

WPLYW ALGORYTMÓW SCALANIA DANYCH NA WYNIKI KARTOWANIA POKRYCIA TERENU - WYBRANE ASPEKTY

THE IMPACT OF VARIOUS IMAGE DATA FUSION METHODS ON THE RESULTS OF LAND USE AND LAND COVER MAPPING - SELECTED ASPECTS

Tomasz Pirowski, Bartosz Garlewicz, Kamila Gryboś

Katedra Geoinformacji, Fotogrametrii i Teledetekcji Środowiska, Wydział Geodezji
Górnictwej i Inżynierii Środowiska, AGH Akademia Górniczo – Hutnicza

SŁOWA KLUCZOWE: integracja danych teledetekcyjnych, klasyfikacja, fotointerpretacja, pokrycie i użytkowania terenu

STRESZCZENIE: W artykule dokonano waloryzacji wybranych metod scalania danych teledetekcyjnych o różnej rozdzielczości pod kątem ich przydatności do kartowania pokrycia i użytkowania terenu. Analizie poddano oryginalne dane Landsat ETM+ (30m), dane Landsat przeliczone do 5m z dodanym do zestawu kanałem IRS PAN 1D (5m) oraz dane Landsat i IRS PAN scalone czterema metodami: IHS, PCA, WMK i PL, charakteryzującymi się wyraźnie odmiennymi algorytmami integracji. Opracowanych w ten sposób sześć zestawów danych poddano klasyfikacji spektralnej metodami maksymalnego prawdopodobieństwa, drzew decyzyjnych i sieci neuronowych. Wyniki uzyskane na danych sprzed i po integracji zestawiono dodatkowo z analizami fotointerpretacyjnymi, wykonanymi równolegle do analiz klasyfikacyjnych. Testy potwierdziły przewagę metody fotointerpretacyjnej nad wynikami klasyfikacji spektralnej, w zależności od zestawu danych, o 6-11% wartości dokładności całkowitej mapy pokrycia i użytkowania terenu. Scalenie danych poprawia ogólną dokładność klasyfikacji o 9% pomiędzy pracą na oryginalnym obrazie Landsat (30m) a zintegrowanym Landsat z IRS (5m), pozwalając uzyskać dokładność 64%. Dla metody fotointerpretacyjnej wzrost dokładności wynosi 6%, osiągając 71%. Wybór metody integracji jest drugorzędny - zróżnicowanie wyników w metodzie fotointerpretacyjnej wynosi 1%, dla metod klasyfikacyjnych około 5% (najlepsza - PL; najgorsza - IHS). Znaczenie dla wyników klasyfikacji ma wybór algorytmu: z wszystkich testowanych zestawów danych najlepsze wyniki uzyskano dla sieci neuronowych (64%), następnie dla drzew decyzyjnych (62%) i metody największego prawdopodobieństwa (59%).

1. WSTĘP

Scalone dane satelitarne stanowią dzisiaj standardowy materiał analityczny. Większość satelitów obrazujących w zakresie optycznym wyposażona jest w sensory wielokanałowe i panchromatyczne, rejestrujące w wyższej rozdzielczości przestrzennej. Stosunek rozmiaru pikseli obu typów obrazu dla satelitów wysokorozdzielczych wynosi najczęściej 4:1 na korzyść obrazu PAN (np. Ikonos, QuickBird, WorldView, Pleiades), dla

średniorozdzielczych jest bardziej zróżnicowana (np. 2:1 Landsat, 5:1 IRS). W przypadku danych TerraAster czy Sentinel-2 brak klasycznego kanału PAN, jednak występuje różnica w wielkości piksela terenowego kanałów widzialnych i podczerwonych. Dualność danych spowodowała naturalną tendencję do ich łączenia w jeden syntetyczny produkt. Pierwsze algorytmy podawane były już w latach 80-tych XX w. (Showengerdt, 1980; Haydn *et al.*, 1982), w latach 90-tych pojawiły się pierwsze zestawienia jakości integracji (Chavez *et al.*, 1991), kontynuowane i rozwijane w kolejnych latach (Rachnin *et al.*, 2000; Osińska-Skotak, 2012; Pirowski, 2013). Wzrastające moce obliczeniowe umożliwiły realizację algorytmów opartych o lokalne charakterystyki obrazów (Hill *et al.*, 1999) oraz wielorozdzielcze analizy obrazów, w tym transformacje falkowe (Aiazzi *et al.*, 1999; Rachnin *et al.*, 2000). Wybrane algorytmy zostały zaimplementowane w formie "czarnych skrzynek" do oprogramowań teledetekcyjnych, jak ERDAS (Ehlers *et al.*, 2010), ENVI (Aiazzi *et al.*, 2007) czy PCI Geomatics (Zhang, 1999). Duża liczba stosowanych algorytmów narzuciła potrzebę usystematyzowania stosowanych metod (Pohl *et al.*, 1998; Borkowski *et al.*, 2015) i sformalizowanie ich oceny (Wald, 2000; Garzelli *et al.*, 2004; Pirowski, 2006). Zwiększenie ilości i różnorodności danych spowodowało, że są na masową skalę automatycznie integrowane i udostępniane, jak w serwisie GoogleMaps czy GoogleEarth. Oferty dystrybutorów danych obejmują w standardowej ofercie produkty scalone. W wyniku tych procesów zatarła się w wielu przypadkach, szczególnie dla mniej doświadczonych użytkowników, granica między faktycznie rejestrowanym obrazem, a sztucznie wytworzonym w wyniku scalenia danych. Powodować to może trudności ze zrozumieniem, iż odpowiednio prowadząc proces integracji, wpływa się na jakość danych obrazowych, a przez to wzrasta ich przydatność zastosowania w określonym celu.

W niniejszej publikacji podjęto próbę odpowiedzi na pytanie, czy dane scalone w istotny sposób poprawiają możliwość kartowania podstawowych kategorii pokrycia terenu? Jeśli tak, to jak duży notuje się wzrost dokładności? Czy wzrost ten znacząco różni się w zależności od wyboru algorytmu integracji danych, od wyboru metody interpretacyjnej bądź automatycznego rozpoznawania treści obrazów? Z uwagi na praktycznie nieograniczoną możliwość wielowariantowych testów, ograniczono się do kartowania danych metodą fotointerpretacyjną oraz poprzez trzy wybrane klasyfikatory spektralne (pikselowe), świadomie rezygnując z najbardziej dziś obiecującej klasyfikacji obiektowej (problem wykorzystania danych panchromatycznych na etapie segmentacji oraz scalonych danych wielospektralnych na kolejnych etapach OBIA stanowi odrębny problem i wymaga poświęcenia temu zagadnieniu obszernych analiz). Testy ograniczono do czterech, reprezentatywnych metod integracji. Pomimo zawężenia analiz, materiał badawczy jest obszerny - obejmuje łącznie 16 zestawów danych do analiz porównawczych.

2. METODYKA

Naczelnym postulatem w procesie integracji danych o różnej rozdzielczości jest zachowanie oryginalnych charakterystyk radiometrycznych kanałów spektralnych przy maksymalnym możliwym ich uszczegółowieniu. Proponowane metody w różnym stopniu realizują to założenie, ale opracowane parametry statystyczne pozwalają łatwo uszeregować metody wg wzmocnienia lub zniekształcenia spektralnego. Natomiast

raportowane doświadczenia z praktycznego stosowania scalonych danych nie są jednoznaczne (Raptis *et al.*, 1998; Shymala *et al.*, 1994; Nikolakopoulos, 2008; Wiemker *et al.*, 1998). W publikacjach najczęściej można spotkać opis zastosowań danych scalonych, zrealizowanych określoną metodą, bez rozszerzonych badań co do możliwości zastosowania innych algorytmów (np. dla celów leśnych - Hill *et al.*, 1999; środowiska wodnego - Ashraf *et al.*, 2012; kłęk żywiolowych - Witharana *et al.*, 2013). Brakuje kompleksowej oceny poszczególnych metod scalania pod kątem ich przydatności do klasyfikacji, i szerzej - powiązania uzyskiwanej jakości kartowania pokrycia terenu z określonymi parametrami statystycznymi, jakimi scharakteryzować można zintegrowane dane lub proces scalania. Tematykę tę podjęto w niniejszej publikacji. Przyjęte rozwiązanie zakłada następujące kroki metodyczne:

1. Opracowanie danych referencyjnych na bazie ortofotomap lotniczych, poprzez fotointerpretację i wektoryzację, a następnie rasteryzację do rozdzielczości piksela terenowego 5 m i 30 m (pkt. 3, pkt. 4).
2. Scalenie danych IRS PAN 1D (5m) z obrazem wielospektralnych Landsat TM (30 m) wybranymi 4 metodami integracji (pkt. 2.2).
3. Przygotowanie zestawów danych: kompozycji barwnych z kanałów oryginalnych i po scaleniu. Niezależna fotointerpretacja każdego zestawu danych - wielospektralnych (komplementarnie KB) i obrazu PAN - do kartowania mapy pokrycia terenu wg przyjętego schematu klasyfikacyjnego, poprzez proces wektoryzacji. Dla każdego zestawu danych opracowanie map rastrowych w rozdzielczości 5 m i 30 m (pkt 5).
4. Klasyfikacja spektralna trzema algorytmami, wg przyjętego schematu klasyfikacyjnego, na materiałach satelitarnych Landsat TM, TM+PAN, oraz po integracji. Dla każdego zestawu danych opracowanie map w rozdzielczości 5 m i 30 m - poprzez multiplikację pikseli (dane TM) lub ich generalizację (dane scalone) (pkt. 2.1, pkt. 5).
5. Odniesienie wyników interpretacji i klasyfikacji do pól referencyjnych w rozdzielczości 5 m i 30 m. Opracowanie macierzy błędów proporcjonalnych i uzyskanie ogólnych dokładności kartowania dla testowanych wariantów (pkt. 5).
6. Wzajemne porównanie uzyskanych wyników. Analiza wpływu na błędy przyjętej docelowej rozdzielczości. Porównanie wyników kartowania do notowanych wartości wzmocnienia spektralnego zniekształcenia i poszczególnych metod scalania (pkt. 6).

Przeprowadzone eksperymenty badawcze należy traktować jako przyczynek do próby podania hierarchii ważności elementów składających się na uzyskanie mapy pokrycia terenu o relatywnie wysokiej dokładności - wpływu rozdzielczości przestrzennej danych wejściowych, zastosowanego algorytmu ich łączenia oraz wybranej metody klasyfikacji.

2.1. Metody klasyfikacji

Kartowanie pokrycia i użytkowania terenu na obszarze testowym wykonano stosując trzy metody klasyfikacji spektralnej: maksymalnego prawdopodobieństwa, sieci neuronowych, drzew decyzyjnych. Metody te wybrano ze względu na dużą bądź wzrastającą popularność oraz odmienną filozofię algorytmów klasyfikujących.

W metodzie największego prawdopodobieństwa (MAXLIKE - *Maximum Likelihood*) piksele przypisywane są do klas pokrycia/użytkowania terenu na podstawie

prawdopodobieństwa. Wśród podstawowych metod klasyfikacji nadzorowanej jest najbardziej dokładnym rozwiązaniem.

Sieć neuronowa to, ogólnie mówiąc, bardzo uproszczony model mózgu. Składa się na nią od kilkuset do kilkudziesięciu tysięcy elementów, zwanych neuronami. Elementy te, za pomocą połączeń o wagach modyfikowanych w trakcie procesu, zwanego procesem uczenia, tworzą swego rodzaju sieć (Tadeusiewicz, 1993). Istnieje wiele typów sieci neuronowych, z których perceptron wielowarstwowy (MLP) cieszy się największą popularnością (Bochenek, 2006;). Wadą jest długotrwały proces uczenia się oraz podatność na proces przeuczenia (*overfitting*), czyli zbytowego dopasowania się do danych treningowych. Otrzymana w czasie uczenia się wiedza jest bardzo trudna do interpretacji, a uwzględnianie tak zwanej wiedzy dziedzinowej jest trudne (Iwaniak, 2002).

Zastosowanie drzew decyzyjnych (CTA - *decision trees*) jest jednym z najbardziej intuicyjnych podejść do problemu klasyfikacji. Rozwiązanie to opiera się na jednej z podstawowych technik pozwalających skutecznie rozwiązywać złożone zadania, czyli "dziel i zwyciężaj" (*divide and conquer*). Drzewo decyzyjne to hierarchiczna struktura, zbudowana z węzłów i łączących je gałęzi. Do węzłów będących liśćmi (węzłami nie posiadającymi potomków) przypisana jest decyzja klasyfikacyjna, a w pozostałych zapisane są reguły podziału (Krętowski *et al.*, 2002). Głównymi zaletami drzew decyzyjnych jest stosunkowo szybka klasyfikacja, zrozumiały proces decyzyjny oraz możliwość poprawy jakości algorytmu, poprzez analizę procesu klasyfikacji i ręczne modyfikowanie reguł decyzyjnych.

2.2. Metody integracji danych obrazowych

Borkowski *et al.* (2015) systematyzują metody integracji następująco: a) substytucji kanałów; b) oparte na działaniach arytmetycznych; c) wykorzystujące właściwości teksturalne obrazów; d) oparte o transformacje liniowe kanałów; e) wykorzystujące filtrację górnoprzepustową; f) oparte o analizę obrazów w różnych rozdzielczościach; g) lokalne statystyki kanałów; h) inne, trudne do sklasyfikowania. W prowadzonej analizie wykorzystano pięć metod integracji danych: IHS, PCA, HPF, PL oraz WMK (rozwińcie akronimów wyjaśniono niżej). Wybór ich podyktowany był popularnością oraz różnorodnością – wspomniane 5 metod lokuje się w czterech ww. grupach metod. Dla pełnej kontroli integrację przeprowadzono w oprogramowaniu Idrisi i MathLab, rezygnując z gotowych, zaimplementowanych w formie "czarnych skrzynek" modułów integracji (*pansharpening*) dostępnych w oprogramowaniach teledetekcyjnych.

IHS-RGB to jedna z pierwszych opracowanych metod integracji (Haydn *et al.*, 1982). Procedura oparta jest na konwersji przestrzeni RGB do postaci IHS i z powrotem, przy czym podczas przekształcenia IHS do RGB za składową natężenia barwy (*Intesity*) podstawiany jest znormalizowany obraz panchromatyczny. Wynika to z założenia, że tylko składowa I zawiera informację przestrzenną, a pozostałe H i S informację tematyczną. Metoda IHS jest ograniczona co do możliwości jednoczesnego użycia do integracji tylko trzech kanałów spektralnych. Pomimo dużych zastrzeżeń związanych z jakością spektralną generowanych produktów (Xiao, 2003; Pirowski 2010), metoda z reguły daje akceptowalne wyniki dla wizualnej interpretacji, a jej modyfikacje znacząco podnoszą jakość

uzyskiwanych syntetycznych obrazów (Mularz *et al.*, 2006; Osińska-Skotak, 2012). W prowadzonych testach wykorzystano standardową metodę IHS.

PCA jest procedurą zbliżoną do metody IHS (Chavez *et al.*, 1991). Wykorzystywana jest transformacja z oryginalnej przestrzeni kanałów do nowej – tym razem głównych składowych. Następnie dokonuje się podmiany kanałów niosących informację przestrzenną i przeprowadza się transformację odwrotną. Poprzez zastąpienie pierwszej składowej, która zawiera maksymalną wariancję w zestawie danych o niskiej rozdzielczości, maksymalizuje się efekt wyższej rozdzielczości w kanałach po transformacji odwrotnej (Shettigara, 1992). W prowadzonych testach wykorzystano metodę PCA-SPS (*Standardized Principal Component Substitution*) opartą o macierz korelacyjną (Shettigara, 1992). Transformacji poddano wszystkie sześć kanałów obrazu wielospektralnego.

HPF (*High-Pass Filter*) to metoda polegająca na zastosowaniu filtracji górnoprzepustowej na obrazie panchromatycznym (Showengerdt, 1980). Takie postępowanie powoduje redukcję niższej częstotliwości (informacji spektralnej), przy jednoczesnym pozostawieniu informacji wysokoczęstotliwościowych, odnoszących się głównie do informacji przestrzennej. Tak powstały obraz dodawany jest, piksel po pikselu, do kanałów spektralnych. Wynikiem jest nowy zestaw danych multispektralnych o podwyższonej rozdzielczości przestrzennej (Chavez *et al.*, 1991). Jakość integracji uzależniona jest głównie od doboru wielkości okna filtrowania oraz doboru wag na etapie dodawania wyników filtracji do kanałów. Metoda cechuje się stabilnymi wynikami i jest często wykorzystywana (Osińska-Skotak, 2012; Witharana *et al.*, 2013). W prowadzonych testach, na podstawie raportowanych wyników przez Pirowskiego (2009), wykorzystano okna filtrowania o wymiarze 9×9 .

Metoda „Piramidy Laplace’a” (PL) należy do grupy metod MRA – *MultiResolution Analysis*, czyli technik integracji danych gdzie zgodnie ze współczynnikami falkowymi tworzone są tzw. piramidy obrazów, czyli sekwencje obrazów o różnej rozdzielczości. W wyniku próbkowania rozmiar obrazu jest dwukrotnie mniejszy w obu kierunkach na każdym poziomie piramidy. Prowadzi to do reprezentacji sygnału na różnych poziomach rozdzielczości, a różnica na poziomie wejściowym i przefiltrowanym jest niezbędna dla rekonstrukcji obrazu czyli podwyższenia jego rozdzielczości (Rockinger *et al.*, 1998). Odpowiednie skonstruowanie piramid obrazów dla danych spektralnych i dla obrazów panchromatycznych – o przynajmniej jednym poziomie dekompozycji więcej – pozwala na zdefiniowanie wzajemnych relacji pomiędzy zestawami danych. Wykorzystanie tych relacji w procesie rekonstrukcji obrazu pozwala wprowadzić dodatkową informację przestrzenną do danych niskorozdzielczych (Aiazzi *et al.*, 1999).

Metoda WMK opracowana w 1998 roku przez Wiemker’a zaliczana jest do grupy metod RSC – *Relative Spectral Contribution*. Cechą wspólną tych rozwiązań jest to, że oryginalna odpowiedź spektralna w danym kanale jest mnożona przez pewien współczynnik, który reprezentuje wkład informacji spektralnej z kanału tematycznego do kanału panchromatycznego i równa się stosunkowi kanału panchromatycznego i tych kanałów spektralnych, które swoim zakresem spektralnym pokrywa kanał panchromatyczny (Wald, 2000). Metody z tej grupy, CN oraz transformacja Brovey’a, zostały opracowane tylko dla wzmacniania trypletu kanałów tworzących kompozycję barwną, przez co nie zachowują pierwotnych charakterystyk spektralnych obrazów.

Wiemker *et al.* (1998) proponują obliczyć średnią odpowiedź spektralną na obrazie oryginalnym oraz po wstępnej integracji z obrazem panchromatycznym, a następnie parametry te wykorzystać do ostatecznego obliczenia jasności syntetycznego obrazu.

3. OBSZAR BADAŃ, DANE

Obszar opracowania stanowi prostokąt o wymiarach 21.6 km × 10.3 km, obejmujący teren miasta Krakowa z przyległymi terenami podmiejskimi. Charakteryzuje się on dużym zróżnicowaniem pokrycia terenu i użytkowania ziemi. Ścisłe centrum miasta to tereny zabudowy zwartej, z enklawami zieleni miejskiej, przecięte rzeką Wisłą. Natomiast na terenach podmiejskich występuje konglomerat różnych komponentów środowiska: zabudowa rozproszona, tereny przemysłowe i komunikacyjne, niewielkie zbiorniki wodne, zwarte obszary leśne oraz obszary użytkowane rolniczo.

Wykorzystany zestaw danych obejmuje obraz wielospektralny (6 kanałów) o rozdzielczości przestrzennej 30 m pozyskanych przez satelitę Landsat 7 ETM+ 7 maja 2000 roku oraz obraz panchromatyczny wykonany przez satelitę IRS 1D o rozdzielczości przestrzennej 5.8 m (przepróbkowany w trakcie ortorektyfikacji do rozdzielczości 5 m) z 21 maja 2000 roku. Dane z tego okresu zostały zastosowane, aby zachować ciągłość i porównywalność dotychczas prowadzonych badań z zakresu przydatności integracji danych (Pirowski 2009, Pirowski, 2010, Pirowski *et al.*, 2013).

Obraz prawdy terenowej, służący do weryfikacji wyników kartowania danych satelitarnych, wykonano na podstawie ortofotomapy ze zdjęć lotniczych w skali 1:5000, pozyskanych w ramach projektu Phare z lat 90-tych (piksel terenowy 0,75m). Dane te cechuje najbliższa zgodność czasowa z obrazami Landsat i IRS z 2000 roku.

4. DANE REFERENCYJNE

Ze względu na występującą różnicę czasową pomiędzy danymi satelitarnymi (2000 rok) i lotniczymi (1997 rok), naczelnym postulatem przy wyborze obszarów referencyjnych była niezmiennosc pokrycia i użytkowania terenu w tym okresie oraz zapewnienie ich zróżnicowania pod względem występujących komponentów środowiska. Wektoryzację na ortofotomapach lotniczych przeprowadzono w programie ArcView wyodrębniając osiem - rozumianych szeroko - klas użytkowania terenu (rys. 1): wody (płynące i stojące: naturalne ciekły, rzeki, kanały, zbiorniki retencyjne, stawy i jeziora), zabudowa zwarta (zwarte zespoły budynków, z nieznacznymi obszarami zieleni i drogami komunikacyjnymi), zabudowa luźna (zabudowania średnie i niskie, z dominacją domków jednorodzinnych oraz lokalnymi trasami komunikacyjnymi), infrastruktura drogowa (sieć drogowa i kolejowa), tereny zadrzewione (lasy a także zadrzewione i zakrzewione tereny miejskie – głównie parki), niska roślinność (trawniki miejskie, łąki, a także grunty orne obsiane roślinnością, trwałe użytki zielone i ugory), brak roślinności (grunty orne nie pokryte roślinnością, składowiska piasku oraz place budowy), ogródki działkowe. Ostatnią dziewiątą klasę stanowią tereny niesklasyfikowane (w tym: obszary niezidentyfikowane, głębokie cienie). Dokonany podział, nie uwzględniający m.in. funkcji obiektów, generalizujący niewielkie obiekty (jak pojedyncze budynki przypisując je do kategorii zabudowy luźnej bądź zwartej), a także

dopuszczający łączenie w jednej klasie różne ich typy (np. gleby odkryte i place budowy; łąki i uprawy) wynikał z uwzględnienia ograniczeń przy stosowania obrazów satelitarnych o średniej rozdzielczości do kartowania pokrycia terenu, gdzie w klasyfikacji podstawowym kryterium przynależności jest charakterystyka spektralna piksela, a w procesie interpretacji - bazującej głównie na kompozycjach barwnych - znaczenia nabiera charakterystyka spektralna oraz wzajemne powiązania odwzorowanych struktur.




Rys. 1. Pola referencyjne, opracowane na podstawie interpretacji zdjęć lotniczych:
A, B, C - tereny zabudowy zwartej z elementami zieleni miejskiej; D - tereny podmiejskie o charakterze rolniczym i rekreacyjnym; E - zabudowa podmiejska i tereny zielone.

W kolejnym kroku pola referencyjne przekształcono na postać rastrową, do dwóch wielkości piksela terenowego: 5 m i 30 m, przestrzegając zasady zgodności siatki pikseli z danymi satelitarnymi. Odnoszenie wyników pracy do obu rozdzielczości pozwoli odpowiedzieć na pytanie, czy oczekiwana poprawa dokładności kartowania na danych scalonych wynika jedynie z lepszego wyznaczenia granic wydzielanych klas, czy też także z poprawy rozpoznania obiektów. Czy w przypadku przyjęcia docelowej, określonej wielkości piksela terenowego, ma znaczenie praca na danych roboczych o wyższej rozdzielczości? Realizując postulaty Congaltona (1997), przyjęto w procesie generalizacji danych zasadę przypisania dla piksela klasy dominującej powierzchniowo.


5. KARTOWANIE POKRYCIA I UŻYTKOWANIA TERENU

Przeprowadzono prace fotointerpretacyjne na oryginalnych danych Landsat oraz po ich integracji, wykorzystując komplementarnie kompozycje barwne (KB123, KB234, KB354, KB247). Na danych IRS 1D pracowano na obrazie w skali szarości, modyfikując kontrast i wykorzystując progowanie. Łącznie poddano interpretacji 5×5 obszarów ($500 \text{ m} \times 500 \text{ m}$) $\times 7$ wariantów (Landsat ETM+, obraz IRS PAN pięć metod integracji,). W celu zapewnienia niezależności interpretacji (wykluczenia "uczenia się" przez operatorów rozpoznania terenu na podstawie wcześniej interpretowanych danych, w tym danych referencyjnych), prace były realizowane przez różne osoby, fragmenty terenu były obracane o 90, 180 i 270 stopni oraz stosowano odbicie lustrzane. Osoba przygotowująca dane referencyjne nie była włączona w proces interpretacji danych satelitarnych. Przykładowy wynik, uzyskany dla pola C dla wybranych wariantów, zestawiono na rysunku 2. Następnie dane zostały przekształcone na postać rastrową, wg analogicznych zasad jakie zastosowano dla pól referencyjnych. Poprzez macierz błędów proporcjonalnych uzyskano dokładności producenta i konsumenta dla każdej z klas oraz dokładność całkowitą dla każdego z wariantów, w dwóch testowanych rozdzielczościach.



Rys. 2. Pole referencyjne C. Wynik fotointerpretacji,.: a) ETM+; b) IRS PAN c) PCA

Obszar testowy poddano wielokrotnej klasyfikacji - dla każdej z trzech metod, na siedmiu zestawach danych: a) oryginalnych danych Landsat (30 m); b) kanałach Landsat wraz z IRS PAN traktowanym jako dodatkowy kanał, c) pięciu metodach integracji. Z uwagi na brak możliwości automatycznego wydzielenia klas "infrastruktura drogowa" oraz "ogródki działkowe", ograniczono schemat klasyfikacyjny do 6 kategorii (rys. 3).



Rys. 3. Pole referencyjne C. Wynik kartowania automatycznego, na danych oryginalnych ETM+ (30m): a) MAXLIKE; b) MLP; c) CTA, oraz po integracji metodą Piramidy Laplace'a (5m): d) MAXLIKE; e) MLP; f) CTA

6. ANALIZA WYNIKÓW

6.1. Kartowanie fotointerpretacyjne danych satelitarnych

W metodzie fotointerpretacyjnej na danych zintegrowanych proces integracji danych nie pozwolił na wyodrębnienie zakładanych 8 kategorii pokrycia terenu, przygotowanych na danych referencyjnych: wiarygodna identyfikacja klasy ogródków działkowych - dobrze rozpoznawalnych na ortofotomapie lotniczej - nie była tutaj możliwa. Dzięki scaleniu danych przyspieszeniu uległ proces interpretacyjny oraz nastąpiło - realizowane poprzez wektoryzację - dokładniejsze wyznaczenie granic dzielących klasy. W niektórych przypadkach pozwoliło to skartować dodatkowe obiekty, które były zgeneralizowane na pierwotnym obrazie Landsat i/lub były niemożliwe do zidentyfikowania na panchromatycznym obrazie IRS (efekt ten dotyczył głównie wydzielenia małych enklaw zieleni miejskiej na obszarze pola referencyjnego B, które stanowiło ściśle centrum miasta).

Uzyskane dokładności całkowite zestawiono na rysunku 4. W celach porównawczych dołączono wyniki uzyskane w procesie fotointerpretacji. Z uwagi na dużą powierzchnię pól referencyjnych, przedział ufności dla podanych wartości, obliczany metodą podaną przez Hejmanowską (2005), wynosi dla rozdzielczości 5 m +/- 0.35%, dla 30 m +/- 2.1%.

Największy wpływ na dokładność kartowania metodą fotointerpretacyjną ma rozdzielczość interpretowanych obrazów. Liczba pikseli poprawnie sklasyfikowanych podczas fotointerpretacji (dokładność całkowita) wzrasta z 62% dla obrazu oryginalnego Landsat (30 m) oraz 65% dla obrazu panchromatycznego IRS (5 m) do 67-68% dla obrazów scalonych. Wybór techniki integracji danych ma drugorzędny wpływ na wynik.

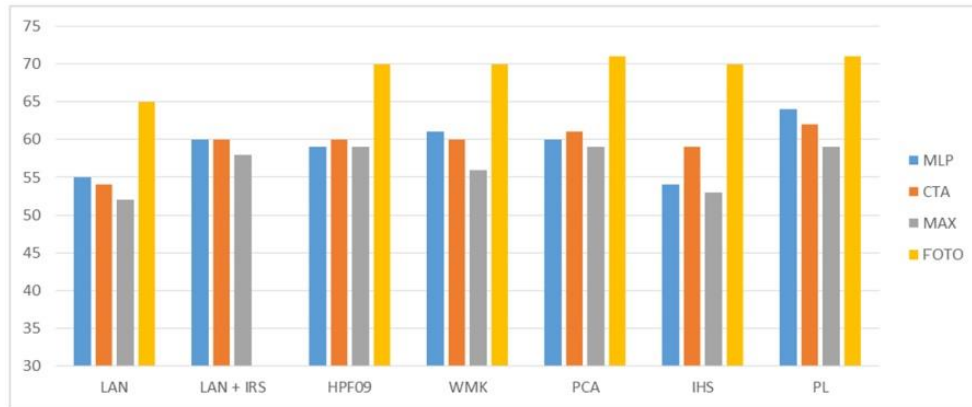
Wybór wielkości docelowego piksela terenowego podczas konwersji obrazów wektorowych na postać rastrową ma wpływ na wynik analizy. Zaobserwować można

wzrost wartości dokładności całkowitej o około 1% - 3% przy odniesieniu się do pola referencyjnego w rozdzielczości 30m zamiast 5m (dotyczy to w podobnym stopniu wyników prac interpretacyjnych na danych oryginalnych jak i zintegrowanych). Najwyższą dokładność całkowitą uzyskano dla metody PCA (ponad 70%), a najniższą dla techniki HPF (około 67%). Interesujące jest więc to, że praca na zintegrowanym obrazie wielospektralnym o rozdzielczości 5m zapewnia na tyle polepszenie interpretacji danych, w stosunku do oryginalnych danych Landsat, że efekt ten nie zanika przy ponownej degradacji do 30 m końcowych map pokrycia i użytkowania terenu - uzyskane wyższe dokładności kartowania nie wynikają jedynie z lepszego wyznaczenia granic klas.

6.1. Kartowanie metodami automatycznymi

Analizując wykres (rys. 4) łatwo zauważyć, że spośród trzech testowanych klasyfikatorów lepsze i porównywalne wyniki uzyskano metodami MLP i CTA, niż metodą MAXLIKE. Dzięki algorytmowi PL uzyskano najwyższe wartości dokładności całkowitej, niezależnie od zastosowanego klasyfikatora, i tak: 64% dla algorytmu MLP, 62% dla CTA oraz 59% dla MAXLIKE. Najgorsze wyniki otrzymano dla algorytmów MAXLIKE i MLP przy pracy na danych zintegrowanych metodą IHS, odpowiednio 53% i 54%. Były to wyniki niższe niż uzyskane na danych oryginalnych Landsat. Zestawiając najlepsze możliwe wyniki klasyfikacji osiągnięte na różnych zestawach danych, przy różnych schematach klasyfikacyjnych (w tym dodatkowe testy, nie prezentowane w publikacji, uwzględniające miksele) potwierdziła się zasada, że najlepsze wyniki uzyskiwano metodą MLP, w drugiej kolejności CTA (przeciętnie dokładność całkowita o 2% niższa), następnie MAXLIKE (przeciętnie około 5% niższa).

Widoczna jest zależność wskazująca na poprawę wyników klasyfikacji przy zastosowaniu danych o wyższej rozdzielczości. Liczba pikseli poprawnie sklasyfikowanych algorytmem największego prawdopodobieństwa wzrasta z 52% dla obrazu LANDSAT do 58% dla niezintegrowanych obrazów LANDSAT+IRS i 59% dla obrazów zintegrowanych metodą PL. Dla algorytmu sieci neuronowych zanotowano wzrost liczby pikseli poprawnie sklasyfikowanych z 56% dla obrazu LANDSAT do 64% dla obrazów zintegrowanych metodą PL. Podobnie dla algorytmu drzew decyzyjnych – dokładność całkowita wzrasta z 54% dla obrazu LANDSAT i 60% dla niezintegrowanych obrazów LANDSAT+IRS do 62% dla obrazów zintegrowanych metodą PL. Są to zmiany większe niż poziom ufności danych, a więc są one znaczące statystycznie. Od ogólnych spostrzeżeń odbiega wynik uzyskany w przypadku danych zintegrowanych metodą IHS, gdzie notowane są wyniki relatywnie mocno zróżnicowane, w niektórych przypadkach nawet gorsze niż dla danych oryginalnych, o rozdzielczości 30 m. W przypadku degradacji wyników do 30 m i odniesienia się do pola referencyjnego w tej rozdzielczości, następuje wzrost dokładności o około 2% dla każdej z metod.

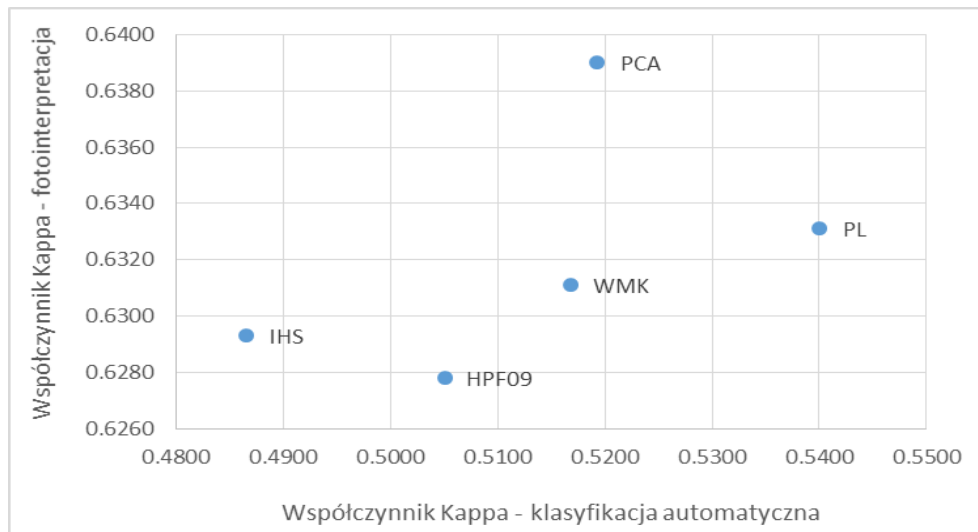


Rys. 4. Dokładność całkowita [w %] kartowania automatycznego (MLP, CTA, MAXLIKE) oraz fotointerpretacyjnego (FOTO). 6 klas pokrycia, pole referencyjne o rozdzielczości 5m.

6.3. Porównanie metod kartowania

Dokładności całkowite uzyskane automatyczną metodą klasyfikacji okazały się zdecydowanie niższe od tych otrzymanych na drodze fotointerpretacji. Przeciętna różnica wynosi 10%, zarówno w odniesieniu do danych oryginalnych Landsat, jak i do danych po integracji. Największą różnicę zanotowano w wynikach opartych o metodę IHS, gdzie wartość dokładności całkowitej najlepszego wyniku klasyfikacji automatycznej jest o 11% niższa niż wynik fotointerpretacji. Z kolei najmniejszą różnicę, wynoszącą 7%, uzyskano dla klasyfikacji wykonywanych na zintegrowanych danych PL. Występujące zróżnicowanie oznacza, że zarówno dla metody interpretacyjnej, jak i automatycznych, istotne znaczenie ma zwiększenie rozdzielczości przestrzennej obrazu wielospektralnego. W przypadku degradacji wyników i odniesieniu się do pól referencyjnych na poziomie 30m zarówno w metodzie interpretacyjnej jak i klasyfikacyjnych uzyskano poprawę o około 2%.

Nie ustalono natomiast relacji pomiędzy wynikami uzyskiwanymi metodą fotointerpretacyjną a metodami automatycznymi, w zależności od zastosowanego algorytmu integracji (rys. 5). Brak też zależności pomiędzy notowanymi parametrami statystycznymi związanymi z jakością integracji, jak RASE, nQ% (Wald, 2010), AIL% (Pirowski, 2010), WT i WP (Pirowski, 2006). Wynika to z faktu, że zachowanie oryginalnych charakterystyk spektralnych kanałów, w różnym stopniu realizowane przez algorytmy scalania, nie wpływa w sposób determinujący na ich przydatność interpretacyjną (Pirowski, 2009). Dla procesów klasyfikacji, traktujących obraz wielospektralny jako duże zbiory danych, sytuacja będzie podobna. Różna jest też "odporność" algorytmów na zmiany radiometrii obrazów. Być może istotnym czynnikiem jest też stopień redundancji klasyfikowanych danych, który znacząco może wzrastać przy określonych algorytmach integracji danych. Potwierdzenie tych przypuszczeń wymaga dalszych prac badawczych.



Rys. 5. Porównanie uzyskanych współczynników Kappa klasyfikacji MLP (oś X) z metodą fotointerpretacyjną. 6 klas pokrycia terenu, rozdzielczość 5m.

7. KONKLUZJE

Przeprowadzone analizy wskazują, że dysponowanie obrazem wielospektralnym o sztucznie podniesionej rozdzielczości przestrzennej w znaczący sposób wpływa na podniesienie ogólnych dokładności opracowywanych na ich podstawie map pokrycia i użytkowania terenu. Dla testowanych danych, przy kartowaniu podstawowych sześciu kategorii pokrycia terenu wzrost względny wynosi 6-9%: dla metody fotointerpretacyjnej pozwala uzyskać dokładności całkowite 71%, dla klasyfikacji 64%. Wybór metody integracji jest drugorzędny - zróżnicowanie wyników w metodzie fotointerpretacyjnej jest pomijalne (około 1%), większe dla metod klasyfikacyjnych (około 5%, ze wskazaniem na metodę PL; odrzuceniem metody IHS). Istotny dla polepszenia wyników klasyfikacji jest wybór algorytmu: najlepsze wyniki uzyskuje się dla sieci neuronowych (64%), następnie dla drzew decyzyjnych (62%) i metody największego prawdopodobieństwa (59%).

Warto zauważyć, że integracja danych, pomimo przeprowadzenia jej na obrazach o dużym zróżnicowaniu rozdzielczości przestrzennej, nie pozwala rozpoznać nowych kategorii pokrycia terenu, a jedynie dodatkowo wykryć i wyznaczyć granice wybranych niewielkich obiektów z listy podstawowych klas, zgeneralizowanych na pierwotnej rozdzielczości danych. Ograniczenia te potwierdził pośrednio brak możliwości wiarygodnego wydzielenia w procesie fotointerpretacyjnym klasy ogródków działkowych, a w procesie klasyfikacji również infrastruktury komunikacyjnej.

W przypadku interpretacji wizualnej przyjęcie docelowej rozdzielczości produktu końcowego nie jest wprost związane z rozdzielczością analizowanych materiałów. Dlatego eksperymentalnie odnoszono się do materiałów referencyjnych na różnych poziomach wielkości piksela terenowego (5m, 30m). Analiza pozwoliła na podanie praktycznego wniosku, że nawet podczas tworzenia produktów na poziomie piksela równego 30 m i skali opracowania 1: 100 000, do interpretacji warto jest wzmocnić dane obrazowe poprzez zwiększenie ich rozdzielczości przestrzennej do poziomu wyższego niż docelowy produkt (w tym przypadku do 5m, aby je następnie zdegradować do 30m). Podobny efekt uzyskano sztucznie degradując wyniki klasyfikacji. Zarówno dla fotointerpretacji, jak i klasyfikacji, zanotowano wzrost dokładności całkowitej około 2%.

Wyniki przeprowadzonych analiz potwierdzają przydatność integracji danych, natomiast nie rozstrzygają o wyborze konkretnego ich algorytmu. Stosowane dotychczas metody porównawcze, proponowane wskaźniki jakościowe i ilościowe nie znajdują wciąż odzwierciedlenia w praktycznym aspekcie wykorzystywania scalonych danych obrazowych w procesie ich interpretacji bądź klasyfikacji spektralnej. Utrudnia to sprawne wykorzystanie integracji danych, gdyż różnorodność algorytmów integracji, w połączeniu z możliwościami stosowania różnych klasyfikatorów (w tym tu nie omawianej segmentacji i klasyfikacji obiektowej), daje użytkownikowi dużą liczbę potencjalnych rozwiązań przez co empiryczny wybór najlepszego wyniku w praktyce jest zbyt czasochłonny. Rozwiązaniem byłoby podanie odpowiednich metod rankingowych, opartych o specjalnie w tym celu opracowane wskaźniki statystyczne, wykraczające poza obecnie stosowane do oceny procesu scalania danych. Planuje się rozszerzenie badań w tym kierunku.

Praca wykonana w ramach badań statutowych AGH nr 11.11.150.949

LITERATURA

- Aiazzi B., Alparone L., Argenti F., Baronti S., 1999. Wavelet and pyramid techniques for multisensor data fusion: a performance comparison varying with scale ratios. *The EOS/SPIE Symposium on Remote Sensing*, Genua.
- Aiazzi B., Baronti S., Selva M., 2007. MS and Pan image fusion by an enhanced Gram-Schmidt spectral sharpening. *New Developments and Challenges in Remote Sensing*, Z. Bochenek (red.). Millpress, Rotterdam.
- Ashraf S., Brabyn L., i Hicks B. J., 2012. Image data fusion for the remote sensing of freshwater environments. *Applied Geography*, 32(2), 619-628.
- Bochenek, Z., 2006. Analiza metod klasyfikacji obszarów miejskich zobrazowanych na wysokorozdzielczych zdjęciach satelitarnych. *Prace IGiK*, Tom LII, zeszyt 110.
- Borkowski A., Głowienka E., Hejmanowska B., Kwiatkowska-Malina J., Kwolek M., Michałowska K., Mikrut S., Pękala A., Pirowski T., Zabrzaska-Gąsiorek B., 2015. GIS i teledetekcja w monitoringu środowiska E. Głowienka (red.), Wyższa Szkoła Inżynierijsko-Ekonomiczna, Rzeszów.
- Chavez P. S., Jr., S. C. Sides, J. A. Anderson, 1991. Comparison of three different methods to merge multiresolution and multispectral data: Landsat TM and SPOT panchromatic. *Photogrammetric Engineering and Remote Sensing*, 57(3), 295-303.

- Congalton, R. G., 1997. Exploring and Evaluating the Consequences of Vector-to-Raster and Raster-to-Vector Conversion. *Photogrammetric Engineering and Remote Sensing*, 63(4), 425-434.
- Ehlers M., Klonus S., Johan Å., Strand P., Rosso P., 2010. Multi-sensor image fusion for pansharpening in remote sensing. *International Journal of Image and Data Fusion*, 1(1), 25-45.
- Garzelli, A., Nencini, F., Alparone, L., Aiazzi, B., Baronti. S., 2004. *Pan-sharpening of Multispectral Images: a Critical Review and Comparison*. IEEE Geoscience and Remote Sensing Letters, vol.1, No. 1, s. 81-84
- Haydn R., Dalke G. W., Henkel J., Bare J. E., 1982. Application of the MS Color Transform to the Processing of Multisensor Data and Image Enhancement, *Proceedings of the International Symposium on Remote Sensing of Arid and SemiArid Lands*, Cairo, Egypt, pp. 599-616
- Hejmanowska B., 2005. *Wpływ jakości danych na ryzyko procesów decyzyjnych wspieranych analizami GIS*. Rozprawa monograficzna nr. 141, AGH, Kraków
- Hill J., Diemer C., Stöver O., Udelhoven Th., 1999. A local correlation approach for the fusion of remote sensing data with different spatial resolutions in forestry applications. *International Archives of Photogrammetry and Remote Sensing*, 32.
- Iwaniak, A., Krówczyńska, M., Paluszyński, W., 2002. Użycie sieci neuronowych do klasyfikacji obszarów miejskich na zdjęciach satelitarnych. *Acta Scientiarum Polonorum. Geodesia et Descriptio Terrarum*, 1(1-2), 5-13.
- Krętowski, M., Bobrowski Ł., 2002. Generowanie wielowymiarowych drzew decyzyjnych na podstawie zbiorów danych.[w:] Stepaniuk J. (red.) *Zeszyty Naukowe Politechniki Białostockiej „Informatyka”*. Zeszyt 1. Wyd. Politechniki Białostockiej.
- Mularz S., Pirowski T., 2006. Aspekty metodyczne integracji danych teledetekcyjnych w oparciu o metodę IHS i jej modyfikacje. AGH, „Geodezja”, T.12, z.2, cz.1, 330-332.
- Nikolakopoulos K. G., 2008. Comparison of nine fusion techniques for very high resolution data. *Photogrammetric Engineering & Remote Sensing*, 74(5), 647-660.
- Osińska-Skotak K., 2012. Ocena przydatności różnych metod integracji obrazów panchromatycznych i wielospektralnych w odniesieniu do zobrazowań WorldView 2. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, 24, 231-244.
- Pirowski T., 2006. Integracja danych teledetekcyjnych pochodzących z różnych sensorów – propozycja kompleksowej oceny scalonych obrazów. *Geoinformatica Polonica*, 8, 59-75.
- Pirowski T., 2009. Ranking metod integracji obrazów teledetekcyjnych o różnej rozdzielczości – ocena formalna scalenia danych Landsat TM i IRS-PAN. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, 20, 343-357.
- Pirowski T., 2010. Ranking metod integracji obrazów teledetekcyjnych o różnej rozdzielczości – ocena walorów fotointerpretacyjnych scalenia danych Landsat TM. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, 21, 327-340.
- Pirowski T., Szczasiuk G., 2013. Selekcja i przetwarzanie wzmocnionych przestrzennie obrazów wielospektralnych Landsat TM – porównanie wyników opartych o dane scalone i dane źródłowe. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, 25, 155-167.
- Pohl C., van Genderen J. L., 1998. Multisensor image fusion in remote sensing: concepts, methods and applications. *International Journal Remote Sensing*, 19., 823-854.

- Ranchin T., Wald L., 2000. Comparison of different algorithms for the improvement of the spatial resolution of images. *Fusion of Earth Data*, Sophia Antipolis, France
- Raptis V. S., Vaughan R. A., Ranchin T., Wald L., 1998. An assessment of different data fusion methods for the classification of an urban environment. *Fusion of Earth*
- Rockinger O., Fechner T., 1998. Pixel-level image fusion: the case of image sequences. *Proceedings SPIE*, Vol. 3374.
- Shettigara V. K., 1992. A generalized component substitution technique for spatial enhancement of multispectral images using a higher resolution data set. *Photogrammetric Engineering & Remote Sensing*, 58, 561-567.
- Schowengerdt R. A., 1980. Reconstruction of multispatial, multispectral image data using spatial frequency content. *Photogrammetric Engineering & Remote Sensing*, 46 (10)
- Shymala R., Kumaran T. V., Marino L., Howarth P., 1994. *Classification methods for Land Cover Mapping*, SPIE vol. 2231.
- Tadeusiewicz, R., 1993. *Sieci neuronowe*. Warszawa: Akademicka Oficyna Wyd. RM.
- Wald L., 2000. Quality of high resolution synthesized images: is there a simple criterion? *Fusion of Earth Data*, Sophia Anipolis, France.
- Wiemker R., Prinz B., Meister G., Franck R., Spitzer H., 1998. Accuracy assessment of vegetation monitoring with high spatial resolution satellite imagery. Contribution to the ISPRS ECO BP'98, Budapest.
- Witharana C., Civco D., Meyer T. H., 2013. Evaluation of pansharpening algorithms in support of earth observation based rapid-mapping workflows. *Applied Geography*, 37, 63-87.
- Xiao G., Jing Z. L., Li J. X., 2003. *Analysis of color distortion and improvement for IHS image fusion*. *Intelligent Transportation Systems*, 1, 80-85
- Zhang Y., 1999. *A new merging method and its spectral and spatial effects*. *International Journal of Remote Sensing*, 20(10).

THE IMPACT OF VARIOUS IMAGE DATA FUSION METHODS ON THE RESULTS OF LAND USE AND LAND COVER MAPPING - SELECTED ASPECTS

KEY WORDS: image fusion, visual interpretation, classification, LULC

Summary

The article valorises selected methods of merging remote sensing data of different resolution in terms of their suitability for mapping land use and land cover. The original Landsat data (30m) was analyzed, Landsat data converted to 5m with IRS PAN 1D (5m) added to the set and Landsat and IRS PAN data merged with four methods: IHS (transformation into space intensity, hue, saturation), PCA (principal components analysis), WMK (Wiemker's method) and PL (laplace pyramid), characterized by distinctly different integration algorithms. Six sets of data developed in this way were subjected to spectral classification by maximum probability methods, decision trees and neural networks. The results obtained on the data from before and after the integration were additionally compiled with photointerpretation analyzes, made in parallel to the classification analyzes.

The research area was the city of Kraków with adjacent suburban areas, 10x20 km in size. For the research objective being pursued, 5 reference squares 500m x 500m were prepared, ensuring diversity and representativeness for the entire analysis area. The reference data was based on a photo interpretation aerial photographs with a field pixel size of 0.75m.

The tests confirmed the predominance of the photo interpretation method over the results of spectral classification, depending on the data set, by 6-11% of the accuracy value of the total land use and land cover maps. Merging data improves the overall accuracy of the 9% classification between work on the original Landsat image (30m) and the integrated Landsat with IRS (5m), allowing for an accuracy of 64%. For the photointerpretation method, the increase is 6%, reaching the accuracy of 71%. The choice of the method of integration is secondary - the variation in results in the photointerpretation method is 1%, for classification methods about 5% (best - PL, worst - IHS). The choice of the algorithm is important for classification results: of all the tested data sets, the best results were obtained for neural networks (64%), then for decision trees (62%) and the maximum probability method (59%).

Dane autorów / Authors details

dr inż. Tomasz Pirowski
pirowski@agh.edu.pl
telefon: 12 617 22 88
fax: 12 617 38 26

mgr inż. Bartosz Garlewicz
bartosz.garlewicz@gmail.com

mgr inż. Kamila Gryboś
kamila.grybos@gmail.com

Przesłano / Submitted 21.12.2018
Zaakceptowano / Accepted 31.12.2018