

3. Analiza empirycznego klasyfikatora Bayesa - asymptotyczna zgodność

dr inż. Urszula Libal

Politechnika Wroclawska

2015

1. Teoretyczny i empiryczny klasyfikator bayesowski

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

klasyfikator empiryczny			
klasa 1	klasa 2	...	klasa M
\hat{p}_1	\hat{p}_2	...	\hat{p}_M
$\hat{f}_1(x)$	$\hat{f}_2(x)$...	$\hat{f}_M(x)$
N_1	N_2	...	N_M
$\{X_j^{(1)}\}_{j=1}^{N_1}$	$\{X_j^{(2)}\}_{j=1}^{N_2}$...	$\{X_j^{(M)}\}_{j=1}^{N_M}$

Optymalny klasyfikator bayesowski w przypadku dwóch klas to reguła postaci

$$\Psi^*(x) = \begin{cases} 1, & \text{gdy } p_1 f_1(x) > p_2 f_2(x), \\ 2, & \text{w przeciwnym wypadku.} \end{cases} \quad (1)$$

Empiryczny klasyfikator bayesowski w przypadku dwóch klas ma postać

$$\Psi^*(x) = \begin{cases} 1, & \text{gdy } \hat{p}_1 \hat{f}_1(x) > \hat{p}_2 \hat{f}_2(x), \\ 2, & \text{w przeciwnym wypadku.} \end{cases} \quad (2)$$

2. Histogram jako nieparametryczny estymator funkcji gęstości

Jednym z prostszych nieparametrycznych estymatorów funkcji gęstości prawdopodobieństwa jest odpowiednio przeskalowany histogram

$$\hat{f}(x) = \hat{f}(x; \Delta, N) \quad (3)$$

$$= \frac{1}{N\Delta} \sum_{j=1}^N 1\{x < X_j \leq x + \Delta\} \quad (4)$$

$$= \frac{1}{N\Delta} \#\{x < X_j \leq x + \Delta\}, \quad (5)$$

którego kształt zależy od liczności N zbioru uczącego (próby) $\{X_j\}_{j=1}^N$ oraz szerokości przedziałów Δ .

3. Typy zbieżności probabilistycznych

Definicja 1. Ciąg $(\theta_N)_{N \in \mathbb{N}}$ jest zbieżny z *prawdopodobieństwem 1* (mocno) do θ , jeśli

$$P \left\{ \lim_{N \rightarrow \infty} \theta_N = \theta \right\} = 1. \quad (6)$$

Definicja 2. Ciąg $(\theta_N)_{N \in \mathbb{N}}$ jest zbieżny *według prawdopodobieństwa* (słabo) do θ , jeśli

$$\forall \varepsilon > 0 \lim_{N \rightarrow \infty} P \{ |\theta_N - \theta| < \varepsilon \} = 1. \quad (7)$$

Definicja 3. Ciąg $(\theta_N)_{N \in \mathbb{N}}$ jest zbieżny *według rozkładu* do θ , jeśli

$$\lim_{N \rightarrow \infty} F_N(x) = F(x). \quad (8)$$

Definicja 4. Ciąg $(\theta_N)_{N \in \mathbb{N}}$ jest zbieżny według średniej z potęgą r do θ , jeśli

$$\lim_{N \rightarrow \infty} E|\theta_N - \theta|^r = 0. \quad (9)$$

W szczególności, ciąg $(\theta_N)_{N \in \mathbb{N}}$ jest zbieżny średniokwadratowo do θ , jeśli

$$\lim_{N \rightarrow \infty} E(\theta_N - \theta)^2 = 0. \quad (10)$$

4. Zależności między typami zbieżności probabilistycznych

$$\theta_N \xrightarrow{P_1} \theta \Rightarrow \theta_N \xrightarrow{P} \theta, \quad (11)$$

$$\theta_N \xrightarrow{L_r} \theta \Rightarrow \theta_N \xrightarrow{P} \theta, \quad (12)$$

$$\theta_N \xrightarrow{P} \theta \Rightarrow \theta_N \xrightarrow{D} \theta. \quad (13)$$

5. Zgodność estymatora

Definicja. Estymator θ_N parametru θ nazywamy *zgodnym*, jeśli

$$\forall \varepsilon > 0 \lim_{N \rightarrow \infty} P\{|\theta_N - \theta| < \varepsilon\} = 1. \quad (14)$$

Równoważnie warunek (14) można zapisać

$$\forall \varepsilon > 0 \lim_{N \rightarrow \infty} P\{|\theta_N - \theta| > \varepsilon\} = 0. \quad (15)$$

Zachodzi również

$$\forall \varepsilon > 0 P\{|\theta_N - \theta| > \varepsilon\} \leq \frac{1}{\varepsilon^2} E(\theta_N - \theta)^2. \quad (16)$$

6. Obciążenie i wariancja estymatora

$$E(\theta_N - \theta)^2 = E\theta_N^2 - 2\theta E\theta_N + \theta^2 \quad (17)$$

$$= E\theta_N^2 - (E\theta_N)^2 + (E\theta_N)^2 - 2\theta E\theta_N + \theta^2 \quad (18)$$

$$= \underbrace{E\theta_N^2 - (E\theta_N)^2}_{\text{var}(\theta_N)} + \underbrace{(E\theta_N - \theta)^2}_{\text{bias}^2(\theta_N)} \quad (19)$$

7. Obciążenie estymatora funkcji gęstości

$$E \hat{f}(x) = E \left(\frac{1}{N\Delta} \sum_{j=1}^N 1 \{x < X_j \leq x + \Delta\} \right) \quad (20)$$

$$= \frac{1}{N\Delta} \sum_{j=1}^N E 1 \{x < X_j \leq x + \Delta\} \quad (21)$$

$$= \frac{1}{N\Delta} N E 1 \{x < X_j \leq x + \Delta\} \quad (22)$$

$$= \frac{1}{\Delta} P \{x < X_j \leq x + \Delta\} \quad (23)$$

$$= \frac{F(x + \Delta) - F(x)}{\Delta} \quad (24)$$

$$\neq f(x) \quad (25)$$

8. Wariancja estymatora funkcji gęstości

$$\text{var } \hat{f}(x) = \text{var} \left(\frac{1}{N\Delta} \sum_{j=1}^N 1 \{x < X_j \leq x + \Delta\} \right) \quad (26)$$

$$= \frac{1}{N^2\Delta^2} \sum_{j=1}^N \text{var} 1 \{x < X_j \leq x + \Delta\} \quad (27)$$

$$= \frac{1}{N^2\Delta^2} N \text{var} 1 \{x < X_j \leq x + \Delta\} \quad (28)$$

$$= \frac{1}{N\Delta^2} \left[E 1^2 \{x < X_j \leq x + \Delta\} - (E 1 \{x < X_j \leq x + \Delta\})^2 \right] \quad (29)$$

$$= \frac{1}{N\Delta^2} \left[P \{x < X_j \leq x + \Delta\} - (P \{x < X_j \leq x + \Delta\})^2 \right] \quad (30)$$

$$= \frac{1}{N\Delta^2} \left[F(x + \Delta) - F(x) - (F(x + \Delta) - F(x))^2 \right] \quad (31)$$

$$= \frac{1}{N\Delta} \left(\frac{F(x + \Delta) - F(x)}{\Delta} \right) [1 - (F(x + \Delta) - F(x))] \quad (32)$$

9. Asymptotyczna redukcja obciążenia i wariancji

Dla ustalonego N , przy $\Delta \rightarrow 0$

$$E \hat{f}(x) = \frac{F(x+\Delta) - F(x)}{\Delta} \rightarrow f(x), \quad (33)$$

czyli

$$\text{bias } \hat{f}(x) \rightarrow 0. \quad (34)$$

Wtedy

$$\text{var } \hat{f}(x) = \underbrace{\frac{1}{N\Delta}}_{\rightarrow \infty} \underbrace{\left(\frac{F(x+\Delta) - F(x)}{\Delta} \right)}_{\rightarrow f(x)} \underbrace{[1 - (F(x+\Delta) - F(x))]}_{\rightarrow 1} \rightarrow \infty. \quad (35)$$

Przy jednoczesnym $\Delta \rightarrow 0$ oraz $N\Delta \rightarrow \infty$

$$\text{bias } \hat{f}(x) \rightarrow 0 \quad (36)$$

oraz

$$\text{var } \hat{f}(x) = \underbrace{\frac{1}{N\Delta}}_{\rightarrow 0} \underbrace{\left(\frac{F(x+\Delta) - F(x)}{\Delta} \right)}_{\rightarrow f(x)} \underbrace{[1 - (F(x+\Delta) - F(x))]}_{\rightarrow 1} \rightarrow 0. \quad (37)$$

Wtedy także

$$E(\theta_N - \theta)^2 \rightarrow 0. \quad (38)$$

Histogram dany wzorem (4) jest *asymptotycznie zgodnym estymatorem* funkcji gęstości prawdopodobieństwa przy $N \rightarrow \infty$, jeśli jednocześnie

$$\Delta \rightarrow 0 \tag{39}$$

oraz

$$N\Delta \rightarrow \infty. \tag{40}$$

Szerokość przedziału Δ może być funkcją N , np. $\Delta_N = \frac{1}{\sqrt{N}}$.