 76,61%, a najniższą (68,6%) klasyfikując zdjęcie wiosenne z 21 kwietnia 2011 roku.
- Pomimo podobnych wartości dokładności całkowitej dla wszystkich zdjęć (oscylującej wokół 70%), dokładności użytkownika i producenta w poszczególnych formach różnią się nawet o kilkadziesiąt procent.
- Kategorie obejmujące wody śródlądowe, lasy i zabudowę miejską klasyfikowały się najdokładniej. Dla nich sztuczne sieci neuronowe są bardzo dobrym narzędziem do przeprowadzenia procesu klasyfikacji.
- Forma upraw mieszanych nie klasyfikuje się poprawnie za pomocą sztucznych sieci neuronowych.
- Dokładność klasyfikacji w dużej mierze zależy od liczby pikseli – im większa jest liczba pikseli, tym wyniki są na wyższym poziomie.

Podziękowania

Dziękujemy Głównemu Inspektoratowi Ochrony Środowiska za udostępnianie bazy Corine Land Cover 2012. Jednostką odpowiedzialną za realizację projektu Corine Land Cover 2012 w Polsce, w ramach programu Copernicus GIO Land Monitoring finansowanego ze środków Unii Europejskiej, był Instytut Geodezji i Kartografii, pełniący rolę jednego z krajowych centrów referencyjnych EIONET ds. pokrycia terenu (NRC Land Cover). Właścicielem danych powstałych w ramach tego projektu jest Unia Europejska, a jednostką odpowiedzialną za rozpowszechnianie danych krajowych jest Główny Inspektorat Ochrony Środowiska, w którym funkcjonuje Krajowy Punkt Kontaktowy ds. współpracy z EEA w ramach EIONET oraz krajowe centrum referencyjne EIONET ds. pokrycia terenu (NRC Land Cover).

Literatura

- Anderson J.R., Hardy E.E., Roach J.T., Witmer R.E., 1976, *A land use and land cover classification system for use with remote sensor data*. „Geological Survey Professional Paper” no. 964, s. 3–10.
- Aitkenhead M.J., Aalders I.H., 2008, *Classification of Landsat Thematic Mapper imagery for land cover using neural networks*. „Intern. Journal of Remote Sensing” Vol. 29, no. 7, s. 2075–2084.
- Baranowski M., Ciołkosz A., 1997, *Opracowywanie baz danych pokrycia terenu dla Polski*. „Prace Instytutu Geodezji i Kartografii” T. 44, z. 95, s. 7–28.
- Bielecka E., Ciołkosz A., 2004, *Metodyczne i realizacyjne aspekty aktualizacji bazy Corine Land Cover*. „Prace Instytutu Geodezji i Kartografii” T. 50, z. 108, s. 73–92.
- Bielecka E., Ciołkosz A., 2005, *Baza danych Corine Land Cover*. Biblioteka Monitoringu Środowiska. Warszawa: Inspekcja Ochrony Środowiska, 76 s.
- Campbell J.B., Wynne R.H., 2011, *Introduction to Remote Sensing*. Fifth Edition, The Guilford Press, s. 335–382.
- Carpenter G.A., Grossberg S., Markuzon N., Reynolds J.H., Rosen D.B., 1992, *Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps*. „IEEE Transactions on Neural Networks” Vol. 3, no. 5, s. 698–713.
- Commission of the European Communities, 1995, *Corine Land Cover*, The European Environment Agency (EEA), <http://www.eea.europa.eu/publications/COR0-landcover> (dostęp 21.12.2015 r.).
- Feranec J., Hazeu G., Christensen S., Jaffrain G., 2007, *Corine land cover change detection in Europe (case studies of the Netherlands and Slovakia)*. „Land Use Policy” no. 24, s. 234–247.
- Hein M., Walde J., Tappeiner G., Tappeiner U., 2009, *Classifiers vs. input variables – The drivers in image classification for land mapping*. „International Journal of Applied Earth Observation and Geoinformation” Vol. 11, no. 6, s. 423–430.
- Hościło A., Tomaszewska M., 2015, *CORINE Land Cover 2012 – 4th CLC inventory completed in Poland*. „Geoinformation Issues” Vol. 6, no. 1(6), s. 49–58.
- Iwaniak A., Krówczyńska M., Paluszyński W., 2002, *Użycie sieci neuronowych do klasyfikowania obszarów miejskich na zdjęciach satelitarnych*. „Geodesia et Descriptio Terrarum” Nr 1(1–2), s. 5–13.
- Jensen, J.R., 2005, *Introductory digital image processing: a remote sensing perspective*. Third ed., Prentice Hall.
- Kacprzyk M., 2013, *Klasyfikacja pokrycia terenu Podlasia na podstawie zdjęć Landsat TM i symulatora sztucznych sieci neuronowych fazy ARTMAP*. Warszawa: Wydział Geografii i Studiów Regionalnych UW, praca licencjacka, s. 5–83.
- Krówczyńska M., 2004, *Wykorzystanie spektralnych i strukturalnych cech obiektów odwzorowanych na zdjęciach satelitarnych w kartowaniu użytkowania ziemi*. Warszawa: Wydział Geografii i Studiów Regionalnych UW, rozprawa doktorska.
- Lula P., Tadeusiewicz R., 2001, *Wprowadzenie do sieci neuronowych*. Kraków, Statsoft Polska.
- Łyko M., 2012, *Opracowanie mapy pokrycia/użytkowania terenu w oparciu o klasyfikację danych wielospektralnych LANDSAT i IKONOS*. Kraków: AGH, praca magisterska, s. 9–76.
- Mas J.F., 2004, *Mapping land use/cover in a tropical coastal area using satellite sensor data, GIS and artificial neural networks*. „Estuarine Coastal and Shelf Science” no. 59, s. 219–230.
- Olczyk J., 2014, *Klasyfikacja pokrycia terenu województwa warmińsko-mazurskiego na podstawie zdjęć Landsat TM i symulatora sztucznych sieci neuronowych*. Warszawa: Wydział Geografii i Studiów Regionalnych UW, praca magisterska.
- Pytlak U., 2013, *Klasyfikacja pokrycia terenu Wielkopolski na podstawie zdjęć Landsat TM i symulatora sztucznych sieci neuronowych fazy ARTMAP*. Warszawa: Wydział Geografii i Studiów Regionalnych UW, praca licencjacka, s. 5–30.
- Tadeusiewicz R., 1993, *Sieci neuronowe*. Wyd. 2, Warszawa: Akadmiczna Oficyna Wydawn. RM.
- Yuan H., Van Der Wiele C.F., Khorram S., 2009, *An Autoated Neural Network System for Land Use/Land Cover Classification from Landsat TM Imagery*. „Remote Sensing” no. 1, s. 243–265.
- Zagajewski B., 2010, *Ocena przydatności sieci neuronowych i danych hiperspektralnych do klasyfikacji Tatr Wysokich*. Warszawa. „Teledetekcja Środowiska” T. 43, s. 7–112.
- Zagajewski B., Jarościńska A., Olesiuk D., 2009, *Metody i techniki badań geoinformatycznych*. Warszawa: Wydział Geografii i Studiów Regionalnych UW, s. 1–117.
- Żmudzka E., 2012, *Wieloletnie zmiany zasobów termicznych w okresie wegetacyjnym i aktywnego wzrostu roślin w Polsce*. „Woda – Środowisko – Obszary Wiejskie” T. 12, 2012 (IV–VI), z. 2, s. 377–389.

The use of the artificial neural networks to update the CORINE Land Cover maps

Summary

Modern land cover maps are the basis of many scientific disciplines and they are widely applied. One of the problems connected with the revision of maps is the data updating procedure. Remote Sensing daily provides us with the new satellite images, that can meet the needs of database updates. In this article the method of classification for land cover with the artificial, neural, fuzzy ARTMAP networks is presented by the authors in accordance with the objectives and legend of the CORINE Land Cover Map on the basis of the Landsat satellite data, which are used to elaborate the land cover maps. The latest CORINE

Land Cover map 2012 polygons are used as the reference and verification data. Three satellite Landsat TM images of 21.04.2011, 05.06.2010, 27.08.2011 are processed by a fuzzy, artificial, neural network classificatory simulator. The area of research was Warsaw and its surrounding area. The results of this research are the classificatory land cover maps and error matrices. Acquired results confirm that the artificial neural networks can be successfully used for land cover updating.

Keywords: classification, Corine Land Cover, artificial neural networks, Warsaw

