


Teoria uczenia się pojęć

(V. Vapnik: Statistical Learning Theory, Wiley 1998)

Materiał uśredni znajduje się w artykule "~~Introduction to~~

"An overview of statistical learning theory" (plik LearningTheory1.pdf)
oraz w pliku TrykedyVC.pdf)

Generator losowych
wektorów (przykładów) $x \in \mathbb{R}^m$
powstających się zgodnie
z ustalonym ale nieznanym
rozkładem $P(x)$



LM - maszyna uczenia ma

do dyspozycji zbiór

funkcji $\{\phi(x, \alpha) : \alpha \in \mathcal{A}\}$

oraz próbek $(x_1, \omega_1), \dots, (x_n, \omega_n)$

wygenerowane zgodnie z nieznanym P_i
rozkładem $P(x, \omega)$

- ma za zadanie wybrać "najlepszą" funkcję
względem kryterium (korelacyjnego) $R(\alpha)$

Funkcja straty

- Rozważmy najprostszy przypadek
tzw. "pattern recognition" $L(\omega, \omega') = \begin{cases} 1 & \omega \neq \omega' \\ 0 & \omega = \omega' \end{cases}$

Wtedy $L(\omega, \phi(x, \alpha))$ może mieć 1 jeśli wybrał funkcję $\phi(x, \alpha)$ dla danej decyzji różną od ω i 0 w przeciwnym przypadku.

- $z = (x, \omega)$
 $Q(z, \alpha) \stackrel{\text{ozn}}{=} L(\omega, \phi(x, \alpha))$, gdzie $z = (x, \omega)$

$$Q(z, \alpha) \in \{0, 1\}$$

- Bardziej złożony przypadek, gdy np. $Q(z, \alpha) \in [A, B]$, gdzie $0 \leq A \leq B$, A, B - dowolne rzeczywiste
- wspomnij o nim dalej; zwykle mogą być uogólnione na ten przypadek.

Ryzyko empiryczne

próbki o dt. l : $z = (z_1, \dots, z_l)$, gdzie $z_i = (x_i, w_i)$ dla $i = 1, \dots, l$

$$R_{\text{emp}}(\alpha) = \frac{1}{l} \sum_{i=1}^l Q(z_i, \alpha) \quad \alpha \in \mathcal{A}$$

Uwaga. $R_{\text{emp}}(\alpha)$ faktycznie zależy od z (ale z reguły nie piszemy $R_{\text{emp}}(\alpha, z)$ ponieważ o tym!)

Ryzyko teoretyczne


$$R(\alpha) = \int Q(z, \alpha) dP(z)$$

catka Lebesgue - Stieltjes'a

$$0 \leq Q(z, \alpha^*) \leq B$$

↑
ustaleno

$$R(\alpha^*) = \int Q(z, \alpha^*) dP(z) = \lim_{m \rightarrow \infty} \sum_{i=1}^m \frac{B}{m} \underbrace{P\{Q(z, \alpha^*) > \frac{iB}{m}\}}_{P\{z : Q(z, \alpha^*) > \frac{iB}{m}\}}$$



Zasada minimalizacji ryzyka empirycznego
 (ERM - empirical risk minimization)

Dla zadanej próbki $Z = (z_1, \dots, z_n)$ wyznaczamy optymalne α_L takie, że

$$R_{emp}(\alpha_L) = \inf_{\alpha \in \mathcal{L}} R_{emp}(\alpha).$$

Czy takie postąpienie gwarantuje, że z warunkiem L "zblizany" się do $R(\alpha_{opt})$ jakie

$$R(\alpha_{opt}) = \inf_{\alpha \in \mathcal{L}} R(\alpha) ?$$

Niespewnosc ERM

$z = (z_1, \dots, z_\ell)$

α_ℓ - optymalne dla z ze względu na

$$R_{\text{emp}}(\alpha) = \frac{1}{\ell} \sum_{i=1}^{\ell} Q(z_i, \alpha)$$

$$R_{\text{emp}}(\alpha_\ell) = \inf_{\alpha \in \mathcal{L}} R_{\text{emp}}(\alpha)$$

$$R(\alpha) = \int Q(z, \alpha) dP(z)$$

$$R(\alpha_{\text{opt}}) = \inf_{\alpha \in \mathcal{L}} R(\alpha)$$

1. $R(\alpha_\ell) \xrightarrow[\ell \rightarrow \infty]{P} R(\alpha_{\text{opt}})$

zn. $\forall \epsilon > 0 \forall \eta > 0 \exists l_0 = l(\epsilon, \eta) \forall \ell > l_0$

$$P\{z : z\text{-problem odd. } \ell \text{ \& } R(\alpha_\ell) - R(\alpha_{\text{opt}}) < \epsilon\} > 1 - \eta$$

2. $R(\alpha_{\text{emp}}) \xrightarrow[\ell \rightarrow \infty]{P} R(\alpha_{\text{opt}})$

Two, $\{Q(z, \alpha) : \alpha \in \mathcal{L}\}$ rodzina funkcji talia, ie $A \leq \int Q(z, \alpha) dP(z) \leq B$ dla $\alpha \in \mathcal{L}$.

Warunkiem koniecznym i dostatecznym na to aby ERM byc maksymalne jest aby dla każdego

$\epsilon > 0$

$\lim_{\ell \rightarrow \infty}$

$$P\{z : z\text{-problem odd. } \ell \text{ \& } \sup_{\alpha \in \mathcal{L}} \{R(\alpha) - R(\alpha_{\text{emp}})\} > \epsilon\} = 0$$

Problemy

1. ~~Co~~ Kiedy zbliżność wymiarowa w skończonej przestrzeni ma miejsce?
2. Jaką reprezentację aby to zbliżność były "szybko"?
3. Jak uogólnić się od metody przedpokoleniowej P w przestrzeniach nie regularności zbliżności?

Z tymi pytaniami związane są pierwsze twierdzenie tw. mutualności w teorii informacji się pojąć.

Ważni pozwalają zapewnić (1-3) są zależne od rodzaju informacji różnych rodzajów entropii znowu funkcji $\{Q(z, x) : x \in L\}$.

$$\{Q(z, \alpha) : \alpha \in \mathcal{L}\}$$


$$Q(z, \alpha) = L(\omega, \Phi(x, \alpha)) \in \{0, 1\}$$
$$z = (x, \omega)$$

(z_1, \dots, z_l) - probha o dē. l $z_i = (x_i, \omega_i)$ ($i = 1, \dots, l$)

$$N^{\mathcal{L}}(z_1, \dots, z_l) = \text{card} \{ (Q(z_1, \alpha), \dots, Q(z_l, \alpha)) : \alpha \in \mathcal{L} \} \leq 2^l$$

$$H^{\mathcal{L}}(z_1, \dots, z_l) = \ln N^{\mathcal{L}}(z_1, \dots, z_l)$$

$$H^{\mathcal{L}}(\mathcal{L}) = \int H^{\mathcal{L}}(z_1, \dots, z_l) dP(z_1, \dots, z_l)$$



Tw. (Pierwszy lemat Millera) $\{Q(z, \alpha) : \alpha \in \mathcal{L}\}$; $Q(z, \alpha) \in \{0, 1\}$

Następujące warunki są równoważne:

$$1. \lim_{l \rightarrow \infty} \frac{H^l(l)}{l} = 0$$

$$2. P \left\{ (z_1, \dots, z_l) : \sup_{\alpha \in \mathcal{L}} \left| \int Q(z, \alpha) P(z) - \frac{1}{l} \sum_{i=1}^l Q(z_i, \alpha) \right| > \varepsilon \right\}$$

$$\xrightarrow{l \rightarrow \infty} 0 \quad ; \text{ dla każdego } \varepsilon > 0$$

$$\forall \varepsilon \exists l(\varepsilon, \mathcal{L}, P) \forall l > l(\varepsilon, \mathcal{L}, P) P \{ \dots \} < \delta$$

Entropia "annealing" :

$$H_{\text{ann}}^{-1}(\ell) = \ln E N^{-1}(z_1, \dots, z_\ell) =$$

$$= \ln \int N^{-1}(z_1, \dots, z_\ell) dP(z_1, \dots, z_\ell)$$

$$H^{-1}(\ell) \leq H_{\text{ann}}^{-1}(\ell)$$

↑
z nierówności Jensena : jeśli ψ wklęsła to $\int \psi(\Phi(x)) dP(x) \leq \psi(\int \Phi(x) dP(x))$

"Drogi kamień milowy!"
Tw. Dle uśrednienia P, \mathcal{L} .

Jeśli $\lim_{\ell \rightarrow \infty} \frac{H^{-1}(\ell)}{\ell} = 0$ to

$$\forall \varepsilon > 0 \exists \theta, c > 0 \exists \ell(\varepsilon, \mathcal{L}, P) \forall \ell > \ell(\varepsilon, \mathcal{L}, P)$$

$$P\{(z_1, \dots, z_\ell) : \sup_{\alpha \in \mathcal{L}} \left| \int Q(z, \alpha) dP(z) - \frac{1}{\ell} \sum_{i=1}^{\ell} Q(z_i, \alpha) \right| > \varepsilon\} < \frac{\theta}{e^{c\varepsilon^2 \ell}}$$

Uważaj. Tylko wariant Borelscy!

Funkcja wzrostu

$$G^{-L}(l) = \limsup_{(z_1, \dots, z_l)} N^{-L}(z_1, \dots, z_l)$$

$$H^{-L}(l) \leq H_{\text{ann}}^{-L}(l) \leq G^{-L}(l)$$

↑
oczywiste

(Tneci kamieni milowy)

Tw, Λ -ustalony; \mathcal{P}_0

Następujące warunki są równoważne:

$$1. \lim_{l \rightarrow \infty} \frac{G^{-L}(l)}{l} = 0$$

$$2. \forall \varepsilon > 0 \exists b, c > 0 \exists l(\varepsilon, \Lambda) \forall l > l(\varepsilon, \Lambda)$$

$$\sup_{P \in \mathcal{P}_0} P\{(z_1, \dots, z_l) : \sup_{\alpha \in \Lambda} \left| \int Q(z, \alpha) dP(z) - \frac{1}{l} \sum_{i=1}^l Q(z_i, \alpha) \right| > \varepsilon\} < \frac{b}{e^{c\varepsilon^2 l}}$$

Entropia dla zbioru funkcji o wartościach rzeczywistych


$$\{Q(z, \alpha) : \alpha \in \mathcal{L}\}$$

zakładamy, że funkcje te są ujemnie ograniczone
tzn. dla pewnych stałych A, B $A \leq Q(z, \alpha) \leq B$
dla $\alpha \in \mathcal{L}$

(z_1, \dots, z_l) - próbka

$$q(\alpha) = (Q(z_1, \alpha), \dots, Q(z_l, \alpha)) \text{ dla } \alpha \in \mathcal{L}$$

$\{q(\alpha) : \alpha \in \mathcal{L}\}$ jest podzbiorem kostki l -wymiarowej
której krawędzie mają długość $|B-A|$



Dla tego zbioru istnieje ^{minimalna} ϵ -sieć w metryce C .
Koczek $N = N^{-1}(\epsilon; z_1, \dots, z_l)$ będzie liczył elementów
minimalnej ϵ -sieci dla $\{q(\alpha) : \alpha \in \mathcal{L}\}$.

$$H^{-1}(\epsilon; z_1, \dots, z_l) = \ln N^{-1}(\epsilon; z_1, \dots, z_l)$$

losowa VC-entropia zbioru $\{Q(z, \alpha) : \alpha \in \mathcal{L}\}$ dla
 (z_1, \dots, z_l) $= P(z_1) \cdot \dots \cdot P(z_l)$

$$H^{-1}(\epsilon; l) = \int H^{-1}(\epsilon, z_1, \dots, z_l) dP(z_1, \dots, z_l)$$

VC-entropia zbioru $\{Q(z, \alpha) : \alpha \in \mathcal{L}\}$ ma próbkach o odległości
 l .

Zbiór $\{q(\alpha) : \alpha \in \mathcal{L}\}$ ma ^{minimalna} ϵ -sieć
 ~~$q(\alpha_1), \dots, q(\alpha_N)$~~ taki:

1. Istnieje $N = N^{-1}(\epsilon, z_1, \dots, z_l)$
wektorów $q(\alpha_1), \dots, q(\alpha_N)$ takich, że
dla każdego $q(\alpha^*)$ dla $\alpha^* \in \mathcal{L}$
istnieje r ($1 \leq r \leq N$) $q(\alpha_r)$
który jest ϵ -bliżki do tego wektora $q(\alpha^*)$
tzn. $C(q(\alpha^*), q(\alpha_r)) =$
 $\max_{1 \leq i \leq l} |Q(z_i, \alpha^*) - Q(z_i, \alpha_r)| \leq \epsilon$

2. N jest ~~liczbą~~ minimalną liczbą wektorów
o powyższej własności.

$q(\alpha_1), \dots, q(\alpha_N)$ - wszystkie wektory minimalnej
 ϵ -sieci dla $\{q(\alpha) : \alpha \in \mathcal{L}\}$.

Tw. Jednostajne dwostronne zbieżność rzędu empirycznego do rzędu funkcyjnego
 zn. $\lim_{l \rightarrow \infty} P \{ (z_1, \dots, z_l) : \sup_{\alpha \in \mathcal{L}} |R(\alpha) - R_{emp}(\alpha)| > \epsilon \} = 0$ dla każdego ϵ

~~jest zbieżność~~ me miejsce wtedy i tylko wtedy
 (*) $\lim_{l \rightarrow \infty} \frac{H^l(\epsilon; l)}{l} = 0$ dla każdego ϵ .

Uwaga. Niezależne modułowe warunki (*) pozwala otrzymać warunki konieczny i dostateczny
 na to by mieć miejsce jednostajnej dwustronnej zbieżności rzędu empirycznego
 do rzędu funkcyjnego zn.

$$\lim_{l \rightarrow \infty} P \{ (z_1, \dots, z_l) : \sup_{\alpha \in \mathcal{L}} (R(\alpha) - R_{emp}(\alpha)) > \epsilon \} = 0 \text{ dla każdego } \epsilon.$$

$$VC\text{-dim}(\mathcal{H}) ; \mathcal{H} = \{Q(z, \alpha) : \alpha \in \mathcal{L}\}$$

1. $N^{\wedge}(z_1, \dots, z_l) = \text{card} \{(Q(z_1, \alpha), \dots, Q(z_l, \alpha)) : \alpha \in \mathcal{L}\}$

2. $G(l) = \sup_{(z_1, \dots, z_l)} \text{lm } N^{\wedge}(z_1, \dots, z_l)$

3. $VC\text{-dim}(\mathcal{H}) = \begin{cases} \max\{l : G(l) = l \text{ or } 2\} & \text{if } \exists l \text{ } G(l) \neq l \text{ or } 2 \\ +\infty & \text{w. p.p.} \end{cases}$

Vurqa matheje (nabija) (z_1, \dots, z_l) .
If $N^{\wedge}(z_1, \dots, z_l) = 2^l$ to induction, ie $\{Q(z, \alpha) : \alpha \in \mathcal{L}\}$

Tw. Funkcja wzrostku G dla $\{Q(z, \alpha) : \alpha \in \mathcal{L}\}$; $Q(z, \alpha) \in \{0, 1\}$
spełnia warunki


$$G^{-1}(l) = l \ln 2$$

stąd h jest ~~określenie~~
albo ~~punkt~~ ograniczenia

$$G^{-1}(l) \begin{cases} = l \ln 2 & \text{dla } l \leq h \\ \leq \ln \left(\sum_{i=0}^h \binom{l}{i} \right) \leq h \left(1 + \ln \frac{l}{h} \right) & \text{dla } l > h \end{cases}$$

h jest największą taką liczbą, że $G^{-1}(l) = l \ln 2$

h nazywamy wymiarem Vapnika-Chernoukha dla $\mathcal{L} (\{Q(z, \alpha) : \alpha \in \mathcal{L}\})$



Dziękuję za rys.
przygotowany przez
Pana Grzegorza Bokotę
korygujący poprzednią
wersję

Tw. Funkcja wzrostku G dla $\{Q(z, \alpha) : \alpha \in \mathcal{L}\}$; $Q(z, \alpha) \in \{0, 1\}$
 spełnia warunek


$$G^{-1}(l) = l \ln 2$$

warunek ~~ograniczenia~~
 albo ~~warunek~~ ograniczenia

$$G^{-1}(l) \begin{cases} = l \ln 2 & \text{dla } l \leq h \\ \leq \ln \left(\sum_{i=0}^h \binom{l}{i} \right) \leq h \left(1 + \ln \frac{l}{h} \right) & \text{dla } l > h \end{cases}$$

h jest największą taką liczbą, że $G^{-1}(l) = l \ln 2$

h nazywamy wymiarem Vapnika-Chernoneukisa dla \mathcal{L} ($\{Q(z, \alpha) : \alpha \in \mathcal{L}\}$)



Dziękuję za rys.
 przygotowany przez
 Pana Grzegorz Bokotę
 korygujący poprzednią
 wersję

Proposed


$$\mathcal{L} = \mathbb{R}$$

$$Q(x, \alpha) = \begin{cases} 1 & x \geq \alpha \\ 0 & x < \alpha \end{cases}$$

$$H = \{Q(x, \alpha) : \alpha \in \mathbb{R}\}$$

$$\dim_{\mathbb{R}}(H) = 1$$

$$l = 1 :$$



$$l = 2 : \text{card} \{(Q(x_1, \alpha), Q(x_2, \alpha)) : \alpha \in \mathbb{R}\} = \text{card} \{00, 11, 01\} < 2^2$$

$$H = H_{\mathcal{L}} = \{ Q(z, \alpha) : \alpha \in \mathcal{L} \} ; \quad Q(z, \alpha) \in \{0, 1\} ; \quad z \in Z$$

$$\mathcal{H} = \{ Z_{\alpha} \subseteq Z : \alpha \in \mathcal{L} \} \quad \text{gdzie} \quad Z_{\alpha} = \{ z \in Z : Q(z, \alpha) = 1 \}$$

$X \subseteq Z$ jest "mierzalny" przez $H(\mathcal{H})$ iff

$$\forall Y \subseteq X \exists \alpha \in \mathcal{L} (Y = Z_{\alpha} \cap X)$$

"każdy podzbiór X musi być rozdzielony przez $H(\mathcal{H})$ "

$Z = (z_1, \dots, z_l)$ (problem o uogólnieniu powyższej definicji)

$$q(\alpha, Z) = (Q(z_1, \alpha), \dots, Q(z_l, \alpha))$$

$N^{\mathcal{L}}(Z) = \text{card} \{ q(\alpha, Z) : \alpha \in \mathcal{L} \} = 2^l$ iff zbiór $\{z_1, \dots, z_l\}$ jest mierzalny przez $H(\mathcal{H})$

$$G^{\circ}(l, H) = \sup_{(z_1, \dots, z_l)} N^{\mathcal{L}}(z_1, \dots, z_l)$$

$$G(l) = G_H(l) = \text{lesup}_{(z_1, \dots, z_l)} N(z_1, \dots, z_l)$$

$$G^\bullet(l) = G_H^\bullet(l) = \sup_{(z_1, \dots, z_l)} N^{\perp}(z_1, \dots, z_l)$$

Zusatz $G_H^\bullet(l)$
 genau bei
 $G^\bullet(l, H)$

Prüfung

$$H = \{[a, +\infty) : a \in \mathbb{R}\}$$

$$\underline{\dim_{\mathbb{R}}(H) = 1}$$

$$G^\bullet(n) = n + 1$$

$$G^\bullet(1) = 2^1$$

$$G^\bullet(2) = 3 < 2^2$$

$$G^\bullet(n) = \binom{n}{0} + \binom{n}{1}$$

Prüfung

$$H = \{(a, b) : a < b, a, b \in \mathbb{R}\}$$

$$\underline{\dim_{\mathbb{R}}(H) = 2}$$

$$G^\bullet(n) = \binom{n+1}{2} + 1$$

$$G^\bullet(1) = 2^1$$

$$G^\bullet(2) = 2^2$$

$$G^\bullet(3) = 7 < 2^3$$

$$G^\bullet(n) = \binom{n}{0} + \binom{n}{1} + \binom{n}{2}$$

Przykład 2

$$\mathcal{X} = \mathbb{R}^2, \quad \alpha = (a, b, c) \in \mathbb{R}^3; \quad x = (x_1, x_2) \in \mathbb{R}^2$$

$$Q(x, \alpha) = \begin{cases} 1 & \text{gdy } ax_1 + bx_2 + c \geq 0 \\ 0 & \text{w p.p.} \end{cases}$$

$$H = \{Q(x, \alpha) : \alpha \in \mathbb{R}^3\}$$

$$\text{VC-dim}(H) = 3$$

$$l=1 \quad \text{card}\{Q(x, \alpha) : \alpha \in \mathbb{R}^3\} = \text{card}\{0, 1\} = 2^1$$

$$l=2 \quad \text{card}\{Q(x^{(1)}, \alpha), Q(x^{(2)}, \alpha) : \alpha \in \mathbb{R}^3\} = 2^2$$


$$l=3 \quad \text{card}\{Q(x^{(1)}, \alpha), Q(x^{(2)}, \alpha), Q(x^{(3)}, \alpha) : \alpha \in \mathbb{R}^3\} = 2^3$$

$x^{(1)}, x^{(2)}, x^{(3)}$ nie są współliniowe np.

$$l=4 \quad \text{card}\{Q(x^{(1)}, \alpha), Q(x^{(2)}, \alpha), Q(x^{(3)}, \alpha), Q(x^{(4)}, \alpha) : \alpha \in \mathbb{R}^3\}$$

$$< 2^4$$

$$\text{VC-dim}(H) = 3$$



Przykład 3


Prostokąty \parallel do osi.

Dla $l = 1, 2, 3, 4$ $G(l) = l \ln 2$.

$l = 5$


- jeśli 3 punkty są współliniowe to

$$N^-(z_1, \dots, z_5) < 2^l$$



Nie istnieje prostokąt taki, by punkt $-$ był na zewnątrz a $++$ wewnątrz

- jeśli żadne z 3 punktów nie są współliniowe to z trzech punktów wybieramy 4, których współrzędne są parą max, min na pierwszej i drugiej współrzędnej; powstaje prostokąt \square . Nie istnieje prostokąt taki by




A był na zewnątrz a B, C, D, E wewnątrz.

Przykład

H - zbiór ~~obrotów~~ hipotez wyznaczonych przez wielokąt na płaszczyźnie

$$\dim_{\mathbb{R}}(H) = +\infty$$

Rozważmy n punktów na okręgu: x_1, \dots, x_n



Każdy podzbiór tego zbioru punktów należy do obszaru wyznaczonego przez wielokąt o wierzchołkach w tych punktach. (pozostałe punkty znajdują się na zewnętrznej stronie obszaru).

Przykład 4

H : hiperpłaszczyzna przechodząca przez 0 : $\sum_{k=1}^n \alpha^k u_k = 0$

$Q(z, \alpha) = \Theta \left(\sum_{k=1}^n \alpha^k u_k \right)$ gdzie Θ - funkcja progu
 $\alpha = (\alpha^1, \dots, \alpha^m)$
 $Q(z, \alpha) = L(\omega, \Phi(x, \alpha)) \in \{0, 1\}$
 $t \in \hat{[-1, 1]}$

$\phi(x, \alpha) = \Theta \left(\sum_{k=1}^m \alpha^k x^k \right)$ 22
 $\alpha = (\alpha^1, \dots, \alpha^m)$
 $x = (x^1, \dots, x^k)$

$\Theta(t) = \begin{cases} 1 & t > 0 \\ -1 & t \leq 0 \end{cases}$
 zbiór decyzji $\{1, -1\}$

VC-dim(H) = n

Łatwo zauważyć, że zbiór ~~wektorów~~ ^{n punktów} ~~jednostkowych~~ $(0, \dots, \frac{1}{i}, \dots, 0)$ może być "poratowany" przez H .

Pokażemy, że nie istnieje $n+1$ punktów taki, że H realizuje zbiór tych punktów. Przyjmijmy, że istnieje takich punktów u_1, \dots, u_{n+1} , że H realizuje zbiór $\{u_1, \dots, u_{n+1}\}$.

Wtedy istnieją 2^{n+1} wektorów $\alpha_i \in \mathbb{R}^n$ ($i=1, \dots, 2^{n+1}$) takich, że macierz (z_{ij}) gdzie $z_{ij} = u_i^T \alpha_j$ ma kolumny z dowolnym rozkładem znaków, wobec tego

macierz $A = \begin{pmatrix} z_{1,1} & \dots & z_{1,2^{n+1}} \\ \vdots & & \vdots \\ z_{n+1,1} & \dots & z_{n+1,2^{n+1}} \end{pmatrix}$

każdej kolumny ma 2^{n+1} możliwych rozkładów znaków
 $\text{sig}(A) = \begin{pmatrix} - & - & \dots & + \\ - & \vdots & & \\ \vdots & \vdots & & \\ - & + & \dots & + \end{pmatrix}$

Wtedy ~~wektory~~ ^{wiersze} A byłyby liniowo niezależne, bo dla każdego stałego wektora jedności 0

c_1, \dots, c_{n+1} takie, że $c_1 \begin{pmatrix} z_{1,1} \\ \vdots \\ z_{1,2^{n+1}} \end{pmatrix} + \dots + c_{n+1} \begin{pmatrix} z_{n+1,1} \\ \vdots \\ z_{n+1,2^{n+1}} \end{pmatrix} \neq 0$. Przyjmijmy, że nie.

~~Wtedy~~ ^{istnieje} i takie, że $(z_{1,i}, \dots, z_{n+1,i})$ ma ten sam rozkład znaków co (c_1, \dots, c_{n+1}) a więc $\sum_{j=1}^{n+1} c_j z_{ji} > 0$ ($\neq 0$). Sprzeczność: w \mathbb{R}^n istnieje ~~co najmniej~~ $n+1$ wektorów liniowo niezależnych.

$$G_H^\bullet(l) = \sup_{(z_1, \dots, z_l)} N^{-1}(z_1, \dots, z_l)$$

$$H = \{\phi(x, \alpha) : \alpha \in \mathcal{L}\}$$

Lemat Saewera

Niech $\dim_{\mathbb{V}C}(H) = d < +\infty$ oraz $d \geq 1$. Wtedy $G_H^\bullet(l) \leq 1 + \binom{l}{1} + \dots + \binom{l}{d}$.

Uwaga. $\binom{l}{d} = 0$ dla $d > l \geq 1$.

Dla $d \geq l$ lemat oznacza, że $G_H^\bullet(l) \leq 1 + \binom{l}{1} + \dots + \binom{l}{l} + 0 + \dots + 0 = 2^l$
co wynika z definicji.

Niech $\Phi(d, l) = 1 + \binom{l}{1} + \dots + \binom{l}{d}$. $\Phi(d, l) < 2^l$ dla $l > d$.

Dla $l > d$ $\Phi(d, l)$ jest wielomianem stopnia d względem l .

$$\Phi(0, l) = 1 \text{ dla } l \geq 1$$

$$\Phi(d, 1) = 2 \text{ dla } d \geq 1$$

$$\Phi(d, l-1) + \Phi(d-1, l-1) = 1 + \binom{l-1}{1} + \dots + \binom{l-1}{d} + \binom{l-1}{d-1} + \dots + 1 = 1 + \binom{l-1}{1} + \dots + \binom{l-1}{d-1} + 1$$

$$\frac{1 + \binom{l-1}{1} + \dots + \binom{l-1}{d-1} + 1}{1 + \binom{l}{1} + \dots + \binom{l}{d}} = \Phi(d, l)$$

1. $d=0$ wtedy dla każdego x i hipotezy $h \in H$ $h(x)$ ma ~~by~~ jedną wartość ^{jedną z wartości funkcji} $\phi(x, \alpha)$ ~~[0 albo 1]~~ ^{przyjmując}.
Wtedy $G_H^\bullet(l) = 1$ dla każdej próbki o ~~du~~ $l \geq 1$ $G_H^\bullet(l) = 1 \leq \Phi(0, l) = 1$.

2. $l=1$ i $d \geq 1$ $\Phi(d, 1) = 2$
 $G_H^\bullet(l) = G_H^\bullet(1) \leq 2 = \Phi(d, 1)$

Domad przez indukcje ze wzgledu na $d+l$.

Jeśli $d+l=2$: $d=0, l=2$ - przypadek 1 }
 $d=1, l=1$ " 2 } teza zachodzi.

Przypuścimy, że teza zachodzi dla wszystkich przypadków gdy $d+l \leq k$ gdzie k jest pewną liczbą ≥ 2 .

Niech $\dim_{\mathbb{C}}(H) = d$ i niech Z będzie problem o d i l zaleg, że $d+l = k+1$.

Przypuścił $(0, k+1), (k, 1)$ są politye przez warunki bierowe. Musimy uszczelnić, że $d \geq 1$ i $l \geq 2$.

Można założyć, że jeśli $Z = (x_1, \omega_1), \dots, (x_l, \omega_l)$ to ciąg x_1, \dots, x_l nie zawiera identycznych wyrazów [możemy odrzucić powtarzające się wyrazy pozostawiając tylko jedno wystąpienie każdego wyrazu i otrzymamy kolejny ciąg i teza wynika z zwi. indukcyjnego].

Niech $E = \{z_1, \dots, z_l\}$ i niech $H_E = H|E = \{h|E : h \in H\}$. Zbiór $H|E$ jest skończony i $N^{\#}(z_1, \dots, z_l) = |H_E|$. Pokażemy, że $|H_E| \leq \Phi(d, l)$.

$F = E - \{z_l\}, \quad H_F = H|F$

$|H_E| = |H_F| + |H_*|$

gdzie H_* to zbiór hipotez $h|z$ z H_F które powstają z $h_1, h_2 \in H_F$ takich, że $h_1|E = h_2|F = h$ oraz $h_1(z_l) \neq h_2(z_l)$.

$(d+(l-1) \leq k)$
z zwi. ind.

$z' = (z_1, \dots, z_{l-1})$
 $|H_F| = N^{\#}(z_1^*, \dots, z_{l-1}^*) \leq G_H(l-1) \leq \Phi(d, l-1)$

Mamy $\dim_{\mathbb{C}}(H_*) = d-1$. W przeciwnym przypadku istnieje problem $z'' = (z_1'', \dots, z_d'')$ "niezależny" przez H_* ale wtedy H miałoby więcej niż d wymiarów (z_1'', \dots, z_d'', z_l) czyli co jest sprzeczne z zwi. $\dim_{\mathbb{C}}(H) = d$.

Wobec tego

$$|H_*| = N_{H^*}^{\mathcal{L}}(z_1^*, \dots, z_{l-1}^*) \leq G_{H^*}(l-1) \leq \Phi(d-1, l-1) \stackrel{\substack{(d-1)+(m-1) \leq k \\ \uparrow \text{zwei. end}}}{\leq} \Phi(d-1, l-1)$$

Ostelecie

~~W~~

$$N_H^{\mathcal{L}}(z_1, \dots, z_l) = |H_E| = |H_F| + |H_*| \leq \Phi(d, l-1) + \Phi(d-1, l-1) = \Phi(d, l).$$

Wniosek

$$1. G_H^{\circ}(l) \leq (l+1)^d$$

jesli $\dim_{\mathbb{R}C}(H) = d < +\infty$ oraz $l \geq d$ - dowolne

$$\text{Dowód} \quad \sum_{i=0}^d \binom{l}{i} \leq \sum_{i=0}^d \frac{l^i}{i!} \leq \sum_{i=0}^d \frac{l^i d!}{i! (d-i)!} = (l+1)^d$$

$$2. G_H^{\circ}(l) \leq \left(\frac{ne}{d}\right)^d \quad \text{jesli } \dim_{\mathbb{R}C}(H) = d < +\infty \text{ oraz } l \geq d.$$

$$\left(\frac{d}{l}\right)^d \sum_{i=0}^d \binom{l}{i} \leq \sum_{i=0}^d \left(\frac{d}{l}\right)^i \binom{l}{i} \leq \sum_{i=0}^d \left(\frac{d}{l}\right)^i \binom{l}{i} = \left(1 + \frac{d}{l}\right)^l \leq e^d.$$

Uwaga Jesli $l \geq d = \dim_{\mathbb{R}C}(H)$ to $G_H(l) = \ln G_H^{\circ}(l) \leq d \ln \frac{ne}{d} = d \left(1 + \ln \frac{l}{d}\right)$

Structural risk minimization (SRM)

Tw. $\{Q(z, \alpha) : \alpha \in \mathcal{L}\}$; $0 \leq Q(z, \alpha) \leq B$ dla $\alpha \in \mathcal{L}$ (*)
 wymiar VC rodziny h .

Nierówność

$$R(\alpha) \leq R_{emp}(\alpha) + \frac{B\epsilon}{2} \left(1 + \sqrt{1 + \frac{4R_{emp}(\alpha)}{B\epsilon}} \right)$$

zachodzi z prawdopodobieństwem $\geq 1 - \eta$ gdzie $\epsilon = 4 \frac{\ln(\ln \frac{2\ell}{h} + 1) - \ln \eta}{\ell}$
 dla wszystkich funkcji z (*)

Dla $\frac{\ell}{h}$ "dużego" drugi składnik jest zaniedbywalny i faktyczne ryzyko $R(\alpha)$ jest bliższe do ryzyka empirycznego $R_{emp}(\alpha)$. Jeśli jednak $\frac{\ell}{h}$ jest "małe" to ~~drugi~~ drugi składnik nie można pominąć i optymalizację $R_{emp}(\alpha)$ nie gwarantuje małej wartości ryzyka. Należy minimalizować oba składniki. SRM ma na celu minimalizację funkcyjnego ryzyka ze względu na ryzyko empiryczne jak i ze względu na wymiar VC skłonu funkcji.

Założmy, że $S = \{Q(z, \alpha) : \alpha \in \Lambda\}$ określona jest strukturalnie tzn. rodziną $\{S_k\}$ podzbiorów S takie, że $S_1 \subset S_2 \subset \dots \subset S_k \subset \dots$ oraz $S^* = \cup S_i$. Strukturalnie to $S_k = \{Q(z, \alpha) : \alpha \in \Lambda_k\}$

Jest doprowadzalna jeśli

1. S^* jest zamknięta w S
2. istnieje VC dla każdego zbioru S_k jest skończony (oznaczy go przez h_k)
3. ~~elementy~~ S_k zawierają funkcje wpółnie ograniczone tzn. dla pewnego $B_k : 0 \leq Q(z, \alpha) \leq B_k$ dla $\alpha \in \Lambda_k$

Losade SRM

• dla zadanej próbki (z_1, \dots, z_l) [a więc l niezależne!] należy wybrać S_m gdzie $m = m(l)$ oraz funkcję z S_m która minimalizuje próg stopu mierności w $\hat{\alpha}$ twierdzeniu.

Jśli $m \nearrow$ to $R_{emp}(\alpha) \downarrow$

$m \nearrow$ to duży składowik w ocenie mierności \nearrow

Wobec tego SRM proponuje pewien trade-off między funkcją empiryczną i teoretyczną funkcji.

Tw. Dla każdego rodzaju funkcyjnie ograniczonej metody SRM zawsze zbieżność do rozwiązania najlepszego z funkcyjnie ograniczonego 1.

Tw. SRM dla struktur dopuszczalnych posiada własność $Q(z, \alpha_L^{n(l)})$
 dla których ciąg wartości ryzyka $R(\alpha_L^{n(l)})$ zbiera do $R(\alpha_{opt})$ asymptotycznie

z szybkością $V(l) = r_{n(l)} + B_{n(l)} \sqrt{\frac{h_{n(l)} \ln l}{l}}$ (**)


jeśli $n = n(l)$ jest takie, że $\lim_{l \rightarrow \infty} \frac{B_{n(l)}^2 h_{n(l)} \ln l}{l} = 0$.

W (**), B_n jest ograniczone dla funkcji z S_m a $r_n(l)$ jest
 szybkością aproksymacji: $r_n = \inf_{\alpha \in \Lambda_n} \int Q(z, \alpha) dP(z) - \inf_{\alpha \in \Lambda} \int Q(z, \alpha) dP(z)$.

Zmienne losowe ξ_l $l=1, \dots$ zbierają do ξ_0 asymptotycznie z szybkością $V(l)$

jeśli mamy zbiór C takie, że $V^{-1}(l) |\xi_l - \xi_0| \xrightarrow{P} C$.

porobienie "matki" S^*
 wykroczenia najmniej ograniczenie
 od gory ryzyka



$h_1 = \dim_{VC}(S_1)$

$h^* = \dim_{VC}(S^*)$

$h_3 = \dim_{VC}(S_3)$