

Optymalizacja architektur sieci głębokiego uczenia dla klasyfikacji obrazów hiperspektralnych

Kamil Książek

*Institut Informatyki Teoretycznej i Stosowanej
Polskiej Akademii Nauk
44-100 Gliwice, Polska*

*Katedra Inżynierii i Analizy Eksploracyjnej Danych
Wydział Automatyki, Elektroniki i Informatyki
Politechniki Śląskiej
44-100 Gliwice, Polska*

kksiazek@iitis.pl, kamil.ksiazek@polsl.pl

Promotor: dr hab. inż. Przemysław Głomb

Promotor pomocniczy: dr Krisztián Búza

Streszczenie

W ostatnich latach uczenie głębokie osiągnęło niekwestionowany sukces w wielu dziedzinach nauki, m.in. w klasyfikacji obrazów hiperspektralnych. Obrazy te są uzyskiwane przy pomocy czujników kamery hiperspektralnej, które przechwytyją dane w dziesiątkach lub setkach wąskich pasm dla każdego piksela z różnych zakresów widma elektromagnetycznego. Mierzą one energię w zakresie światła widzialnego, a także bliskiej i dalekiej podczerwieni. Obrazowanie hiperspektralne znajduje zastosowanie w nieinwazyjnej klasyfikacji substancji, m.in. w geologii, rolnictwie precyzyjnym, monitorowaniu środowiska, hydrologii oraz wojskowości.

W tej pracy skupiamy się na problemie optymalizacji sieci głębokiego uczenia w klasyfikacji danych hiperspektralnych. Z powodu różnorodności i złożoności architektur, dobór oraz konfiguracja sieci dla danego problemu stanowią wyzwanie. Jako środowisko testowe w zadaniu optymalizacji sieci

neuronowych wybraliśmy problem klasyfikacji krwi i substancji krwiopodobnych na zbiorze danych złożonym z obrazów hiperspektralnych. Zastosowaliśmy kilka nowoczesnych architektur, tj. jedno-, dwu- i trójwymiarowe sieci splotowe, sieć rekurencyjną opartą na komórkach GRU oraz wielowarstwowy perceptron. Zaprojektowaliśmy dwa różne scenariusze eksperymentów, czyli najczęściej wykorzystywany scenariusz uczenia transduktywnego (ang. *Hyperspectral Transductive Classification*), w którym próbki zarówno w zbiorze treningowym jak i testowym pochodzą z jednego obrazu oraz bardziej realistyczny scenariusz uczenia induktywnego (ang. *Hyperspectral Inductive Classification*), w którym zbiór testowy pochodzi z innego źródła niż zbiór treningowy. W scenariuszu induktywnym oceniliśmy również wpływ różnych substancji tła oraz dni akwizycji obrazów na wydajność sieci. Zaobserwowaliśmy, że w scenariuszu transduktywnym dokładność klasyfikacji wszystkich testowanych metod przekraczała 90%, podczas gdy w scenariuszu induktywnym była ona znacznie niższa i wahała się między 57,2 a 99,5%. Co więcej, w niektórych przypadkach, bardziej złożone metody jak sieci splotowe, były mniej wydajne niż wielowarstwowy perceptron. Zauważyliśmy również problem ze stabilnością sieci dla jednej z architektur stosowanych w eksperymentach. Problem ten został rozpatrzony w kolejnych rozdziałach i doprowadził do badań nt. zanikającego gradientu, a w konsekwencji do metod reinicjalizacji sieci.

Jednym z głównych ograniczeń wydajności sieci w scenariuszu induktywnym jest obecność pikseli zawierających mieszaniny widm różnych substancji. Dlatego do dalszych badań wybraliśmy jedną z gałęzi sieci neuronowych, tj. liniowe autokodery. Są one uczone bez etykiet, lecz pomimo ich prostoty, mogą osiągać konkurencyjne wyniki. Przeprowadziliśmy serię eksperymentów rozmieszczenia spektralnego, w których dokonywano rekonstrukcji oryginalnych widm substancji. Zaobserwowaliśmy, że w niektórych przypadkach sieci trenowane z użyciem jednego zestawu hiperparametrów osiągają różne poziomy wydajności. Przeprowadziliśmy szerokie badania statystyczne, które potwierdziły istotne znaczenie inicjalizacji wag na końcowy błąd rekonstrukcji sieci. Co więcej, zidentyfikowaliśmy problem martwych aktywacji w sieciach korzystających z funkcji aktywacji ReLU, związany z dużą liczbą nieaktywnych neuronów. W niektórych sytuacjach zjawisko to utrudnia, a nawet uniemożliwia prawidłowy trening sieci. Zaproponowaliśmy trzy metody reinicjalizacji sieci, które łagodzą negatywne skutki martwych aktywacji. W oparciu o wartości progowe współczynników martwych aktywacji dokonujemy reinicjalizacji podzbioru lub wszystkich wag sieci, w zależności od wybranej metody reinicjalizacji. Potwierdzamy, że dla eksperymentów z użyciem danych hiperspektralnych proponowane metody zwiększają wydajność sieci. Oceniliśmy również skuteczność tych podejść dla zbioru danych

MNIST. Zaobserwowane wyniki prowadzą do wniosku, że metody reinicjalizacji sieci są wydajnym rozwiązaniem i zmniejszają błąd rekonstrukcji sieci, zwłaszcza dla nieoptymalnych zestawów hiperparametrów.

Omawiana rozprawa stanowi wkład w dyskusję nt. optymalizacji sieci głębokiego uczenia do klasyfikacji danych hiperspektralnych poprzez obszerne badania nowoczesnych architektur. Co więcej, diskutowany w niej jest problem stabilności sieci i proponowane są trzy metody reinicjalizacji sieci, aby złagodzić rozpoznane zjawisko martwych aktywacji.