

Ranking - minimalizacja ryzyka wypukłego

Wojciech Rejchel

Wiśła 2009

Opis problemu

- $Z = (X, Y)$, $Z' = (X', Y')$ - niezależne o tym samym rozkładzie
- $X \in \mathcal{X} \subset \mathbb{R}^d$, $Y \in \mathbb{R}$

Opis problemu

- $Z = (X, Y)$, $Z' = (X', Y')$ - niezależne o tym samym rozkładzie
- $X \in \mathcal{X} \subset \mathbb{R}^d$, $Y \in \mathbb{R}$
- X, X' - obserwowane wektory cech
- Y, Y' - nieznanne etykiety

Opis problemu

- $Z = (X, Y)$, $Z' = (X', Y')$ - niezależne o tym samym rozkładzie
- $X \in \mathcal{X} \subset \mathbb{R}^d$, $Y \in \mathbb{R}$
- X, X' - obserwowane wektory cech
- Y, Y' - nieznanne etykiety
- Z jest "lepszy" od Z' , jeśli $Y > Y'$

Opis problemu

- Reguła rangująca $f : \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}$

Opis problemu

- Reguła rangująca $f : \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}$



Przewidujemy $y > y'$, jeśli $f(x, x') > 0$

Opis problemu

- Reguła rangująca $f : \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}$



Przewidujemy $y > y'$, jeśli $f(x, x') > 0$

- Minimalizacja ryzyka

$$L(f) = P(\text{sgn}(Y - Y') f(X, X') < 0) \rightsquigarrow \arg \min_{f \in \mathcal{F}} L(f)$$

Opis problemu

- $Z_1 = (X_1, Y_1), \dots, Z_n = (X_n, Y_n)$ - niezależne kopie Z

Opis problemu

- $Z_1 = (X_1, Y_1), \dots, Z_n = (X_n, Y_n)$ - niezależne kopie Z
- Minimalizacja ryzyka empirycznego

$$L_n(f) = \frac{1}{n(n-1)} \sum_{i \neq j} \mathbb{I}[\text{sgn}(Y_i - Y_j) f(X_i, X_j) < 0]$$

$$\rightsquigarrow \arg \min_{f \in \mathcal{F}} L_n(f)$$

Wypukłe ryzyko

- ψ - wypukła funkcja straty

Wypukłe ryzyko

- ψ - wypukła funkcja straty
- $A(f) = \mathbf{E} \psi[\text{sgn}(Y - Y') f(X, X')] \rightsquigarrow f^* = \arg \min_{f \in \mathcal{F}} A(f)$

Wypukłe ryzyko

- ψ - wypukła funkcja straty
- $A(f) = \mathbf{E} \psi[\text{sgn}(Y - Y') f(X, X')] \rightsquigarrow f^* = \arg \min_{f \in \mathcal{F}} A(f)$
- Minimalizacja ryzyka empirycznego

$$A_n(f) = \frac{1}{n(n-1)} \sum_{i \neq j} \psi_f(Z_i, Z_j),$$

gdzie $\psi_f(z, z') = \psi[\text{sgn}(y - y') f(x, x')]$

Wypukłe ryzyko

- ψ - wypukła funkcja straty
- $A(f) = \mathbf{E} \psi[\text{sgn}(Y - Y') f(X, X')] \rightsquigarrow f^* = \arg \min_{f \in \mathcal{F}} A(f)$
- Minimalizacja ryzyka empirycznego

$$A_n(f) = \frac{1}{n(n-1)} \sum_{i \neq j} \psi_f(Z_i, Z_j),$$

gdzie $\psi_f(z, z') = \psi[\text{sgn}(y - y') f(x, x')]$

- $\rightsquigarrow f_n = \arg \min_{f \in \mathcal{F}} A_n(f)$

Ryzyko i ryzyko względne

- Dla dowolnego $0 < \alpha < 1$

$$P \left(A(f_n) \leq A_n(f_n) + \frac{C(\mathcal{F}, \psi) \ln \alpha^{-1}}{n^\beta} \right) \geq 1 - \alpha$$

Ryzyko i ryzyko względne

- Dla dowolnego $0 < \alpha < 1$

$$P \left(A(f_n) \leq A_n(f_n) + \frac{C(\mathcal{F}, \psi) \ln \alpha^{-1}}{n^\beta} \right) \geq 1 - \alpha$$

-

$$P \left(A(f_n) \leq A(f^*) + \frac{C(\mathcal{F}, \psi) \ln \alpha^{-1}}{n^\beta} \right) \geq 1 - \alpha$$

Ryzyko i ryzyko względne

- Dla dowolnego $0 < \alpha < 1$

$$P \left(A(f_n) \leq A_n(f_n) + \frac{C(\mathcal{F}, \psi) \ln \alpha^{-1}}{n^\beta} \right) \geq 1 - \alpha$$

-

$$P \left(A(f_n) \leq A(f^*) + \frac{C(\mathcal{F}, \psi) \ln \alpha^{-1}}{n^\beta} \right) \geq 1 - \alpha$$

- $\beta = 1/2$ - Clemencon(2008)

Dekompozycja Hoeffdinga



$$A(f) - A_n(f) = 2P_n[A(f) - P\psi_f] - U_n(h_f)$$

Dekompozycja Hoeffdinga



$$A(f) - A_n(f) = 2P_n[A(f) - P\psi_f] - U_n(h_f)$$



$$P\psi_f(z) = \mathbf{E}[\psi_f(Z, Z')|Z = z]$$

$$P_n(g) = \frac{1}{n} \sum_{i=1}^n g(Z_i)$$

Dekompozycja Hoeffdinga

- $$A(f) - A_n(f) = 2P_n[A(f) - P\psi_f] - U_n(h_f)$$

- $$P\psi_f(z) = \mathbf{E}[\psi_f(Z, Z') | Z = z]$$

$$P_n(g) = \frac{1}{n} \sum_{i=1}^n g(Z_i)$$

- $$h_f(Z_1, Z_2) = \psi_f(Z_1, Z_2) - P\psi_f(Z_1) - P\psi_f(Z_2) + A(f)$$

$$U_n(h_f) = \frac{1}{n(n-1)} \sum_{i \neq j} h_f(Z_i, Z_j)$$

Składnik empiryczny

1 Nierówność Tallagrand

Składnik empiryczny

1 Nierówność Tallagrand

- $\exists B > 0 \quad \forall f \in \mathcal{F} \quad \text{Var}[P\psi_f(Z)] \leq B A(f)$

Składnik empiryczny

1 Nierówność Tallagrand'a

- $\exists_{B>0} \forall_{f \in \mathcal{F}} \quad \text{Var}[P\psi_f(Z)] \leq B A(f)$
- $\exists_{B>0} \forall_{f \in \mathcal{F}} \quad \text{Var}[P\psi_f(Z) - P\psi_{f^*}(Z)] \leq B [A(f) - A(f^*)]$

Składnik empiryczny

1 Nierówność Tallagrand'a

- $\exists_{B>0} \forall_{f \in \mathcal{F}} \quad \text{Var}[P\psi_f(Z)] \leq B A(f)$
- $\exists_{B>0} \forall_{f \in \mathcal{F}} \quad \text{Var}[P\psi_f(Z) - P\psi_{f^*}(Z)] \leq B [A(f) - A(f^*)]$

2 Ograniczenie punktów stałych funkcji podpierwiastkowych

Składnik empiryczny

Twierdzenie 1

Dla dowolnych $K > 1$ oraz $0 < \alpha < 1$

$$P \left(A(f_n) \leq \frac{K}{K-1} P_n(P\psi_{f_n}) + D \frac{\ln n + \ln \alpha^{-1}}{n} \right) \geq 1 - \alpha.$$

Zdegenerowany U -proces

- $$\left\{ U_n(h_f) = \frac{1}{n(n-1)} \sum_{i \neq j} h_f(Z_i, Z_j) : f \in \mathcal{F} \right\}$$

Zdegenerowany U -proces

- $$\left\{ U_n(h_f) = \frac{1}{n(n-1)} \sum_{i \neq j} h_f(Z_i, Z_j) : f \in \mathcal{F} \right\}$$

- $$h_f(Z_i, Z_j) = \psi_f(Z_i, Z_j) - P\psi_f(Z_i) - P\psi_f(Z_j) + A(f).$$

Zdegenerowany U -proces

- $$\left\{ U_n(h_f) = \frac{1}{n(n-1)} \sum_{i \neq j} h_f(Z_i, Z_j) : f \in \mathcal{F} \right\}$$

- $$h_f(Z_i, Z_j) = \psi_f(Z_i, Z_j) - P\psi_f(Z_i) - P\psi_f(Z_j) + A(f).$$

- $$\mathbf{E} \left(\sup_{f \in \mathcal{F}} |U_n(h_f)| \right)^p \leq C \mathbf{E}_Z \mathbf{E}_\sigma \left(\sup_{f \in \mathcal{F}} |S_n(h_f)| \right)^p, \quad p \geq 1$$

Zdegenerowany U -proces

$$\left\{ U_n(h_f) = \frac{1}{n(n-1)} \sum_{i \neq j} h_f(Z_i, Z_j) : f \in \mathcal{F} \right\}$$

$$h_f(Z_i, Z_j) = \psi_f(Z_i, Z_j) - P\psi_f(Z_i) - P\psi_f(Z_j) + A(f).$$

$$\mathbf{E} \left(\sup_{f \in \mathcal{F}} |U_n(h_f)| \right)^p \leq C \mathbf{E}_Z \mathbf{E}_\sigma \left(\sup_{f \in \mathcal{F}} |S_n(h_f)| \right)^p, \quad p \geq 1$$

$$S_n(h_f) = \frac{1}{n(n-1)} \sum_{i \neq j} \sigma_i \sigma_j h_f(Z_i, Z_j)$$

Zdegenerowany U -proces

Twierdzenie 2

Dla dowolnej $0 < \alpha < 1$

$$P\left(U_n(h_{f_n}) \leq D \frac{\ln \alpha^{-1}}{n}\right) \geq 1 - \alpha.$$

Nierówność probabilistyczna dla ryzyka

Twierdzenie 3

Dla dowolnej $0 < \alpha < 1$

$$P \left(A(f_n) \leq C A_n(f_n) + D \frac{\ln n + \ln \alpha^{-1}}{n} \right) \geq 1 - \alpha.$$

Nierówność probabilistyczna dla względnego ryzyka

Twierdzenie 4

\mathcal{F} - wypukła oraz ψ - "ściśle wypukła". Dla dowolnej $0 < \alpha < 1$

$$P\left(A(f_n) \leq A(f^*) + D \frac{\ln n + \ln \alpha^{-1}}{n}\right) \geq 1 - \alpha.$$

Przykłady

- Liniowe reguły rangujące

$$\mathcal{F} = \{f(x, x') = a^T(x - x') + b : a, x, x' \in \mathbb{R}^d, b \in \mathbb{R}\}$$

Przykłady

- Liniowe reguły rangujące

$$\mathcal{F} = \{f(x, x') = a^T(x - x') + b : a, x, x' \in \mathbb{R}^d, b \in \mathbb{R}\}$$

- AdaBoost

Przykłady

- Liniowe reguły rangujące

$$\mathcal{F} = \{f(x, x') = a^T(x - x') + b : a, x, x' \in \mathbb{R}^d, b \in \mathbb{R}\}$$

- AdaBoost

$$\psi(x) = \exp(-x)$$

Przykłady

- Liniowe reguły rangujące

$$\mathcal{F} = \{f(x, x') = a^T(x - x') + b : a, x, x' \in \mathbb{R}^d, b \in \mathbb{R}\}$$

- AdaBoost

$$\psi(x) = \exp(-x)$$

\mathcal{R} - skończony VC-wymiar

Przykłady

- Liniowe reguły rangujące

$$\mathcal{F} = \{f(x, x') = a^T(x - x') + b : a, x, x' \in \mathbb{R}^d, b \in \mathbb{R}\}$$

- AdaBoost

$$\psi(x) = \exp(-x)$$

\mathcal{R} - skończony VC-wymiar

-

$$\text{conv}_T(\mathcal{R}) = \left\{ f(x, x') = \sum_{j=1}^T w_j r_j(x, x') : \sum_{j=1}^T w_j = 1, \right. \\ \left. 0 \leq w_j \leq 1, r_j \in \mathcal{R} \text{ dla } j = 1, \dots, T \right\}$$

Pytania

- Czy reguła f_n jest także "dobra" dla 0 – 1 funkcji straty?

Pytania

- Czy reguła f_n jest także "dobra" dla 0 – 1 funkcji straty?
- $L(f) \leq A(f)$

Bibliografia

M. A. Arcones, E. Giné, *U-processes indexed by Vapnik-Chervonenkis classes of functions with applications to asymptotics and bootstrap of U-statistics with estimated parameters*, Stochastic Process. Appl., vol. 52, pp. 17-38, 1994.

P. L. Bartlett, O. Bousquet, S. Mendelson, *Local Rademacher complexities*, Ann. Statist., vol. 33, pp. 1497-1537, 2005.

P. L. Bartlett, M. I. Jordan, J. D. McAuliffe, *Convexity, Classification, and Risk Bounds*, Journal of the American Statistical Association, vol. 101, pp. 138-156, 2006.

S. Clemençon, G. Lugosi, N. Vayatis, *Ranking and empirical minimization of U-statistics*, Ann. Statist., vol. 36, pp. 844-874, 2008.

Y. Freund, R. Iyer, R. E. Schapire, Y. Singer, *An efficient boosting algorithm for combining preferences*, J. Machine Learning Research, vol. 4, pp. 933-969, 2004.

V. H. de la Pena, E. Giné, *Decoupling: from dependence to independence*. Springer-Verlag, New York, 1999.