

2. Empiryczna wersja klasyfikatora bayesowskiego

dr inż. Urszula Libal

Politechnika Wroclawska

2015

1. Brak pełnej informacji probabilistycznej

Klasyfikator bayesowski wymaga pełnej informacji probabilistycznej, tzn. muszą być znane prawdopodobieństwa *a priori* klas oraz funkcje gęstości prawdopodobieństwa w klasach.

Nieznane rozkłady prawdopodobieństwa w klasach 1, 2, ..., M można estymować na podstawie M ciągów uczących.

Każdy ciąg uczący zawiera N_k obserwacji $\{X_j^{(k)}\}_{j=1}^{N_k}$ z klasy $k \in \{1, 2, \dots, M\}$.

| 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 |

2. Estymacja prawdopodobieństw a priori klas

Prawdopodobieństwa a priori klas estymujemy za pomocą *częstości* ich występowania, tj.

$$\hat{p}_k = \frac{N_k}{N_1 + N_2 + \dots + N_M}. \quad (1)$$

dla każdej klasy $k \in \mathcal{M}$, $\mathcal{M} = \{1, 2, \dots, M\}$.

3. Estymacja funkcji gęstości prawdopodobieństwa

- *Metody parametryczne* - zakładamy pewien rozkład prawdopodobieństwa i estymujemy jego parametry.
- *Metody nieparametryczne* - umożliwiają estymację dowolnego rozkładu.

4. Histogram

Standardowy *histogram* dzieli przestrzeń cech \mathcal{X} na przedziały o szerokości Δ , a następnie zlicza liczbę n_i obserwacji, które wpadły do i -tego przedziału $I_i = (t_i, t_i + \Delta]$, tzn.

$$n_i = \#\{X_j \in I_i\} = \#\{X_j \in (t_i, t_i + \Delta]\} \quad (2)$$


$$= \#\{X_j \leq t_i + \Delta\} - \#\{X_j < t_i\} \quad (3)$$

$$= \sum_{j=1}^N (1\{X_j \leq t_i + \Delta\} - 1\{X_j < t_i\}). \quad (4)$$

Histogram to funkcja schodkowa


$$h(x; \Delta, N) = \sum_i n_i 1_{\{x \in I_i\}}, \quad (5)$$

która w punkcie x należącym do i -tego przedziału przyjmuje wartość n_i
(pozostałe elementy sumy są wtedy zerowe).



Rysunek 1. Przykładowy histogram dla ciągu uczącego o liczności $N = 1000$.

Źródło: opracowanie własne



Rysunek 2. Deska Galtona - przykład nieparametrycznej estymacji funkcji gęstości dla rozkładu normalnego.

Źródło: [2]

5. Nieparametryczna estymacja funkcji gęstości prawdopodobieństwa


Funkcja gęstości prawdopodobieństwa $f(x)$ spełnia warunek

$$\int_{\mathcal{X}} f(x) = 1. \quad (6)$$

Aby histogram estymował funkcję gęstości prawdopodobieństwa, należy go znormalizować poprzez podzielenie liczby n_i obserwacji przez całkowitą liczbę obserwacji N oraz szerokość przedziału Δ .

Nieparametryczny estymator funkcji gęstości prawdopodobieństwa przyjmuje formę:

$$\hat{f}(x) = \hat{f}(x; \Delta, N) = \sum_i \frac{n_i}{N\Delta} 1_{\{x \in I_i\}}. \quad (7)$$



Rysunek 3. Nieparametryczna estymacja gęstości dla różnych szerokości przedziałów histogramu.

Źródło: [1]

5. Empiryczna wersja klasyfikatora bayesowskiego

Korzystając z zasady *plug-in*, wstawiamy do algorytmu bayesowskiego odpowiednie estymatory:

- w miejsce prawdopodobieństw *a priori* wystąpienia klas p_k - ich częstości $\hat{p}_k, k \in \mathcal{M}$,
- w miejsce funkcji gęstości prawdopodobieństwa w klasach $f_k(x)$ - ich nieparametryczne estymatory $\hat{f}_k(x), k \in \mathcal{M}$.

Empiryczny klasyfikator bayesowski w przypadku dwóch klas przyjmuje wtedy postać

$$\Psi^*(x) = \begin{cases} 1, & \text{gd } \hat{p}_1 \hat{f}_1(x) > \hat{p}_2 \hat{f}_2(x), \\ 2, & \text{w przeciwnym wypadku.} \end{cases} \quad (8)$$

Jeżeli w obu klasach przyjęto identyczny podział przestrzeni cech na przedziały I_i , to empiryczny klasyfikator bayesowski w przypadku dwóch klas otrzymuje postać

$$\Psi^*(x) = \begin{cases} 1, & \text{gdy } \frac{N_1}{(N_1+N_2)} \sum_i \frac{n_i^{(1)}}{N_1 \Delta} 1\{x \in I_i\} > \frac{N_2}{(N_1+N_2)} \sum_i \frac{n_i^{(2)}}{N_2 \Delta} 1\{x \in I_i\}, \\ 2, & \text{w przeciwnym wypadku.} \end{cases} \quad (9)$$

Regułę decyzyjną (9) można uprościć. Jeżeli zaobserwowano cechę o wartości x z i -tego przedziału histogramu, tzn. $x \in I_i$, to empiryczny klasyfikator bayesowski bazuje jedynie na licznosciach obserwacji w tym przedziale w klasie 1 i klasie 2

$$\Psi^*(x) = \begin{cases} 1, & \text{gdy } n_i^{(1)} > n_i^{(2)}, \\ 2, & \text{w przeciwnym wypadku.} \end{cases} \quad (10)$$

Przy założeniu, że analizowany obraz

$$x \in (t_i, t_i + \Delta], \quad (11)$$

empiryczny klasyfikator bayesowski przyjmuje ostatecznie postać opartą w jawny sposób o ciągi uczące $\{X_j^{(1)}\}_{j=1}^{N_1}$ oraz $\{X_j^{(2)}\}_{j=1}^{N_2}$:


$$\Psi^*(x) = \begin{cases} 1, & \text{gdy } \sum_{j=1}^{N_1} \left(1 \{X_j^{(1)} \leq t_i + \Delta\} - 1 \{X_j^{(1)} < t_i\} \right) \\ & > \sum_{j=1}^{N_2} \left(1 \{X_j^{(2)} \leq t_i + \Delta\} - 1 \{X_j^{(2)} < t_i\} \right), \\ 2, & \text{w przeciwnym wypadku.} \end{cases} \quad (12)$$

6. Zjawisko pustej przestrzeni

Zjawisko pustej przestrzeni, inaczej zwane przekleństwem wymiarowości,

występuje w przypadku:

- dużej liczby cech (dużego wymiaru zadania $D \gg 1$),
- zbyt małej liczby obserwacji (liczności ciągów uczących N_k w klasach $k \in \mathcal{M}$).



Rysunek 4. Ilustracja przekleństwa wymiarowości, obrazująca wykładniczy wzrost liczby obszarów, na które podzielono przestrzeń cech w zadaniu estymacji nieparametrycznej.

Źródło: [1]

Literatura

- [1] C.M. Bishop, *Pattern Recognition and Machine Learning*, Springer Series: Information Science and Statistics (2006).
- [2] http://pl.wikipedia.org/wiki/Deska_Galtona
- [3] <http://www.youtube.com> (szukaj pod hasłem: *Galton board*)