

**OCENA MOŻLIWOŚCI WYKORZYSTANIA TEKSTURY W ROZPOZNANIU
PODSTAWOWYCH KLAS POKRYCIA TERENU NA ZDJĘCIACH
SATELITARNYCH RÓŻNEJ ROZDZIELCZOŚCI**

**EVALUATION OF USABILITY OF TEXTURE IN IDENTIFYING
BASIC LAND COVER CLASSES ON THE SATELLITE IMAGES
OF DIFFERENT RESOLUTIONS**

Stanisław Lewiński, Sebastian Aleksandrowicz

Centrum Badań Kosmicznych PAN, Zespół Obserwacji Ziemi

SŁOWA KLUCZOWE: klasyfikacja obiektowa, OBIA, tekstura

STRESZCZENIE: Podjęto próbę prześledzenia możliwości podziału treści zdjęcia, stosowanego w klasyfikacji obiektowej, na dwie podstawowe klasy związane z „niskimi” i „wysokimi” wartościami tekstury w funkcji różnej rozdzielczości zdjęć. Na podstawie kanału panchromatycznego zdjęcia KOMPSAT-2 o rozdzielczości 1 m przygotowano zestaw danych o rozdzielczości 1, 2, 4, 8, 16, 32 i 64 m. Następnie przetworzono je wybranymi funkcjami tekstury, które wykorzystywane są w toku klasyfikacji obiektowej: filtr Sobel, filtr Laplacian, suma filtrów Sigma, przekształcenie PanBF oraz funkcje Haralick’a: korelacja, homogeniczność i entropia. Na ich podstawie wykonano analizę rozróżnialności czterech podstawowych klas pokrycia terenu: tereny zabudowane, lasy, pola uprawne i woda. Dla każdej rozdzielczości i przekształcenia obliczono odległość Bhattacharya oraz odległość Jeffries-Matusita (J-M). Założono, że dwie klasy są dobrze rozróżnialne jeżeli wartość J-M jest większa od 1.7. Uzyskane wyniki w postaci odległości J-M przedstawione są w tabelach 1-7.

W przypadku wszystkich siedmiu przekształceń najlepsze wyniki rozróżnialności klas zaobserwowano na zdjęciach o największej rozdzielczości. Natomiast wyraźne pogorszenie rozróżnialności nastąpiło w przypadku zdjęć o rozdzielczości 8 m i mniejszej. Zdecydowanie najlepsze wyniki uzyskano na podstawie przekształceń wykonanych filtrem Laplacian, a następnie Sobel, Sigma oraz przekształceniem PanBF. W porównaniu z nimi przydatność funkcji Haralick’a do podziału treści zdjęcia na dwie klasy tekstury okazała się zdecydowanie mniejsza. Przedstawione wyniki znajdują praktyczne zastosowanie w pracach nad doбором odpowiednich algorytmów klasyfikacyjnych zdjęć satelitarnych o bardzo wysokiej, wysokiej a także średniej rozdzielczości.

1. WSTĘP

Tekstura jest jedną z podstawowych cech obrazów i odgrywa kluczową rolę w procesie interpretacji wizualnej zdjęć lotniczych i satelitarnych. W cyfrowym przetwarzaniu zdjęć satelitarnych wykorzystywane są różnorodne funkcje dedykowane teksturze. Działają one najczęściej na zasadzie filtrów wykonujących obliczenia w przesuwającym się oknie. Uzyskujemy obraz, którego wartości są uzależnione od charakteru i relacji przestrzennych występujących między zobrazowanymi obiektami. Zależnie od zastosowanych funkcji

wybrane cechy obrazu zostają uwydatnione w porównaniu z obrazem wejściowym. Podstawowymi miarami tekstury jest wariancja oraz entropia. Powszechnie wykorzystywane są również funkcje Haralick'a, (tekstura jest określana na podstawie symetrycznej znormalizowanej macierzy zdarzeń) oraz filtry dedykowane do wykrywania krawędzi (Haralick et al., 1973; Jensen i Toll, 1982; van der Sanden i Hoekman, 2005).

W klasyfikacjach zdjęć satelitarnych i lotniczych wykonywanych z zastosowaniem tradycyjnych algorytmów, opartych na analizie pojedynczych pikseli, informacja o teksturze jest wykorzystywana w postaci dodatkowej warstwy obrazowej (Gong et al., 1992; Mumby i Edwards, 2002). Odmianą sytuację mamy w przypadku klasyfikacji obiektowej, w której nie są analizowane pojedyncze piksele, lecz tzw. obiekty będące grupami pikseli spełniającymi ustalone warunki podobieństwa. Tekstura jest jedną z podstawowych cech rozpoznawczych, wykorzystywaną między innymi w klasyfikacji terenów zabudowanych (de Martino et al., 2003; Wang et al., 2003; Morale et al., 2003; Corcoran i Winstanley, 2008; Lewiński i Bochenek, 2008)

De Kok i Wężyk (2008) zaproponowali podział treści zdjęcia na obiekty charakteryzujące się „wysokimi” i „niskimi” wartościami tekstury. Do pierwszej grupy należą tereny zurbanizowane, wszystkie typy roślinności związanej z wysokimi drzewami oraz tereny bez pokrywy roślinnej nie wykorzystywane rolniczo. W skład drugiej grupy wchodzi głównie tereny rolnicze, łąki oraz wody. Wstępny podział na dwie klasy wykonywany jest na podstawie wysokorozdzielczych danych panchromatycznych i ma istotne znaczenie klasyfikacyjne (de Kok, 2010; Tiede et al., 2010). Taki sposób postępowania został zastosowany między innymi w algorytmie klasyfikacyjnym SATChMo-K2, który został opracowany w ramach projektu SATChMo/Geoland2 (Lewiński et al., 2010).


2. DANE SATELITARNE I TEREN BADAŃ

Prezentowane prace zostały wykonane na podstawie zdjęcia satelitarnego KOMPSAT-2 zarejestrowanego w dniu 10 września 2009. Zdjęcie KOMPSAT-2 składa się z czterech kanałów danych wielospektralnych (kanał niebieski: 0.45–0.52 μm , zielony: 0.52–0.60 μm , czerwony: 0.63–0.69 μm , bliska podczerwień: 0.76–0.90 μm) o rozdzielczości przestrzennej 4 m oraz kanału panchromatycznego (0.50–0.90 μm) o rozdzielczości 1 m. Wartości tekstury analizowane były na podstawie oryginalnych danych panchromatycznych oraz uzyskanych na ich podstawie obrazów o mniejszej rozdzielczości.

Na rysunku 1 przedstawiona jest kompozycja barwna zdjęcia KOMPSAT-2 terenu badań. Obejmuje on swoim zasięgiem tereny wokół miasta Miłosław w powiecie Września. Na powierzchni ponad 8000 ha dominującą formą pokrycia terenu są lasy i pola uprawne. Występuje również zabudowa o średnim stopniu zwarcia oraz stawy.

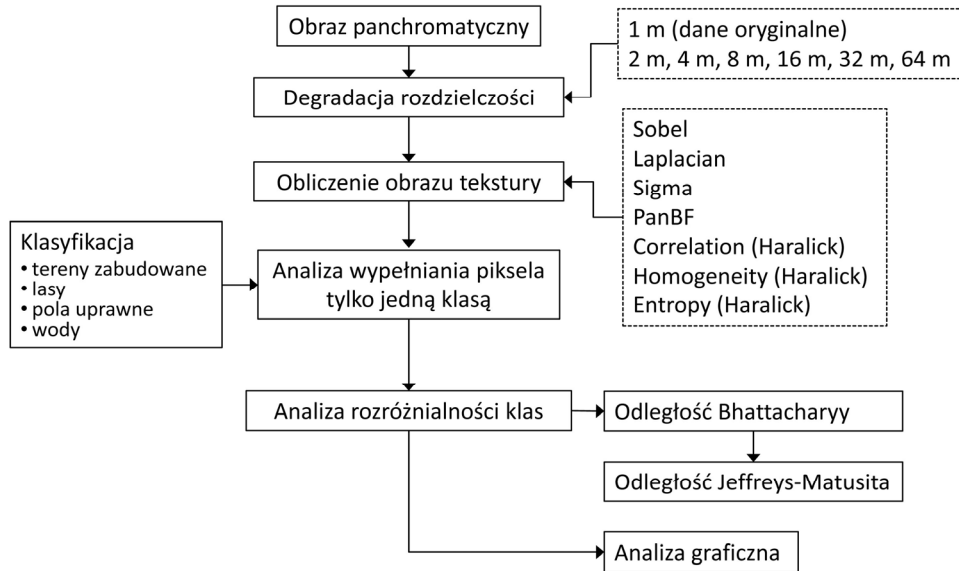
3. METODA POSTĘPOWANIA

Sposób postępowania przedstawiono na rysunku 2. Danymi wyjściowymi jest kanał panchromatyczny zdjęcia KOMPSAT-2 o rozdzielczości 1 m. Na jego podstawie, stosując funkcję „image degradation” oprogramowania ERDAS-IMAGINE, został utworzony zbiór obrazów o mniejszej rozdzielczości: 2, 4, 8, 16, 32 i 64 m.



Rys. 1. Teren badań, okolice miasta Miłosław (pow. Września). Zdjęcie KOMPSAT-2 oraz klasyfikacja z podziałem na cztery podstawowe klasy pokrycia terenu

Rozpoznanie możliwości podziału treści zdjęcia na „niską” i „wysoką” teksturę wykonano w środowisku oprogramowania klasyfikacji obiektowej eCognition, analizując różne metody uzyskania obrazu tekstury. Zastosowano cztery filtry krawędziowe: Sobel 3×3 , Laplacian 3×3 , Sigma oraz PanBF. Obraz tekstury Sigma jest sumą filtrów Lee-Sigma wykrywających krawędzie jasnych i ciemnych obiektów. Przekształcenie PanBF zaproponowane przez de Kok i Wężyk (2008) jest ilorzem danych panchromatycznych i tekstury Sigma. Analizy wykonano również dla trzech funkcji Haralick’a: korelacja, homogeniczność i entropia. W procesie segmentacji zastosowano podział treści zdjęcia na obiekty o wymiarach 128×128 m. Taki sposób postępowania pozwolił na ograniczenie wpływu segmentacji na uzyskiwane wyniki. Następnie wyselekcjonowano obiekty całkowicie wypełnione jedną z czterech klas: tereny zabudowane, lasy, wody oraz tereny rolnicze. W tym celu posłużono się wynikami klasyfikacji obiektowej wykonanej na podstawie zdjęcia KOMPSAT-2 z zastosowaniem algorytmu SATChMo-K2 (dokładność całkowita klasyfikacji fragmentu zdjęcia wyniosła 85%, dodatkowo przeprowadzono edycję ręczną segmentów wypełnionych całkowicie tylko jedną analizowaną klasą). Na rysunku 2 przedstawiono obraz klasyfikacyjny czterech analizowanych klas, wyświetlony na tle kompozycji barwnej. Zaznaczone są jedynie te obiekty, które są całkowicie wypełnione tylko jedną klasą pokrycia terenu.



Rys. 1. Schemat postępowania

Analiza rozróżnialności klas została wykonana z zastosowaniem odległości Bhattacharyy, która jest w teledetekcji powszechnie stosowaną miarą odległości spektralnej. Na jej podstawie obliczono odległość Jeffreys-Matusita (J-M), która została wykorzystana do określenia odseparowania od siebie poszczególnych klas pokrycia terenu (Jensen J.R., 1996).

4. WYNIKI

Uzyskane wyniki są przedstawione w tabelach: 1, 2, 3, 4, 5, 6 i 7. Dla poszczególnych rozdzielczości zdjęć podane są wartości odległości J-M między analizowanymi klasami. W praktyce klasyfikacyjnej przyjmujemy, że dwie klasy są od siebie całkowicie odseparowane, jeżeli uzyskana odległość J-M jest większa niż 1.8. W prezentowanym materiale przyjęto założenie, że rozdzielenie klas na podstawie tekstury jest możliwe, jeżeli wartość J-M jest większa od 1.70. Wartości spełniające ten warunek zostały wyróżnione.

Tab. 1. Rozróżnialność klas pokrycia terenu na podstawie tekstury: homogeniczność

Homogeniczność (Haralick)	odległość Jeffreys-Matusita						
	rozdzielczość zdjęcia						
Klasy pokrycia terenu	1 m	2 m	4 m	8 m	16 m	32 m	64 m
tereny rolnicze / lasy	1.50	1.55	1.64	1.51	0.71	0.01	0.03
las / zabudowa	1.20	1.13	0.95	0.31	0.06	0.31	0.33
zabudowa / wody	1.31	1.56	1.85	1.81	1.73	1.55	1.18
tereny rolnicze / zabudowa	0.48	0.61	0.73	1.13	0.87	0.39	0.19
las / wody	1.99	1.97	1.97	1.88	1.71	1.33	0.78
tereny rolnicze / wody	1.09	0.92	0.61	0.78	0.91	0.86	0.69
zabud. i las / ter.rol. i wody	1.38	1.44	1.51	1.34	0.77	0.08	0.01

Tab. 2. Rozróżnialność klas pokrycia terenu na podstawie tekstury: korelacja

Korelacja (Haralick)	odległość Jeffries-Matusita						
	rozdzielczość zdjęcia						
Klasy pokrycia terenu	1 m	2 m	4 m	8 m	16 m	32 m	64 m
tereny rolnicze / lasy	0.76	0.92	1.27	1.23	0.70	0.14	0.00
las / zabudowa	0.29	0.42	0.35	0.08	0.04	0.03	0.01
zabudowa / wody	1.11	1.00	0.33	1.47	1.25	0.32	0.03
tereny rolnicze / zabudowa	0.70	0.82	0.81	1.30	1.03	0.29	0.01
las / wody	0.81	0.62	0.50	1.38	0.92	0.19	0.05
tereny rolnicze / wody	0.54	0.58	0.96	1.64	1.02	0.15	0.00
zabud. i las / ter.rol. i wody	0.70	0.86	1.23	1.23	0.71	0.15	0.00

Tab. 3. Rozróżnialność klas pokrycia terenu na podstawie tekstury: entropia

Entropia (Haralick)	odległość Jeffries-Matusita						
	rozdzielczość zdjęcia						
Klasy pokrycia terenu	1 m	2 m	4 m	8 m	16 m	32 m	64 m
tereny rolnicze / lasy	1.87	1.83	1.57	0.77	0.09	0.03	0.04
las / zabudowa	0.43	0.24	0.21	0.91	1.09	0.56	0.23
zabudowa / wody	2.00	2.00	2.00	1.99	1.94	1.69	1.08
tereny rolnicze / zabudowa	1.70	1.72	1.19	1.60	1.28	0.39	0.10
las / wody	2.00	2.00	2.00	1.95	1.75	1.29	0.64
tereny rolnicze / wody	1.66	1.48	0.90	0.40	0.37	0.45	0.31
zabud. i las / ter.rol. i wody	1.83	1.78	1.48	0.76	0.15	0.01	0.02

Tab. 4. Rozróżnialność klas pokrycia terenu na podstawie tekstury: Sobel

Sobel	odległość Jeffries-Matusita						
	rozdzielczość zdjęcia						
Klasy pokrycia terenu	1 m	2 m	4 m	8 m	16 m	32 m	64 m
tereny rolnicze / lasy	1.93	1.83	1.23	0.22	0.03	0.20	0.19
las / zabudowa	0.42	0.63	0.62	1.27	0.61	0.22	0.03
zabudowa / wody	2.00	2.00	1.99	2.00	1.80	0.64	0.06
tereny rolnicze / zabudowa	1.99	2.00	1.80	1.78	0.40	0.08	0.20
las / wody	2.00	2.00	1.94	1.55	0.83	0.14	0.06
tereny rolnicze / wody	2.00	2.00	1.97	0.85	0.32	0.29	0.10
zabud. i las / ter.rol. i wody	1.92	1.82	1.22	0.25	0.02	0.18	0.19

Tab. 5. Rozróżnialność klas pokrycia terenu na podstawie tekstury: Pan_BF

Pan_BF	odległość Jeffries-Matusita						
	rozdzielczość zdjęcia						
Klasy pokrycia terenu	1 m	2 m	4 m	8 m	16 m	32 m	64 m
tereny rolnicze / lasy	1.91	1.83	1.72	1.30	0.33	0.00	0.02
las / zabudowa	0.27	0.19	0.97	0.58	0.51	0.42	0.12
zabudowa / wody	2.00	2.00	2.00	2.00	1.98	1.61	0.22
tereny rolnicze / zabudowa	1.83	1.75	0.97	1.61	0.99	0.36	0.05
las / wody	2.00	2.00	2.00	2.00	1.93	1.19	0.02
tereny rolnicze / wody	1.80	1.36	1.09	0.50	0.21	0.26	0.02
zabud. i las / ter.rol. i wody	1.90	1.81	1.60	1.27	0.39	0.01	0.02

Tab. 6. Rozróżnialność klas pokrycia terenu na podstawie tekstury: Sigma (suma filtrów Sigma)

Sigma	odległość Jeffries-Matusita						
	rozdzielczość zdjęcia						
Klasy pokrycia terenu	1 m	2 m	4 m	8 m	16 m	32 m	64 m
tereny rolnicze / lasy	1.93	1.92	1.81	1.10	0.20	0.01	0.22
las / zabudowa	0.40	0.44	0.33	1.25	1.14	0.52	0.35
zabudowa / wody	2.00	2.00	1.96	2.00	2.00	1.59	0.06
tereny rolnicze / zabudowa	1.95	1.97	1.69	1.99	1.66	0.39	0.02
las / wody	2.00	2.00	1.99	1.91	1.67	0.97	0.16
tereny rolnicze / wody	2.00	2.00	2.00	1.95	1.19	0.48	0.09
zabud. i las / ter.rol. i wody	1.92	1.91	1.79	1.09	0.24	0.01	0.18

Tab. 7. Rozróżnialność klas pokrycia terenu na podstawie tekstury: Laplacian

Laplacian	odległość Jeffries-Matusita						
	rozdzielczość zdjęcia						
Klasy pokrycia terenu	1 m	2 m	4 m	8 m	16 m	32 m	64 m
tereny rolnicze / lasy	1.93	1.93	1.85	1.22	0.29	0.01	0.20
las / zabudowa	0.39	0.39	0.59	1.15	1.22	0.66	0.53
zabudowa / wody	2.00	2.00	2.00	2.00	2.00	1.57	0.07
tereny rolnicze / zabudowa	1.95	1.97	1.99	1.99	1.78	0.58	0.14
las / wody	2.00	2.00	2.00	1.93	1.71	0.63	0.52
tereny rolnicze / wody	2.00	2.00	2.00	1.97	1.26	0.23	0.05
zabud. i las / ter.rol. i wody	1.92	1.92	1.84	1.21	0.33	0.00	0.15

Z punktu widzenia podziału treści zdjęcia na „niską” i „wysoką” teksturę istotną rolę odgrywają wyniki rozróżnialności klas połączonych, które są sumą terenów zabudowanych i lasów oraz terenów rolniczych i wody. Dla miar tekstury uzyskanych z zastosowaniem

funkcji Haralick (tabela 1, 2 i 3) zadowalające wyniki uzyskano jedynie w przypadku entropii. Na jej podstawie można uzyskać podział na „niską” i „wysoką” teksturę na zdjęciach o rozdzielczości 1 i 2 m. Dla zdjęć o mniejsze rozdzielczości wartości J-M są na dużo niższym, niezadowalającym, poziomie. Stosując filtr Sobel oraz przekształcenie PAN_BF uzyskujemy zdecydowanie lepsze wyniki jednakże, podobnie jak w przypadku funkcji Haralick, dotyczą one najwyższych rozdzielczości 1 i 2 m. Zdecydowanie najlepsze wyniki zostały uzyskane dla przekształceń Sigma oraz Laplacian. Stosując je uzyskano wysokie wartości J-M również dla zdjęć o rozdzielczości 4 m.

W tabelach przedstawiono również wyniki rozróżnialności między poszczególnymi analizowanymi klasami. Z punktu widzenia klasyfikacji istotne jest przede wszystkim odseparowanie terenów zabudowanych. Podobnie jak w przypadku klas połączonych wyniki uzyskane na podstawie funkcji Haralick nie są zadowalające. Zdecydowanie lepsze wyniki uzyskujemy dla pozostałych przekształceń. Stosując filtr Laplacian na podstawie tekstury można odseparować tereny zabudowane od rolniczych nawet w przypadku zdjęć o rozdzielczości 16m. Równocześnie należy zwrócić uwagę, że nie we wszystkich przypadkach można rozróżnić zabudowę od lasów. Potwierdza to, że obie te klasy należą do tzw. wysokiej tekstury.

5. PODSUMOWANIE

Celem przeprowadzonych badań było porównanie możliwości wykonania podziału treści zdjęcia satelitarnego na „niską” i „wysoką” teksturę z wykorzystaniem danych o różnej rozdzielczości i zastosowaniem różnych funkcji tekstury. Najlepsze wyniki uzyskano dla przekształcenia kanału panchromatycznego wykonanego z zastosowaniem filtra Laplacian. Dobre wyniki uzyskano również posługując się sumą filtrów Sigma. W obu przypadkach jest możliwe wykonanie podziału na „niską” i „wysoką” teksturę na podstawie danych o rozdzielczości 1, 2 i 4 m. W przypadku mniejszych rozdzielczości nie można uzyskać zadowalających wyników. Stosując filtr krawędziowy Sobel oraz przekształcenie PAN_BF zakres wykorzystania zostaje ograniczony jedynie do zdjęć o rozdzielczości 1 i 2 m. Funkcje Haralick okazały się najmniej przydatne. Oznacza to, że funkcje te nie powinny być wykorzystywane do podziału treści zdjęcia na dwie podstawowe klasy związane z wartościami tekstury.

Przedstawione wyniki potwierdzają znaną zależność, że wartości tekstury są związane z rozdzielczością przestrzenną zdjęcia. Równocześnie wykazują, że najlepsze wyniki uzyskano na podstawie zdjęć o rozdzielczości 1, 2 i 4 m. Oznacza to, że metodę klasyfikacji z podziałem treści zdjęcia na „niską” i „wysoką” teksturę można z powodzeniem stosować opracowując takie zdjęcia jak: GeoEye-1, WorldView-1, QuickBird, IKONOS, KOMPSAT-2, Cartosat-2, EROS-A i B, FORMOSAT-2, DMC-2 oraz zdjęcia o nieznacznie niższej rozdzielczości (5 m) rejestrowane skanerami RadidEye i SPOT.

W przypadku zdjęć o rozdzielczości 8 m i mniejszej, miary tekstury są skutecznym narzędziem klasyfikacyjnym jednak wykonanie podziału na „niską” i „wysoką” teksturę nie jest możliwe.

Przedstawione prace zostały wykonane w ramach projektu Geoland2 / SATChMo, który jest realizowany w Centrum Badań Kosmicznych PAN.

6. LITERATURA

- Corcoran P., A Winstanley A., 2008. Using texture to tackle the problem of scale in land-cover classification. *ObjectBased Image Analysis (2008)*, Publisher: Springer, Pages: 113–132.
- de Kok R., Wężyk P., 2008. Principles of full autonomy in image interpretation. The basic architectural design for a sequential process with image objects. In: *Object-Based Image Analysis*. Blaschke Th., Lang S., Hay G.J. (Eds). Series: *Lecture Notes in Geoinformation and Cartography*. Springer Berlin Heidelberg, ISSN: 1863-2246, pp. 697–710.
- de Kok R., 2010. An object based approach on the detection of landscape features in the Czech Republic. *Geomatics in support of the Common Agricultural Policy, Proceedings of the 16th GeoCAP Annual Conference, Bergamo 24th–26th Nov 2010*, p. 27–31.
- Gong P., Marceau D. J., Howarth P. J., 1992. A comparison of spatial feature extraction algorithms for land-use classification with SPOT HRV data. *Remote sensing of environment*, vol. 40, p. 137–151.
- Haralick R. M., Shanmugan K., Dinstein I., 1973. Textural Features for Image Classification. *IEEE Transactions on Systems, Man and Cybernetics*, Vol. SMC-3, No.6. pp. 610–621.
- Jensen J.R., 1996. *Introductory digital image processing, a remote sensing perspective*. Second edition. Prentice Hall, Upper Saddle River, New Jersey.
- Jensen J.R., Toll D.L., 1982. Detecting residential Land use development at the urban fringe. *Photogrammetric Engineering & remote Sensing*, vol. 48, p. 629–643.
- Lewiński St., Bochenek B., 2008. Rule-based classification of SPOT imagery using object-oriented approach for detailed land cover mapping. *Proceedings of the 28th EARSeL Symposium "Remote sensing for a changing Europe"*, Istanbul, Turkey, 2–5 June 2008, pp. 197–204.
- Lewiński St., Bochenek Z., Turlej K., 2010. Application of object-oriented method for classification of VHR satellite images using rule-based approach and texture measures. *Geoinformation Issues*, Vol. 2, No 1 (2).
- De Martino, M.; Causa, F.; Serpico, S.B., 2003. Classification of optical high resolution images in urban environment using spectral and textural information. *Geoscience and Remote Sensing Symposium, 2003. IGARSS '03. Proceedings. 2003 IEEE International*, vol. 6.
- Morales, D.I. Moctezuma, M. Parmiggiani, F., 2003. Urban and non urban area classification by texture characteristics and data fusion. *Geoscience and Remote Sensing Symposium, 2003. IGARSS '03. Proceedings. 2003 IEEE International*, vol. 6.
- Mumby P. J., Edwards A. J., 2002. Mapping marine environments with IKONOS imagery: enhanced spatial resolution can deliver greater thematic accuracy, *Remote Sensing of Environment*, vol. 82, p. 248–257.
- van der Sander J.J., Hoekman D.H., 2005. Review of relationships between gray-tone co-occurrence, semivariance, and autocorrelation based image texture analysis approaches. *Canadian Journal of Remote Sensing*, vol.31, No. 3, pp. 207–213.
- Tiede D., Lang S., Hölbling D., Füreder P., 2010. Transferability of OBIA rule sets for IDP camp analysis in Darfur. Ed. E.A. Addink and F.M.B. Van Coillie, *GEOBIA 2010, Geographic Object-Based Image Analysis*, Ghent, Belgium, 29 June – 2 July.
- Wang Y. W., Wang Y. F., Xue Y., Gao W., 2003. A new algorithm for remotely sensed image texture classification and segmentation. *Geoscience and Remote Sensing Symposium, 2003. IGARSS '03. Proceedings. 2003 IEEE International*, vol. 6.

**EVALUATION OF USABILITY OF TEXTURE IN IDENTIFYING
BASIC LAND COVER CLASSES ON THE SATELLITE IMAGES
OF DIFFERENT RESOLUTIONS**

KEY WORDS: object-oriented classification, OBIA, texture

SUMMARY: An attempt was made to trace the possibility of division of the content of satellite images into two basic classes associated with the "low" and "high" values of the texture. This classification approach is applied during object-oriented classification and results are dependent on spatial resolution. On the basis of panchromatic channel of KOMPSAT-2 image of 1m resolution a data set with a resolution of 1, 2, 4, 8, 16, 32 and 64 m were prepared. Then images were processed using selected texture functions: Sobel, Laplacian and Sigma filters, transformation PanBF as well as Haralick functions: correlation, homogeneity and entropy. On the basis of texture images an analysis of discrimination of four basic land cover classes has been done: built-up areas, forests, agriculture areas and water. These classes were selected because built-up areas and forest belong to "high" texture and remaining two are usually represented by "low" values of texture. For each texture image form using different functions and spatial resolution, Bhattacharya distance and next Jeffries-Matusita (J-M) distance between land cover classes were calculated. Results are presented in tables 1, 2, 3, 4, 5, 6 and 7. They also include J-M distance between "low" and "high" texture. It was assumed that two classes are well separated if the value of J-M distance is over 1.7.

In the case of all seven texture transformations the best results of class discrimination were observed for images with the highest resolution. Distinct deterioration of discrimination between "low" and "high" texture took place in the case of images with a resolution of 8 m or less. By far the highest J-M values were obtained on the basis of Laplacian filter and next using Sigma filter, PanBF and the Sobel filter. In comparison usefulness of the Haralick function has proved much less. The presented results could be practically applied in the work on classification algorithms of very high, high and medium resolution satellite images.

Dr hab. inż. Stanisław Lewiński
e-mail: stlewinski@cbk.waw.pl
telefon: +48 22 4966286
fax: +48 22 840 31 31

Mgr inż. Sebastian Aleksandrowicz
e-mail: saleksandrowicz@cbk.waw.pl
telefon: +48 22 49 66 388
fax: +48 22 840 31 31