

Streszczenie rozprawy doktorskiej

„New methods for hyperspectral image classification”

(„Nowe metody klasyfikacji obrazów hiperspektralnych”)

mgr inż. Michał Romaszewski

Instytut Informatyki Teoretycznej i Stosowanej Polskiej Akademii Nauk

Niniejsza rozprawa doktorska podejmuje tematykę zastosowania metod uczenia maszynowego do klasyfikacji obrazów hiperspektralnych. Systemy obrazowania hiperspektralnego (*ang. hyperspectral imaging, HSI*) zwane także systemami spektroskopii obrazowej (*ang. imaging spectroscopy*) rejestrują obraz w postaci setek wąskich pasm zwanych także kanałami, zwykle w zakresie od 400nm do 2500nm widma fali elektromagnetycznej, co stanowi zakres światła widzialnego i bliskiej podczerwieni (*ang. visible and near-infrared, VNIR*) oraz krótkiej podczerwieni (*ang. short-wavelength infrared, SWIR*). Dane hiperspektralne pozwalają na detekcję, identyfikację i ocenę zmian stanu obrazowanych substancji, wykorzystując fakt że substancje te w różny sposób odbijają, absorbują albo emitują promieniowanie elektromagnetyczne, w zależności od swojego składu chemicznego oraz tekstury powierzchni.

Problem hiperspektralnej klasyfikacji zdefiniować można w następujący sposób: mając dany zbiór przykładów tzn. pikseli hiperspektralnych oraz zbiór klas odpowiadających materiałom na obrazie, należy przypisać każdemu pikselowi etykietę jednej z klas. Klasyfikacja obrazów hiperspektralnych jest złożonym problemem; wynika to z faktu, że obrazy te są duże, wielowymiarowe, koszt uzyskania etykiet danych treningowych jest znaczący, a w danych występują niekorzystne zjawiska np. obecność szumu o złożonej strukturze. Bogactwo zastosowań obrazów hiperspektralnych oraz liczne wyzwania badawcze stanowią motywację dla rozwoju nowych metod ich klasyfikacji. Jednymi z najskuteczniejszych metod do klasyfikacji obrazów hiperspektralnych są algorytmy wykorzystujące uczenie częściowo nadzorowane oraz uczenie wielowidokowe.

Uczenie częściowo nadzorowane polega na wykorzystaniu do trenowania klasyfikatora zarówno danych o znanych etykietach jak i danych bez etykiet. Uczenie wielowidokowe zakłada, że zbiór cech danych da się podzielić na rozłączne podzbiory, przetwarzane różnymi metodami; wyniki tych metod

są potem łączone w celu uzyskania końcowego wyniku. Zbadanie wielowidokowych algorytmów klasyfikacji hiperspektralnej było celem tej rozprawy doktorskiej. Tezą tej rozprawy jest, że **wykorzystanie uczenia wielowidokowego i częściowo nadzorowanego w algorytmach klasyfikacji zwiększa precyzję klasyfikacji obrazów hiperspektralnych.**

W wyniku przeprowadzonych badań:

1. Opracowano nowe algorytmy klasyfikacji hiperspektralnej.
2. Dokonano teoretycznej i eksperymentalnej analizy wybranych wielowidokowych, częściowo nadzorowanych algorytmów klasyfikacji.

Pracę podzielono na sześć rozdziałów.

Rozdział pierwszy stanowi wprowadzenie do tematyki obrazowania hiperspektralnego oraz definiuje problem klasyfikacji w oparciu o uczenie wielowidokowe i częściowo nadzorowane.

Algorytm wykorzystujący uczenie wielowidokowe i częściowo nadzorowane do klasyfikacji danych hiperspektralnych przedstawiony został w rozdziale drugim. Algorytm ten oparty jest o podejście zwane współuczniem (*ang. co-training*), w którym dwa procesy klasyfikują dane w oparciu o rozłączne zbiory cech, a następnie zbiór treningowy każdego z nich jest rozszerzany o podzbiór przykładów sklasyfikowanych przez drugi proces. Inspiracją dla przedstawionego algorytmu była także metoda śledzenie-uczenie-detekcja (*ang. tracking-learning-detection, TLD*) służąca do śledzenia obiektów w strumieniach wideo. Przedstawiony algorytm wykorzystuje dwa procesy zwane P- i N-ekspertem, które oceniają przynależność pikseli do klas; P-ekspert stawia hipotezę o przestrzennej ciągłości pikseli należących do każdej klasy a N-ekspert zakłada spektralne podobieństwo pikseli w klasie. Łącząc oceny ekspertów algorytm w sposób iteracyjny klasyfikuje zbiór danych. Algorytm ten przetestowany został na sześciu różnorodnych zbiorach danych reprezentujących przewidywane zastosowania oraz został porównany z wiodącymi metodami w dziedzinie. Wyniki eksperymentów pokazują że przedstawiony algorytm pozwala na precyzyjną klasyfikację obrazów hiperspektralnych.

Wnioski z rozdziału drugiego wykorzystane zostały w rozdziale trzecim, gdzie dokonano analizy teoretycznej wybranych własności wielowidokowych, częściowo nadzorowanych algorytmów klasyfikacji. Analizę tę przeprowadzono w oparciu o zaproponowaną rodzinę algorytmów grafowych. W rozdziale zaproponowano reprezentację wielowidokowego zbioru danych w postaci

ciągu nieskierowanych grafów ważonych oraz zdefiniowano problem wielowidokowej, częściowo nadzorowanej klasyfikacji na takim zbiorze danych. Zaproponowano również rodzinę modelowych algorytmów opartych o błędzenie losowe po grafie, takich, że własności teoretyczne tych algorytmów ułatwiają ich analizę. Zdefiniowano pojęcie grafu łączonego oraz udowodniono, że dla zaproponowanych algorytmów warunkiem koniecznym zakończenia klasyfikacji, tzn. sytuacji w której algorytm przypisuje etykiety wszystkim przykładom w zbiorze danych jest, aby każdy przykład bez etykiety był połączony z przykładem treningowym w grafie łączonym. Pokazano że w wyniku podziału grafu łączonego na czyste składowe spójne, tzn. składowe spójne o węzłach należących do jednej klasy, jeśli w każdej czystej składowej spójnej znajduje się przynajmniej jeden przykład treningowy, to zaproponowane algorytmy bezbłędnie sklasyfikują taki zbiór danych. Udowodniono również warunek konieczny i wystarczający do bezbłędnej klasyfikacji zbioru danych przez zaproponowane algorytmy.

Wybrane wyniki teoretyczne z rozdziału trzeciego przetestowane zostały w scenariuszach klasyfikacji hiperspektralnej w rozdziale czwartym. Zdefiniowana została specjalna miara warunku wystarczającego, pozwalająca na sprawdzenie założeń warunku koniecznego i wystarczającego do bezbłędnej klasyfikacji przez zaproponowaną rodzinę algorytmów. Wykorzystując tą miarę pokazano, że precyzję klasyfikacji można zwiększyć poprzez zastosowanie uczenia wielowidokowego, nałożenie ograniczeń na zbiór danych treningowych lub ograniczenie liczby klasyfikowanych w danej iteracji przykładów. Przetestowano także zdefiniowany w poprzednim rozdziale algorytm w scenariuszu klasyfikacji hiperspektralnej. Uzyskane wyniki wskazują, że pod względem precyzji klasyfikacji danych hiperspektralnych algorytm ten dorównuje lub przewyższa standardowe klasyfikatory takie jak maszyny wektorów wspierających (*ang. Support Vector Machines, SVM*) jednak, ze względu na uproszczenia mające ułatwić jego analizę teoretyczną, nie dorównuje on algorytmowi zaproponowanemu w rozdziale drugim.

Celem rozdziału piątego niniejszej rozprawy była analiza zastosowania proponowanego w poprzednich rozdziałach podejścia do klasyfikacji w rozwiązywaniu różnorodnych problemów badawczych związanych z przetwarzaniem danych hiperspektralnych. Analizy dokonano w oparciu o trzy prace dotyczące klasyfikacji i detekcji hiperspektralnej. Pokazano że proponowane podejście może być etapem pośrednim bardziej skomplikowanego algorytmu służącego do rozszerzania zbiorów treningowych; Przedstawiono, jak zaobserwowane w rozdziale drugim własności opisanego tam algorytmu mogą być

wykorzystane do wspomagania procesu hiperspektralnej detekcji pozostałości gazów prochowych (*ang. gunshot residue, GSR*); Zaproponowano sposób połączenia przedstawionego algorytmu klasyfikacji z metodą selekcji kanałów spektralnych w oparciu o analizę wielowymiarowych kumulant wyższych rzędów (*ang. higher order multivariate cumulants, HOMC*).

Podsumowanie prac przedstawiono w rozdziale szóstym tej rozprawy. Uzyskane wyniki teoretyczne i eksperymentalne wspierają tezę że wykorzystanie uczenia wielowidokowego i częściowo nadzorowanego w algorytmach klasyfikacji zwiększa precyzję klasyfikacji obrazów hiperspektralnych.