

Próba numerycznej klasyfikacji treści wielospektralnych obrazów cyfrowych

1. Wprowadzenie

Fotografując przez selektywne filtry optyczne (tzn. przepuszczające promieniowanie elektromagnetyczne tylko o określonej długości fali) otrzymujemy tzw. wyciągi spektralne. Jeśli kamera wyposażona jest w kilka obiektywów i na każdym jest założony inny filtr, to zarejestrujemy kilka wyciągów spektralnych – będzie to zdjęcie wielospektralne. Jeśli na powierzchni zdjęcia wydzieli się elementarne powierzchnie – tzw piksele- (np. o wymiarach $50 \times 50 \mu\text{m}$), dla każdej pomierzy się gęstość optyczną i będzie się ją zapisywać np. na nośniku magnetycznym, to uzyskamy cyfrową postać zdjęcia.

Obraz cyfrowy można także uzyskać na drodze rejestracji elektronicznej. Takie rozwiązanie zastosowane jest w systemach skanerowych, zainstalowanych na satelitach obrazujących Landsat, SPOT i innych.

Skaner (ściśle zainstalowane w nim detektory) mierzy ilość energii promienistej odbitej lub emitowanej przez piksele terenowe (np. fragment pola o wymiarze $10 \times 10 \text{ m}$) w określonym przedziale widma elektromagnetycznego. Mierzona energia nazywana jest odpowiedzią spektralną określonych pikseli.

Obraz cyfrowy jest to zapisany na komputerowym nośniku danych zbiór odpowiedzi spektralnych, przyporządkowanych pikselom terenowym. Zbiór taki można sobie wyobrazić jako tablicę dwuwymiarową zawierającą I linii, z których każda składa się z J pikseli. Jeśli rejestracja dotyczyła kilku przedziałów widma (kanałów), to otrzymujemy wielospektralny obraz cyfrowy (będzie to teraz tablica trójwymiarowa $I \times J \times K$, gdzie K jest liczbą kanałów spektralnych).

Każdy piksel na obrazie wielospektralnym scharakteryzowany jest nie przez jedną lecz kilka (K) odpowiedzi spektralnych. Dzięki temu skuteczniej można sklasyfikować obraz, czyli wydzielić w nim różne obiekty, np. zabudowania, lasy, pola, rzeki, itp. (tzw. klasy). Klasyfikację przeprowadza się różnymi metodami. W następnym punkcie przedstawiono ogólne zasady tzw. klasyfikacji nadzorowanej.

2. Klasyfikacja nadzorowana

Zasadniczą cechą klasyfikacji nadzorowanej jest konieczność wyświetlenia obrazu na ekranie monitora komputera oraz potrzeba posiadania elementarnej wiedzy o danym obszarze (z reguły korzysta się z dostępnej mapy topograficznej). Na obrazie trzeba zaznaczyć tzw. „próbki” poszczególnych obiektów: np. mała powierzchnia rozpoznana jest jako las iglasty, itd. Takie próbki będą podstawą do „nauczenia” komputera, czym charakteryzują się poszczególne rozpoznawane obiekty (próbki te nazywa się inaczej „polami treningowymi”). Odpowiedni program klasyfikacyjny obliczy na podstawie każdej próbki parametry statystyczne każdego obiektu. Następnie przystępuje do analizy całego obszaru (piksel po pikselu), będzie badał, czy aktualny reprezentuje las, pole, czy też inny obiekt. Należy podkreślić, że wspomniane próbki zawierają kilkadziesiąt czy kilkaset pikseli (np. prostokąt 10×10 pikseli), natomiast cały obraz ma wymiar np. 3000×3000 pikseli.

W następnym punkcie przedstawiono jeden z najprostszych algorytmów klasyfikacyjnych jaki stosuje się w metodzie klasyfikacji nadzorowanej.

3. Klasyfikator prostopadłościenny – algorytm

Założmy (dla uproszczenia) że:

- będziemy analizować obraz zawierający dwa kanały spektralne czyli tablicę o rozmiarze $I \times J \times 2$ (patrz punkt 1),
- przeprowadzono już wybór pól treningowych dla wszystkich wyróżnionych klas (obiektów).

Dla każdej klasy należy na podstawie próbki określić:

- wartość średnią odpowiedzi spektralnych

$$S_1 = \frac{1}{L} \sum_1^L P_{L1}$$

$$S_2 = \frac{1}{L} \sum_1^L P_{L2}$$

gdzie:

S_1, S_2 – średnie wartości jasności dla kanału 1 i 2

P_{L1}, P_{L2} – odpowiedzi spektralne znajdujące się e „próbce” dla kanału 1 i 2

L – liczebność próbki (ilość pikseli)

- wariancję (W) i odchylenie standardowe (δ)

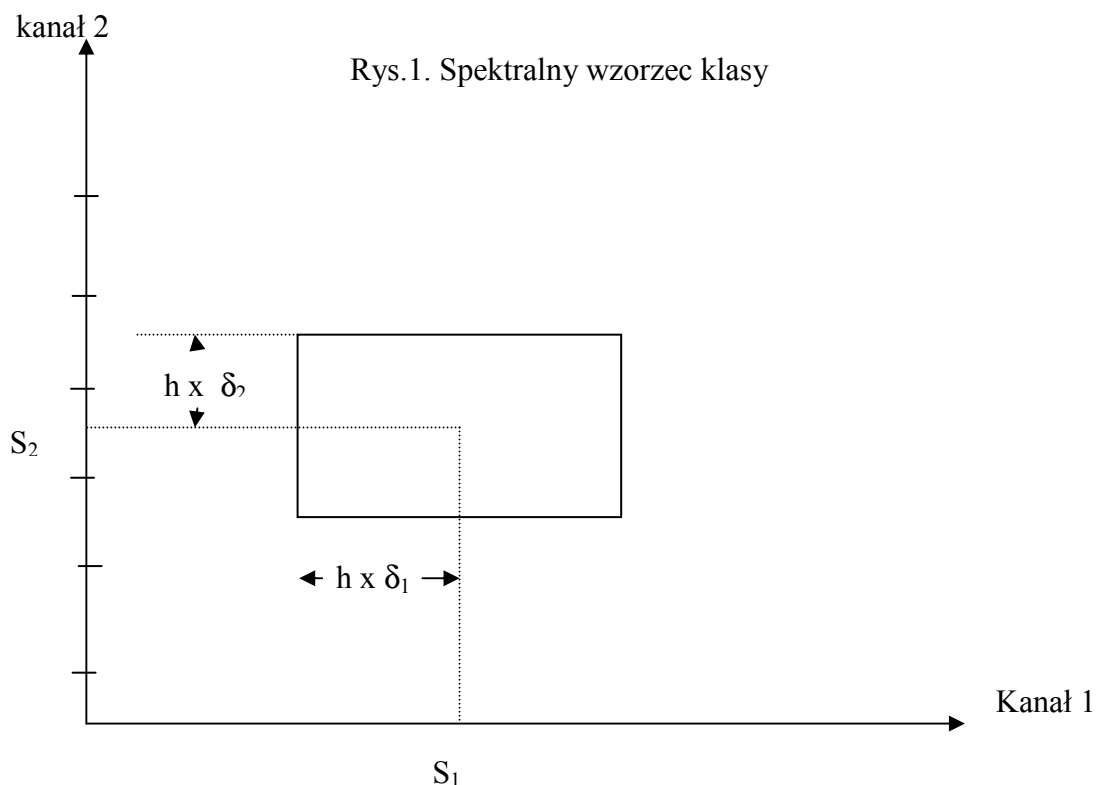
$$W_1 = \frac{1}{L-1} \sum_1^L (P_{L1} - S_1)^2$$

$$W_2 = \frac{1}{L-1} \sum_1^L (P_{L2} - S_2)^2$$

$$\delta_1 = \sqrt{W_1}$$

$$\delta_2 = \sqrt{W_2}$$

Te wielkości pozwalają zdefiniować spektralne wzorce poszczególnych klas w sposób przedstawiony na poniższym rysunku:



Jeśli przyjmie się wielkość $h=2$, to wówczas poziom ufności przydziału piksela do klasy wynosi 95%.

Po zdefiniowaniu wzorców wszystkich klas następuje końcowy etap: przydzielenie pikseli do poszczególnych klas. Polega ono na badaniu, w którym prostokacie (wzorcu) znajduje się dany piksel. W przypadku, gdy liczba kanałów spektralnych K jest większa niż 2, wówczas bada się przynależność do wnętrza K -wymiarowego prostopadłościannu (stąd nazwa: klasyfikator prostopadłościenny).

4. Przykładowe przeprowadzenie klasyfikacji.

Dane, które otrzymują studenci zostały ułożone sztucznie i obejmują:

- próbki czterech klas (A, B, C, D), każda jest prostokątnym fragmentem obrazu o wielkości 6x5 pikseli ($L=30$)
- obraz podlegający klasyfikacji o wielkości 10x10 pikseli.

Każdy piksel reprezentowany jest przez dwie liczby całkowite, symulujące odpowiedzi spektralne w umownych kanałach 1 i 2 (górna liczba-kanał 1).

Klasyfikację należy przeprowadzić według algorytmu opisanego w pktcie 3.

Po obliczeniu parametrów S i δ wykonuje się graficzne zestawienie wzorców klas (na jednym wykresie należy narysować prostokątne wzorce wszystkich klas – porównaj Rys.1). Najlepiej do tego celu użyć papieru kratkowanego formatu A4. Następnie przyporządkowuje się 100 pikseli podanego obrazu w stosunku do klas A, B, C, D (czyli bada się przynależność do wnętrza wzorców tych klas). Efektem jest tablica o wymiarze 10x10 elementów, czyli podobna do klasyfikowanego obrazu ale zawierająca w poszczególnych „okienkach” wartości A, B, C, D.

W trakcie klasyfikacji mogą zachodzić dwa szczególne przypadki:

- analizowany piksel należy do wnętrza dwóch (lub więcej) wzorców klas; należy go przyporządkować do tej klasy, której środek leży bliżej tego piksela,
- analizowany piksel nie należy do wnętrza żadnego wzorca; określamy go jako „niesklasyfikowany” – litera N.