



UNIwersytet PRzyrodniczy we Wroclawiu

## Data Mining Wykład 5

Naiwny klasyfikator Bayes'a

---

---

---

---

---

---

---

---

### Naiwny klasyfikator Bayesa

- Naiwny klasyfikator Bayesa jest klasyfikatorem statystycznym - oparty na twierdzeniu Bayesa
- Niech  $X$  oznacza przykład, którego klasa nie jest znana. Każdy przykład jest reprezentowany w postaci  $n$ -wymiarowego wektora,  $X=(x_1, x_2, \dots, x_n)$
- $P(C|X)$  prawdopodobieństwo a-posteriori (prawdopodobieństwo obliczane na podstawie wyników doświadczenia, czyli częstości), że przykład  $X$  należy do klasy  $C$

UNIwersytet PRzyrodniczy we Wroclawiu

---

---

---

---

---

---

---

---

### Reguła Bayesa

Przykład  $X$  klasyfikujemy jako pochodzący z tej klasy  $C_i$ , dla której wartość  $P(C_i | X)$ ,  $i = 1, 2, \dots, m$ , jest największa.

UNIwersytet PRzyrodniczy we Wroclawiu

---

---

---

---

---

---

---

---

### Naiwny klasyfikator Bayesa - Przykła

- Przykład: Dany zbiór przykładów opisujących wnioski kredytowe klientów banku:

$$P(\text{Ryzyko=niskie} \mid \text{Wiek}=38, \text{Status=rozводnik}, \text{Dochód=niski}, \text{Dzieci}=2)$$

- oznacza prawdopodobieństwo a-posteriori, że klient,  $X=(38, \text{rozводnik}, \text{niski}, 2)$ , składający wniosek kredytowy jest klientem o niskim ryzyku kredytowym (klient wiarygodny)

UNIWERSYTET PRZYRODNICZY WE WROCLAWIU

---

---

---

---

---

---

---

---

---

---

### Twierdzenie Bayesa

- W jaki sposób oszacować prawdopodobieństwo a-posteriori  $P(C|X)$ ?

$$P(C|X) = (P(X|C) * P(C))/P(X),$$

- $P(C)$  oznacza prawdopodobieństwo a-priori wystąpienia klasy  $C$  (tj. prawdopodobieństwo, że dowolny przykład należy do klasy  $C$ ),
- $P(X|C)$  oznacza prawdopodobieństwo a-posteriori, że  $X$  należy do klasy  $C$ ,
- $P(X)$  oznacza prawdopodobieństwo a-priori wystąpienia przykładu  $X$

UNIWERSYTET PRZYRODNICZY WE WROCLAWIU

---

---

---

---

---

---

---

---

---

---

### Naiwny klasyfikator Bayesa (1)

- Dany jest zbiór treningowy  $D$  składający się z  $n$  przykładów
- Załóżmy, że atrybut decyzyjny przyjmuje  $m$  różnych wartości definiując  $m$  różnych klas  $C_i$ ,  $i = 1, \dots, m$
- Niech  $s_i$  oznacza liczbę przykładów z  $D$  należących do klasy  $C_i$
- Klasyfikator Bayesa przypisuje nieznanemu przykładowi  $X$  do tej klasy  $C_i$ , dla której wartość  $P(C_i|X)$  jest największa

UNIWERSYTET PRZYRODNICZY WE WROCLAWIU

---

---

---

---

---

---

---

---

---

---

### Naiwny klasyfikator Bayesa (2)

- Prawdopodobieństwo  $P(X)$  jest stałe dla wszystkich klas - klasa  $C_i$ , dla której wartość  $P(C_i | X)$  jest największa, to klasa  $C_i$ , dla której wartość  $P(X | C_i) * P(C_i)$  jest największa
- Wartości  $P(C_i)$  zastępujemy estymatorami  $s_i/n$  (względną częstością klasy  $C_i$ ), lub zakładamy, że wszystkie klasy mają to samo prawdopodobieństwo  $P(C_1) = P(C_2) = \dots = P(C_m)$

UNIWERSYTET PRZYRODNICZY WE WROCLAWIU

---

---

---

---

---

---

---

---

---

---

### Naiwny klasyfikator Bayesa (3)

- W jaki sposób obliczyć  $P(X|C_i)$ ?
- Dla dużych zbiorów danych, o dużej liczbie deskryptorów, obliczenie  $P(X|C_i)$  będzie bardzo kosztowne
- Wymaga ono oszacowania ogromnej liczby prawdopodobieństw i jest rzędu  $k^p$ , gdzie  $p$  oznacza zmienne, natomiast  $k$  oznacza liczbę wartości tych zmiennych np. dla  $p=30 \rightarrow 2^{30}$  czyli około  $10^9$
- Przyjmując założenie o niezależności atrybutów, możemy przyjąć, że wszystkie zmienne są warunkowo niezależne przy danych klasach. Wówczas możemy zastąpić prawdopodobieństwo warunkowe  $P(X|C_i)$  iloczynem prawdopodobieństw

$$P(X|C_i) = \prod_{j=1}^n P(x_j | C_i)$$

UNIWERSYTET PRZYRODNICZY WE WROCLAWIU

---

---

---

---

---

---

---

---

---

---

### Naiwny klasyfikator Bayesa (4)

- Prawdopodobieństwa  $P(x_1|C_i)$ ,  $P(x_2|C_i)$ , ...,  $P(x_n|C_i)$  można estymować w oparciu o zbiór treningowy następująco:

jeżeli  $j$ -ty atrybut jest atrybutem kategoriowym, to  $P(x_j | C_i)$  estymujemy względną częstością występowania przykładów z klasy  $C_i$  posiadających wartość  $x_j$  dla  $j$ -tego atrybutu,  $(s_{ij}/s_i)$

jeżeli  $j$ -ty atrybut jest atrybutem ciągłym, to  $P(x_j | C_i)$  estymujemy funkcją gęstości Gaussa

$$f(x) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

(zakładając rozkład normalny wartości atrybutów)

UNIWERSYTET PRZYRODNICZY WE WROCLAWIU

---

---

---

---

---

---

---

---

---

---

## Przykład (1)

- Rozważmy Przykład:  
Chcemy dokonać predykcji klasy, do której należy nowy przypadek
  - C1 (kupi\_komputer = 'tak')
  - C2 (kupi\_komputer = 'nie')
- Nowy przypadek:
  - X = (wiek='<=30', dochód='średni', student = 'tak', status='kawaler')
  - Maksymalizujemy wartość  $P(X/C_i) * P(C_i)$ , dla  $i=1,2$

UNIWERSYTET PRZYRODNICZY WE WROCLAWIU

## Przykład (2)

ID	wiek	dochód	student	status	kupi_komputer
1	<=30	wysoki	nie	kawaler	nie
2	<=30	wysoki	nie	zonaty	nie
3	31..40	wysoki	nie	kawaler	tak
4	>40	średni	nie	kawaler	tak
5	>40	niski	tak	kawaler	tak
6	>40	niski	tak	zonaty	nie
7	31..40	niski	tak	zonaty	tak
8	<=30	średni	nie	kawaler	nie
9	<=30	niski	tak	kawaler	tak
10	>40	średni	tak	kawaler	tak
11	<=30	średni	tak	zonaty	tak
12	31..40	średni	nie	zonaty	tak
13	31..40	wysoki	tak	kawaler	tak
14	>40	średni	nie	zonaty	nie

UNIWERSYTET PRZYRODNICZY WE WROCLAWIU

## Przykład (3)

$$P(\text{kupi\_komputer} = \text{'tak'}) = P(C1) = 9/14 = 0.643$$

$$P(\text{kupi\_komputer} = \text{'nie'}) = P(C2) = 5/14 = 0.357$$

$$P(\text{wiek} \leq \text{'30'} \mid \text{kupi\_komputer} = \text{'tak'}) = 2/9 = 0.222$$

$$P(\text{wiek} \leq \text{'30'} \mid \text{kupi\_komputer} = \text{'nie'}) = 3/5 = 0.6$$

$$P(\text{dochód} = \text{'średni'} \mid \text{kupi\_komputer} = \text{'tak'}) = 4/9 = 0.444$$

$$P(\text{dochód} = \text{'średni'} \mid \text{kupi\_komputer} = \text{'nie'}) = 2/5 = 0.4$$

$$P(\text{student} = \text{'tak'} \mid \text{kupi\_komputer} = \text{'tak'}) = 6/9 = 0.667$$

$$P(\text{student} = \text{'tak'} \mid \text{kupi\_komputer} = \text{'nie'}) = 1/5 = 0.2$$

$$P(\text{status} = \text{'kawaler'} \mid \text{kupi\_komputer} = \text{'tak'}) = 6/9 = 0.667$$

$$P(\text{status} = \text{'kawaler'} \mid \text{kupi\_komputer} = \text{'nie'}) = 2/9 = 0.4$$

UNIWERSYTET PRZYRODNICZY WE WROCLAWIU

## Przykład (4)

Korzystając z obliczonych prawdopodobieństw, otrzymujemy:

$$P(X | \text{kupi\_komputer}='tak') = 0.222 * 0.444 * 0.667 * 0.667 = 0.044$$

$$P(X | \text{kupi\_komputer}='nie') = 0.600 * 0.400 * 0.200 * 0.400 = 0.019$$

Stąd:

$$P(X | \text{kupi\_komputer}='tak') * P(\text{kupi\_komputer}='tak') = 0.044 * 0.643$$

$$= \mathbf{0.028}$$

$$P(X | \text{kupi\_komputer}='nie') * P(\text{kupi\_komputer}='nie') = 0.019 * 0.357$$

$$= \mathbf{0.007}$$

Naiwny klasyfikator Bayesa zaklasyfikuje nowy przypadek X do klasy:

**kupi\_komputer = 'tak'**

UNIWERSYTET PRZYRODNICZY WE WROCLAWIU

## Problem „częstości zero”

A co jeżeli dana wartość atrybutu nie występuje dla wszystkich klas?

Przykładowo: wiek='31..40' dla klasy „nie”

– Prawdopodobieństwo wynosi 0, tj.

$$P(\text{wiek}='31..40' | \text{kupi\_komputer}='nie') = 0$$

– A-posteriori prawdopodobieństwo również wynosi 0

Rozwiązanie:

**dodać 1 do licznika wystąpień każdej pary  
<wartość atrybutu – klasa>  
(estymator Laplace'a)**

UNIWERSYTET PRZYRODNICZY WE WROCLAWIU

## Podsumowanie - Naiwny klasyfikator Bayesa

- Założenie o niezależności atrybutów znacznie redukuje koszt obliczeń
- Jeżeli założenie jest spełnione, naiwny klasyfikator Bayesa jest optymalny, tzn. zapewnia najlepszą dokładność klasyfikacji w porównaniu z innymi klasyfikatorami
- Założenie rzadko spełnione w praktyce – jednakże naiwny klasyfikator Bayesa jest zaskakująco dokładny

UNIWERSYTET PRZYRODNICZY WE WROCLAWIU