

JAROSŁAW ZAWADZKI, CHRIS J. CIESZEWSKI, MICHAŁ ZASADA

Wykorzystanie metod geostatystycznych do klasyfikacji ekosystemów leśnych przy użyciu technik satelitarnych

Use of geostatistical methods for classification of forest ecosystems using satellite imagery

ABSTRACT

The role of textural information can be essential when analyzing remote images of forest ecosystems. Geostatistically based methods that use textural information are widely used in image processing. The role of geostatistical methods in analyzing remote sensing images of forest areas increased rapidly during the last several years following advancements in high-resolution remote-sensor technology. The results of numerous applications of geostatistical methods for processing remotely sensed forest images are very encouraging. This paper summarizes the geostatistical methods for remote sensing classification of forest ecosystems.

KEY WORDS

remote sensing, textural classification, geostatistics, spatial information, semivariance, semivariogram

Wstęp

Lasy pokrywają prawie 40% powierzchni lądów [Westoby 1989] i są jednym z najważniejszych ekosystemów na Ziemi. Z powodu dużego znaczenia ekonomicznego i ekologicznego lasy podlegają nieustannemu monitorowaniu. Pomiaru terenowe są najdokładniejszym sposobem zbierania szczegółowych informacji na temat cech i stanu lasów, są one jednak często bardzo kosztowne i czasochłonne, zwłaszcza w przypadku wykorzystywania ich w dużej skali. Obserwacje satelitarne stanowią skuteczną i tanią alternatywną metodę analizowania lasów w krótkim czasie na dużych obszarach [Ciołkosz i Kęsik 1989; Campbell 1994; Wynne i in. 2000], stosowaną coraz częściej również w polskim leśnictwie [Mozgawa i in. 1994; Popławski i Zawila-Niedźwiecki 1995; Mozgawa 2000]. Zaawansowana analiza zdjęć satelitarnych pozwala wyznaczyć parametry biofizyczne lasu takie jak powierzchnia projekcyjna aparatu asymilacyjnego (leaf area index, LAI), produkcja pierwotna, pierścicowe pole przekroju, biomasa czy miąższość

[Wilson 1995; Wulder 1998; Wulder i in. 1996, 1999, 2000; Holmgren i in. 2000]. Dodatkową zaletą danych pochodzących z obserwacji satelitarnych jest łatwość ich przetwarzania za pomocą różnorodnych narzędzi informatycznych (systemy informacji geograficznej, bazy danych,

JAROSŁAW ZAWADZKI

Zakład Metod Matematycznych
Instytut Systemów Inżynierii Środowiska PW
ul. Nowowiejska 20
00-661 Warszawa
jarek97@yahoo.com

CHRIS J. CIESZEWSKI

D.B. Warnell School of Forest Resources
University of Georgia
Athens, GA 30602 USA
biomat@uga.edu

MICHAŁ ZASADA

Samodzielny Zakład Dendrometrii i Nauki
o Produkcyjności Lasu, Wydział Leśny SGGW
ul. Nowoursynowska 159
02-787 Warszawa
zasada@delta.sggw.waw.pl

programy do obróbki obrazów, programy statystyczne, itp.). Wymienione atuty powodują, że obserwacje satelitarne są najbardziej odpowiednie do inwentaryzacji wielkoobszarowych.

Istotnym ograniczeniem badań obszarów zalesionych dokonywanych za pomocą technik satelitarnych jest stała przestrzenna zdolność rozdzielcza czujników satelitarnych powodująca, że obrazy pochodzące z danego satelity są odpowiednie tylko do konkretnego rodzaju analiz, na przykład do inwentaryzacji wielkoobszarowej. Tymczasem struktura przestrzenna lasów wykazuje wiele skal zmienności, związanych ze specyficznymi obiektami występującymi w tych lasach, takimi jak pojedyncze drzewa, grupy drzew lub innej roślinności, drzewostany, itd.

Uzyskanie coraz bardziej szczegółowych informacji na temat badanych ekosystemów leśnych wymaga stosowania coraz większych zdolności rozdzielczych. Obserwacje lotnicze, które mogą być wykonywane z praktycznie dowolną zdolnością rozdzielczą, są niestety bardzo drogie. W ostatnim pięcioleciu dostępne stały się również wysokorozdzielcze sondy satelitarne, jak również sondy satelitarne ze zmienną zdolnością rozdzielczą [Abiodun 1998; Aplin i in. 1999a, 1999b; Atkinson i Tate 1999]. Jednakże wysoka cena zdjęć uzyskanych za pomocą tych sond oraz koszt obróbki tych zdjęć powodują, że nie są one dotychczas powszechnie stosowane. Tym niemniej należy oczekiwać, że wysoko- i zmiennorozdzielcze techniki satelitarne w nieodległej przyszłości wydatnie zwiększą rolę obserwacji satelitarnych w badaniach lasów.

Analiza zdjęć satelitarnych obszarów zalesionych oparta jest zarówno na ich własnościach spektralnych jak i teksturalnych. Wykorzystanie informacji spektralnej zawartej w zdjęciach satelitarnych w postaci wartości jasności spektralnej pikseli tworzących te zdjęcia stanowiło do niedawna główną technikę analizy. Z powodu stosunkowo niskiej zdolności rozdzielczej sond satelitarnych informacja przestrzenna traktowana była do tej pory jako mniej istotna. Jednakże jasność spektralna poszczególnych pikseli nie jest niezależna od jasności pikseli sąsiednich. Wprost przeciwnie: najczęściej istnieje między nimi bardzo wyraźna korelacja, która może być precyzyjnie wyznaczona, a następnie wykorzystana np. w procedurach klasyfikacyjnych.

Klasyfikacja zdjęć satelitarnych (zwana niekiedy segmentacją) jest procesem łączenia pikseli w skończoną liczbę klas lub kategorii na podstawie ich właściwości. Jeżeli piksel spełnia pewien zbiór warunków, jest on przypisany do klasy pikseli, która odpowiada tym warunkom (ERDAS Field Guide 1990). Uwzględnienie informacji przestrzennej pozwala na znacznie bardziej precyzyjną analizę zdjęć satelitarnych. Z tego właśnie powodu współcześnie obserwuje się gwałtownie rosnące zainteresowanie badaniami korelacji przestrzennych w analizie obrazów satelitarnych obszarów leśnych. Informacja przestrzenna staje się niezwykle cenna zwłaszcza w przypadku, gdy spektralne charakterystyki poszczególnych grup pikseli reprezentujących różne drzewostany są bardzo zbliżone. Podobna sytuacja istnieje również w przypadku, kiedy piksele przedstawiające poszczególne drzewostany wykazują bardzo dużą zmienność jasności spektralnej.

W celu efektywnego wykorzystania informacji przestrzennej istniejącej w zdjęciach satelitarnych rozwinięto wiele różnorodnych technik analitycznych. Szczególne miejsce pomiędzy nimi zajmują metody geostatystyczne. Podstawy i przykład zastosowań metod geostatystycznych w satelitarnych badaniach lasu zostały zaprezentowane w artykule Zawadzkiego i in. [2003]. Niniejszy artykuł stanowi kontynuację wspomnianej pracy i prezentuje zagadnienie wykorzystania metod geostatystycznych do klasyfikacji obszarów leśnych przy użyciu technik satelitarnych. Z uwagi na rozległość zagadnienia, autorzy nie wnikali w złożone aspekty teoretyczne metod geostatystycznych koncentrując się raczej na prezentacji ważniejszych osiągnięć w opisywanej dziedzinie. Ułatwi to czytelnikowi uzyskanie rozległej wiedzy na temat zastosowania metod geostatystycznych do klasyfikacji lasów, którą można szczegółowo pogłębić studiując cytowaną literaturę.

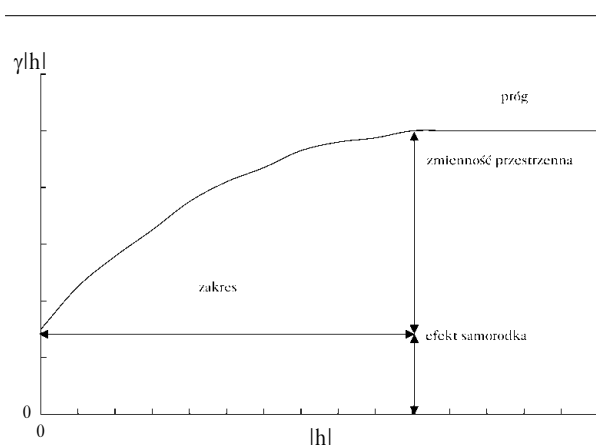
Zastosowanie semiwariancji do interpretacji zdjęć satelitarnych obszarów leśnych

Badania ciągłości przestrzennej wykonuje się najczęściej wykorzystując podstawową miarę geostatystyczną – semiwariancję, której wykres nosi nazwę semiwariogramu oraz semiwariancję wzajemną (krzyżową), której wykres nazywa się semiwariogramem wzajemnym (krzyżowym). Najczęściej obserwowanymi odmianami semiwariancji występujących na obrazach satelitarnych obszarów leśnych to semiwariancja klasyczna, której wykres (wariogram, semiwariogram) przedstawiony jest na rycinie 1. Semiwariancja jest również powiązana z innymi miarami ciągłości przestrzennej, jak funkcja kowariancji lub funkcja korelacji zwana korelogramem [Deutch i Journel 1998]. Miary te zostały szczegółowo opisane od strony teoretycznej w literaturze [Isaaks i Srivastava 1989; Deutch i Journel 1998; Zawadzki i in. 2003].

Obrazy satelitarne mogą być źródłem danych do wykonania obliczeń geostatystycznych miar ciągłości przestrzennej. Miary te obliczane są wówczas z wykorzystaniem wartości jasności spektralnych pikseli jako zmiennych. Często obliczenia semiwariancji wykonuje się również na podstawie tzw. wskaźników wegetacyjnych, takich jak np. znormalizowany wskaźnik wegetacyjny NDVI [Tucker 1986; Rouse 1973; De Fries 1994; Eldvige i Chen 1995], skorygowany wskaźnik wegetacyjny NDVIc [Nemani i in. 1993] czy stosunek współczynników odbicia dla pasma średniej podczerwieni i widzialnego pasma czerwonego [Jordan 1969].

ZWIĄZEK PARAMETRÓW SEMIWARIANCJI KLASYCZNEJ Z WŁASNOŚCIAMI LASÓW. Poszczególne charakterystyki semiwariogramów obrazów satelitarnych obszarów leśnych mają swoją określoną interpretację oraz potencjalne zastosowanie.

- a) Zakres oddziaływania wskazuje na odległość, powyżej której wartości jasności spektralnej pikseli nie są skorelowane przestrzennie. Parametr ten określa więc odległość wokół wybranego punktu, na jakiej interpolacja wykorzystująca informację przestrzenną (np. kriging) może być efektywnie wykonywana. Z tego względu odległość równa zakresowi



Ryc. 1.

Semiwariancja klasyczna
A classic semivariance

Oznaczenia: lhl – długość wektora separacji; $\gamma|hl$ – wartość semiwariancji dla danej odległości

Notation: lhl – lag vector; $\gamma|hl$ – semivariance value for a given distance


może stanowić naturalną jednostkę odległości w badanym ekosystemie. Zakres wskazuje również na optymalną zdolność rozdzielczą sondy satelitarnej, właściwą do obserwacji obiektów występujących na zdjęciu [Curran 1990, 1998; Woodcock i in. 1988a, 1988b]. W celu ustalenia optymalnej rozdzielczości sondy satelitarnej, zakres zmienności na badanym obszarze leśnym wyznacza się na drodze pomiarów naziemnych lub lotniczych [Atkinson 1993, 1997]. Ponadto zakres określa optymalny wymiar ruchomego okna służącego do wyznaczania miar statystycznych charakteryzują-

cych teksturę badanego zdjęcia satelitarnego [Treitz i Howarth 2000]. Miary statystyczne obliczone metodą ruchomego okna mogą być następnie zastosowane do klasyfikacji (segmentacji) zdjęcia satelitarnego lub jego obróbki graficznej. Zakres jest związany z wielkością występujących na zdjęciu największych obiektów, wykazujących korelacje przestrzenne [Jupp i in. 1988, 1989].

- b) Próg stanowi miarę zmienności jasności spektralnej tych pikseli, między którymi nie występuje korelacja przestrzenna. Jasność spektralna pikseli zależy od intensywności odbitej fali elektromagnetycznej rejestrowanej przez czujniki satelity. Dlatego też wartość progu nie opisuje wyłącznie własności badanego lasu, ale raczej złożony proces oddziaływania fali elektromagnetycznej ze środowiskiem leśnym. Wartości progu semiwariogramu obliczanego z obrazów satelitarnych zależą silnie od długości fali elektromagnetycznej stosowanej do obserwacji. Na przykład obserwacje lasów sosnowych prowadzone przez satelitę Landsat TM w paśmie promieniowania widzialnego (pasmo czerwone: 0,63-0,69 μm) prowadzą do innych wartości progu, niż obserwacje w pasmach promieniowania podczerwonego (pasmo bliskiej podczerwieni: 0,76-0,90 μm lub pasmo średniej podczerwieni: 1,55-1,75 μm). Wynika to z różnego stopnia pochłaniania i odbijania promieniowania widzialnego i podczerwonego przez korony drzew [Curran 1988].
- c) Efekt samorodka reprezentuje zmienność niezależną od odległości, która wynika z błędów pomiarowych oraz zmienności na niewielkich odległościach [Journel i Huibregts 1978]. W przypadku obserwacji satelitarnych wiąże się on z faktem, że pojedynczy pomiar, odpowiadający jednemu pikselowi, nie jest punktowy, lecz obejmuje określony obszar powierzchni lasu. W związku z tym efekt samorodka rośnie wraz ze zmniejszaniem się przestrzennej zdolności rozdzielczej sondy satelitarnej. Zbyt duży efekt samorodka może więc wskazywać na konieczność zwiększenia zdolności rozdzielczej sondy satelitarnej użytej do rozwiązywania danego problemu.

Podstawowe (klasyczne) formy semiwariancji mogą również występować w różnych odmianach [Curran 1988]. Jedną z najważniejszych odmian semiwariancji klasycznej jest forma periodyczna. W przypadku niskorozdzielczych technik satelitarnych (przestrzenna zdolność rozdzielcza 20-30 m) semiwariancje periodyczne obserwuje się, gdy na zdjęciu satelitarnym istnieją powtarzające się wzory pochodzące na przykład od regularnie powtarzających się drzewostanów czy regularnie rozłożonych pól uprawnych, pastwisk, grup drzew, itd. Przykładową semiwariancję periodyczną przedstawiono na rycinie 2. W przypadku wysokorozdzielczych technik satelitarnych periodyczny charakter semiwariancji jest najczęściej rezultatem obserwacji koron pojedynczych drzew, tworzących strukturę okresową [Bruniquel-Pinel, Gastellu-Etchegorry 1998]. Wariogramy klasyczne lub ich odmiany mogą być modelowane przy użyciu kilku tzw. modeli podstawowych zwanych czasami „strukturami zagnieżdżonymi” (nested structures) [Zawadzki i in. 2003].

Ważną klasę semiwariancji otrzymywanych często na podstawie zdjęć satelitarnych lasów są semiwariancje nie posiadające wyraźnej struktury przestrzennej. Takie „nieklasyczne” semiwariancje są bardzo trudne do modelowania, szczególnie w przypadku posługiwania się techniką ruchomego okna w celach segmentacji zdjęcia satelitarnego. Tym niemniej nawet semiwariancje nie wykazujące wyraźnej struktury przestrzennej mogą dostarczyć wiele istotnych informacji wykorzystywanych następnie w procedurach klasyfikacyjnych. Częściowy lub zupełny brak struktury przestrzennej może mieć kilka przyczyn. Do najczęściej spotykanych należy fakt niewystępowania korelacji przestrzennych (ryc. 3). Inną przyczyną może być występowanie dodatkowych




Ryc. 2.

Semiwariancja periodyczna
A periodic semivariance

Oznaczenia: $h|l$ – długość wektora separacji; $\gamma|l|$ – wartość semiwariancji dla danej odległości

Notation: $h|l$ – lag vector; $\gamma|l|$ – semivariance value for a given distance

Strahler i in. 1986]. W takich przypadkach obliczanie miar ciągłości przestrzennej z „surowych” danych jest często niewłaściwe, a wariogramy wykazują charakterystyczny paraboliczny wzrost dla dużych wartości modułu wektora separacji h ($\gamma \approx Ah^2 + Bh + C$ dla dużych h , ryc. 4). Przed wyliczeniem tych miar należy usunąć trend z badanego zbioru danych. Jest to zadanie najczęściej bardzo skomplikowane, a niekiedy niewykonalne. Często niewłaściwe usunięcie trendu, wykonywane na przykład automatycznie w niektórych programach, powoduje większe błędy w obliczeniach semiwariancji, niż obliczenia wykonywane na podstawie danych wyjściowych. Szczegóły metod usuwania trendu można znaleźć w cytowanych już pracach. Należy jednak podkreślić, że w związku



Ryc. 3.

Semiwariancja z dominującym efektem samorodka
Pure nugget effect


Oznaczenia: $h|l$ – długość wektora separacji; $\gamma|l|$ – wartość semiwariancji dla danej odległości.

Notation: $h|l$ – lag vector; $\gamma|l|$ – semivariance value for a given distance

zjawisk wpływających na jasność spektralną pikseli zdjęcia satelitarnego, które nie są związane z właściwościami lasu. Przykładem takich zjawisk może być nierównomierne oświetlenie obszarów leśnych przez Słońce, co spowodowane jest występowaniem na przykład nierówności terenu, mgieł lub chmur, prędkością wiatru, kątem obserwacji badanego terenu, dzienną zmianą położenia Słońca nad horyzontem, itp. [Granberg 1987; Guyot 1989]. Wiąże się to często również z występowaniem trendu w zbiorze danych [Journel, 1978, 1986; Isaaks i Srivastava 1985; Webster i Olivier 1990;

tym, że usuwanie trendu ze zdjęć satelitarnych jest najczęściej bardzo pracochłonne, a rezultaty tej operacji są niepewne, intensywnie rozwijane są ostatnio metody klasyfikacji wielkoobszarowej, które nie wymagają usuwania trendu.

Bardzo ważną przyczyną występowania nieklasycznych form semiwariancji jest wyjątkowa złożoność ekosystemów leśnych, w których występuje często jednocześnie wiele różnorodnych korelacji przestrzennych o różnym zasięgu i intensywności, trudnych do jednoznacznego wyodrębnienia, a zatem i do modelowania. Semiwariancje zatem



Ryc. 4.


Semiwariancja z trendem

An unbounded semivariance

Oznaczenia: lhl – długość wektora separacji; $\gamma|lhl$ – wartość semiwariancji dla danej odległości.Notation: lhl – lag vector; $\gamma|lhl$ – semivariance value for a given distance

lacji przestrzennej dla małych odległości. Liniowy wzrost semiwariancji dla większych odległości oraz brak nasycenia wynika z wolno zanikających, słabych korelacji występujących na większych odległościach.

Warto zaznaczyć również, że pewne cechy wariogramów, które najczęściej są niepożądane, można wykorzystać do badania lasów i ich klasyfikacji wielkoobszarowych. Jako przykład może służyć tzw. efekt krawędzi, polegający na niestabilnym zachowaniu się semiwariogramów dla odpowiednio dużego modułu wektora separacji lhl [Ryc. 6; Cressie 1993]. Efekt ten wynika z gwałtownego zmniejszenia liczby par punktów używanych do obliczenia wariogramu, gdy odległość między tymi parami zaczyna przekraczać połowę długości lub szerokości obszaru na



Ryc. 5.

Semiwariancja z wieloma skalami korelacji


A semivariance with multiple correlation scales

Oznaczenia: lhl – długość wektora separacji; $\gamma|lhl$ – wartość semiwariancji dla danej odległości.Notation: lhl – lag vector; $\gamma|lhl$ – semivariance value for a given distance

zależą silnie od zdolności rozdzielczej stosowanej sondy satelitarnej. Problem ten był wielokrotnie dyskutowany w literaturze [Atkinson 1993; Jupp 1988, 1989]. Wynika to m.in. z tzw. efektu skali, który polega na tym, że z tych samych danych można uzyskać inną informację w zależności od stosowanej zdolności rozdzielczej sondy satelitarnej (Marceau i in. 1994 a, b). Nałożenie się różnorodnych korelacji przestrzennych prowadzi bardzo często do charakterystycznej formy wariogramu przedstawionej na rycinie 5. Początkowy szybki wzrost semiwariancji tego typu wynika z szybkiego spadku korelacji

którym badamy korelacje przestrzenne (na przykład badanego drzewostanu). Na podstawie efektu krawędzi można wyznaczyć wielkość obszaru o podobnych właściwościach przestrzennych (wielkość różnego typu drzewostanów).

Jak już wspomniano, zdolność rozdzielcza sondy satelitarnej jest podstawowym parametrem, który należy wziąć pod uwagę, gdy wykonuje się analizę geostatystyczną zdjęcia satelitarne. Uważa się [Strahler 1986], że przypadek niskich zdolności rozdzielczych zachodzi wówczas, gdy zdolność rozdziel-



Ryc. 6.

Efekt krawędzi

Edge effect

Oznaczenia: lhl – długość wektora separacji; γ_{lhl} – wartość semiwariancji dla danej odległości.Notation: lhl – lag vector; γ_{lhl} – semivariance value for a given distance

dy Landsat obszarów leżących w USA można nabyć w amerykańskim EROS Data Center w cenie 425 USD za scenę o wymiarach 180×180 kilometrów z rozdzielczością przestrzenną 30 metrów dla pasm widzialnych).

Wymienione sondy są tradycyjnie wykorzystywane do badań oraz wykonywania map różnorodnych ekosystemów roślinnych przy wykorzystaniu informacji spektralnej obecnej w zdjęciach satelitarnych. Metody klasyfikacji na podstawie niskorozdzielczej informacji spektralnej są wystarczająco dobre w celu klasyfikacji roślinności posiadającej wyraźne różne charakterystyki spektralne. Na przykład stosunkowo dobrze opracowano metody klasyfikacji pozwalające wykonywać za pomocą sond niskorozdzielczych wielkoobszarowe inwentaryzacje w których wyodrębnia się lasy liściaste, lasy iglaste, wody, pola uprawne oraz tereny zabudowane [Curran 1988]. Stosowanie metod geostatystycznych w przypadku niskorozdzielczych technik satelitarnych pozwala na zwiększenie dokładności klasyfikacji przez uwzględnienie korelacji przestrzennych pomiędzy pikselami.

Wysokorozdzielcze sondy satelitarne dokonują obserwacji z przestrzenną zdolnością rozdzielczą około 1 m w przypadku sond monochromatycznych (pracujących w jednym paśmie) oraz około 3 m w przypadku sond multispektralnych (pracujących w kilku pasmach). Za przykład służyć tu mogą takie sondy, jak QuickBird, OrbView czy EROS [Alpin i in. 1997; Fritz 1996]. Jednakże wysokorozdzielcze zdjęcia satelitarne są ciągle bardzo drogie, a ich przetwarzanie cyfrowe jest bardzo kosztowne i czasochłonne. Z drugiej strony wysokorozdzielcze dane dostarczają bardzo precyzyjnej informacji na temat właściwości lasu na małych obszarach. Wysokorozdzielcze sondy satelitarne pozwalają zaobserwować oddzielne drzewa oraz odróżnić wiele gatunków drzew i krzewów występujących w lasach. Niewątpliwie w najbliższej przyszłości wysokorozdzielcze sondy satelitarne będą odgrywać znaczącą rolę w klasyfikacji wielkoobszarowej lasów. Jednakże stosowanie takich sond wymaga również zmiany metod obróbki cyfrowej zdjęć satelitarnych m.in. przez szersze niż dotąd wykorzystanie informacji przestrzennej.

W literaturze znaleźć można wiele metod statystycznych wykorzystujących informację przestrzenną w celach klasyfikacji obrazów satelitarnych. Można je podzielić na 3 różne kate-

cza sondy satelitarnej jest mniejsza niż wymiary najczęściej występujących obiektów na zdjęciu satelitarnym, zaś przypadek wysokiej zdolności rozdzielczej ma miejsce wtedy, gdy zdolność ta jest większa, niż wymiary najczęściej występujących obiektów na zdjęciu satelitarnym.

Niskorozdzielcze techniki satelitarne są najbardziej odpowiednie dla klasyfikacji wielkoobszarowych. Amerykańskie sondy Landsat oraz francuskie sondy Spot ciągle dostarczają większość danych satelitarnych i są stosunkowo łatwo dostępne ze względu na niską cenę (na przykład zdjęcie satelitarne sondy

gorie, które zostaną opisane poniżej. Z powodu ograniczonej objętości artykułu autorzy skoncentrowali się głównie na omówieniu geostatystycznych metod klasyfikacji. Pozostałe metody zostały tylko krótko naszkicowane; zainteresowany Czytelnik może wykorzystać natomiast liczne odnośniki literaturowe zamieszczone w tych paragrafach.

METODY KLASYFIKACJI WYKORZYSTUJĄCE INFORMACJĘ PRZESTRZENNĄ W SPOSÓB POŚREDNI. Większość popularnych metod tej kategorii polega na dodaniu pewnej statystycznej informacji w postaci nowej warstwy zdjęcia satelitarne. Dodatkowe warstwy zawierają informację statystyczną, która jest uzyskiwana na podstawie analizy pasm radiometrycznych przez zastosowanie odpowiednich filtrów statystycznych. Najbardziej rozpowszechnione są filtry oparte na obliczeniach średniej arytmetycznej, mediany oraz wariancji jasności spektralnej pikseli metodą ruchomego okna. Wielkość ruchomego okna ma najczęściej wymiar kilku lub kilkunastu pikseli. Wyliczone w ten sposób wielkości statystyczne stają się dodatkowymi charakterystykami wszystkich pikseli tworzących zdjęcie satelitarne, mogą więc być wykorzystane w celu klasyfikacji tych pikseli [Arai 1993; Chen i in. 1997; Woodcock i Harvard 1992]. W metodach tych informacja przestrzenna nie jest wykorzystywana bezpośrednio.

METODY KLASYFIKACJI DROGĄ ANALIZY KORELACJI PRZESTRZENNYCH NIE WYKORZYSTUJĄCE GEOSTATYSTYCZNYCH MIAR CIĄGŁOŚCI PRZESTRZENNYCH. Istnieje wiele metod analizy korelacji przestrzennych, które nie wykorzystują bezpośrednio geostatystycznych miar ciągłości przestrzennej. Na przykład Labovitz i Masouka [1984] wykorzystali do klasyfikacji autokorelacje przestrzenne obliczane tradycyjną metodą ruchomego okna. Goodchild [1986] badał korelacje przestrzenne wykorzystując statystyki Moran'a oraz Geary'ego. Anselin [1995] rozwinął w tym celu technikę lokalnego wskaźnika zależności przestrzennej (local indicator of spatial association technique – LISA). Hay i in. [1996] wprowadzili nową technikę analizy tekstury zdjęć satelitarnych, zwaną metodą trójkątnego prymitywnego sąsiedztwa (triangulated primitive neighborhood method – TPN). Metodę tą zastosowano na przykład do badań przestrzennych właściwości wysokorozdzielczych zdjęć lotniczych obrazów leśnych uzyskanych z CASI (Compact Airborne Spectrographic Imager).

METODY KLASYFIKACJI OPARTE NA ANALIZIE GEOSTATYSTYCZNYCH MIAR CIĄGŁOŚCI PRZESTRZENNYCH. Geostatystyczne metody klasyfikacji obszarów leśnych na podstawie zdjęć satelitarnych można podzielić się na dwie grupy:

1. Metody wykorzystujące technikę ruchomego okna w celu wyznaczenia geostatystycznych miar ciągłości.
2. Metody nie wykorzystujące techniki ruchomego okna.

Metody wykorzystujące technikę ruchomego okna w celu wyznaczenia geostatystycznych miar ciągłości. Wybór rozmiaru ruchomego okna jest sprawą zasadniczą dla obliczeń miar zmienności przestrzennej. W większości przypadków, ze względu na szybkość obliczeń, używane jest kwadratowe ruchome okno o stałej wielkości. W tym przypadku obliczenia są najszybsze, lecz nie zawsze precyzyjne. Ruchome okno nie powinno być ani zbyt małe, ani zbyt duże. Zbyt duże okno zawiera wiele pikseli należących do różnych klas, co utrudnia proces klasyfikacji. Ponadto okno takie (przesuwane piksel po pikselu) powoduje, że gwałtownie rośnie czas obliczeń. Zbyt małe ruchome okno nie zawiera odpowiednio dużej liczby pikseli, które pozwalałyby na wiarygodne obliczenie, a następnie ewentualne wymodelowanie semiwariancji. Najczęściej wymiary ruchomego okna są ustalane drogą prób podczas fazy treningu [Miranda i in. 1992; Miranda i Carr 1994; Miranda i in. 1996; Chica-Olmo i Abarca-Hernandez 2000]. Najdokładniejsze rezultaty podczas klasyfikacji są osiągnięte przy użyciu ruchomego okna, którego rozmiary

44 Jarosław Zawadzki, Chris J. Cieszewski, Michał Zasada

(a niekiedy i kształt) są dobierane automatycznie w zależności od lokalnej zmienności przestrzennej zdjęcia satelitarnego. Takie okno zwane jest czasami oknem geograficznym [Merchant 1984; Dillworth 1991]. Merchant [1984] zaproponował wykorzystanie okna geograficznego do klasyfikacji zdjęć satelitarnych otrzymanych przy użyciu sondy Landsat TM. W celu automatycznego określenia optymalnych wymiarów okna geograficznego wykorzystuje się często semiwariancję [Franklin i McDermid 1993; Franklin i in. 1996, 1997]. Okno geograficzne zostało zastosowane do obserwacji lasów w celu estymacji powierzchni projekcyjnej aparatu asymilacyjnego [Wilson 1995; Wulder 1998; Wulder i in. 1996, 1999, 2000].

Wykorzystując metody geostatystyczne w połączeniu z techniką ruchomego okna stosuje się dwie różne metodologie. Pierwsza z nich polega na obliczaniu oraz dokładnym modelowaniu semiwariancji (lub innych miar ciągłości przestrzennej) w ruchomym oknie, a następnie wykorzystaniu parametrów modelowanej semiwariancji (progów i zakresu oddziaływania) w procedurach klasyfikacyjnych. Takie podejście zostało wykorzystane przez Ramsteina i Raffy'iego [1989]. W ich pracy zdjęcia satelitarne otrzymane za pomocą sondy Landsat TM były analizowane przy użyciu semiwariancji kierunkowych (anizotropowych). Autorzy rozważali niewielką liczbę wyraźnie różnych klas: lasy, pola oraz różne typy obszarów zabudowanych. Wyniki badań sugerowały, że próg semiwariancji nie jest parametrem dobrze klasyfikującym wymienione tutaj klasy. Właściwym parametrem do tych celów okazał się według wymienionych autorów zakres semiwariancji. W związku z tym, taką klasyfikację nazwano jednoparametrową klasyfikacją teksturalną (one-parameter texture classification). W pracy tej semiwariancję empiryczną, obliczaną techniką ruchomego okna, modelowane były przy użyciu modelu wykładniczego. W celu skrócenia czasu obliczeniowego, parametry semiwariancji nie były wyznaczane tradycyjnie metodą najmniejszych kwadratów, ale były wyznaczane na podstawie wartości semiwariancji w pierwszym kroku przy użyciu uproszczonych wzorów zawierających jedynie średnie wartości jasności spektralnej pikseli oraz ich kwadratów. Drogą prób Autorzy ustalili optymalny wymiar ruchomego okna jako 11×11 pikseli. Stwierdzono (dla pasma czerwonego), że zakres semiwariancji (mierzony w pikselach) wynosił: $a < 1,8$ dla zabudowań; $1,8 < a < 3,1$ dla pól uprawnych oraz $a > 3,1$ dla lasów.

Druga, częściej stosowana metoda klasyfikacji geostatystycznej przy wykorzystaniu techniki ruchomego okna, nie wymaga modelowania semiwariancji. Jest to podejście mające ogromną przewagę nad metodą wymagającą modelowania semiwariancji w ruchomym oknie ze względu na brak nadzwyczaj wysokich wymagań obliczeniowych związanych z modelowaniem ogromnych ilości zbiorów danych w ruchomym oknie, piksel po pikselu. Dodatkowo, semiwariancję obliczaną na podstawie zdjęć satelitarnych obszarów leśnych są wyjątkowo skomplikowane i najczęściej dokładne ich modelowanie w ruchomym oknie nie jest w praktyce możliwe. W metodzie tej zamiast modelowania semiwariancji lub innych miar ciągłości przestrzennej analizowane są statystycznie parametry semiwariancji empirycznych wyliczanych w ruchomym oknie. Parametrami tymi mogą być klasyczne parametry semiwariancji takie jak zakres, próg oraz efekt samorodka, jak również inne parametry otrzymane drogą analizy wykresów semiwariancji empirycznych, takich jak wartości lub nachylenie semiwariancji w poszczególnych krokach, średnie wartości semiwariancji, różnorodne miary związane z kształtem semiwariancji, itd. Po raz pierwszy metoda ta została użyta w latach dziewięćdziesiątych XX w. [Miranda 1992; Miranda i Carr 1994; Miranda i in. 1996]. Wykorzystano w niej algorytm klasyfikacji teksturalnej oparty na badaniu semiwariancji (semivariance tekstural classifier – STC). W algorytmie tym w ruchomym oknie wyliczane są wartości semiwariancji w sześciu kolejnych krokach. Wartości te są wykorzystywane w procesie klasyfikacji jako dodatkowe warstwy zdjęcia

satelitarnego. Metoda STC wykazała swoją przydatność w wielu obserwacjach satelitarnych. Na przykład w celu klasyfikacji roślinności na Borneo wykorzystano tę metodę do analizy zdjęć radarowych (Shuttle Image Radar-B, pasmo L – 23,4 cm). W badaniu tym semiwariancje obliczane były w ruchomym oknie o wymiarach 7×7 pikseli. Rezultaty klasyfikacji geostatystycznej były zgodne z poprzednimi badaniami roślinności na Borneo [Ford i Casley 1988]. Podobne badania były wykonywane w celu klasyfikacji roślinności w północno-zachodniej Brazylii za pomocą badań radarowych przy użyciu sondy JERS-1, ze zdolnością rozdzielczą 18 m. W badaniach tych wyróżniono cztery klasy: wody, roślinność zwartą, roślinność otwartą i roślinność nadrzeczną. Dokładność klasyfikacji (weryfikowana za pomocą pomiarów na powierzchni ziemi) uzyskana metodą STC wynosiła 0,58; 0,67; 0,68 oraz 0,60 odpowiednio dla wody, roślinności otwartej, roślinności zwartej oraz roślinności nadrzecznnej.

Bardzo efektywną metodą wykorzystującą informację przestrzenną (teksturalną) jest rozwinięta niedawno metoda, polegająca na jednoczesnym obliczaniu w ruchomym oknie, piksel po pikselu, kilku teksturalnych miar zmienności przestrzennej (textural measures of spatial variability – TMSV). Metoda ta została opracowana z myślą o badaniach satelitarnych roślinności i została pomyślnie przetestowana w celach klasyfikacji obszarów leśnych. W istocie metoda TMSV jest udoskonaloną metodą STC. Różnica między nimi polega na tym, że metoda TMSV używa większej ilości bardziej złożonych miar zmienności przestrzennej obliczanych w ruchomym oknie. W związku z tym metoda ta jest bardziej precyzyjna niż metoda STC. Metoda TMSV została zaimplementowana w postaci dwóch pakietów komputerowych MXTEXT oraz MXMULT [Carr 1996] napisanych w języku Fortran. Programy te wykorzystują kilka wybieranych algorytmów klasyfikacji: minimalnej odległości do średniej (minimum-distance-to mean), największego prawdopodobieństwa (maximum likelihood), bayesowski (Bayesian).

Istnieją również odmiany metody TMSV klasyfikacji teksturalnej zdjęć satelitarnych [np. Chica-Olmo i Abarca-Hernandez 2000], wykorzystujące bardzo złożone miary korelacji przestrzennej, m.in. korelacje między pikselami należącymi do różnych pasm. Na przykład wymienieni tutaj autorzy wyliczali zbiór tych miar na podstawie głównych składowych [principal components; Kasprzak i in. 1997] wyliczanych odpowiednio z pasm widzialnych TM1, TM2, TM3 oraz pasm promieniowania podczerwonego TM4, TM5, TM7 sondy Landsat TM5. Główne składowe wyliczano również na podstawie madogramów, semiwariancji krzyżowych oraz pseudo semiwariancji krzyżowych [Deutch i Journel 1998]. Dodatkowo w procesie klasyfikacji używano wymiaru fraktalnego tekstury zdjęć satelitarnych. Wyniki obserwacji satelitarnych z zaawansowanymi metodami TMSV prowadzą do dwóch ważnych wniosków:

1. uwzględnienie informacji przestrzennej obok informacji spektralnej zwiększa dokładność nawet o kilkadziesiąt procent,
2. szczególnie ważne do zwiększenia dokładności klasyfikacji są wielowymiarowe (międzypasmowe) miary korelacji przestrzennej takie jak semiwariancje krzyżowe, pseudo-semiwariancje krzyżowe lub madogramy krzyżowe.

Podobne badania roślinności nadmorskiej przeprowadzili Jakomulska i Clarke [2001] na podstawie danych lotniczych (Airborne Data Acquisition and Registration System 5500) o zdolności rozdzielczej 2,5 m. W badaniach tych zastosowano trzy pasma promieniowania: zielone, czerwone i podczerwone. Analizowano sześć różnych klas roślinności. Miary ciągłości przestrzennej obliczane były techniką ruchomego okna o zmiennych wymiarach (okno geograficzne). Analizowano bardzo duży zbiór miar korelacji przestrzennej, które zakwalifikowano do czterech

grup: (1) parametry indywidualne (np. wartości semiwariancji w poszczególnych krokach), (2) parametry globalne (np. suma wartości semiwariancji (wariancji krzyżowej), średnia wartość semiwariancji, suma modułu różnic między semiwariancją i semiwariancją krzyżową), (3) parametry związane z zakresem lub progiem semiwariancji (np. różnica pomiędzy semiwariancją krzyżową i semiwariancją w odległości równej zakresowi, stosunki wartości progów dla różnych pasm), (4) różnorodne miary związane z kształtem semiwariancji. Tak liczny zbiór teksturalnych miar korelacji analizowano ze względu na ich przydatność w procesie klasyfikacji stosując metodę głównych składowych lub analizę korelacji. Wykazano, że najbardziej efektywnymi parametrami różniącymi badane klasy w procesie klasyfikacji są: progi semiwariancji i semiwariancji krzyżowej, suma modułów różnic pomiędzy wariogramem eksperymentalnym a modelem sferycznym w kolejnych krokach, wartości pseudo-wariancji krzyżowej w odległości równej zakresowi. Wykorzystanie informacji przestrzennej poprawiło jakość klasyfikacji o około 15-20% przy całkowitej dokładności równej około 80%.

Duży wysiłek uczyniono również w kierunku opracowania metod wykorzystujących anizotropowe (kierunkowe) właściwości korelacji przestrzennych. Na przykład St-Onge i Cavayas [1995, 1997] rozwinęli zbiór algorytmów przeznaczonych do klasyfikacji wielkoobszarowych lasów za pomocą wysokorozdzielczych technik satelitarnych (MEIS-II, przestrzenna zdolność rozdzielcza około 1m). Informacja przestrzenna była uzyskiwana dzięki pomiarom zakresów semiwariancji obliczanych na podstawie monochromatycznych zdjęć satelitarnych w trzech różnych kierunkach przy użyciu techniki ruchomego okna. Zakresy te wykorzystane były następnie jako parametry funkcji regresji. Taka precyzyjna procedura, w połączeniu z wysoką zdolnością rozdzielczą, pozwala sklasyfikować lasy m.in. pod względem średnicy koron drzew, zadrzewienia czy stopnia zwarcia koron drzew.

Szczególnie ważną rolę w klasyfikacji lasów metodami geostatystycznymi pełnią metody kokrigingu. Metody te należą do najnowocześniejszych geostatystycznych metod estymacji przestrzennej wykorzystujących dodatkową informację poprawiającą jakość klasyfikacji [Deutch i Journel 1998]. Metody kokrigingu, w których do estymacji używana jest więcej niż jedna zmienna, są szczególnie użyteczne, kiedy zmienna główna jest rzadko próbkowana, a zmienna dodatkowa jest próbkowana gęsto lub jest wręcz nadmiarowa. Technika ta poprawia istotnie dokładność estymacji i zmniejsza wariancję błędów w stosunku do tradycyjnego krigingu. Kokriging idealnie nadaje się do estymacji przestrzennej w wielu dziedzinach, gdzie kosztownym lub trudnym do wykonania pomiarom towarzyszą liczne, skorelowane z nimi pomiary dodatkowe. Obserwacje satelitarne są wręcz modelowym obszarem takich zastosowań. W literaturze polskiej kokriging został dokładnie opisany w artykule Zawadzkiego [2003].

Wartość estymowana w kokrigingu jest kombinacją liniową zarówno pomiarów zmiennej głównej jak i pomiarów zmiennej pomocniczej. Można wyrazić to równaniem:

$$\hat{U}(\mathbf{x}_0) = \sum_{i=1}^n a_i(\mathbf{x}_i) \cdot U_i(\mathbf{x}_i) + \sum_{j=1}^m b_j(\mathbf{x}_j) \cdot V_j(\mathbf{x}_j)$$

gdzie \hat{U}_0 jest szacunkiem zmiennej U w położeniu \mathbf{x}_0 . U_1, \dots, U_n są wartościami pomiarów zmiennej głównej w położeniach \mathbf{x}_i ($i=1..n$). V_1, \dots, V_m są wartościami pomiarów zmiennej pomocniczej w położeniach \mathbf{x}_j ($j=1..m$). a_1, \dots, a_n oraz b_1, \dots, b_m są zależnymi od położenia wagami kokrigingu, które należy obliczyć, w celu oszacowania \hat{U}_0 .

Metody kokrigingu zostały zastosowane w klasyfikacji wielkoobszarowej stosunkowo niedawno ze względu na duże wymagania obliczeniowe systemów komputerowych oraz konieczność rozwinięcia efektywnych pakietów statystycznych realizujących kokriging. Hudak

i in.[2002] integrowali na przykład dane sond Lidar i Landsat w celu zbadania oraz wykonania map wysokości drzew w lasach zachodniego Oregonu (USA). Dane otrzymywane z sondy Lidar (przestrzenna zdolność rozdzielcza poniżej 1 m) dostarczają szczegółowej informacji na temat struktury koron drzew w kierunku pionowym. Z drugiej strony dane te obejmują niewielkie obszary badanych lasów [Lefsky i in. 1999]. Z kolei dane z sondy Landsat dotyczą bardzo dużych powierzchni, ale nie zawierają dokładnej informacji na temat struktury pionowej lasów. Porównanie pięciu różnych metod statystycznych (klasycznych i przestrzennych) wykazało największą przydatność kokrigingu w celu wielkoobszarowej klasyfikacji wysokości drzew w badanych lasach. Autorzy wykazali, że próbkowanie w sieci kwadratów o boku 250 pozwala osiągnąć wystarczającą dokładność i szybkość mapowania.

Zaprezentowane powyżej przykłady nie wyczerpują oczywiście wszystkich możliwości wykorzystania metod geostatystycznych wykorzystujących ruchome okno w celu badania lasów. Na uwagę zasługują również inne prace dotyczące np.: wpływu kopalni na stan lasów [Levesque i King 1999; Bowers i in. 1994], w której wykorzystanie informacji przestrzennej okazało się zasadnicze; zmian chorobowych lasów w Szwajcarii [Kohl i Gertner 1997]; badania wpływu obserwowanej roślinności na parametry semiwariancji [Wallace i in. 2000] czy inne, np. [Cohen i in. 1990; Elvidge i Chen 1995; Huijbregts 1975; Lévesque i King 1999; McBratney i Webster 1986; Sun i Quin 1993; Wallerman i in. 2002], które nie będą tu jednak szczegółowo omawiane.

Metody geostatystyczne nie wykorzystujące techniki ruchomego okna. Część metod klasyfikacji wielkoobszarowej nie wykorzystuje techniki ruchomego okna. Metody te były i są rzadziej spotykane, niż metody wykorzystujące ruchome okno. Intensywny rozwój metod geostatystycznych dostarczył jednak impulsu do rozwoju również i tych metod. Zaletą tego rodzaju metod klasyfikacji może być uniknięcie wad tradycyjnych metod klasyfikacji, do których należą:

1. konieczność posiadania pomiarów na powierzchni Ziemi w celu wykonania właściwego treningu w procesie klasyfikacji,
2. wykorzystywanie do klasyfikacji głównie informacji spektralnej,
3. wykorzystywanie założenia (najczęściej niespełnionego w realnych sytuacjach) o normalności rozkładu charakterystyk spektralnych pikseli,
4. wykorzystanie w procesie klasyfikacji informacji przestrzennej obszarów o rozmiarach pikseli, bez uwzględnienia obszarów o większych i mniejszych powierzchniach.

Metody nie wykorzystujące techniki ruchomego okna w celu wyznaczenia geostatystycznych miar ciągłości pozwalają uniknąć tych zasadniczych niedogodności. Przykładem takiej klasyfikacji jest metoda zaproponowana przez van der Meera (1996), który zastosował nieparametryczną, geostatystyczną metodę klasyfikacji opartą na technice krigingu indykatorowego [Isaaks i Srivastava 1989; Deutch i Journel 1998; Zawadzki 2003]. Metoda zaproponowana przez van der Meera ma następujące zalety:

1. Klasyfikacja jest wykonywana na podstawie informacji spektralnej, którą można ustalić posługując się badaniami laboratoryjnymi. W ten sposób można wyeliminować uciążliwe pomiary na powierzchni Ziemi, mające na celu ustalenie charakterystyk spektralnych badanych klas.
2. Nie zależy od postaci rozkładu statystycznego charakterystyk spektralnych pikseli.
3. Uwzględnienie korelacji przestrzennej pozwala na klasyfikację obszarów mniejszych niż pojedyncze piksele.
4. Pozwala na precyzyjną ocenę niepewności wykonanej klasyfikacji, wykonywaną na podstawie metod krigingu indykatorowego.

Chociaż opisana tutaj metoda zastosowana została do klasyfikacji utworów geologicznych jest ona uważana za obiecującą również do klasyfikacji roślinności.

Podobne badania zastosowane do klasyfikacji roślinności z wykorzystaniem metod kokrigingu wykonane zostały przez de Bruina [2000] w badaniu sadów oliwkowych w południowej Hiszpanii za pomocą sondy Landsat TM. Uwzględnienie metod geostatystycznych spowodowało ponad trzykrotne zwiększenie powierzchni sklasyfikowanych sadów. Ciekawym przykładem zastosowania metod geostatystycznych do klasyfikacji zdjęć lasów nie wykorzystujących techniki ruchomego okna jest praca Dungan'a [1998]. Autor porównał trzy geostatystyczne metody: kriging, kokriging i warunkową symulację stochastyczną [Deutch i Journel 1998] oraz tradycyjny model liniowej regresji, analizując zdjęcia lasów uzyskane za pomocą sondy AVIRIS (Airborne Visible/Infrared Imaging Spectrometer). Autor analizował siedem różnych pasm sondy w obszarze widzialnym, traktując jedno pasmo (21) jako zmienną główną, a pozostałe 6 pasm (7, 9, 10, 12, 13 i 22) jako zmienne dodatkowe. W przypadku, gdy korelacje między zmienną główną, a zmienną pomocniczą były umiarkowanie silne (współczynnik korelacji liniowej Pearsona nie przekraczał 0,89), najlepszą metodą analizy zdjęć okazał się kokriging.

Zakończenie

Geostatystyczne miary zmienności przestrzennej dostarczają unikatowej informacji na temat zdjęć satelitarnych. Zastosowanie metod geostatystycznych w celach klasyfikacji wielkoobszarowych lasów nie jest łatwe, głównie ze względu na bardzo skomplikowaną i różnorodną strukturę przestrzenną lasów. Pomimo to w ostatnich latach, wraz z rozwojem wysokorozdzielczych technik satelitarnych, dokonuje się ogromny postęp w wykorzystaniu informacji przestrzennej zawartej w zdjęciach satelitarnych. Powiązanie informacji przestrzennej z informacją spektralną umożliwia obecnie wykonywanie klasyfikacji wielkoobszarowych lasów z dużą dokładnością oraz za niewielką cenę. W związku z tym wiedza na temat możliwości zastosowania metod geostatystycznych w naukach leśnych staje się coraz bardziej istotna.

Literatura

- Abiodun A. A. 1988. Remote sensing in the information age. *Space Policy*. 14: 229-238.
- Anselin L. 1995. Local indicators of spatial association – LISA. *Geogr. Anal.* 27: 93-115.
- Aplin P., Atkinson P. M., Curran P. J. 1999. Fine Spatial Resolution Satellite Sensors for the next decade. *Int. J. Remote Sens.* 18: 3873-3881.
- Aplin P., Atkinson P. M., Curran P. J. 1999. Fine Spatial Resolution Simulated Satellite Sensor Imagery for Land Cover Mapping in the United Kingdom. *Int. J. Remote Sens.* 68: 206-216.
- Arai K. 1993. A classification method with a spatial-spectral variability. *Int. J. Remote Sens.* 33: 768-776.
- Atkinson P. M. 1993. The effect of spatial resolution on the experimental variogram of airborne MSS imagery. *International Journal of Remote Sensing*. 14: 1005-1011.
- Atkinson P. M. 1997. Selecting the spatial resolution of airborne MSS imagery for small-scale agricultural mapping. *Int. J. Remote Sens.* 18: 1903-1917.
- Atkinson P. M. Tate N. J. 1999. *Advances in remote sensing and GIS analysis*. pp. 257-258. John Wiley and Sons, Chichester. 288 p.
- Bowers W., Franklin S., Hudak J., McDermid G. 1994. Forest structural damage analysis using semivariance. *Can. J. Remote Sens.* 20:102-115.
- Bruniquel-Pinel V., Gastellu-Etcheberry J. P. 1998. Sensitivity of Texture of High Resolution Images of Forest to Biophysical and Acquisition Parameters. *Remote Sens. of Environ.* 65: 61-85.
- Campbell J. B. 1994. *Introduction to Remote Sensing*. Guilford Press. New York.
- Ciołkosz A., Kęsik A. 1989. *Teledetekcja satelitarna*. PWN, Warszawa.
- Chen Y. Q., Nixon M. S., Thomas D. W. 1997. On texture classification. *Int. J. Syst. Sci.* 28: 669-682.
- Chica-Olmo M., Abarca-Hernandez F. 2000. Computing geostatistical image texture for remotely sensed data classification. *Comput. Geosci.* 26: 373-383.
- Cohen W. B., Spies T. A., Bradshaw G. A. 1990. Semivariograms of digital imagery for analysis of conifer canopy structure. *Remote Sens. Environ.* 34: 167-178.

- Cressie N. A. C. 1993. Statistics for Spatial Data, John Wiley & Sons, Inc.
- Curran P. 1980. Multispectral remote sensing of vegetation amount. Prog. Phys. Geog. 22: 61-78.
- Curran P. J. 1988. The semivariances in remote sensing: an introduction. Remote Sens. Environ. 24: 493-507.
- De Bruin S. 2000. Predicting the areal extent of land-cover types using classified imagery and geostatistics. Remote Sens. Environ. 74: 387-396.
- De Fries R. S., Townshend J. R. G. 1994. NDVI-derives land cover classifications at a global scale. International Journal of Remote Sensing, 15:3567-3586.
- Dillworth M., Whistler, J., Merchant J. 1994. Measuring landscape structure using geographic and geometric windows, Photogramm. Eng. and Rem., 60: 1215-1224.
- Deutch C. V., Journel A. G. 1998. GSLIB Geostatistical Software Library, Oxford University Press.
- Dungan J. 1998. Spatial prediction of vegetation quantities using ground and image data. Int. J. Remote Sens. 19: 267-285.
- Elvidge C. D., Chen Z. 1995. Comparison of Broad-Band and Narrow-Band Red and Near-Infrared Vegetation Indices. Remote Sens. Environ. 54: 38-48.
- ERDAS Field Guide. 1990. Fifth Edition, Erdas Inc., Atlanta, Georgia. 672 p.
- Ford J. P., Casey D. J. 1988. Shuttle radar mapping with diverse incidence angles in the rainforest of Borneo. Int. J. Remote Sens. 9: 927-943.
- Franklin S. E., McDermid G. J. 1993. Empirical relations between digital SPOT HRV and CASI spectral response and lodgepole pine (*Pinus contorta*) forest stand parameters, Int. J. Remote Sens. 14: 2331-2348.
- Franklin S. E., Wulder M. A., Lavigne M. B. 1996. Automated derivation of geographic window sizes for use in remote sensing digital image texture analysis. Comput. Geosci. 22: 665-673.
- Franklin S. E., Lavigne M., Deuling M., Wulder M., Hunt E. 1997. Estimation of forest leaf area index using remote sensing and GIS data for modeling net primary productivity. Int. J. Remote Sens. 18: 3459-3471.
- Fritz L. 1996. The era of commercial earth observation satellites. Photogramm. Eng. and Rem. 62: 39-45.
- Gastellu-Etcheberry V., Demarez V., Pinel V., Zagolski F. 1966. Modeling Radiative Transfer in Heterogeneous 3-D Vegetation Canopies. Remote Sens. Environ. 58: 131-156.
- Isaaks E. H., Srivastava R. M. 1989. An Introduction to Applied Geostatistics. Oxford University Press. Oxford. 561.
- Goodchild M. 1986. Spatial autocorrelation. Concepts and Techniques in Modern Geography, 47. GeoBooks. Norwich.
- Granberg H. B. 1987. A forest shading model using bit-mapped graphics. Agric. For. Meteorol. 43: 225-234.
- Guyot G., Guyon D., Riom J. 1989. Factors affecting spectral response of forest canopies: a review. Geocarto Int. 3: 3-18.
- Hay G. J., Niemann K. O., McLean G. F. 1996. An object-specific image-texture analysis of H-resolution forest imagery. Remote Sens. Environ. 55: 108-122.
- Holmgren J., Joyce S., Nilsson M., Olsson H. 2000. Estimating Stem Volume and Basal Area in Forest Compartments by Combining Satellite Image Data with Field Data. Scand. J. For. Res. 15: 103-111.
- Hudak A. T., Lefsky M. A., Cohen W. B., Berterretche M. 2002. Integration of lidar and Landsat ETM+ data for estimating and mapping forest canopy height. Remote Sens. Environ. 82: 397-416.
- Huibrégts C. J. 1975. Regionalized variables and quantitative analysis of spatial data. in: Display and Analysis of Spatial Data pp. 38-53. Davis, J. C. and McCullagh, M. J. [red.]. 1975. John Wiley & Sons, London. 378 p.
- Jakomulska A., Clarke K. 2001. Variogram-derived measures of textural image classification, P. 345-355 W: Proc. of Conference on Geostatistics for Environmental Applications. Monestiez P., Allard D., Froidevaux R. [red.], Kluwer Academic Publishers.
- Jordan C. F. 1969. Derivation of leaf area index from quality of light on the forest floor. Ecology, 50: 663-666.
- Journel A. G., Huibrégts C. J. 1978. Mining Geostatistics, Academic Press, London. 600p.
- Journel A. G. 1986. Geostatistics: models and tools for the earth sciences. Math. Geol. 18: 119-140.
- Journel A. G. 1993. Geostatistics: roadblocks and challenges. P. 213-224. In Proc. of Fourth International Geostatistics Congress. Geostatistics Troia'92. A. Soares [red.], Kluwer Academic Publisher, Dordrecht.
- Jupp D. L. B., Strahler A. H., Woodcock C. E. 1988. Autocorrelation and regularization in digital images. I. Basic theory. IEEE T. Geosci. Remote. 26: 467-473.
- Jupp D. L. B., Strahler A. H., Woodcock C. E. 1989. Autocorrelation and regularization in digital images. II. Simple image models. IEEE T. Geosci. Remote. 27: 247-258.
- Kasprzak T., Lasek M., Pęczkowski M. 1997. Statystyczna analiza wielowymiarowa za pomocą komputera, Wydawnictwa Uniwersytetu Warszawskiego.
- Kohl M., Gertner G. 1997. Geostatistics in evaluating forest damage surveys: considerations on methods for describing spatial distributions. Forest Ecology and Management 95, 131-140.
- Labowitz M., Masouka E. 1984. The influence of autocorrelation in signature extraction – An example from a geobotanical investigation of Cotter Basin, Montana. Int. J. Remote Sens. 5: 315-332.
- Lefsky M. A., Cohen W. B., Acker S. A., Parker G. G., Spies, T. A., Harding D. 1999. Lidar Remote Sensing of the Canopy Structure and Biophysical Properties of Douglas-Fir Western Hemlock Forests, Remote Sensing of Environment. 70: 339-361.

- Lévesque J., King J. D. 1999. Airborne Digital Camera Image Semivariance for Evaluation of Forest Structural Damage at an Acid Mine Site. *Remote Sens. Environ.* 68: 112-124.
- Marceau D., Howarth P., Gratton D. 1994a. Remote sensing and the measurement of geographical entities in a forested environment. 1. The scale and spatial aggregation problem. *Remote Sens. Environ.* 49: 93-104.
- Marceau D., Gratton D., Fournier R., Fortin J. 1994b. Remote sensing and the measurement of geographical entities in a forested environment. 2. The optimal spatial resolution. *Remote Sens. Environ.* 49: 105-117.
- McBratney A. B., Webster R. 1986. Choosing function for semivariograms of soil properties and fitting them to sampling estimates. *Journal of Soil Sciences*, 37:617-639.
- Meer van der F. 1996. Classification of remotely sensed imagery using an indicator kriging approach: application to the problem of calcite-dolomite mineral mapping. *Int. J. Remote Sens.* 17: 1233-1249.
- Merchant J. 1984. Using spatial logic in classification of Landsat TM data. P. 378-385 in *Proc. of 9th Ann. Pecora Symp.* Sioux Falls, South Dakota.
- Miranda F., MacDonald J., Carr J. R. 1992. Application of the semivariogram textural classifier (STC) for vegetation discrimination using SIR-B data of Borneo. *Int. J. Remote Sens.* 13: 2349-2354.
- Miranda F. P., Carr J. R. 1994. Application of the semivariogram textural classifier (STC) for vegetation discrimination using SIR-B data of the Guiana Shield, north-western Brazil. *Rem. Sens. Rev.* 10: 155-168.
- Miranda F., Fomesca L., Carr J. R., Taranik J. 1996. Analysis of JERS-1 (Fuyo-1) SAR data for vegetation discrimination in northwestern Brazil using the semivariogram textural classifier (STC). *Int. J. Remote Sens.* 17: 3523-3529.
- Mozgawa J. 2000. Teledetekcja Obszarów Leśnych – powiązania z SIP i zastosowania w LP W: System Informacji Przestrzennej w Lasach Państwowych. *Podręcznik Użytkownika Leśnej Mapy Numerycznej*: 72-82.
- Mozgawa J., Kadlewicz T., Kosiński K., Grudziński T., Botul K. 1994. Odzworowanie biogeocenozy Białowieskiego Parku Narodowego na zdjęciach satelitarnych TM. *Fotointerpretacja w Geografii*, Tom 24: 90-99.
- Nemani R., Pierce L., Running S. 1993. Forest ecosystem process at the watershed scale: Sensitivity to remotely-sensed Leaf Area Index estimates. *International Journal of Remote Sensing*, 14: 2519-2539.
- Popławski Z. F., Zawila-Niedzwiecki T. 1995. System informacji przestrzennej w analizie stanu lasu Sudetów z wykorzystaniem danych teledetekcyjnych. *Sylvan*, 8: 73-86.
- Ramstein G., Raffy M. 1989. Analysis of the structure of radiometric remotely sensed images. *Int. J. Remote Sens.* 17: 3523-3529.
- Rouse J. W., Haas R. H., Schell J. A., Deering D. W. 1973. Monitoring vegetation systems in the great plains with ERTS. P. 309-317 in *Proc. of Third ERTS Symposium*. NASA SP-351. NASA. Washington, DC.
- Strahler A., Woodcock C. E., Smith J. 1986. On the nature of models in remote sensing. *Remote Sens. Environ.* 20: 121-139.
- St-Onge B. A., Cavayas F. 1995. Estimating forest stand structure from high resolution imagery using the directional variogram. *Int. J. Remote Sens.* 16: 1999-2001.
- St-Onge B. A., Cavayas F. 1997. Automated forest structure mapping from high resolution imagery based on directional semivariogram estimates. *Remote Sens. Environ.* 61: 82-95.
- Sun X. H., Quin P. 1993. Texture analysis for remotely sensed imagery. P. 311-322 in *Proc. of the Ninth Thematic Conference on Geological Remote Sensing*, Pasadena, California.
- Treitz, P. Howarth P. 2000. High spatial remote sensing data for forest ecosystem classification: an examination of spatial scale. *Remote Sens. Environ.* 72: 268-289.
- Tucker C. J., Fung I. Y., Keeling C. D., Gammon R. H. 1986. Relationship between atmospheric CO₂ variations and a satellite-derived vegetation index. *Nature*: 319: 195-199.
- Wallace C. S. A., Watts J. M., Yool S. R. 2000. Characterizing the spatial structure of vegetation communities in the Mojave Desert using geostatistical techniques. *Comput. Geosci.* 26: 397-410.
- Wallerman J., Joyce S., Vencatasawmy C. P., Olsson H. 2002. Prediction of forest stem volume using kriging adapted to detected edges. *Can. J. Forest Res.* 32: 509-518.
- Webster R., Olivier M. A. 1990. *Statistical Methods in Soil and Land Resource Survey*. Oxford University Press. Oxford. 316p.
- Westoby J. 1989. *Introduction to world forestry: people and their trees*. Basil Blackwell Ltd., Oxford. 228.
- Woodcock C. E., Strahler A. H., Jupp D. B. 1988a. The use of variograms in remote sensing: I. Scene models and simulated images. *Remote Sens. Environ.* 25: 323-348.
- Woodcock C. E., Strahler, A. H., Jupp D. B. 1988b. The use of variograms in remote sensing: II. Real digital images. *Remote Sens. Environ.* 25: 349-379.
- Woodcock C. E., Harvard V. J. 1992. Nested-hierarchical scene models and image segmentation. *Int. J. Remote Sens.* 13: 3167-3187.
- Woodcock C. E., Macomber S. A., Pax-Lenney M. Cohen W. B. 2001. Monitoring large areas for forest change using Landsat: Generalization across space, time and Landsat sensors. *Remote Sens. Environ.* 78: 194-203.
- Wulder M., Franklin S., Lavigne M., Deuling M., Hunt E. 1996. Estimation of the net primary productivity of the Fundy Model Forest. FL, 4-7, 10, 327-332. in *Proc. of conference on Global Networks for Environmental Information, Eco-Inforna '96*, Lake Buena Vista. Florida.

- Wulder M. 1998.** Optical remote-sensing techniques for the assessment of forest inventory and biophysical parameters, *Prog. in Phys. Geog.* 22: 449-476.
- Wulder M., LeDrew E., Franklin S., Lavigne M. 1998.** Aerial image texture information in the estimation of northern deciduous and mixed wood forest leaf area index (LAI). *Remote Sens. Environ.* 64: 67-76.
- Wulder M. 1999.** Image spectral and spatial information in the assessment of forest structural and biophysical data. P. 267-281. in *Proc. of the International Forum on Automated Interpretation of High Spatial Resolution Digital Imagery for Forestry*. Natural Resources Canada, Canadian Forest Service. Pacific Forestry Center. Victoria, BC, Canada.
- Wulder M. A., LeDrew E. F., Franklin S. E., Lavigne M. B. 2000.** Local maximum filtering for the extraction of tree locations and basal area from high spatial resolution imagery. *Remote Sens. Environ.* 73: 103-114.
- Wynne R. H., Oderwald R. G., Reams G. A., Scrivani J. A. 2000.** Optical remote sensing for forest area estimation. *Journal of Forestry*. 98(5): 31-36.
- Zawadzki J. 2003.** Wstęp do Integracji Danych Przestrzennych, przyjęto do publikacji w *Wiadomościach Statystycznych*. Wydawnictwa GUS.
- Zawadzki J., Cieszewski C. J., Zasada M. 2003.** Semiwariacje tekstury obrazów satelitarnych Landsat TM obszarów leśnych. *Sylwan* 7: 40-52.

SUMMARY

Use of geostatistical methods for classification of forest ecosystems using satellite imagery

This paper summarizes the geostatistical methods for remote sensing classification of forest ecosystems. We begin by discussing the use of semivariances in interpretation of remotely sensed images of forested areas. We describe the influence of forest attributes on the parameters of classic semivariance. We then provide details of various methods of satellite image classifications. We start with the description of methods that do not use geostatistical measures and then go through those that use geostatistics indirectly. Finally we focus on methods utilizing measures of spatial continuity, and among these we describe in detail groups of methods that use and do not use moving windows in the classification process.

Geostatistical measures of spatial continuity provide unique information about remotely sensed images. The role of textural information can be essential, especially in cases where spectral characteristics of investigated objects are similar. The use of geostatistically-based methods in large-scale classification is not a trivial task, mostly because of complicated patterns and internal structure of forests. The use of geostatistical methods in analyzing remote sensing images of forest areas increased rapidly during the last several years following advancements in high-resolution remote-sensor technology. Currently, linking spatial and spectral information allows for a highly accurate and relatively inexpensive large-scale forest classification. The results of numerous applications of geostatistical methods for processing remotely sensed forest images are very encouraging.