

# Notatki do wykładów: "Naiwny" klasyfikator Bayesowski

(c) Marcin Sydow

# Naiwny Bayes

Notatki do  
wykładów:  
"Naiwny"  
klasyfikator  
Bayesowski

(c) Marcin  
Sydow

Tu zakładamy na ogół, że wszystkie atrybuty są kategoriyczne. Mamy zbiór treningowy  $T$  składający się z  $N$   $n$ -wymiarowych wektorów atrybutów.

Traktujemy atrybuty  $X_i$  i atrybut decyzyjny  $Y$  jako zmienne losowe

Mamy zaklasyfikować wektor  $x = (x_1, x_2, \dots, x_n)$

Stosujemy wzór Bayesa:

$$P(Y = y | X = x) = \frac{P(X = x | Y = y)P(Y = y)}{P(X = x)}$$

(interpretacja: prawdopodobieństwo tego, że atrybut decyzyjny wynosi  $y$  pod warunkiem, że wartości atrybutów opisane są przez wektor  $x$ )

# Zasada klasyfikatora Bayesa

Notatki do  
wykładów:  
"Naiwny"  
klasyfikator  
Bayesowski

(c) Marcin  
Sydow

Wektorowi  $x$  przydzielimy tę klasę (wartość atrybutu decyzyjnego)  $y$ , dla którego powyższe prawdopodobieństwo jest najwyższe.

Obliczamy więc powyższe wyrażenie dla wszystkich możliwych klas (wartości atrybutu decyzyjnego  $Y$ ) i wybieramy najwyższą wartość prawdopodobieństwa.

Ponieważ wszystkie powyższe porównywane wyrażenia mają ten sam mianownik ( $P(X = x)$ ), więc można go pominąć.

# “Naiwny” klasyfikator Bayesa

Kluczowe dla “naiwnego” klasyfikatora Bayesowskiego jest (“naiwne”) założenie, że atrybuty są parami niezależne, a więc:

$$P(X = (x_1, \dots, x_n) | Y = y) = P(X_1 = x_1 | Y = y) * \dots * P(X_n = x_n | Y = y)$$

Otrzymujemy więc po zastosowaniu powyższego założenia wzór:

$$P(Y = y | X = (x_1, \dots, x_n)) \propto P(X_1 = x_1 | Y = y) * \dots * P(X_n = x_n | Y = y) * P(Y = y)$$

gdzie już bezpośrednio ze zbioru treningowego w prosty sposób można obliczyć oszacowania:

- $P(X_i = x_i | Y = y)$  (proporcja tych przypadków w zbiorze testowym, które mają wartość atrybutu  $X_i = x_i$  wśród przypadków mających wartość atrybutu decyzyjnego  $Y = y$ )
- oraz  $P(Y = y)$  (proporcja przypadków w zbiorze treningowym, które mają wartość atrybutu decyzyjnego  $Y = y$ )

Może się zdarzyć, że w zbiorze uczącym nie występuje żaden przypadek, w którym zachodzi  $X_j = x_j$  oraz  $Y = y$  dla pewnego atrybutu  $j$ .

W takim wypadku oszacowane prawdopodobieństwo  $P(X_j = x_j | Y = y)$  wynosiłoby zero i wyzerowało cały iloczyn, niezależnie od wartości pozostałych prawdopodobieństw  $P(X_i = x_i | Y = y)$ .

Aby tego uniknąć stosuje się tzw. wygładzanie, czyli zapewnienie, że zera zastępowane będą pewną (bardzo małą) wartością kosztem odpowiedniego zmniejszenia pozostałych (niezerowych) prawdopodobieństw dla tego atrybutu.

# Najprostsze wygładzanie

Notatki do  
wykładów:  
"Naiwny"  
klasyfikator  
Bayesowski

(c) Marcin  
Sydow

W najprostszym rodzaju wygładzania, do licznika proporcji dla danego atrybutu i dodajemy zawsze jeden a do mianownika tyle, ile jest różnych możliwych wartości tego atrybutu. W ten sposób zmodyfikowane prawdopodobieństwa sumują się do 1, ale nigdy nie wystąpi 0 nawet jak nie ma takiego przypadku w zbiorze treningowym.

Dziękuję za uwagę