

# Deep learning applications in biomedical engineering - streszczenie

Konrad Duraj

Jednym z pierwszych, powszechnie wykorzystywanych algorytmów sztucznej inteligencji były tzw. "*systemy eksperckie*". Takie systemy bardzo często bazowały na logice rozmytej. Aby utworzyć system inferencji logiką rozmytą, naukowcy muszą wpiery stworzyć tzw. "*bazę wiedzy*" - jest to twór, reprezentujący wiedzę domenową, pochodzącą od ekspertów. Korzystając z takiej bazy, naukowcy są w stanie stworzyć zestaw reguł rozmytych, które opisują zależność pomiędzy cechami podawanymi na wejście takiego systemu, a jego wyjściem. Z jednej strony, systemy eksperckie są często opisywane jako transparentne, łatwe do implementacji i użytkowania oraz sterowalne i dostrajalne. Z drugiej strony są one unikatowe dla danego problemu i domeny, kosztowne do wypracowania oraz nie pozwalają na stworzenie nowej wiedzy dotyczącej danego problemu. Aby stworzyć system inferencji rozmytej należy:

- stworzyć bazę wiedzy - akwizycja wszystkich niezbędnych informacji dotyczących danego problemu,
- stworzyć proces ekstrakcji cech - polega na wyznaczeniu cech, z danych w surowej postaci (obrazy, audio, itp.), które mogą okazać się przydatne w procesie budowania systemu inferencji,
- stworzenie systemu inferencji rozmytej.

Uczenie maszynowe jest alternatywną metodologią budowania rozwiązań z zakresu sztucznej inteligencji. Polega ono na zebraniu dużej ilości, oznaczonych danych opisujących dany problem i stworzeniu modelu statystycznego, zdolnego do przetworzenia cech wejściowych i konwersji ich na daną klasę/kategorię. Aby stworzyć model uczenia maszynowego należy podjąć następujące kroki:

- zebranie zbioru danych i jego annotacja,
- utworzenie procesu ekstrakcji cech,
- selekcja algorytmu - zastępuje proces ręcznego tworzenia funkcji mapującej.

Uczenie głębokie jest pójściem o jeden krok naprzód, poprzez pozwolenie algorytmowi dokonania procesu selekcji cech, odrzucamy jakąkolwiek transparentność na rzecz automatyzacji ekstrakcji i klasyfikacji cech. Ten paradygmat doprowadził do rewolucji w dziedzinach takich jak wizja komputerowa czy przetwarzanie języka naturalnego. Algorytmy uczenia głębokiego mogą zostać również użyte do przetwarzania danych biomedycznych (prace wymienione w rozprawie), takich jak:

1. Przewidywanie toksyczności molekuł,
2. Rozpoznawania akcji kierowców na drodze, bazując na sygnale EOG,
3. Detekcja uderzeń serca w sygnałach sejsmokardiograficznych,
4. Segmentacja składowych EKG.

Ponadto, niniejsza rozprawa porusza kwestie związane z problematyką we wdrożeniu i bezpiecznym użytkowaniu tych systemów. Jedną z największych wad, w kontekście aplikacji medycznych jest problem transparentności/wyjaśnialności procesu decyzyjnego tych algorytmów. Aby algorytmy głębokiego uczenia zostały wprowadzone jako standardowe systemy wsparcia opieki zdrowotnej, koniecznym jest wypracowanie metody pozwalającej wyjaśnić oraz prześledzić "tok rozumowania" głębokich sieci neuronowych. W niniejszej rozprawie zaproponowany został nowy rodzaj algorytmu, nazwany "*uczeniem reprezentacji rozmytej*", który łączy ze sobą sieci neuronowe oraz systemy inferencji logiką rozmytą. Ten rodzaj algorytmu, bazuje na założeniu, że sieć neuronowa zamiast predykcji powinna na swoim wyjściu podawać wyjaśnienia, które w tym konkretnym przypadku mają formę systemu inferencji logiką rozmytą.