

Budowa modeli klasyfikacyjnych w oparciu o funkcję odległości w przestrzeni zdarzeń i uogólnienie pojęć probabilistycznych na przestrzenie metryczne

C. Dendek prof nzw. dr hab. J. Mańdziuk

Politechnika Warszawska,
Wydział Matematyki i Nauk Informatycznych

Outline

- 1 Cel prac
- 2 Pojęcia podstawowe
- 3 Klasyfikacja k-NN

Zagadnienia

Cel pracy

- teoretyczne wyprowadzenie miary odległości w przestrzeniach probabilistycznych
- wykorzystanie teorii w praktycznych zastosowaniach klasyfikacyjnych (k -NN)
- znalezienie uogólnień możliwych do zastosowania dla innych klasyfikatorów

Norma trójkątna

Norma trójkątna $T(x, y)$:

- uogólnienie koniunkcji w logice wielowartościowej

- (monotoniczność)

$$\forall a, b, c, d \in [0, 1] \ a \leq b \wedge c \leq d \Rightarrow T(a, c) \leq T(b, d)$$

- (przemienność) $\forall x, y \in [0, 1] \ T(x, y) = T(y, x)$

- (łączność) $\forall x, y, z \in [0, 1] \ T(x, T(y, z)) = T(T(x, y), z)$

- (neutralność względem “prawdy” – liczby 1)

$$\forall x \in [0, 1] \ T(x, 1) = x$$

Rozmyta relacja równoważności

Rozmyta relacja równoważności $R(x, y)$

- $R(1, 1) = R(0, 0) = 1$
- $R(1, 0) = R(0, 1) = 0$

Rozmyta równoważność metryczna

Rozmyta równoważność metryczna R_M

- 1 $\forall_{x,y \in [0,1]} R_M(x, y) = R_M(y, x)$
- 2 $\forall_{x,y \in [0,1]} R_M(x, y) = 1 \Leftrightarrow x = y$
- 3 $R_M(1, 0) = 0$
- 4 $\forall_{x,y,z \in [0,1]} R_M(x, y) \geq T(R_M(x, z), R_M(z, y))$

Rozmyta równoważność metryczna

Rozmyta równoważność metryczna R_M

Dla danej normy trójkątnej można zbudować równoważność metryczną (przy pomocy residuum):

$$\vec{T}(a, b) = \sup_{z \in [0,1]} \{z \mid T(a, z) \leq b\}.$$

$$R_M(a, b) = \overleftarrow{T}(a, b) = \min(\vec{T}(a, b), \vec{T}(b, a)).$$

Odległość rozmytą można wprowadzić jako

$$d_M(x, y) = 1 - R_M(x, y)$$

Wielowymiarowe rozmyte równoważności metryczne

Wielowymiarowe rozmyte równoważności metryczne

Jednowymiarowe równoważności metryczne można łączyć przy wykorzystaniu norm trójkątnych (odległość wielowymiarowa):

$$R_C = T(R_1, \dots, R_n)$$

Kopuły statystyczne

Kopuły statystyczne

1 (zerowalność)

$$\forall \mathbf{u}=(u_1, \dots, u_n) \in [0, 1]^n \min(u_1, \dots, u_n) = 0 \Rightarrow C(\mathbf{u}) = 0$$

2 (minimalność) $\forall \mathbf{u}=(1, \dots, 1, u_k, 1, \dots, 1) \in [0, 1]^n C(\mathbf{u}) = u_k$

3 (n -monotoniczność) wybierając dowolne punkty $x_1, \dots, x_n, y_1, \dots, y_n$ tak, aby $\forall i \in \{1, \dots, n\} 0 \leq x_i < y_i \leq 1$ i oznaczając

- $Q = \{x_1, y_1\} \times \dots \times \{x_n, y_n\}$,
- $\text{sgn}_Q : Q \rightarrow \{0, 1\}, \mathbf{p} = (z_1, \dots, z_n) \mapsto (-1)^{\text{card}\{k \in \{1, \dots, n\} | z_k = x_k\}}$

spełniony jest warunek

$$\sum_{\mathbf{p} \in Q} \text{sgn}_Q(\mathbf{p}) C(\mathbf{p}) \geq 0$$

Kopuły statystyczne

Kopuły statystyczne

- bliskie pojęciu norm trójkątnych (bez przemienności i monotoniczności)
- rozważamy jedynie kopuły monotoniczne
- określają miarę na zbiorze (tak jak dystrybuanty)
- Twierdzenie Sklara:
Dla każdego rozkładu prawdopodobieństwa charakteryzowanego dystrybuantą $F(x_1, \dots, x_n)$ istnieje taka kopuła $C(z_1, \dots, z_n)$, że dla rozkładów brzegowych charakteryzowanych dystrybuantami $F_1(x_1), \dots, F_n(x_n)$ zachodzi

$$F(x_1, \dots, x_n) = C(F_1(x_1), \dots, F_n(x_n)).$$

Miara odległości pomiędzy zdarzeniem losowym i punktem z przestrzeni obserwacji

Odległość probabilistyczna

$$\begin{aligned}d(x; v) &= \int_{F^{-1}(\hat{x}-|\hat{x}-\hat{v}|)}^{F^{-1}(\hat{x}+|\hat{x}-\hat{v}|)} dF(x) = \\ &= \min(1, \hat{x} + |\hat{x} - \hat{v}|) - \max(0, \hat{x} - |\hat{x} - \hat{v}|)\end{aligned}$$

Uogólnienie odległości probabilistycznej: kopuły statystyczne

Uogólnienie odległości probabilistycznej

- odległość probabilistyczna jest jednowymiarową miarą
- poprzez liczenie miar hiperprostokątów

Miara odległości pomiędzy 2 zdarzeniami losowymi

Odległość probabilistyczna

Można wykorzystać normę trójkątną w celu symetryzacji:

$$D(u, v) = 1 - T(1 - d(u; v), 1 - d(v; u)).$$

Specyfika klasyfikatora k-NN

Specyfika klasyfikatora k-NN

- najwyższa “rozdzielczość” dla niewielkich wartości miary odległości
- możliwość zastosowania przybliżeń prawdziwych w otoczeniu 0.

Miary odległości dla klasyfikatora k-NN

Miary odległości dla klasyfikatora k-NN

W pracy wyprowadzono poprzez przybliżanie rozwinięć określonych norm trójkątnych następujące typy łączeń:

- łączenie liniowe
- łączenie ważone
- łączenie oparte o miękkie normy trójkątne
- łączenie w oparciu parametryzowaną t-normę Yagera
- łączenie w oparciu o odległość Mahalanobisa.

Miary odległości dla klasyfikatora k-NN

Miary odległości dla klasyfikatora k-NN

W pracy wyprowadzono następujące typy symetryzacji:

- symetryzacja w oparciu o t-normę maksymalną
- symetryzacja w oparciu o t-normę maksymalną zastosowaną bezpośrednio
- symetryzacja w oparciu o parametryzowaną t-normę Yagera
- symetryzacja w oparciu o t-normę multiplikatywną
- symetryzacja w oparciu o t-normę Łukasiewicza
- symetryzacja w oparciu o wartość oczekiwaną argumentów.

Dziękuję za uwagę

Dziękuję za uwagę