

U-smile – nowa metoda oceny zmiennej predykcyjnej bez progu decyzyjnego: wizualizacja i interpretacja za pomocą współczynnika rLR




Barbara Więckowska
Katedra i Zakład Informatyki i Statystyki
Uniwersytet Medyczny w Poznaniu

Czym jest metoda U-smile:

To metoda oceny jakości klasyfikacji modeli uczenia maszynowego :

Ocena wizualna:



Ocena liczbowa: współczynniki na 3 poziomach:

- **Overall (level 3)**
ocenia cały model
- **Netto or groups level (level 2)**
ocenia oddzielnie klasę zdarzeń i braku zdarzeń
- **Subgroups level (level1)**
ocenia oddzielnie poprawę/pogorszenie w klasie zdarzeń i braku zdarzeń

Założenia dotyczące algorytmu ML:

1. Model klasyfikacji binarnej

przewiduje jedną z dwóch klas (np. 0 lub 1, Tak/Nie)

2. Uczenie nadzorowane




wymaga oznaczonych danych (z etykietami)

3. Zwraca prawdopodobieństwo zdarzenia


zamiast tylko klasy, podaje prawdopodobieństwo przynależności do klasy (np. $P(y=1 \mid X)$)

Step 1

Probability Generation





$$\frac{\text{orange} \times \text{blue}}{\text{orange} + \text{blue}} = \text{Naive Bayes}$$




Step 2

Probability Quality Assessment




Ocena klasyfikacji modelu ML

Porównanie: badany model vs klasyfikacja losowa



Porównanie klasyfikacji dwóch modeli ML

Porównanie: model nowy vs model referencyjny



LR test


high rLR

model nowy

lepszy niż

model referencyjny


high ΔAUC



DeLong test

Porównanie klasyfikacji dwóch modeli ML

Porównanie: model nowy vs model referencyjny




$rLR = 0\%$

model nowy

podobny do

modelu referencyjnego

$\Delta AUC = 0$



LR test


DeLong test

Co to jest XML?

XML (eXplainable Machine Learning) to podejście w dziedzinie uczenia maszynowego, które kładzie nacisk na zwiększenie przejrzystości, interpretowalności i zaufania do modeli ML.


**Powinniśmy dostarczać informacji
w sposób zrozumiały nie tylko dla specjalisty, ale dla
przeciętnego użytkownika ML**

Różne dane można różnie oceniać:



Żyjemy w świecie emocji i emotikonek

Krótkich komunikatów



		Reszty modelu referencyjnego	
		Reszty modelu nowego poprawiającego przewidywane prawdopodobieństwo	
		Reszty modelu nowego pogarszającego przewidywane prawdopodobieństwo	

Idea stojąca za U-smile



$\{0\}$

Brak zdarzenia



$\{1\}$

Zdarzenie

Zmienna dodana do modelu:

$\{+\}$

Poprawia

$\{-\}$





Pogarsza

$\{-\}$

Pogarsza

$\{+\}$

Poprawia




Oś Y

U-smile interpretacja

Rozmiar Punktu

- $rLR_0^- = \frac{LR_0^-}{LR_{0(max)}}$
- $rLR_0^+ = \frac{LR_0^+}{LR_{0(max)}}$
- $rLR_1^- = \frac{LR_1^-}{LR_{1(max)}}$
- $rLR_1^+ = \frac{LR_1^+}{LR_{1(max)}}$

- $I_0^- = \frac{n_0^-}{n_0}$
- $I_0^+ = \frac{n_0^+}{n_0}$
- $I_1^- = \frac{n_1^-}{n_1}$
- $I_1^+ = \frac{n_1^+}{n_1}$



$$netto_0 = \{^+_0\} - \{-_0\}$$

$$netto_1 = \{^+_1\} - \{-_1\}$$


$$overall = netto_0 + netto_1$$

LR test

———— $p < \alpha$

----- $p > \alpha$

Ocena całościowa i w klasach



Całościowa ocena modelu

overall

*Ocena poszczególnych klas :
braku zdarzeń (0) i zdarzeń (1)*


netto₀

*Zdolność do
wykluczania
zdarzenia*

netto₁

*Zdolność do
potwierdzani
a zdarzenia*

Ocena całościowa i w klasach



Całościowa ocena modelu

AUC

Ocena poszczególnych klas


Punkt odcięcia

swoistość

*Zdolność do
wykluczania
zdarzenia*


czułość

*Zdolność do
potwierdzania
zdarzenia*



Symetria
w ocenie
ilościowej i jakościowej


$$\boxed{netto_0} = \boxed{netto_1}$$



Symetria

w ocenie
ilościowej i jakościowej


$$\boxed{\textit{netto}_0} = \boxed{\textit{netto}_1}$$



Asymetria

w ocenie
jakościowej


$$\boxed{\textit{netto}_0} \neq \boxed{\textit{netto}_1}$$





Asymetria


w ocenie
ilościowej

$$\boxed{\textit{netto}_0} \neq \boxed{\textit{netto}_1}$$












Jeden U-smile


ROC vs ROC_{los}




ROC_1 vs ROC_2




Możliwe kształty wykresu U-smile




p>0.05



p<0.05



p<0.05



Podsumowanie

- Jeden wykres U-smile zamiast jednej krzywej ROC
- Jeden wykres U-smile zamiast porównania dwóch krzywych ROC
- U-smiel nie wymaga punktu odcięcia by ocenić oddzielnie klasę zdarzeń i braku zdarzeń
- Symetria wykresu w intuicyjny sposób wskazuje na podobne znaczenie obu klas (zdarzeń i braku zdarzeń)
- Ocena ilościowa: wysokość uśmiechu i jego kształt (rLR)
- Ocena jakościowa: wielkość punktów wykresu
- Ocena istotności statystycznej: typ linii na wykresie (dotted vs solid)



Dziękuję

Barbara Więckowska
Katedra i Zakład Informatyki i Statystyki
Uniwersytet Medyczny w Poznaniu
bbwieckowska@gmail. com