

Sztuczna Inteligencja w medycynie – projekt (instrukcja)

Bożena Kostek

Cel projektu

- Celem projektu jest przygotowanie systemu wnioskowania, wykorzystującego wybrane algorytmy sztucznej inteligencji;
- Nabycie umiejętności pogłębionej analizy danych medycznych.

Zadania projektowe

Projekt obejmuje:

- Wybór i zapoznanie się z wybraną bazą danych medycznych;
- Zapoznanie się z jednostką chorobową i rodzajem danych, które opisują daną chorobę;
- Krytyczną analizę danych zawartych w bazie;
- Wstępne przygotowanie danych (np. parametryzacja, normalizacja, dyskretyzacja danych, redukcja danych wybranymi metodami, np. metoda PCA (*Principle Component Analysis*, metoda głównych składowych));
- Podział danych na zbiory: treningowe, **walidacyjne**, testowe;
- Wybór klasyfikatora/ów (systemu) – z uzasadnieniem;

Zadania projektowe

Projekt obejmuje:

- Klasyfikację zbioru testowego;
- Przedstawienie uzyskanych wyników;
- Analizę uzyskanych wyników (skuteczność – macierz pomyłek, analiza wyników walidacji krzyżowej, inne wskaźniki klasyfikacji);
- Pokazanie dalszych kierunków rozwoju przygotowanego systemu wnioskowania (klasyfikacji danych medycznych) - – krytyczna analiza uzyskanych wyników klasyfikacji;
- W sprawozdaniu pisemnym należy podać odwołania do bibliografii
- Prezentację wyników oraz przygotowanie sprawozdania z przebiegu projektu.

Analiza danych – wskaźniki jakości klasyfikacji

- TP – True Positive – liczba obserwacji poprawnie zaklasyfikowanych do klasy pozytywnej
- TN – True Negative – liczba obserwacji poprawnie zaklasyfikowanych do klasy negatywnej
- FP – False Positive – liczba obserwacji zaklasyfikowanych do klasy pozytywnej podczas, gdy w rzeczywistości pochodzą z klasy negatywnej
- FN – False Negative – liczba obserwacji zaklasyfikowanych do klasy negatywnej podczas, gdy w rzeczywistości pochodzą z klasy pozytywnej

Analiza danych – wskaźniki jakości klasyfikacji

- TPR (True Positive Rate) – określa zdolność klasyfikatora do wykrywania klasy pozytywnej (stanu patologicznego)
- $TPR = TP / (TP + FN)$
- TNR (True Negative Rate) – określa zdolność klasyfikatora do wykrywania klasy negatywnej (stanu normalnego)
- $TNR = TN / (TN + FP)$
- FPR (False Positive Rate) – określa, jak często klasyfikator popełnia błąd, klasyfikując stan normalny jako patologiczny
- $FPR = FP / (FP + TN)$
- FNR (False Negative Rate) – określa, jak często klasyfikator popełnia błąd, klasyfikując stan patologiczny jako normalny

Analiza danych – wskaźniki jakości klasyfikacji

- SE (*sensitivity*, czułość) – określa zdolność klasyfikatora do wykrywania klasy pozytywnej (stanu patologicznego)
- $SE = TP / (TP + FN)$
- SP (*specificity*, specyficzność) – określa zdolność klasyfikatora do wykrywania klasy negatywnej (stanu normalnego)
- $SP = TN / (TN + FP)$
- Przy czym, istnieją takie zależności:
- $SE = TPR$ $1 - SE = FNR$
- $SP = TNR$ $1 - SP = FPR$
- ACC (*Total Accuracy*) – całkowita sprawność klasyfikatora, określa prawdopodobieństwo poprawnej klasyfikacji, czyli stosunek poprawnych klasyfikacji do wszystkich klasyfikacji
- $ACC = (TP + TN) / (TP + TN + FP + FN)$

Zadania projektowe – redukcja danych

- Obsługa wartości pustych (ang. *missing values*, *null values*) oraz oddalonych (ang. *outliers*) jest niezmiernie ważna w procesie redukcji wymiarowości.
- Wiele z metod redukcji wymiarowości albo w ogóle nie zadziała w obecności pustych wartości albo otrzymane wyniki będą zniekształcone poprzez istnienie danych oddalonych.
- Nieuwzględnienie z kolei w analizie eksploracyjnej części danych (odrzuć wierszy ze „złymi” danymi) jest ze statystycznego punktu widzenia dyskusyjne.

Bazy danych medycznych - przykłady

- <http://archive.ics.uci.edu/ml/datasets/Echocardiogram>
- <http://archive.ics.uci.edu/ml/datasets/Heart+Disease>
- <http://archive.ics.uci.edu/ml/datasets/Hepatitis>
- <http://archive.ics.uci.edu/ml/datasets/Liver+Disorders>
- <http://archive.ics.uci.edu/ml/datasets/Lung+Cancer>
- <http://archive.ics.uci.edu/ml/datasets/Breast+Cancer+Wisconsin+%28Diagnostic%29>
- <http://biostat.mc.vanderbilt.edu/wiki/Main/DataSets?CGISESSID=10713f6d891653ddcbb7ddb79cffb79>

Prezentacje projektowe

I prezentacja powinna zawierać:

- Wybór i zapoznanie się z wybraną bazą danych medycznych;
- Zapoznanie się z jednostką chorobową i rodzajem danych, które opisują daną chorobę;
- Wstępne przygotowanie danych (np. parametryzacja, normalizacja, dyskretyzacja danych, redukcja danych wybranymi metodami, np. metoda PCA (*Principle Component Analysis*, metoda głównych składowych));
- Krytyczną analizę danych zawartych w bazie;
- Wybór klasyfikatora/ów/systemu - uzasadnienie

Prezentacje projektowe

II prezentacja powinna zawierać:

- Podział danych na zbiory: treningowe, walidacyjne, testowe;
- Klasyfikację zbioru testowego;
- Przedstawienie uzyskanych wyników;
- Analizę uzyskanych wyników (skuteczność – macierz pomyłek, analiza wyników walidacji krzyżowej, inne wskaźniki klasyfikacji);
- Pokazanie dalszych (możliwych) kierunków rozwoju przygotowanego systemu wnioskowania (klasyfikacji danych medycznych) – krytyczna analiza uzyskanych wyników klasyfikacji.