

# **1. Klasyfikator bayesowski**

dr inż. Urszula Libal

Politechnika Wroclawska

2016

# 1. Pełna informacja probabilistyczna

Rozpoznawany obraz pochodzi z pewnej klasy ze zbioru wszystkich klas

$$\mathcal{M} = \{1, 2, \dots, M\}. \quad (1)$$

Znane są prawdopodobieństwa *a priori* klas oraz funkcje gęstości prawdopodobieństwa w klasach:

klasa 1	klasa 2	...	klasa M
$p_1$	$p_2$	...	$p_M$
$f_1(x)$	$f_2(x)$	...	$f_M(x)$

## 2. Zero-jedynkowa funkcja strat

Zero-jedynkowa funkcja strat  $\mathcal{L}^{0-1}$  przyjmuje dwie wartości

$$\mathcal{L}^{0-1}(C, J) = \begin{cases} 0, & \text{gdy } C = J, \\ 1 & \text{gdy } C \neq J, \end{cases} \quad (2)$$

gdzie  $C$  to klasa, do której zaklasyfikowany został obraz pochodzący z klasy  $J$ .

### 3. Ryzyko dla 0-1 funkcji strat

Ryzyko algorytmu  $\Psi$  dla dowolnej funkcji strat  $\mathcal{L}$  definiujemy następująco

$$\mathcal{R}[\Psi] = \mathbb{E}\{\mathcal{L}(\Psi(X(\omega)), J(\omega))\} \quad (3)$$

$$= \int_{\mathcal{X}} \sum_{j \in \mathcal{M}} \mathcal{L}(i, j) p_j f_j(x) dx \quad (4)$$

$$= \sum_{j \in \mathcal{M}} p_j \sum_{i \in \mathcal{M}} \mathcal{L}(i, j) \int_{\mathcal{D}_x^{(i)}} f_j(x) dx. \quad (5)$$

## 4. Problem klasyfikacji dla dwóch klas

Obszary decyzyjne to

$$\mathcal{D}_X^{(1)} = \{x \in \mathcal{X} : \Psi(x) = 1\}, \quad (6)$$

$$\mathcal{D}_X^{(2)} = \{x \in \mathcal{X} : \Psi(x) = 2\}, \quad (7)$$

takie, że

$$\mathcal{D}_X^{(1)} \cup \mathcal{D}_X^{(2)} = \mathcal{X}, \quad (8)$$

$$\mathcal{D}_X^{(1)} \cap \mathcal{D}_X^{(2)} = \emptyset. \quad (9)$$

W przypadku szczególnym, dla dwóch klas  $\mathcal{M} = \{1, 2\}$  oraz dla 0-1 funkcji strat, ryzyko wynosi

$$\mathcal{R}[\Psi] = p_1 \mathcal{L}^{0-1}(1, 1) \int_{\mathcal{D}_{\mathcal{X}}^{(1)}} f_1(x) dx + p_1 \mathcal{L}^{0-1}(2, 1) \int_{\mathcal{D}_{\mathcal{X}}^{(2)}} f_1(x) dx \quad (10)$$

$$+ p_2 \mathcal{L}^{0-1}(1, 2) \int_{\mathcal{D}_{\mathcal{X}}^{(1)}} f_2(x) dx + p_2 \mathcal{L}^{0-1}(2, 2) \int_{\mathcal{D}_{\mathcal{X}}^{(2)}} f_2(x) dx. \quad (11)$$

Po uproszczeniu

$$\mathcal{R}[\Psi] = p_1 \int_{\mathcal{D}_{\mathcal{X}}^{(2)}} f_1(x) dx + p_2 \int_{\mathcal{D}_{\mathcal{X}}^{(1)}} f_2(x) dx. \quad (12)$$

Funkcja gęstości prawdopodobieństwa cech pochodzących z obu klas  $\{1, 2\}$  to mieszanina gęstości prawdopodobieństw cech w klasach

$$f(x) = p_1 f_1(x) + p_2 f_2(x). \quad (13)$$

Przekształcamy wzór (12)

$$\mathcal{R}[\Psi] = p_1 \int_{\mathcal{X} \setminus \mathcal{D}_{\mathcal{X}^{(1)}}} f_1(x) dx + p_2 \int_{\mathcal{X} \setminus \mathcal{D}_{\mathcal{X}^{(2)}}} f_2(x) dx \quad (14)$$

$$= \int_{\mathcal{X}} f(x) - p_1 \int_{\mathcal{D}_{\mathcal{X}^{(1)}}} f_1(x) dx - p_2 \int_{\mathcal{D}_{\mathcal{X}^{(2)}}} f_2(x) dx \quad (15)$$

$$= 1 - P_c[\Psi] \quad (16)$$

$$= P_e[\Psi]. \quad (17)$$

## 5. Algorytm bayesowski

Algorytm bayesowski  $\Psi^*$  (optymalny) minimalizuje ryzyko średnie

$$\mathcal{R}[\Psi^*] = \min_{\Psi} \mathcal{R}[\Psi]. \quad (18)$$




Dla dwóch klas oraz dla 0-1 funkcji strat minimalizacja ryzyka algorytmu  $\Psi^*$  oznacza minimalizację średniego prawdopodobieństwa błędnej klasyfikacji  $P_e$ , ponieważ

$$\mathcal{R}[\Psi^*] = P_e[\Psi^*] = p_1 \int_{\mathcal{D}_{\mathcal{X}^*(2)}} f_1(x) dx + p_2 \int_{\mathcal{D}_{\mathcal{X}^*(1)}} f_2(x) dx. \quad (19)$$

Jednocześnie warunek ten oznacza maksymalizację średniego prawdopodobieństwa poprawnej klasyfikacji  $P_c$ , ponieważ

$$\mathcal{R}[\Psi^*] = 1 - P_c[\Psi^*] = 1 - \left( p_1 \int_{\mathcal{D}_{\mathcal{X}^*(1)}} f_1(x) dx + p_2 \int_{\mathcal{D}_{\mathcal{X}^*(2)}} f_2(x) dx \right). \quad (20)$$



Rysunek 1. Prawdopodobieństwo błędnej klasyfikacji: a) dowolnego algorytmu, b) algorytmu optymalnego (bayesowskiego).

Algorytm bayesowski sprowadza się do reguły

$$\Psi^*(x) = \begin{cases} 1, & \text{gd } p_1 f_1(x) > p_2 f_2(x), \\ 2, & \text{gd } p_1 f_1(x) < p_2 f_2(x). \end{cases} \quad (21)$$

Z twierdzenia Bayesa prawdopodobieństwo *a posteriori* klasy  $k \in \{1, 2\}$ , gdy zaobserwowano  $x$  wynosi

$$P(k|x) = \frac{p_k f_k(x)}{\sum_{i \in \mathcal{M}} p_i f_i(x)} = \frac{p_k f_k(x)}{f(x)}, \quad (22)$$

gdzie

$$f(x) = p_1 f_1(x) + p_2 f_2(x). \quad (23)$$

## 7. Oszacowanie ryzyka dla $M$ klas

Dla algorytmu bayesowskiego w przypadku rozłączności nośników funkcji gęstości

$$P_e[\Psi^*] = 0. \quad (24)$$

W przypadku  $p_1 f_1(x) = p_2 f_2(x)$  dla  $M = 2$  klas

$$P_e[\Psi_*] = 0.5. \quad (25)$$

W problemie  $M$ -klasowym zachodzi

$$0 \leq P_e[\Psi_*] \leq \frac{M-1}{M}. \quad (26)$$

## Literatura

- [1] M. Kurzyński, *Rozpoznawanie obiektów. Metody statystyczne*. Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław (1997).
- [2] J. Han, M. Kamber, J. Pei, *Data Mining: Concepts and Techniques*, 3rd ed., Elsevier, (2012).

## Zadanie

**Zad.** Wyznacz punkt graniczny oraz ryzyko dla bayesowskiego algorytmu rozpoznawania obrazów, jeżeli funkcja gęstości prawdopodobieństwa cech w klasie 1 wynosi  $f_1$ , w klasie 2 -  $f_2$ , a  $p_1$  i  $p_2$  to prawdopodobieństwa *a priori* wystąpienia klas.

Dane:

$$f_1(x) = \left(-\frac{9}{2}x + 3\right) \mathbb{1}_{\left[0, \frac{2}{3}\right]}$$

$$f_2(x) = (2x) \mathbb{1}_{[0, 1]}$$

a)  $p_1 = \frac{1}{2}, p_2 = \frac{1}{2}$

b)  $p_1 = \frac{2}{3}, p_2 = \frac{1}{3}$