

Krystian Pyka
Klaus Steinnocher

OPTYMALIZACJA DANYCH W KLASYFIKACJI WIELOSPEKTRALNYCH OBRAZÓW SATELITARNYCH Z UWZGLĘDNIENIEM TEKSTURY

1. Wprowadzenie

Komputerowo wspomagana klasyfikacja treści wielospektralnych obrazów satelitarnych stała się klasycznym narzędziem przy opracowywaniu drobnoskalowych map użytkowania terenu. Wiarygodność takiej klasyfikacji nie jest jednak zadawalająca. Poszukuje się wciąż nowych rozwiązań. Jedną z tendencji jest wykorzystanie obrazów multisensoralnych, czyli rejestrowanych przez różne systemy satelitarne np. Landsat TM, SPOT, seria obrazów rosyjskich. Rozwinięciem tej koncepcji jest wprowadzanie dodatkowych informacji, w tym parametrów opisujących teksturę obrazu, czyli tzw. obrazów teksturalnych.

Jednakże znaczne powiększanie zbioru danych może doprowadzić do utraty kontroli nad procesem klasyfikacyjnym lub w sposób istotny zwiększać jego czasochłonność (dynamiczny wzrost wydajności narzędzi komputerowych jest prawie równoważony przez szybki przyrost objętości danych).

Dlatego powstaje potrzeba takiej selekcji danych lub redukcji cech, które przy znacznym zmniejszeniu objętości danych zapewniają prawie identyczną zdolność do wydzielenia tematycznych. Niniejsze opracowanie prezentuje użyteczność tzw. kryterium śladowego, znanego z analizy dyskryminacyjnej, do oceny separacji klas w pojedynczych obrazach i ich liniowych kombinacjach.

2. Dane testowe, obrazy teksturalne

Wykorzystano zestaw danych przygotowany w ramach eksperymentu ISPRS (Schultz, 1990). Obejmuje on obrazy LANDSAT TM, SOJUS KFA, SEASAT, przedstawiające okolice Frankfurtu. Aby ograniczyć wpływ reliefu terenowego, skupiono się na relatywnie płaskim fragmencie o rozmiarach około 13 km x 13 km (512x512 pikseli)

Tekstura obrazu jest pojęciem szeroko stosowanym w fotointerpretacji, trudno jednak o jednoznaczną, formalną definicję tego pojęcia. W konsekwencji i parametryzacja tekstury nie może być opisana prostą formułą. Syntetyczny przegląd metod kwantyfikacji tekstury obrazu podają Irons & Petersen (1981). Obok prostych i mało przydatnych parametrów statystycznych stosuje się bardziej złożone, ale poprawniej opisujące teksturę,

twz. parametry syntaktyczne. Wymagają one budowania macierzy sąsiedztwa dla określonego otoczenia elementu obrazu (Haralick et.al. 1973). Macierz sąsiedztwa zawiera unormowane częstości p_{ij} , definiujące wystąpienie w określonym kierunku, w określonej odległości dwóch pikseli, z których jeden ma wartość i a drugi j . Na podstawie macierzy sąsiedztwa można obliczać różne parametry, z których dla celów niniejszego opracowania wybrano dwa: odwrotny moment odległości (IDM) i drugi moment (ASM):

$$\text{ASM} = \text{SS} (p_{ij})^2$$

$$\text{IDM} = \text{SS} \frac{1}{1 + (i - j)} \cdot p_{ij}$$

Przy obliczaniu macierzy sąsiedztwa zachowano następujące warunki: wielkość otoczenia 9x9 pikseli, dwa kierunki poszukiwania par ij - poziomy i pionowy (końcowa macierz jest średnią z wartości w obu kierunkach). Parametry ASM i IDM liczono dla wszystkich kanałów obrazu LANDSAT TM z pominięciem kanału podczerwonego oraz dla obrazu SOJUS KFA. Odpowiednie obliczenia zrealizowano na komputerze System 2400 firmy Impuls (Babnik & Steinnocher, 1991).

3. Kryterium śladowe

W statystyce kryterium to występuje również pod nazwami: metoda śladu macierzy, transformacja Hotellinga (Fukunaga, 1972). Za autorów tej miary dyskryminacji klas, uważani są Hotelling i Lowley (Ahrens, Lauter, 1974).

Adaptując kryterium śladowe dla celów klasyfikacji treści obrazów poczynimy następujące założenia:

- d - wymiar przestrzeni cech, równy liczbie analizowanych obrazów (kanały spektralne, obrazy teksturalne),
- L_i - liczba pikseli zawarta w polu treningowym klasy i .
- x_i - wektor cech reprezentujący poszczególne piksele w polu treningowym i (wymiar d),
- m_i - wektor wartości (cech) średnich klasy i (wymiar d),
- k - liczba wydzielonych klas,
- q_i - prawdopodobieństwo a-priori wystąpienia klasy i .

Dla każdej klasy można określić macierz wariancyjno-kowariancyjną C_i :

$$C_i = \frac{1}{L_i - 1} \sum (x_i - m_i) \cdot (x_i - m_i)^T \quad (1)$$

oraz globalny wektor wartości średnich dla k - klas:

$$m = \frac{1}{\sum L_i} \sum L_i \cdot m_i \quad (2)$$

Przy takich założeniach można zdefiniować tzw. macierz zmienności wewnętrznej C (średnia z macierzy C_i) oraz macierz zmienności zewnętrznej H (macierz różnic pomiędzy wartościami średnimi w klasach):

$$C = \frac{1}{\sum q_i} \sum q_i \cdot C_i \quad (3)$$

$$H = \sum q_i (m_i - m)(m_i - m)^T \quad (4)$$

Kryterium śladowe jest określane następująco:

$$T^2 = \frac{1}{\sum q_i} \text{tr}(H \cdot C^{-1}) \quad (5)$$

T^2 jest wielowymiarową miarą dyskryminacyjną, która charakteryzuje zdolność wzajemnej separacji klas: im większa jest wartość T^2 tym lepiej zróżnicowane są klasy (Ahrens, Lauter, 1974).

Na podstawie macierzy zmienności wewnętrznej i zewnętrznej można zbudować liniową transformację cech o następujących właściwościach:

- pierwsza z uzyskanych (nowych) cech zapewnia najlepsze warunki separacji klas spośród wszystkich możliwych kombinacji liniowych cech pierwotnych,
- liczba nowych (transformowanych) cech jest co najmniej o 1 mniejsza od liczby klas,
- nowe cechy są wzajemnie liniowo niezależne.

Taką transformację realizuje poniższa formuła:

$$y = W^T \cdot x \quad (6)$$

gdzie:

y - wektor nowych cech,

x - wektor cech pierwotnych,

W - macierz wektorów własnych określona dla macierzy $H \cdot C^{-1}$

Transformacja Hotellinga wykazuje podobieństwo do tzw. metody składowych głównych, stosowanej powszechnie do redukcji przestrzeni spektralnej. Różnica tkwi w sposobie obliczenia parametrów:

- w metodzie składowych głównych tworzona jest przestrzeń rozpięta na wektorach własnych macierzy wariancyjno-kowariancyjnej określonej dla wszystkich pikseli obrazu,
- transformacja według kryterium śladowego rozpina przestrzeń na wektorach własnych macierzy $H \cdot C^{-1}$, z których każda liczona jest na podstawie pikseli zawartych w wydzielonych polach treningowych.

4. Wybór optymalnego zestawu obrazów

Celem klasyfikacji było opracowanie typowej mapy użytkowania terenu. Wyróżniono sześć klas:

- las liściasty,
- las iglasty,
- zabudowa przemysłowa,
- tereny rolne,
- zabudowa podmiejska,
- wody.

Dla każdej z tych klas, na kompozycji RGB zbudowanej z trzech kanałów LANDSAT TM, zdefiniowano jedno pole treningowe. Zatem klasyfikacja miała odszukać obszary o bardzo wysokim stopniu podobieństwa do wskazanych próbek.

Do oceny separacji klas wybrano poniższe zestawy obrazów, przy specyfikacji których zastosowano podane skróty:

- TM1, TM2... - kolejne kanały spektralne obrazu LANDSAT TM
- RAD - obraz radarowy SEASAT
- SOJ - obraz SOJUS KFA
- INX - indeks wegetacji zdefiniowany jako $(TM3-TM2)/(TM3+TM2)$
- ITM3- parametr tekstury IDM dla obrazu TM3 (analogicznie ITM4, ITM7, ISOJ)
- ATM3- parametr tekstury ASM dla obrazu TM3 (analogicznie ATM4, ATM7, ASOJ)

- I: TM1, TM3, TM4, TM5, TM7 (5 obrazów)
- II: jak I oraz SOJ, RAD, INX (8 obrazów)
- III: ITM3, ITM4, ITM7, ISOJ, ATM3, ATM4, ATM7, ASOJ (8 obrazów teksturalnych)
- IV: suma obrazów z zestawu II i III (16 obrazów)
- V: TM1, TM4, TM5, SOJ, INX, ITM3, ISOJ, ASOJ (8 obrazów)
- VI: trzy pierwsze obrazy uzyskane z transformacji Hotellinga przeprowadzonej w stosunku do zestawu IV (3 obrazy)
- VII: dwa pierwsze obrazy z transformacji Hotellinga dla zestawu II oraz dwa pierwsze obrazy z takiej transformacji ale przeprowadzonej dla zestawu III (4 obrazy)

Warto zwrócić uwagę, że zestaw III złożony jest tylko z obrazów teksturalnych, natomiast zestaw IV zawiera wszystkie obrazy występujące w zestawach I - V.

Z kolei zestawy VI i VII są uzyskane na drodze transformacji optymalizującej ślad macierzy $H \cdot C^{-1}$ i powinny wykazywać dobre własności dyskryminujące.

rysunek w pliku **rys61.tif** na całą stronę

Rys. 6.1. Wartości kryterium śladowego dla różnych zestawów danych

Dla każdego z zestawów liczono kryterium śladowe T^2 zarówno dla wszystkich sześciu klas jak i tylko dla klas najgorzej separowalnych: zabudowa przemysłowa i przedmieście. Zgodnie z przewidywaniami, największą wartością T^2 charakteryzuje się zestaw IV. Wartości T^2 dla pozostałych zestawów danych pokazane są na rys.6.1.

Bardziej detaliczne porównanie kryterium śladowego dla wyróżnionych zestawów danych przedstawione jest w publikacji Pyka, Steinnocher: "Auswahl eines optimalen..." ZPF, 4/1994.

5. Klasyfikacja i dyskusja wyników

Dla wyróżnionych w pkt.4 zestawów danych została przeprowadzona klasyfikacja nadzorowana metodą największego prawdopodobieństwa. Weryfikacja przynależności pikseli do klas odbywała się przy poziomie popełnienia błędu $\alpha = 0,1$, co musiało powodować znaczący udział pikseli niesklasyfikowanych. Ponieważ zestaw IV posiada najlepszą zdolność separacji klas, uznano, że wyniki klasyfikacji z tych danych będą stanowiły odniesienie dla pozostałych.

Klasyfikacja uzyskana dla zestawu I i II (bez obrazów teksturalnych) charakteryzuje się stosunkowo małym procentem pikseli niesklasyfikowanych (rys.6.1), dużym rozdrobnieniem powierzchni klas. Ponadto zauważone zostały dyskusyjne lub błędne interpretacje:

- obszar dworca towarowego (torowiska) został przydzielony do klasy zabudowa przemysłowa,
- łąki i sady owocowe w wielu fragmentach stały się terenami rolnymi,
- specyficzny kompleks pól golfowych został sklasyfikowany jako las i tereny rolne.

Klasyfikacja na podstawie samych obrazów teksturalnych (III) zawiera znacznie bardziej skomasowane klasy ale bardzo dużą liczbę pikseli niesklasyfikowanych. Wyszczególnione wcześniej krytyczne interpretacje są w tym przypadku prawie w całości skierowane do grupy pikseli niesklasyfikowanych. Klasyfikacje odniesione do zestawów V - VII wykazują bardzo duże wzajemne podobieństwo także w aspekcie pikseli niesklasyfikowanych (rys.6.1). Należy podkreślić fakt, że rezultaty klasyfikacji dla zestawu VI (trzy obrazy z transformacji Hotellinga) są bardzo zbliżone do wyników, które dała klasyfikacja 16 obrazów (zestaw IV).

Reasumując, najwięcej zastrzeżeń budzi klasyfikacja dla danych I i II, czyli nie zawierających informacji o teksturze. Warto jeszcze zwrócić uwagę na stopień redukcji pikseli niesklasyfikowanych po przeprowadzeniu filtracji typu majority (wskazanie na klasę o największej liczbie wystąpień w oknie 3x3). Po raz kolejny dane I i II zachowują się inaczej od pozostałych - rys. 6.1 i 6.2. Widać wyraźnie, że weryfikacja przynależności pikseli była zbyt liberalna, wynik zawiera bardzo dużo pojedynczych pikseli leżących w otoczeniu innych klas (I, II). Efekt ten został w dużym stopniu wyeliminowany po wprowadzeniu informacji o teksturze obrazu. Na rys. 6.2 przedstawiono wyniki klasyfikacji dla zestawów II, III, IV, V. Potwierdzają one zasygnalizowane wcześniej korzyści uwzględnienia obrazów teksturalnych.

6. Podsumowanie

Przedstawiono metodę optymalnego wyboru danych do klasyfikacji. W obliczu korzyści jakie dają obrazy teksturalne a także w związku z możliwością uwzględnienia obrazów multisensoralnych, zarówno selekcja danych jak i redukcja przestrzeni cech staną się niezbędnym elementem procesu klasyfikacyjnego.

Redukcja przestrzeni cech realizowana np. poprzez transformację Hotellinga, powinna ułatwić bardziej detaliczną klasyfikację, gdyż odniesiona ona jest do mniejszej liczby obrazów zachowujących dobre właściwości separacji obiektów.

Nowe, wysokorozdzielcze systemy satelitarne (np. KVR-1000) powinny być włączane do klasyfikacji poprzez reprezentację teksturalną. Uwzględnienie tekstury pozwala na rozróżnienie spektralnie podobnych a jakościowo różnych obiektów.

Literatura

Ahrens H., Lauter J. (1974): Mehrdimensionale Varianzanalyse, Akademik Verlag, Berlin.

Babnik J., Steinnocher K. (1991): Digital image Processing on a Transputer System. Schriftenreihe der Osterr. Computergesellschaft, Band 58, 1-9.

Fukunaga K. (1972): Introduction to Statistical Pattern Recognition. Academic Press, New York and London.

Haralick R.M., Shanmugam K., Dinstein I. (1973): Textural Features for Image Classification.

Irons J.R., Petersen G.W. (1981): Texture Transforms of Remote Sensing Data. Remote Sensing of Environment, 11, 359-370.

Schultz, B.S. (1990): Analyse der statistischen Voraussetzungen zur Klassifizierung multispektraler Daten. ZPF 58 (3), 66-74.

Selecting of an Optimum Data Set for Multispectral Classification Including Texture Features

Summary

A multivariate criterion is used to estimate the quality of landuse classification. Spectral bands and textural features are combined in the classification process. A trace value (5) derived from the covariance matrices of each class (3) and covariance matrix of the class means (4) is applied as discriminant for the classes. An example demonstrates the method and its use for data reduction.

Fig.6.1 presents a trace value for many variations of data. Classification results for data with and without texture are shown in fig.6.2.