

Teoria de Vapnik - Chervanenkis (VC)

Motivação: Obter majorações uniformes para probabilidade de forte discrepância entre risco e risco empírico, quando a classe de funções classificadoras NÃO é contínua.

(X, Y) , $X \in \mathcal{X}$, $Y \in \{0, 1\}$

\mathcal{F} = classe de funções classificadoras de \mathcal{X} em $\{0, 1\}$

risco de classificadores $f \in \mathcal{F}$

$$R(f) = \mathbb{P}(f(X) \neq Y)$$

Risco empírico: Dada amostra $(x_1, y_1), \dots, (x_n, y_n)$ iid

$$R_n(f) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{f(x_i) \neq y_i\}}$$

Des. Hoeffding

$$\mathbb{P}(|R_n(f) - R(f)| > \varepsilon) \leq 2e^{-2n\varepsilon^2}$$

↑
depende de f !!!

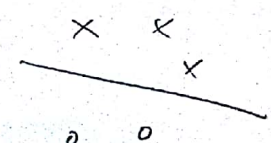
$$\mathbb{P}\left(\bigcup_{f \in \mathcal{F}} |R_n(f) - R(f)| > \varepsilon\right) \leq \sum_{f \in \mathcal{F}} \mathbb{P}(|R_n(f) - R(f)| > \varepsilon) = 2|\mathcal{F}|e^{-2n\varepsilon^2}$$

Se \mathcal{F} for finito ou numerável \Rightarrow $|\mathcal{F}|$ é finito

Problema: Em geral \mathcal{F} é contínuo.

Exemplo:

1) $\mathcal{X} = [0, 1]$, $\mathcal{F} = \{f(x) = \mathbb{1}_{\{x < t\}}, t \in [0, 1]\}$

2)  \mathbb{R}^2 \mathcal{F} = classe de retas em \mathbb{R}^2

$$f: \mathcal{X} \rightarrow \{0,1\}$$

x_1, x_2, \dots, x_n amostra dada

↓ classificação

$$\{f(x_1), f(x_2), \dots, f(x_n) : (x_1, x_2, \dots, x_n) \in \mathcal{X}^n\}$$


De quantas maneiras podemos classificar de forma binária uma sequência de n pontos? $R/2^n \leftarrow \boxed{VC}$.

Outra forma de atacar o problema: (mais ingenua).

No exemplo: $\mathcal{X} = [0,1]$

$$\mathcal{F} = \{f(x) = \mathbb{1}_{\{x < t\}} : t \in [0,1]\}$$

$$0 < r < 1$$



$$\mathcal{F}_r = \{f(x) = \mathbb{1}_{\{x < kr\}} : k = 1, \dots, r\}$$

Observe que $\forall f \in \mathcal{F}, \forall \epsilon > 0, \exists \bar{r} = \bar{r}(\epsilon)$ tal que $\forall r > \bar{r} \exists f' \in \mathcal{F}_r$ satisfazendo $|R(f) - R(f')| \leq \epsilon$

Dado \mathcal{X} e \mathcal{F} classes de funções de \mathcal{X} em $\{0,1\}$

Amostra de treinamento:

$$(x_1, y_1), \dots, (x_n, y_n)$$

Definição: coeficiente de fragmentação (shatter coefficient) $S(\mathcal{F}, n)$

$$S(\mathcal{F}, n) = \max_{(x_1, x_2, \dots, x_n) \in \mathcal{X}^n} |N_{\mathcal{F}}(x_1, \dots, x_n)| \quad \text{onde}$$

$$N_{\mathcal{F}}(x_1, \dots, x_n) = \{f(x_1), \dots, f(x_n) : f \in \mathcal{F}\}$$


Observe que $S(\mathcal{F}, n) \leq 2^n$.

Exemplo:

$$\mathcal{X} = \mathbb{R}^2$$


\mathcal{F} = classificadores definidos por rectas

n=2



$$S(\mathcal{F}, 2) = 2^2 = 4$$


n=3



2^3 casos possíveis

Sempre consigo classificar, então $S(\mathcal{F}, 3) = 2^3 = 8$.

n=4



Não temos como separar as duas classes com uma recta.

$$S(\mathcal{F}, 4) < 2^4$$

Definição A dimensão de VC da classe \mathcal{F} é definida como

$$VC(\mathcal{F}) = \max \{ n \geq 1 : S(\mathcal{F}, n) = 2^n \}$$

"Tamanho efectivo" da classe \mathcal{F} .

Lembro que se \mathcal{F} for finito ou enumeravel

$$\mathbb{P} \left(\bigcup_{f \in \mathcal{F}} |R_n(f) - R(f)| > \epsilon \right) \leq \sum_{f \in \mathcal{F}} 2 e^{-2n\epsilon^2}$$

$$\leq \boxed{2N e^{-2n\epsilon^2}} \quad \text{Si } |\mathcal{F}| = N.$$

8

Teorema: Desigualdade VC

$$\mathbb{P} \left(\sup_{f \in \mathcal{F}} |R_n(f) - R(f)| > \varepsilon \right) \leq 8 S(\mathcal{F}, n) e^{-n\varepsilon^2/32}$$

e

$$\mathbb{E} \left[\sup_{f \in \mathcal{F}} |R_n(f) - R(f)| \right] \leq 2 \sqrt{\frac{\log S(\mathcal{F}, n) + \log 2}{n}}$$

Lema de Sauer

$$S(\mathcal{F}, n) \leq (n+1)^{VC(\mathcal{F})}$$

Usando o Lema de Sauer e a desigualdade VC demonstramos o seguinte corolário:

Corolário: Seja $\hat{f}_n = \operatorname{argmin} \{ R_n(f) : f \in \mathcal{F} \}$.

$$\text{Então } \mathbb{E} [R(\hat{f}_n)] - \inf_{f \in \mathcal{F}} R(f) \leq 4 \sqrt{\frac{\log S(\mathcal{F}, n) + \log 2}{n}}$$

$$\leq 4 \sqrt{\frac{VC(\mathcal{F}) \log(n+1) + \log 2}{n}}$$

Demonstração:

$$R(\hat{f}_n) - \inf_{f \in \mathcal{F}} R(f)$$

$$= R(\hat{f}_n) - R_n(\hat{f}_n) + R_n(\hat{f}_n) - \inf_{f \in \mathcal{F}} R(f)$$

$$= [R(\hat{f}_n) - R_n(\hat{f}_n)] + \sup_{f \in \mathcal{F}} [R_n(\hat{f}_n) - R(f)]$$

Note que: por definição: $R_n(\hat{f}_n) \leq R_n(f) \forall f \in \mathcal{F}$

$$\leq [R(\hat{f}_n) - R_n(\hat{f}_n)] + \sup_{f \in \mathcal{F}} [R_n(f) - R(f)]$$

$$\leq \underbrace{|R(\hat{f}_n) - R_n(\hat{f}_n)|}_{*} + \sup_{f \in \mathcal{F}} |R_n(f) - R(f)|$$

$$* \leq \sup_{f \in \mathcal{F}} |R(f) - R_n(f)|, \text{ por tanto}$$

$$\leq 2 \sup_{f \in \mathcal{F}} |R(f) - R_n(f)|$$

Agora si calculamos esperanza los dois lados, e usamos Teorema VC

$$\begin{aligned} \mathbb{E} [R(\hat{f}_n)] - \inf_{f \in \mathcal{F}} R(f) &\leq 2 \mathbb{E} \left[\sup_{f \in \mathcal{F}} |R(f) - R_n(f)| \right] \\ &\leq 2 \times 2 \sqrt{\frac{\log S(\mathcal{F}, n) + \log 2}{n}} \end{aligned}$$