


Głębokie uczenie z danych strukturalnych

W dobie szybkiego rozwoju telekomunikacji, finansów, czy medycyny, ogromne ilości danych są generowane w sposób ciągły. Do ich przetwarzania oraz analizowania można wykorzystać techniki uczenia maszynowego. Głębokie sieci neuronowe są obecnie najważniejszą klasą systemów uczących się, które są w stanie rozwiązać skomplikowane problemy. Jednakże, w najprostszym przypadku sieci neuronowe mogą przetwarzać jedynie dane reprezentowane jako wektory o jednakowym rozmiarze.

W praktyce, często mamy do czynienia z danymi strukturalnymi, które nie mogą być reprezentowane w powyższej formie wektorowej:

- W przetwarzaniu języka naturalnego, dokumenty składają się z ciągów różnej długości.
- W cheminformatyce, związki chemiczne reprezentowane są przez grafy.
- W wizji komputerowej, obrazy to zbiory różnej wielkości.
- W naukach społecznych, dane to skomplikowane sieci zależności.

Jako że nie jest możliwe uczenie typowych sieci na danych strukturalnych, to dodatkowe narzędzia są projektowane. Każdy nowy typ danych powoduje nietrywialne problemy związane z przetwarzaniem przez sieć, co jest bardzo problematyczne w praktyce. W naszej opinii, obecne metody są niewystarczające do zachowania całej informacji zawartej w skomplikowanym opisie danych strukturalnych.



(a) Graf związku chemicznego.



(b) Sieć reprezentująca skomplikowane zależności

Celem projektu jest konstrukcja teoretycznie uzasadnionej metodologii, która pozwoli sieciom neuronowym w konsystentny sposób przetwarzać dowolne typy danych. Cel projektu jest zgodny z obecnymi trendami w uczeniu maszynowym i w konsekwencji może mieć wpływ na rozwój tej dziedziny nauki. W szczególności, wyniki projektu będą miały konsekwencje w przetwarzaniu języka naturalnego oraz wizji komputerowej, które są najczęstszymi obszarami stosowania głębokich architektur.

W ramach projektu, skonstruujemy generyczne podejście, które będzie mogło być stosowane do różnorodnych danych strukturalnych. Skupimy się na teoretycznym uzasadnieniu podejścia. Ponadto, zweryfikujemy jego przydatność w problemach praktycznych takich jak: klasyfikacja dokumentów, rekonstrukcja obrazów, przewidywanie aktywności związków chemicznych.