

**INTEGRACJA OBRAZÓW RADAROWYCH I OPTYCZNYCH DLA POTRZEB
TWORZENIA MAP POKRYCIA TERENU**

**INTEGRATION OF RADAR AND OPTICAL DATA FOR LAND COVER
MAPPING**

Monika Badurska

Katedra Geoinformacji, Fotogrametrii i Teledetekcji Środowiska,
Akademia Górniczo-Hutnicza w Krakowie

SŁOWA KLUCZOWE: klasyfikacja, integracja danych, SAR, tekstura

STRESZCZENIE: Analizując wady i zalety danych pochodzących z różnych sensorów można stwierdzić, że dostarczane przez nie dane mogą okazać się często niekompletne lub niewystarczające. Dla danych optycznych ograniczeniem może okazać się rejestracja w trudnych warunkach atmosferycznych, dla danych radarowych niewystarczająca rozdzielczość lub występowanie szumów radarowych. Biorąc pod uwagę te wszystkie czynniki, szczególnie interesujące wydaje się być łączenie obrazów pochodzących z różnych źródeł i ich wspólne wykorzystanie. Korzyści płynące z integracji obrazów radarowych z optycznymi sprawdzono pod kątem możliwości polepszenia wyników klasyfikacji obszarów miejskich. Próbowano odpowiedzieć na pytanie, w jakim stopniu dane radarowe mogą polepszyć wynik klasyfikacji i czy mogą być one alternatywnym źródłem w przypadku braku danych optycznych. Nie skupiono się na samych technikach klasyfikacji, wykorzystano standardowe klasyfikatory w podejściu nadzorowanym. Zwrócono jednak uwagę na dynamicznie rozwijającą się w ostatnim czasie klasyfikację obiektową i podjęto próbę porównania jej wyników z klasyczną klasyfikacją opartą na pikselach. Ponieważ w przypadku danych radarowych bardzo cennym źródłem informacji jest tekstura, to jej wykorzystaniu poświęcono główną część prac. W rezultacie, zastosowanie odpowiednio dobranych miar teksturalnych z tzw. macierzy zdarzeń (ang. *Grey Level Co-occurrence Matrix* - GLCM) spowodowało wzrost dokładności wspólnej klasyfikacji w porównaniu do klasyfikacji uzyskanej dla poszczególnych sensorów.

1. WSTĘP

Teledetekcja oparta na analizie obrazów zarejestrowanych w zakresie widzialnym jest z powodzeniem wykorzystywana w produkcji i aktualizacji map terenów miejskich i monitoringu zmian ich użytkowania. Pewne ograniczenia mogą pojawić się w przypadku konieczności rejestracji obrazów optycznych w specyficznych i trudnych warunkach, na przykład w miejscach gdzie często zalegają chmury. W przypadku, kiedy wymagane są systematyczne, wieloczasowe i niezawodne metody pomiaru, obrazy radarowe mogłyby stać się alternatywnym źródłem danych. Ich istotną przewagą jest możliwość rejestracji w ciągu dnia i w nocy, niezależnie do warunków pogodowych i środowiskowych, dzięki

czemu mogą być one częściej pozyskiwane. Pomimo to, wykorzystanie danych radarowych, szczególnie w kontekście aplikacji miejskich, nie jest upowszechnione. W znacznej mierze, powodem może być specyficzny charakter tych obrazów, trudniejsze przetwarzanie, a przede wszystkim brak satelitarnych sensorów obrazujących z odpowiednią rozdzielczością przestrzenną. Sytuację może zmienić pojawienie się w ostatnim czasie satelity TerraSAR-X, a w przyszłości COSMO/SkyMed, których rozdzielczość przestrzenna będzie porównywalna do istniejących wysokorozdzielczych obrazów optycznych.


Problematyką fuzji danych z różnych sensorów zajmuje się między innymi Data Fusion Technical Committee of IEEE-GRSS (International Institute of Electrical and Electronic Engineers, Geoscience and Remote Sensing Society), skupiający środowisko naukowe oraz organizujący konferencje związane z tą tematyką. W tym roku komitet ogłosił konkurs związany z klasyfikacją obszarów miejskich z wykorzystaniem udostępnionych obrazów radarowych i optycznych a głównym celem całego przedsięwzięcia było sprawdzenie istniejącej metodologii w tym zakresie. Ogłoszony konkurs zachęcił autorkę artykułu do przyjrzenia się bliżej problematyce integracji danych z różnych sensorów, a publikacja jest opisem wstępnych prac możliwych do zrealizowania dzięki udostępnionym danym.

Obrazy radarowe rejestrowane przez sensor SAR (*Synthetic Aperture Radar*) dostarczają ogromną liczbę danych na temat właściwości strukturalnych i dielektrycznych obiektów, co wydaje się szczególnie przydatne w tak złożonym środowisku, jakim jest obszar miejski. Główna część prac została więc skupiona na wyciągnięciu jak największej ilości informacji z danych SAR i ich wykorzystaniu w klasyfikacji z danymi optycznymi. Możliwości te były jednak w pewien sposób ograniczone, a wynikało to z udostępnionych danych radarowych (tylko obrazy amplitudy, przetworzone, bez polaryzacji). Ostatecznie, w przypadku danych radarowych skupiono się na informacji o teksturze obrazów, która może być szczególnie przydatna dla obszarów miejskich o dużej różnorodności. Do klasyfikacji obrazów wykorzystano parametry teksturalne Haralick'a, tworzone na podstawie macierzy zdarzeń (GLCM – *Grey Level Co-Occurrence Matrix*), co szczegółowo zostało opisane w dalszej części publikacji.

2. OPIS DANYCH I CHARAKTERYSTYKA ANALIZOWANEGO OBSZARU

Dane zostały udostępnione przez Data Fusion Technical Committee of IEEE-GRSS, który ogłosił konkurs na klasyfikację zestawu obrazów pochodzących z różnych sensorów. Zbiór danych dotyczył obszaru miasta Pavia w północnej części Włoch, a w jego składzie znalazło się dziewięć obrazów radarowych (tylko obrazy amplitudy), pozyskanych przez sensor ERS-1 i 2 (1992-1995) oraz dwa obrazy Landsata (TM5 z 1994 i TM7 z 2000 roku). Wszystkie obrazy były udostępnione w formie przetworzonej (przepróbkowane, wpasowane), o wielkości piksela ok. 10.5m.

Do przeprowadzenia analizy dokładności klasyfikacji udostępniony został również wzorzec (tzw. *ground-truth*). Należy zwrócić uwagę, że głównym celem była klasyfikacja obszarów miejskich, dlatego wzorzec zawiera przede wszystkim informację na temat rodzajów zabudowy miejskiej.



Rys. 1. Obraz wzorca oraz charakterystyka zabudowy miasta

3. CECHY TEKSTURALNE HARALICK'A


Każdy obraz cyfrowy posiada pewne charakterystyczne cechy związane z występowaniem kolorów, kontrastem, powtarzającymi się motywami faktury, ich wielkością i kształtem. Istnieją metody analizy obrazów pozwalające opisać te cechy za pomocą pewnych miar statystycznych. Miary te mogą być obliczane na podstawie różnych charakterystyk statystycznych wyznaczanych bezpośrednio z obrazu (histogram pierwszego rzędu) lub z macierzy (ewentualnie wektorów) opisujących relacje między pikselami o poszczególnych poziomach szarości (histogram drugiego lub wyższego rzędu) (Rudnicki, 2002).

Na podstawie histogramu pierwszego rzędu możemy obliczyć proste cechy teksturalne, takie jak odchylenie standardowe czy wariancję. W latach 70-tych Haralick (Haralick et al., 1979a) zaproponował bardziej złożone miary, obliczane na podstawie tzw. macierzy zdarzeń (*Grey-Level Co-Occurrence Matrix*), opisującej jak często różne kombinacje poziomów szarości pikseli występują na obrazie cyfrowym (Hall-Beyer, 2000).

Co-Occurrence Matrix lub *Grey-Level Co-Occurrence Matrix*, występująca pod skrótem GLCM, nie posiada jednoznacznej nazwy w języku polskim. Najczęściej pojawiające się określenia to: macierz zdarzeń, przejść, koincydencji oraz histogram drugiego rzędu. W niniejszym artykule wykorzystywana będzie nazwa „macierz zdarzeń”.

3.1. Macierz zdarzeń

Macierz zdarzeń jest macierzą kwadratową a jej rozmiar określony jest ilością poziomów szarości obrazu. Wartości macierzy określają ile razy piksel o danej jasności (piksel referencyjny) sąsiaduje z pikselem o innej jasności (pikselem sąsiednim) a związek ten wyznaczany jest dla określonego kierunku oraz odległości między nimi (Hall-Beyer, 2000). Badanymi kierunkami są najczęściej 0°, 45°, 90°, 135° (Rys. 2), co przy zadanej odległości d odpowiada wektorom w układzie współrzędnych x,y : $[0,d]$, $[d,d]$, $[d,0]$, $[d,-d]$.




Rys. 2. Rozmieszczenie badanych kierunków

Można wyróżnić następujące etapy tworzenia macierzy zdarzeń:

- stworzenie pustej ramki macierzy,
- określenie przestrzennych relacji między pikselem referencyjnym a pikselem sąsiednim (odległość i kierunek),
- zliczenie wystąpień poszczególnych par pikseli i wypełnienie ramki macierzy,
- stworzenie macierzy symetrycznej (dodanie do istniejącej macierzy jej transpozy),
- normalizacja macierzy – nadanie macierzy rozkładu prawdopodobieństwa, poprzez podzielenie wartości każdego jej elementu $V_{i,j}$ przez sumę wszystkich elementów (liczbę wszystkich par), (1).

$$(1) P_{i,j} = \frac{V_{i,j}}{\sum_{i,j=0}^{N-1} V_{i,j}}$$


Ilustracja poniżej (Rys. 3) przedstawia etapy tworzenia horyzontalnej macierzy zdarzeń obliczonej dla odległości jednego piksela (1,0). Symetryczna i znormalizowana macierz stanowi podstawę do obliczenia miar teksturalnych.



Rys. 3. Etapy tworzenia macierzy zdarzeń: a) przykładowy obraz; b) pusta ramka macierzy zdarzeń; c) zliczenie wystąpień poszczególnych par pikseli (1,0); d) przekształcenie macierzy w macierz symetryczną; e) macierz symetryczna po normalizacji

3.2. Cechy teksturalne

Haralick jako pierwszy zaproponował 14 cech teksturalnych, które z powodzeniem od lat wykorzystywane są w klasyfikacji obrazów. Wszystkie miary obliczane są na podstawie znormalizowanej macierzy zdarzeń. Podobnie jak w przypadku filtracji, najpierw definiowana jest wielkość okna, dla którego obliczane są parametry teksturalne. Przyjmują one postać pojedynczych wartości, które są przypisywane środkowemu pikselowi okna. W taki sposób tworzony jest cały obraz przedstawiający wartości tekstury (Rys. 4).



Rys. 4. Obrazy tekstury stworzone na podstawie macierzy zdarzeń, wykorzystane w klasyfikacji: a) średnia, b) jednorodność, c) entropia, d) drugi moment

Haralick sugerował obliczenie wszystkich miar teksturalnych we wszystkich czterech kierunkach, obliczenie średniej i zakresu każdej miary, a następnie wykorzystanie ich jako sygnatury w procesie klasyfikacji. Ostatecznie wykorzystuje się tylko pewną grupę miar, ponieważ większość z nich jest ze sobą mocno skorelowana. Miary teksturalne można podzielić na trzy grupy (Hall-Beyer, 2000):

- kontrastu (kontrast, jednorodność, odmienność),
- uporządkowania (entropia, drugi moment, energia),
- statystyczna (średnia, wariancja, korelacja).

Jedną z zasad, jaką można się kierować przy wyborze odpowiednich miar, jest wybór po jednym parametrze z grupy kontrastu i uporządkowania, oraz dwóch parametrów z grupy statystycznej (najczęściej średniej i korelacji). Nie ma niestety uniwersalnej metody wyboru, a pierwszym etapem prac jest najczęściej wizualna selekcja obrazów tekstury.

Podczas przeprowadzonej klasyfikacji wykorzystano obrazy teksturalne stworzone w programie ENVI. Program ten posiada możliwość obliczenia 8 miar teksturalnych na podstawie macierzy zdarzeń, po zdefiniowaniu wielkości okna i wektora przesunięcia. Poniżej przedstawiono równania miar obliczanych w programie ENVI (Hall-Beyer, 2000).

$$(2) \text{kontrast} = \sum_{i,j=0}^{N-1} P_{i,j} (i - j)^2$$

$$(3) \text{odmienność} = \sum_{i,j=0}^{N-1} P_{i,j} |i - j|$$

$$(4) \text{jednorodność} = \sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i - j)^2}$$

$$(5) \text{ drugi_moment} = \sum_{i,j=0}^{N-1} P_{i,j}^2 \quad \text{energia} = \sqrt{\text{drugi_moment}}$$

$$(6) \text{ entropia} = \sum_{i,j=0}^{N-1} P_{i,j} (-\ln P_{i,j})$$

$$(7) \text{ średnia} = \mu = \mu_i = \mu_j = \sum_{i,j=0}^{N-1} i(P_{i,j}) = \sum_{i,j=0}^{N-1} j(P_{i,j})$$

$$(8) \text{ wariancja} = \sigma^2 = \sigma_i^2 = \sigma_j^2 = \sum_{i,j=0}^{N-1} P_{i,j} (i - \mu_i)^2 = \sum_{i,j=0}^{N-1} P_{i,j} (j - \mu_j)^2$$

$$(9) \text{ korelacja} = \sum_{i,j=0}^{N-1} P_{i,j} \left[\frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right]$$

4. KLASYFIKACJA OBRAZÓW

4.1. Klasyfikacja pikselowa

Klasyczna klasyfikacja obrazów ma na celu pogrupowanie wszystkich pikseli w klasy, na podstawie ich własności statystycznych. Liczba klas była w tym przypadku z góry określona zgodnie ze udostępnionym wzorcem, który przedstawiał przede wszystkim trzy klasy określające rodzaj zabudowy miejskiej (centrum, zabudowa miejska i podmiejska) oraz szczytkowo roślinność i wodę. Analizując wzorec i wszystkie obrazy, wybrano w miarę jednorodnie i reprezentatywne pola treningowe dla każdej klasy.

Klasyfikację pikselową przeprowadzono w programie ENVI wykorzystując klasyfikator maksymalnego prawdopodobieństwa.

4.1.1. Oddzielna klasyfikacja dla obrazów z poszczególnych sensorów

W pierwszym etapie sprawdzono możliwości klasyfikacji przeprowadzonej oddzielnie dla danych z poszczególnych sensorów. Klasyfikację wykonano dla wszystkich dziewięciu obrazów radarowych, wszystkich kanałów Landsata TM5 oraz Landsata TM7. W przypadku danych radarowych konieczne było przeprowadzenie filtracji adaptacyjnej w celu usunięcia szumów radarowych tzw. *speckle effect*. Wybrano filtr adaptacyjny Frosta o wielkości okna [7x7].

4.1.2. Wspólna klasyfikacja obrazów radarowych i optycznych

W przypadku wspólnej klasyfikacji danych z różnych sensorów sprawdzano kombinację różnych obrazów radarowych oraz kanałów z satelity Landsat. Dla danych radarowych przeprowadzono analizę składowych głównych (ang. PCA – *Principal Component Analysis*), technikę liniowej transformacji danych obrazowych, w wyniku

której z oryginalnych danych uzyskuje się nowy zestaw obrazów, tzw. składowych. Dzięki analizie składowych głównych, nowo utworzony zestaw obrazów radarowych był nieskorelowany. Ostatecznie do wspólnej klasyfikacji wykorzystano pierwszą składową wszystkich obrazów SAR, oraz wszystkie kanały Landsat TM5 i TM7.

4.1.3. Wykorzystanie cech teksturalnych obrazów radarowych

Ponieważ wykorzystanie samych obrazów radarowych we wspólnej klasyfikacji z danymi optycznymi nie przyniosło poprawy rezultatów, zdecydowano się na włączenie informacji na temat tekstury danych radarowych.

Wszystkie obrazy teksturalne stworzono na podstawie pierwszej składowej z dziewięciu obrazów radarowych. Parametry teksturalne zostały obliczone dla poziomej macierzy zdarzeń (1,0) przy wielkości okna 39x39. Spośród wygenerowanych ośmiu obrazów teksturalnych, do dalszych prac wybrano tylko cztery: średnią, jednorodność, entropię i drugi moment (Rys. 4).

Ostatecznie do klasyfikacji wykorzystano następujący zbiór danych: pierwszą składową obrazów radarowych (1_PCA_ERS), cztery obrazy teksturalne (średnia, jednorodność, entropia, drugi moment), wszystkie kanały obrazu Landsat TM5 i TM7.

4.2. Klasyfikacja obiektowa

W przypadku klasyfikacji obiektowej, analizie podlegają nie pojedyncze piksele, ale obiekty tworzone w procesie zwanym segmentacją obrazu. Ogromną zaletą tej metody jest możliwość wykorzystania dodatkowych informacji na temat badanych obiektów. Oprócz danych spektralnych, obiekt posiada kształt, teksturę, kontekst oraz określone położenie względem innych obiektów (eCognition User Guide 3).

Proces segmentacji obrazu, dobór odpowiednich parametrów określających powstałe segmenty, ma decydujące znaczenia na wyniki samej klasyfikacji. Wielkość tworzonych segmentów określa parametr skali, określający maksymalną dozwoloną heterogeniczność wynikowych obiektów obrazu. Jednorodność powstającego obiektu jest natomiast definiowana przez kolor i kształt, przy czym kryterium kształtu złożone jest z dwóch parametrów: gładkości i zwartości. W praktyce, w procesie segmentacji użytkownik napotyka na różne problemy a określenie odpowiednich parametrów segmentacji jest procesem złożonym i czasochłonnym.

Prace dotyczące klasyfikacji obiektowej przeprowadzono w programie eCognition. Klasyfikacja w eCognition bazuje na logice rozmytej a dostępne są trzy rodzaje klasyfikacji:

- oparta na polach treningowych z wykorzystaniem klasyfikatora najbliższego sąsiada (*SNN* - *Standard Nearest Neighbour*), działającego w wielowymiarowej przestrzeni cech,
- oparta na wiedzy przedstawionej w formie jednowymiarowych funkcji przynależności,
- kombinacja wyżej wymienionych.

4.2.1. Wspólna klasyfikacja obrazów radarowych z optycznymi z wykorzystaniem tekstury.

W ostatnim etapie starano się sprawdzić czy przeprowadzenie klasyfikacji obiektowej dla takiego zbioru danych jak w przypadku klasyfikacji pikselowej może przynieść lepsze wyniki. Zestaw obrazów, który okazał się najlepszy w klasyfikacji opartej na pikselach nie okazał się jednak odpowiedni w przypadku klasyfikacji obiektowej. Podobnie jak wcześniej, wykorzystano obrazy tekstury, ale przy nieco innych parametrach macierzy zdarzeń (wielkość okna 21x21). Decydujące znaczenie w całym procesie klasyfikacji odegrał dobór odpowiednich parametrów w etapie segmentacji, który dla takiego zestawu danych o niskiej rozdzielczości okazał się bardzo czasochłonny i trudny do analizy wizualnej.

W programie eCognition możliwa jest również analiza cech dotycząca tekstury obrazu. Miary teksturalne obliczane są na podstawie macierzy zdarzeń (GLCM) oraz wektora różnic poziomów szarości (GLDV - *Grey Level Difference Vector*), liczonego jako suma przekątnych macierzy zdarzeń. Miary można obliczyć dla każdego kanału i we wszystkich kierunkach, a następnie ich cechy dla poszczególnych klas opisać za pomocą funkcji przynależności.

Sprawdzone zostały dwie metody klasyfikacji: opartej wyłącznie na polach treningowych oraz kombinacji informacji zawartej w polach treningowych z wiedzą na temat klas. Ponieważ wykorzystanie cech teksturalnych w programie eCognition, możliwe jest tylko przy klasyfikacji opartej na wiedzy o klasach, zapisanej w postaci funkcji przynależności, zdecydowano, że do zestawu danych wykorzystanych w procesie klasyfikacji, zostaną włączone obrazy teksturalne stworzone w programie ENVI. Dzięki temu, możliwe było przeprowadzenie klasyfikacji opartej wyłącznie na polach treningowych (tych samych, które były wykorzystane w programie ENVI).

Ostatecznie klasyfikację przeprowadzono dla następującego zbioru danych: pierwsza składowa obrazów radarowych (1_PCA_ERS), trzy obrazy teksturalne (średnia, entropia, drugi moment), 4 pierwsze składowe obrazu Landsat TM5 (4_PCA_Landsat TM5) i TM7 (4_PCA_Landsat TM7).

Parametry segmentacji obrazu, przy wykorzystaniu zarówno kanałów radarowych i optycznych: skala – 45, kolor – 0.2, gładkość – 0.7, zwartość – 0.3.

5. WYNIKI KLASYFIKACJI I WNIOSKI


Podczas klasyfikacji obszaru miasta Pavia, największe trudności sprawiało rozróżnienie obszarów miejskich z podmiejskimi i to właśnie te klasy uzyskiwały najniższe dokładności. Obszary miejskie charakteryzowały się większą gęstością budynków i mniejszą ilością roślinności, ale nawet przy obserwacji wizualnej, trudno było zdecydować, czy dany fragment powinien należeć do klasy miejskiej czy podmiejskiej. Ponieważ obszary podmiejskie w znacznej części zawierały tereny zielone, powodowało to często błędną klasyfikację roślinności w okolicach miasta jako tereny zabudowy podmiejskiej.

Zaproponowane w programie eCognition podejście obiektowe oparte wyłącznie na polach treningowych dało wyniki bardzo zbliżone do podejścia pikselowego. W dalszym ciągu jednak nie udało się usunąć nadmiarowości klasy podmiejskiej, przez co część

roślinności była błędnie klasyfikowana jako zabudowa podmiejska. Problem ten został ostatecznie rozwiązany po uwzględnieniu w procesie klasyfikacji wiedzy na temat klas (za pomocą funkcji przynależności), ale nie pomógł w rozróżnieniu samych rodzajów zabudowy, przez co ogólna dokładność spadła do 61,6%. Wyniki wszystkich opisanych klasyfikacji zostały przedstawione w tabeli poniżej (Tab 1).

Tab 1. Wyniki klasyfikacji

		Zestaw danych	Całkowita dokładność	Indeks Kappa
ENVI	Klasyfikator Maksymalnego Prawdopodobieństwa	ERS 1/2 (9 obrazów)	42,20%	0,1867
		Landsat TM5	61,90%	0,4109
		Landsat TM7	60,30%	0,3923
		1_PCA_ERS Landsat TM5 Landsat TM7	62,92%	0,4340
		1_PCA_ERS obrazy teksturalne (39x39) • średnia • jednorodność • entropia • drugi moment Landsat TM5 Landsat TM7 (Rys. 5a)	69,37%	0,5230
eCognition	SNN – Standardowy Najbliższego Sąsiada	1_PCA_ERS obrazy teksturalne (21x21) • średnia • entropia • drugi moment 4_PCA_Landsat TM5 4_PCA_Landsat TM7 (Rys. 5b)	69,10%	0,5180
	SNN + funkcje przynależności	1_PCA_ERS obrazy teksturalne (21x21) • średnia • entropia • drugi moment 4_PCA_Landsat TM5 4_PCA_Landsat TM7 (Rys. 5c)	61,60%	0,4350



Rys. 5. Wyniki wspólnej klasyfikacji obrazów radarowych z optycznymi z wykorzystaniem obrazów teksturalnych: a) klasyfikacja pikselowa, b) klasyfikacja obiektowa na podstawie pól treningowych, c) klasyfikacja obiektowa na podstawie pól treningowych i funkcji przynależności

Przeprowadzone prace potwierdziły, że wspólne wykorzystanie obrazów radarowych i optycznych może przynieść wiele korzyści w tworzeniu map pokrycia terenu. Ze względu na charakter udostępnionych danych radarowych (tylko przetworzony obraz amplitudy) nie przedstawiono w pełni możliwości obrazów SAR, mimo to, już samo wykorzystanie informacji o teksturze poprawiło wynik klasyfikacji. Dokładność wspólnej klasyfikacji w stosunku do klasyfikacji tylko dla danych optycznych wzrosła z 61,90% do 69,37%. Pomimo dużych możliwości, jakie daje program eCognition w definiowaniu klas, dla zbioru danych o niskiej rozdzielczości przestrzennej nie udało się poprawić rozróżnienia obszarów zabudowy miejskiej.

6. LITERATURA

Amarsaikhan D., Ganzorig M., Ache P., Blotvogel H., 2007. The integrated use of optical and InSAR data for urban land-cover mapping, *International Journal of Remote Sensing*, Vo. 28, No. 6, 1161-1171.

Ban Y., Hu H., 2007. RADARSAT Fine-Beam SAR data for land-cover mapping and change detection in the rural-urban fringe of the greater Toronto area, *Urban Remote Sensing Joint Event*, IEEE, ISBN: 1-4244-0712-5.

Dekker R.J., 2003. Texture analysis and classification of ERS SAR images for map updating of urban areas in The Netherlands, *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 41, No. 9.

eCognition User Guide 3. „Concepts and Methods”

Hall-Beyer M., 2000. GLCM Texture: A Tutorial.

<http://www.cas.sc.edu/geog/rslab/Rsc/mod6/6-5/texture/tutorial.html#practical>

Haralick R.M., Shanmugam K., Einstein I., 1979a. Textural features for image classification. *IEEE Transactions on system, man and cybernetics*, Vol. SMC-3, No. 6, s. 610-617

Haralick, R.M., 1979b. Statistical and Structural Approaches to Texture. *Proceedings of the IEEE*, 67:786-804

Materka A., Strzelecki M., 1998. *Texture Analysis Methods – A Review*, Technical University of Lodz, Institute of Electronics, COST B11 report, Brussels

Remote Sensing Data Fusion Contest, 2007: <http://tlclab.unipv.it/dftc/home.do>

Rudnicki Z., 2002. Wybrane metody przetwarzania i analizy cech obrazów teksturowych. *Informatyka w Technologii Materiałów*, Nr 1, Tom 2, s. 1-18.

Zheng Z., JiXian Z., GuoMan H., Rong-bin W., 2004. The textural analysis and interpretation of high resolution AIRSAR images, XXth ISPRS Congress, 12-23 July 2004 Istanbul, Turkey, Commission 2

Praca została wykonana w ramach badań statutowych AGH nr 11.11.150.459

INTEGRATION OF RADAR AND OPTICAL DATA FOR LAND COVER MAPPING

KEY WORDS: classification, data fusion, SAR, texture

SUMMARY: While analysing the advantages and drawbacks of data coming from different sensors , it can be observed that acquired data can be often incomplete or insufficient. Registration in difficult atmospheric conditions can be the limitation factor for optical data, whereas for the radar data it can be the insufficient resolution or occurring speckle effect. Taking into consideration all these factors, the integration of images from various sources and using them jointly seem to be very interesting. The benefits resulting from the integration of radar and optical images were checked for possible improvement of the results of classification of urban areas. The question is how radar images can improve the result of classification and whether they can be the alternative source in case of lack of optical images. The analysis of various techniques of classification was not the main concern, but the standard classification in supervised approach was used. The attention was also drawn to the object-based classification developing very dynamically recently, and attempt was made to compare the results of pixel and object-based classification. Due to the fact that, for the radar data, the most important source of information is the texture, that was the main focus of the work. . Consequently, the use of suitably selected textural features from co-occurrence matrix (Grey Level Co-occurrence Matrix – GLMC) caused the increase of accuracy of joint classification, as compared to classification of images from individual sensors.

mgr inż. Monika Badurska
e-mail: monika.badurska@gmail.com
telefon: (12) 6174485