

# Výpočtové učenie

26. apríla 2006

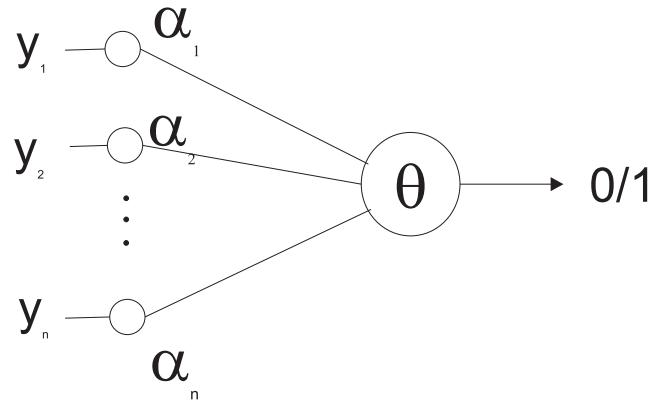
# Kapitola 1

## VC Dimenzia

### 1.1 Rastová funkcia

Vapnik, Chervonenkis - 1971

Najvýznamnejší pojem pre teóriu výpočtového učenia.



Obrázok 1.1: Perceptrón

#### Perceptrón

Pre stav  $\omega = (\alpha_1, \alpha_2, \dots, \alpha_n, \Theta)$  funkcia  $h_\Omega \in H$  z  $X = \mathbb{R}^n$  do  $\{0, 1\}$  je daná

$$h_\omega(y) = \begin{cases} 1, & \text{ak } \sum_{i=1}^n \alpha_i y_i \geq \Theta \\ 0, & \text{inak} \end{cases}$$

$\omega \vdash h_\omega$  nie je injekcia;

pre ľubovoľné  $\lambda \in \mathbb{R}$ , stav  $\lambda * \omega$  definuje tú istú funkciu.

$\Pi_H(x)$  = počet klasifikácií podľa  $H$ , t.j. počet rôznych vektorov tvaru

$$(h(\bar{x}_1), \dots, h(\bar{x}_m))$$

kde  $h$  prebieha všetky hypotézy v  $H$ ,  $\bar{x} = (\bar{x}_1, \dots, \bar{x}_m)$ .

$H$  môže byť nekonečný ...  $H|\bar{E}_{\bar{x}}$ ,  $E_x = \{\bar{x}_1 \dots \bar{x}_m\}$  je konečný a má kardinalitu  $\Pi_H(\bar{x})$ .

$$\Pi_H(\bar{x}) \leq 2^m$$

**Definícia 1.1.1** *Rastová funkcia je*

$$\Pi_H(m) = \max\{\Pi_H(\bar{x}) : \bar{x} \in X^m\}$$

**Definícia 1.1.2** Hovoríme, že vzorka  $\bar{x}$  dĺžky  $m$  je rozbitá podľa  $H$  alebo  $H$  rozbíja  $\bar{x}$ , ak počet možných klasifikácií podľa  $H$  je  $2^m$ , t.j.  $H$  poskytuje všetky možné klasifikácie.

- Ak príklady v  $\bar{x}$  nie sú rôzne, tak  $\bar{x}$  nemôže byť rozbitá.
- Ak príklady v  $\bar{x}$  sú rôzne,  $x$  je rozbitá podľa  $H \Leftrightarrow$  ak pre ľubovoľné  $S \subseteq E_x$  existuje nejaká hypotéza  $h \in H$  taká, že pre ľubovoľné  $1 \leq i \leq m$  platí

$$h(\bar{x}_i) = 1 \Leftrightarrow \bar{x}_i \in S.$$

$S$  je potom podmnožina sústredujúca kladné príklady.

**Definícia 1.1.3** VC dimenzia  $H$  je maximálna dĺžka vzorky, ktorú  $H$  rozbíja. Ak neexistuje, hovoríme, že VC je  $\infty$ .

$$VCdim(H) = \max\{m : \Pi_H(m) = 2^m\}$$

**Príklady:**

1.  $X = \mathbb{R}$ ,  $H \subseteq$  lúče;  $x = (x_1, \dots, x_m)$  je tréningová vzorka,  $x_1 < x_2 < \dots < x_m$ .  
Pre  $\Theta \in \mathbb{R}$ ,  $r_\Theta = 1 \Leftrightarrow x_i \geq \Theta$ .  
Množina klasifikovaných vektorov  $\dots m + 1$ .  
 $(0 \dots 00), (0 \dots 01), \dots (1 \dots 11)$   
Ľubovoľná vzorka s rôznymi príkladmi má jeden z týchto klas. vektorov (spermutovaný).  $\Rightarrow \Pi_H(m) = m + 1$   
V prípade rovnakých príkladov počet klasifikácií je menší.
2.  $r_\Theta$ ,  $H$  je priestor lúčov. Nech je daná tréningová vzorka  $(x_1, x_2)$  dĺžky 2,  $x_1 < x_2$ .  
 $\Rightarrow$  neexistuje lúč taký, že  $h(x_1) = 1$  a  $h(x_2) = 0$ , pretože by muselo platiť  $x_2 < \Theta \leq x_1$ .  
 $\Rightarrow H$  nerozbíja žiadnu vzorku dĺžky 2.  $H$  rozbíja ľubovoľnú vzorku dĺžky 1  $\Rightarrow VCdim(H) = 1$ .
3. Nech  $X = \mathbb{R}^2$ .  $H$  je hypotézový priestor perceptrónu  $P_2$ ,  $x = (x_1, x_2, x_3)$  sú tri nekolineárne rôzne body.  $X$  je rozbitá pomocou  $H \Leftrightarrow$  ak pre ľubovoľnú podmnožinu  $S \subseteq E_x = \{x_1, x_2, x_3\}$  platí, že  $S$  a  $E_x$  sú separovateľné.  
 $\Rightarrow VCdim(H) \geq 3$  ( $P_2$  rozbíja 3 nekolineárne body.)  
Rovnosť dokážeme tým, že nájdeme vzorku, ktorej príklady sa nedajú separovať  $\Rightarrow$  existuje vzorka dĺžky 4, ktorú  $P_2$  nerozbíja.

**Tvrdenie 1** Ak  $H$  je konečný hypotézový priestor, tak  $VCdim(H) \leq \ln |H|$ .

**Dôkaz:**

Počet klasifikácií podľa konečného  $H$  vzorky ľubovoľnej dĺžky je najviac počet rôznych hypotéz v  $H$

$$\Rightarrow \Pi_H(m) \leq |H|$$

VCdim je najväčšie  $d$ , pre ktoré  $\Pi_H(d) = 2^d$ .

$$2^d = \Pi_H(d) \leq |H| \Rightarrow d = \Pi_H(d) \leq \ln |H|.$$

□

**Príklad:** Urobíme odhad pre  $VCdim(M_n)$ . Platí  $|M_n| = 3^n$ ,  $M_n$  sú monočleny.

$VCdim(M_n) \leq (\ln 3) * n$  je horná hranica. Aká je dolná hranica? Pokúsime sa dokázať, že je rovná  $n$ .

Tvrďime, že  $M_n$  rozbíja každú vzorku dĺžky  $n$ :

$(e_1, e_2, \dots, e_n)$ , kde  $e_i = (0 \dots 010 \dots 0)$ , kde 1 je na i-tom mieste,  $1 \leq i \leq n$ .

Predpokladajme, že  $(q_1, \dots, q_n) = q \in \{0, 1\}^n$ . Ukážeme, že existuje  $h \in M_n$  také, že  $h(e_i) = q_i$  pre  $1 \leq i \leq n$ .

Ak  $q = (1 \dots 1)$  vezmeme za  $h$  prázdnú hypotézu.

Ak  $q = (0 \dots 00 \dots 01)$  tak  $h$  vytvoríme ako konjunkciu negácií literálov, pre ktoré  $q_j = 0$ .

$$\Rightarrow VCdim(M_n) \geq n \text{ pre ľubovoľné } n.$$

## 1.2 VC dimenzia reálnych perceptrónov

**Veta 1** Pre ľubovoľné  $n$  nech  $P_n$  je reálny perceptrón s  $n$  vstupmi. Potom

$$VCdim(P_n) = n + 1.$$

**Dôkaz:**  $P_n$  je v stave  $\omega = (\alpha_1 \alpha_2 \dots \alpha_n \Theta)$   
 $h_\omega$  - funkcia, ktorú perceptrón počíta

$$h_\omega(y) = 1 \Leftrightarrow \alpha_1 y_1 + \dots + \alpha_n y_n \geq \Theta.$$

Označme

$$\begin{aligned} l_\omega^+ &= \{y \in \mathbb{R}^n : \sum_{i=1}^n \alpha_i y_i \geq \Theta\} \\ l_\omega^- &= \{y \in \mathbb{R}^n : \sum_{i=1}^n \alpha_i y_i < \Theta\} \\ l_\omega &= \{y \in \mathbb{R}^n : \sum_{i=1}^n \alpha_i y_i = \Theta\} \end{aligned}$$

$C \subseteq \mathbb{R}^n$  je **konvexná**, ak pre ľubovoľné  $x, y \in C$  a ľubovoľné reálne číslo  $\lambda$ ,  $0 \leq \lambda \leq 1$ , bod  $\lambda x + (1 - \lambda)y \in C$ .

Priek  $\mathbb{R}^n$  ľubovoľných 2 konvexných množín v  $\mathbb{R}^n$  je konvexná množina. Pre ľubovoľnú množinu bodov  $S \subseteq \mathbb{R}^n$  existuje najmenšia konvexná množina obsahujúca  $S$ :

$conv(S)$  ... konvexný obal  $S$  je priek všetkých konvexných množín obsahujúcich  $S$ ;

**Pripomeňme Radonovu vetu:**

**Veta 2** Nech  $n$  je kladné celé číslo,  $E$  je ľubovoľná množina  $n+2$  bodov z  $\mathbb{R}^n$ . Potom existuje  $\emptyset \neq S \subseteq E$  taká, že

$$conv(S) \cap conv(E \setminus S) \neq \emptyset.$$

Nech  $x = \underbrace{(x_1 \dots x_{n+2})}_{\text{rozsne}}$  je ľubovoľná vzorka príkladov z  $\mathbb{R}^n$  dĺžky  $n+2$ .

$E_x$  je množina príkladov v  $x \dots |E_x| = n+2$ . Podľa Radonovej vety existuje  $S \neq \emptyset$ ,  $S \subseteq E_x$

$$conv(S) \cap conv(E_x \setminus S) \neq \emptyset.$$

Predpokladajme, že existuje  $h_{omega}$  v  $P_n$  také, že  $S$  je množina pozitívnych príkladov  $h_\omega$  v  $E_x$ .

$$\Rightarrow S \subseteq l_\omega^+, E_x \setminus S \subseteq l_\omega^-$$

Pretože uzavretý polpriestor  $l_\omega^+$  a otvorený  $l_\omega^-$  sú disjunktné a sú konvexné v  $\mathbb{R}^n \Rightarrow conv(S) \subseteq l_\omega^+$ ,  $conv(E_x \setminus S) \subseteq l_\omega^-$

$$conv(S) \cap conv(E_x \setminus S) \subseteq conv(S) \cap conv(E_x \setminus S) = \emptyset$$

$\Rightarrow$  neexistuje taká  $h_\omega$ , a preto x nie je rozbitá  $p_n$ .  $\Rightarrow$  žiadna vzorka dĺžky  $n+2$  nie je rozbitá pomocou  $p_n$ .

$$\Rightarrow VCdim(P_n) \leq n + 1.$$

Opačná nerovnosť:  $o \in \mathbb{R}^n$ ,  $o = (0, 0 \dots 0)$ ,  $e_i = (0 \dots 10 \dots 0)$ ,  $1 \leq i \leq n$ . Ukážeme, že  $P_n$  rozbíja  $x = (o, e_1, \dots e_n)$  dĺžky  $n+1$ .

Nech  $S \subseteq E_x = \{o, e_1 \dots e_n\}$ . Nech

$$\alpha i = \begin{cases} 1, & \text{ak } e_i \in S \\ -1, & \text{ak } e_i \notin S \end{cases}$$

$$\Theta = \begin{cases} -\frac{1}{2}, & \text{ak } o \in S \\ +\frac{1}{2}, & \text{ak } o \notin S \end{cases}$$

Priamou verifikáciou, ak  $\omega = (\alpha_1 \dots \alpha_n \Theta)$  je stav  $P_n$ , potom množina pozitívnych príkladov  $h_\omega$  je práve  $S \Rightarrow VCdim(P_n) \geq n + 1$ .  $\square$

### 1.3 Sauerova lema

Rastová funkcia - miera počtu rôznych klasifikácií vzorky dĺžky  $m$  na pozitívne a negatívne príklady podľa  $H$ , pokiaľ  $VCdim H$  je max. hodnota  $m$ , pre ktorú platí  $\Pi_H(m) = 2^m$ .

**Veta 3 (Sauerova lema):** Nech  $d \geq 0$  a  $m \geq 1$  sú celé kladné čísla, nech  $H$  je hypotézový priestor s  $VCdim(H) = d$ . Potom

$$\Pi_H(m) \leq \underbrace{1 + \binom{m}{1} + \binom{m}{2} + \dots + \binom{m}{d}}_{\Phi(d,m)}.$$

Binomické koeficienty splňajú

$$\binom{a}{b} = \binom{a-1}{b} + \binom{a-1}{b-1}$$

Zavedieme funkciu:

$$\Phi(0, m) = 1 \quad (m \geq 1);$$

$$\Phi(d, 1) = 2 \quad (d \geq 1)$$

$$\Phi(d, m) = \Phi(d, m-1) + \Phi(d-1, m-1), \quad (d \geq 1, m \geq 2)$$

**Dôkaz:** Ak  $VCdim(H) = d = 0$ , potom príklad x-ľub.,  $h(x)$  je rovnaké (buď 0 alebo 1) pre ľub. hypotézu  $h \in H$ .  $\Rightarrow \Pi_H(x) = 1$  pre ľub. vzorku dĺžky  $m \Rightarrow \Pi_H(m) = 1 = \Phi(0, m) \Rightarrow$  veta platí pre  $d = 0$ .

Ak  $m = 1$  a  $d \geq 1 \Rightarrow \Pi_H(1) \leq 2 = \Phi(d, 1)$

Indukciou na  $d + m$ :

- Prípad  $d + m = 2$  je dokázaný.
- Predpokladajme, že veta platí pre  $d + m \leq k$ , kde  $k \geq 2$  a nech  $H$  je hypotézový priestor s  $VCdim = d$ , x je trénovacia vzorka dĺžky  $m$ , kde  $d + m = k + 1$ .

Prípady  $(d, m) = (0, k+1)$  a  $(d, m) = (k, 1)$  sú už dokázané.

Nech  $d \geq 1$ ,  $m \geq 2$ , x obsahuje rôzne príklady,  $E$  je množina príkladov v x,  $H_E = H|E$  je obmedzenie hypotéz  $H$  na  $E$ .

$\Rightarrow H_E$  je konečný a  $\Pi_H(x) = |H_E|$ .

Potrebuje ukázať, že  $|H_E| \leq \Phi(d, m)$ .

Nech  $F = E \setminus \{x_m\}$ ,  $H_F = H|F$ .

Dve rôzne hypotézy  $h, g \in H_E$  pri obmedzení na  $F$  dávajú tú istú hypotézu z  $H_F$  práve vtedy, keď sa zhodujú na  $F$  a nezhodujú na  $x_m$ .

$H_*$  je množina všetkých hypotéz, ktoré vzniknú takto:

Ak  $h^* \in H_*$ , tak sú možné obe rozšírenia  $h^*$  na funkciu na  $E \dots$  hypotézu z  $H_E$ .  $h^*$  je rozšírenie  $\Rightarrow |H_E| = |H_F| + |H_*|$ .

Nech  $x' = (x_1 \dots x_{m-1})$ . Potom

$$|H_F| = \Pi_H(x') \leq \Pi_H(m-1) \leq \Phi(d, m-1)$$

protože  $d + (m-1) \leq k$ .

Tvrdíme, že  $VCdim(H_*)$  je najviac  $d-1$ . Ak by  $VCdim(H_*) = d \Rightarrow h^*$  rozbíja nejakú vzorku  $z = (z_1 \dots z_d)$  dĺžky d príkladov z  $F$ .

Pre

$$h^* \in H_* \left\{ \begin{array}{ll} h_1 \in H_E \dots & h_1(x_m) = 0 \\ h_2 \in H_E \dots & h_2(x_m) = 1 \end{array} \right.$$

$\Rightarrow H_E$  a teda  $H$  rozbíja vzorku  $(z_1 \dots z_d x_m)$  dĺžky  $d+1$ , čo je v spore s  $VCdim(H) \leq d$ .

$\Rightarrow VCdim(H_*) \leq d-1$ .

Použitím indukčnej hypotézy

$$|H_*| = \Pi_{H_*}(x'0) \leq \Pi_{H_*}(m-1) \leq \Phi(d-1, m-1)$$

protože  $(d-1) + (m-1) \leq k$ . Kombináciou oboch výsledkov dostaneme

$$\Pi_H(x) = |H_E| = |H_F| + |H_*| \leq \Phi(d, m-1) + \Phi(d-1, m-1) = \Phi(d, m).$$

□

**Tvrdenie 2** Pre všetky  $m \geq d \geq 1$  platí  $\Phi(d, m) < \left(\frac{e \cdot m}{d}\right)^d$ .

**Tvrdenie 3** Nech  $H$  je ľubovoľný hypotézový priestor obsahujúci aspoň 2 hypotézy a definovaný na konečnom príkladovom priestore  $X$ , potom  $VCdim(H) > \frac{\ln |H|}{1 - \ln |X|}$ .

## 1.4 Úlohy k VC-dim

1. Ukážte, že ak  $X = \mathbb{R}$  a  $H$  je množina všetkých uzavretých intervalov, tak  $\Pi_H(m) = 1 + m + \frac{1}{2}m(m-1)$ .
2. Popíšte expl. hypotézový priestor  $P_1$  a ukážte, že  $VCdim(P_1) = 2$ .
3. Ukážte, že ak  $H$  je hypotézový priestor reálneho perceptrónu  $P_2$ , tak  $\Pi_H(4) = 14$ .
4. Nech  $H$  má konečnú  $VCdim$ . Pre  $h \in H$  definujme  $\bar{h}$

$$\bar{h} = 1 \Leftrightarrow h(x) = 0$$

a nech komplement  $H$  je priestor  $\{\bar{h} : h \in H\}$ . Dokážte, že majú oba priestory rovnakú VC dimenziu.

5. Dokážte
  - (a)  $\Phi(d, m) = \Phi(d, m-1) + \Phi(d-1, m-1)$ ,  $d \geq 1, m \geq 2$
  - (b)  $\Phi(d, m) \leq m^d$ ,  $m \geq d > 1$ .
6. Monočlen je monotónny, ak neobsahuje žiadne negované literály. Dokážte, že priestor monotónnych monočlenov definovaný na  $\{0, 1\}^*$  má VC dimenziu práve  $n$ .
7. Hypotézový priestor  $H$  je lineárne usporiadany, ak má aspoň 2 hypotézy a ak pre ľubovoľné dve  $h, g \in H$  platí  
buď  $h(x) = 1 \Rightarrow g(x) = 1$   
alebo  $g(x) = 1 \Rightarrow h(x) = 1$   
Dokážte, že ak  $H$  je lineárne usporiadany,  $VCdim(H) = 1$ .
8. Nech  $G_n$  je množina hypotéz z  $P_n$ , pre ktoré nulový vektor  $o$  je negatívny príklad. Predpokladajme, že vzorka  $x = (x_1 \dots x_m)$  je rozbitá pomocou  $G_n$ . Prečo sa žiadne  $x_i$  nesmie rovnať 0? Dokážte, že vzorka  $(x_1 \dots x_m, 0)$  je rozbitá pomocou  $P_n$ . Dokážte, že  $VCdim(G_n) = n$ .

## Kapitola 2

# Učenie a VC dimenzia

### 2.1 Úvod

Ukážeme, že pre ľub. hypotézový priestor  $H$  nutnou a postačujúcou podmienkou pre jeho potenciálnu naučiteľnosť je konečná VC dimenzia.

Máme potenciálne naučiteľné hypotézové priestory práve tie, ktoré majú konečnú VC dimenziu?

### 2.2 VC dimenzia a potenciálna naučiteľnosť

Označenie:  $\bar{s} = (\bar{x}, \bar{b})$  pre  $\bar{s} = ((x_1, b_1) \dots (x_m, b_m)) \in (X \times \{0, 1\})^m$ . Ak  $t$  je cieľový koncept a  $\bar{s}$  je tréningová vzorka pre  $t$ , potom  $\bar{s}$  označíme  $(\bar{x}, t(\bar{x}))$ .

Toto zdôrazňuje fakt, že keď  $\bar{s} \in S(m, t)$  sú dané len hodnoty  $t$  na prvkoch tréningovej vzorky  $\bar{x}$ .

$H[\bar{x}, t]$  podmnožinu  $H$ , ktorá je v súlade s  $\bar{s}$   $H[(\bar{x}, t(\bar{x}))]$

Pozorovaná chyba hypotézy  $h \in H$  na  $\bar{s}$

$$er_{\bar{s}}(h) = \frac{1}{m} |\{i : h(x_i) \neq b_i\}|$$

$H[\bar{s}] = \{h \in H \mid h(x_i) = t(x_i), 1 \leq i \leq m\}$ ,  $H[\bar{s}]$  je množina hypotéz, ktoré majú nulovú chybu na  $\bar{s}$ .

Ak  $\bar{s} = (\bar{x}, t(\bar{x}))$ , potom  $er_{\bar{s}}(h)$  sa nazýva pozorovaná chyba  $h$  na  $\bar{x}$  vzhľadom na  $t$   $er_{\bar{s}}(h, t)$ , alebo  $er_{\bar{s}}(h)$ , ak  $t$  je zrejmé.

**Veta 4** Ak hypotézový priestor má nekonečnú VC dimenziu, tak nie je potenciálne naučiteľný.

#### Dôkaz:

Nech  $H$  má nekonečnú VC dimenziu, t.j. pre ľub.  $m > 0$  existuje vzorka  $\bar{z}$  dĺžky  $2m$ , ktorá je rozbitá podľa  $H$ .

Nech  $E = E_{\bar{z}}$  je množina príkladov v tejto vzorke a definujme rozdelenie pravdepodobnosti  $\mu$  na  $X$

$$\mu(x) = \begin{cases} \frac{1}{2^m} & \text{pre } x \in E \\ 0 & \text{inak} \end{cases}$$

Vzhľadom na  $\mu$  každý príklad v  $E$  má rovnakú pravdepodobnosť prezentácie a ostatné príklady majú pravdepodobnosť 0.

$$\mu^m \dots E^m \quad \text{a } 0 \text{ inde}$$

Teda s pravdepodobnosťou 1 náhodne vybratá vzorka  $\bar{s}$  dĺžky  $m$  je vzorkou príkladov z  $E$ .

Nech  $\bar{s} = (\bar{x}, t(\bar{x})) \in S(m, t)$ . S pravdepodobosťou 1 (vzhľadom  $\mu^m$ ) máme  $x_i \in E$  pre  $1 \leq i \leq m$ . Pretože  $\bar{z}$  je rozbitá podľa  $H$ , ex. hypotéza  $h \in H$  taká ,že

$$h(x_i) = t(x_i) \text{ pre } 1 \leq i \leq m \quad \text{a}$$

$$h(x) \neq t(x) \text{ pre vsetky ostatne } x \in E$$

Z toho vyplýva, že  $h \in H[\bar{s}]$ : h má chybu aspoň  $\frac{1}{2}$  vzhľadom na t.

Ukázali sme, že pre ľub.  $m > 0$ , ľub. t ex. pravdep. r oz.  $\mu$  na X také, že udalosť  $H[\bar{s}] \cap B_{\frac{1}{2}} = \emptyset$  má pravdepodobnosť 0.

Teda neex. žiadne  $m_0 > 0$ ,  $m_0 = m_0(\frac{1}{2}, \frac{1}{2})$  pre ktoré by sme mohli tvrdiť, že pre všetky  $m > m_0 \mu^m \{ \bar{s} \in S(m, t) | H[\bar{s}] \cap B_{\frac{1}{2}} = \emptyset \} > \frac{1}{2}$ .

$\Rightarrow H$  nie je potenciálne naučiteľné.  $\square$

**Príklad:** Pre každú  $A \subseteq R$  definujeme charakteristickú funkciu

$$\chi_A : \chi_A(y) = \begin{cases} 1 & \text{ak } y \in A \\ 0 & \text{inak} \end{cases}$$

U-systém všetkých podmnožín R takých, ktoré sú konečnými zjednoteniami uzavretých intervalov

$J = \{\chi_A : A \in U\}$  - priestor zjedn. intervalov

$\text{VCdim}(J)$  je nekonečná!

$\bar{x} = (x_1 \dots x_m)$  je trén. vzorka príkladov z R,  $E_x$  je odp. množ. príkladov  $S \subseteq E_x$ ; k S je možné skonštruovať  $A \in U$  tak, že  $S \subseteq A$  a  $(E_{\bar{x}} S) \cap A = \emptyset$  takto:

Pre každé  $x_i \in S$  nech  $A_i$  je interval, ktorý obsahuje  $x_i$  ale neobsahuje žiadny iný prvok  $x \in E_{\bar{x}}$ .

Nech  $A = \bigcup A_i$ , A je konečné zjednotenie

$$\chi_A = 1 \quad \text{na} \quad S$$

$$\chi_A = 0 \quad \text{na} \quad E_{\bar{x}} - S$$

Inak povedané, J rozbíja  $\bar{x}$ .

Pretože tento argument je použiteľný a platí len pre konečné vzorky  $\Rightarrow \text{VC dim}(J)$  je nekonečná.

Poznamka :

J je obsiahnutý v priestore všetkých uzavretých podm. R (char. funkcií).

Čo by sa dalo povedať o VC dim tohto všeobec. priestoru?

Jeho VC dim je nekonečná.

H-hypotézový priestor def. na príkl. priestore X

t-cieľový koncept v H

$\mu$  - pravdepodobnostné rozdelenie na X

$\epsilon$  - ľub. r.č.  $0 \leq \epsilon \leq 1$

Nech  $t, \mu, \epsilon$  - fixné, ale ľubovoľné

Definujme

$$Q_m^\epsilon = \{x \in X^m : H[x, t] \cap B_\epsilon \neq \emptyset\}$$

Pravdepodobnosť výberu trén. vzorky, pre ktorú existuje konzist., ale  $\epsilon$ -zlá hypotéza je

$$\mu^m = \{\bar{s} \in S(m, t) : H[\bar{s}] \cap B_\epsilon \neq \emptyset\}$$

čo je vlastne  $\mu^m(Q_m^\epsilon)$ .

Teda ukázať, že H je potenciálne naučiteľný znamená nájsť hornú hranicu  $f(m, \epsilon)$  pre  $\mu^m(Q_m^\epsilon)$ , ktorá je nezávislá od t a  $\mu$  a ktorá ide k 0, keď  $m \rightarrow \infty$

Potom

$$\forall (0 < \delta < 1) \exists (m_0) \forall (m \geq m_0) \quad f(m, \epsilon) < \delta$$

$m_0 = m_0(\delta, \epsilon)$ ,  $m_0$  je tiež hornou hranicou pre veľkosť trén. vzorky.

Tvrdenie: Nech H je hypotézový priestor definovaný na príkladovom priestore  $X, t, \mu, \epsilon$  sú ľub. ale pevne dané. Potom

$$\mu^m \{ \bar{s} \in S(m, t) : H[\bar{s}] \cap B_\epsilon \neq \emptyset \} < \underbrace{2\Pi_H(2m) 2^{\frac{-\epsilon m}{2}}}_{f(m, \epsilon)}$$

pre vš.  $m \geq \frac{8}{\epsilon}$ .

$$\Pi_H(m) \leq 1 + \binom{m}{1} + \binom{m}{2} + \dots + \binom{m}{d} \quad \text{polynóm}$$

$$\lim_{n \rightarrow \infty} 2\Pi_H(2m)2^{\frac{-\epsilon m}{2}} \rightarrow 0 \quad ?$$

Kľúčový výsledok: VC dim implikuje potenciálnu naučiteľnosť.

**Veta 5** Ak má hypotézový priestor konečnú VC dimenziu, potom je potenciálne naučiteľný.

D: 4 fázy

- Ohraničiť  $\mu^m(Q_m^\epsilon)$  pravdepodobnosťou určitej podmnožiny  $R_m^\epsilon$  v  $X^{2m}$
- Použitím skupiny akcií ohraničiť pravdepodobnosť  $R_m^\epsilon$  pomocou konečných výrazov
- Vyjadriť túto hranicu pomocou  $\Pi_H$  - komb. argumentami
- Použiť argument posl. lemy na vyjadrenie výsledku, že  $\mu^m(Q_m^\epsilon) \rightarrow 0$ , ked  $m \rightarrow \infty$

### 1.fáza:

$\bar{x}, \bar{y} \in X^m, \bar{xy} \in X^{2m}$  - je trén. vzorka dĺžky  $2m$

$$R_m^\epsilon = \{\bar{xy} \in X^{2m} : \exists h \in B_\epsilon \text{ pre ktorú } er_{\bar{x}}(h) = 0 \text{ a } er_{\bar{y}}(h) > \frac{\epsilon}{2}\}$$

Lema 1: Pre vš.  $m \leq \frac{8}{\epsilon}$  platí

$$\mu^m(Q_m^\epsilon) \geq 2\mu^{2m}(R_m^\epsilon).$$

D:

$\chi_Q \dots$  charakteristická funkcia  $Q_m^\epsilon$ :

$$\chi_Q(\bar{x}) = 1, \text{ ak } \bar{x} \in Q_m^\epsilon$$

$$\chi_Q(\bar{x}) = 0, \text{ inak.}$$

$$\chi_R(\bar{xy}) = \chi_Q(\bar{x})\psi_{\bar{x}}(\bar{y}), \text{ kde}$$

$$\psi_{\bar{x}}(\bar{y}) = \begin{cases} 1 & \text{ak } \exists h \in H[\bar{x}] \cap B_\epsilon \text{ s } er_{\bar{y}}(h) > \frac{\epsilon}{2} \\ 0 & \text{inak} \end{cases}$$

$$\mu^{2m}(R_m^\epsilon) = \int \chi_R(\bar{xy}) = \int (\chi_Q(\bar{x}) \int \psi_{\bar{x}}(\bar{y}))$$

$\int$  sú cez celé relevantné priestory;

Vnútorný integrál je pravdepodobnosť, že pri danom  $\bar{x}$  existuje  $h \in B_\epsilon$ , ktoré je konzistentné s  $\bar{x}$  a splňuje  $er_{\bar{y}}(h) > \frac{\epsilon}{2}$ .

Tento integrál určite nie je menej než pravdep., že partikulárne  $h \in B_\epsilon$  konzist. s  $\bar{x}$  splňuje  $er_{\bar{y}}(H) > \frac{\epsilon}{2}$ .

$$?? \Rightarrow \mu^{2m}(R_m^\epsilon) \geq \int \frac{1}{2} \chi_Q(\bar{x}) = \frac{1}{2} \mu^m(Q_m^\epsilon)$$

Chernovova hranica (bin. rozdelenie)

$0 \leq p \leq 1$ , LE(p,m,s)-pravdepodobnosť najviac s úspechov v m nezávislých pokusoch, z ktorých každý má pravdepodob. p.

$$LE(p,m,(1-\beta)mp) \leq e^{\frac{-\beta^2 mp}{2}} \quad \text{pre ľub. } 0 \leq \beta \leq 1.$$

Nech  $h \in B_\epsilon$ ,  $er_\mu(h) = \epsilon_h > \epsilon$ . Pre  $\bar{y} \in X^m$ ,  $mer_{overline{y}}(h)$  označuje počet komponentov, na ktorých t a h sa líšia = je to bin. rozdelená náh. prem.

$$\mu^m\{\bar{y} : er_{\bar{y}}(h) \leq \frac{\epsilon}{2}\} = \mu^m\{\bar{y} : mer_{\bar{y}}(h) \leq \frac{\epsilon}{2}m\}$$

$$\leq \mu^m\{\bar{y} : mer_{\bar{y}}(h) \leq \frac{\epsilon_h}{2}m\} = LE(\epsilon_h, m, (1 - \frac{1}{2})m\epsilon_h)$$

$$\leq exp(\frac{-\epsilon_h m}{8}) < exp(\frac{-\epsilon m}{8})$$

???

## 2.fáza:

Nech  $i \in \{1, \dots, m\}$

$\tau_i$  je permutácia, ktorá vymení i a  $m+i$  tý prvok;

Nech  $G_m$  je grupa generovaná permutáciami  $\tau_i \{1 \leq i \leq m\}$   $|G_m| = 2^m$

Lema 2: Pre dané  $\bar{z} \in X^{2m}$  nech  $\Gamma(\bar{z})$  označuje počet  $\sigma \in G_m$ , pre ktoré  $\sigma\bar{z} \in R_m^\epsilon$ . Potom  $|G_m| \mu^{2m}(R_m^\epsilon) \leq \max \Gamma(\bar{z})$  kde max je cez vš.  $\bar{z} \in X^{2m}$ .

## 3.fáza:

Pre ľub.  $h \in B_\epsilon$  nech

$$R_m^\epsilon(h) = \{\bar{xy} \in X^{2m} : er_{\bar{x}}(h) = 0 \quad \text{a} \quad er_{\bar{y}}(h) > \frac{\epsilon}{2}\}$$

Pre  $\bar{z} \in X^{2m}$ ,  $\Gamma(h, \bar{z})$  počet  $\sigma \in G_m$ , ktoré transformujú  $\bar{z}$  na vektor v  $R_m^\epsilon(h)$ .

Lema 3:  $m > 0$ ,  $h \in B_\epsilon$ . Potom  $\Gamma(h, \bar{z}) < 2^{m(1-\frac{\epsilon}{2})}$  pre vš.  $\bar{z} \in X^{2m}$ .

Lema 4: Pre ľub.  $m > 0$   $\mu^{2m}(R_m^\epsilon) < \Pi_H(2m)2^{-\frac{\epsilon m}{2}}$

**4. fáza:** - kombinácia predch. výsledkov

## 2.3 Zložitosť vzorky konzistentných algoritmov

Fakt: Ak hypotézový priestor  $H$  má konečnú  $VC$  dimenziu, tak je potencionálne naučiteľný.

Inak povedané:

K ľubovoľným parametrom  $\delta$  - dôveryhodnosť,  $\epsilon$  - presnosť ( $0 < \delta, \epsilon < 1$ ), existuje vzorka dĺžky  $m_0 = m_0(H, \delta, \epsilon)$  taká, že

$$m \geq m_0 \implies \mu^m \{s \in S(m, t); H[s] \cap B_\epsilon = 0\} > 1 - \delta \quad (2.1)$$

pre ľubovoľné pravdepodobnostné rozdelenie  $\mu$  na  $X$  ľubovoľný cieľový koncept  $t \in H$ .

Teda z toho vyplýva, že

- Ľubovoľný konzistentný učiaci algoritmus  $L$  pre  $H$  je *pac* a ďalej
- Ľubovoľné  $m_0(H, \delta, \epsilon)$ , pre ktoré platí vyššie uvedená podmienka, je horná hranica na zložitosť vzorky  $m_L(H, \delta, \epsilon)$ .

Ukážeme, že existuje presnejší výraz pre  $m_0$ , a teda pre hornú hranicu na zložitosť vzorky ľubovoľného konzistentného učiaceho algoritmu  $L$  pre  $H$ .

Pripomeňme, že bolo dokázané, že ak  $H$  je konečný hypotézový priestor a  $L$  je konzistentný učaci algoritmus pre  $H$ , tak  $L$  je *pac* a platí

$$m_L(H, \delta, \epsilon) \leq \left\lceil \frac{1}{\epsilon} \ln \left( \frac{|H|}{\delta} \right) \right\rceil \quad (2.2)$$

Horná hranica, ktorú odvodíme, závisí od  $VC$  dimenzie  $H$  a nie od mohutnosti  $H$ .

**Veta:** Predpokladajme, že  $H$  je hypotézový priestor s konečnou  $VC$  dimenziou  $d \geq 1$  a platí  $0 < \delta, \epsilon < 1$ . Nech

$$m_0 = m_0(H, \delta, \epsilon) = \left\lceil \frac{4}{\epsilon} (d \cdot \lg(\frac{12}{\epsilon}) + \lg(\frac{2}{\delta})) \right\rceil \quad (2.3)$$

Potom pre ľubovoľné  $m \geq m_0$  platí

$$\mu^m \{s \in S(m, t); H[s] \cap B_\epsilon \neq \emptyset\} < \delta. \quad (2.4)$$

**Dôsledok:** Predpokladajme, že hypotézový priestor  $H$  má  $VC$  dimenziu  $d \geq 1$ . Potom ľubovoľný konzistentný učaci algoritmus  $L$  pre  $H$  je *pac* so zložitosťou vzorky

$$m_L(H, \delta, \epsilon) \leq \left\lceil \frac{4}{\epsilon} (d \cdot \lg(\frac{12}{\epsilon}) + \lg(\frac{2}{\delta})) \right\rceil \quad (2.5)$$

Toto už je slúbený výsledok.

**Príklad 1:** Nech  $H$  je priestor lúčov. Jeho  $VC$  dimenzia je  $VCdim(H) = 1$ , teda ak  $L$  je ľubovoľný konzistentný učiaci algoritmus pre priestor lúčov, máme

$$m_L(H, \delta, \epsilon) \leq \left\lceil \frac{4}{\epsilon} \left( d \cdot \lg\left(\frac{12}{\epsilon}\right) + \lg\left(\frac{2}{\delta}\right) \right) \right\rceil \quad (2.6)$$

My sme priamo dokázali, že

$$m_0 = \left\lceil \frac{1}{\epsilon} \ln\left(\frac{1}{\delta}\right) \right\rceil. \quad (2.7)$$

Vidíme, že hranica vypočítaná priamo je lepšia než vyplývajúca z  $VC$  dimenzie. Avšak priame argumenty sú mnohokrát ťažké a v tomto prípade je zrejmé, že ak  $\delta$  a  $\epsilon$  sú toho istého radu, tak tieto hranice sa líšia len o konštantu.

**Príklad 2:** Reálny perceptrón  $P_n$  má  $VC$  dimenziu  $n + 1$ . Predpokladajme, že pre ľubovoľnú tréningovú vzorku pre hypotézu v  $P_n$  máme nájsť stav  $\omega$  perceptrónu taký, že  $h_\omega$  je konzistentná so vzorkou. Potom keď použijeme tréningovú vzorku dĺžky

$$\left\lceil \frac{4}{\epsilon} \left( (n+1) \cdot \lg\left(\frac{12}{\epsilon}\right) + \lg\left(\frac{2}{\delta}\right) \right) \right\rceil \quad (2.8)$$

máme zaručenú približne správnu hypotézu bez ohľadu na cieľovú hypotézu a pravdepodobnostné rozdeľenie príkladov.

## 2.4 Dolné hranice pre zložitosť vzorky

Pripomeňme, že sme dokázali, že ak priestor  $H$  má nekonečnú  $VC$  dimenziu, tak nie je potenciálne naučiteľný.

**Veta:** Predpokladajme, že hypotézový priestor  $H$  má  $VC$  dimenziu  $d \geq 1$ . Potom existuje konzistentný pac učiaci algoritmus  $L$  pre  $H$  taký, že pre ľubovoľné  $\delta$  a  $\epsilon$  zložitosť vzorky splňuje

$$m_L(H, \delta, \epsilon) \geq d(1 - \epsilon).$$

Uvedený výsledok je sice jednoduchý, ale je použiteľný len na konzistentné učiace algoritmy. Ďalej neposkytuje univerzálnu dolnú hranicu na zložitosť vzorky konzistentného učiaceho algoritmu; skôr sa zoberá najhoršími možnými konzistentnými učiacimi algoritmami. Ukážeme silnejší výsledok Ehrenfeuchta et al. - 1989, ktorý poskytuje dolnú hranicu na zložitosť vzorky ľubovoľného pac učiaceho algoritmu pre hypotézový priestor konečnej  $VC$  dimenzie.

**Veta:** Pre ľubovoľný hypotézový priestor  $H$  s  $VC$  dimenziou  $d \geq 1$  a pre ľubovoľný pac učiaci algoritmus  $L$  pre  $H$  platí

$$m_L(H, \delta, \epsilon) > \frac{d-1}{32\epsilon} \quad (2.9)$$

pre  $\delta \leq \frac{1}{100}$  a  $\epsilon \leq \frac{1}{8}$ .

Ak by sme uvažovali, že zložitosť vzorky prekročí  $(d_0 - 1)/32\epsilon$ , kde  $d_0$  je ľubovoľné kladné číslo spĺňajúce  $VCdim(H) \geq d_0$ , tak by sme mohli dokázať nasledujúce tvrdenie:

**Tvrdenie:** Ak hypotézový priestor  $H$  má konečnú  $VC$  dimenziu, tak neexistuje žiadny pac učiaci algoritmus pre  $H$ .

Tieto výsledky podporujú tvrdenie, že  $VC$  dimenzia je dobrá miera "expresívnej sily" hypotézového priestoru  $H$ : väčšia  $VC$  dimenzia  $H$  znamená väčšiu zložitosť vzorky pre pac učenie  $H$ . V skutočnosti

výsledky môžu byť zovšeobecnené aj pre prípady, keď  $C$  je ľubovoľný konceptový priestor s  $VC$  dimenziou a aspoň  $d_0 \geq 1$  a  $H$  je ľubovoľný hypotézový priestor (nie nutne rovný  $C$ ).

Ak  $L$  je učiaci algoritmus pre  $(C, H)$ , vstupom do  $L$  musí byť tréningová vzorka dĺžky väčšej než  $(d_0 - 1)/32\epsilon$ , aby bola zaručená presnosť  $\epsilon \leq \frac{1}{8}$  s pravdepodobnosťou  $1 - \delta > 99/100$ . Ak  $C$  má nekonečnú  $VC$  dimenziu, tak nemôže existovať žiadny učiaci algoritmus pre  $(C, H)$ , ktorý je *pac* pre ľubovoľný hypotézový priestor  $H$ .

**Príklad:** Ak  $J$  je priestor všetkých zjednotení intervalov, tak pretože  $J$  má nekonečnú  $VC$  dimenziu, neexistuje žiadny *pac* učiaci algoritmus pre  $(J, H)$  pre ľubovoľný hypotézový priestor  $H$ . Vyššie uvedený výsledok je veľmi silný. Ukazuje nielen to, že neexistuje žiadny konzistentný alebo efektívny *pac* učaci algoritmus, ale tiež, že pre dané neohraničené výpočtové zdroje žiadny algoritmus nemôže *pac* naučiť  $J$  nezávisle od toho ako by boli reprezentované výstupné hypotézy. Samozrejme, tieto závery platia pre ľubovoľný priestor nekonečnej  $VC$  dimenzie, takých ako priestor všetkých uzavretých množín alebo priestor charakteristických funkcií všetkých polygonálnych oblastí v  $\mathbf{R}^2$ .

Iný výsledok týkajúci sa dolných hraníc zaviedol Blumer et al., 1989. Tento výsledok obsahuje  $\delta$  a  $\epsilon$ , ale nezávisí od  $VC$  dimenzie hypotézového priestoru. Toto sa dá použiť na netriviálne hypotézové priestory, t. j. také priestory, ktoré obsahujú viac než dve hypotézy.

**Veta:** Predpokladajme, že  $L$  je ľubovoľný *pac* učaci algoritmus pre netriviálny hypotézový priestor  $H$ . Potom

$$m_L(H, \delta, \epsilon) > \frac{(1 - \epsilon)}{\epsilon} \ln\left(\frac{1}{\delta}\right), \quad (2.10)$$

pre ľubovoľné  $0 < \delta, \epsilon < 1$ .

## 2.5 Porovnanie hraníc zložitosti vzoriek

Ako už bolo uvedené, mnohé predchádzajúce výsledky môžu byť zovšeobecnené pre prípad, keď konceptový a hypotézový priestor sú rôzne. Ukážeme hranice pre zložitosť vzorky v týchto všeobecnejších prípadoch.

**Veta:** Nech  $C$  je konceptový a  $H$  je hypotézový priestor a predpokladajme, že  $H$  má konečnú  $VC$  dimenziu aspoň 1. Ak  $L$  je ľubovoľný konzistentný učaci algoritmus pre  $(C, H)$ , potom  $L$  je *pac* a pre zložitosť vzorky platí

$$m_L \leq \left\lceil \frac{4}{\epsilon} (VCdim(H) \lg\left(\frac{12}{\epsilon}\right) + \lg\left(\frac{2}{\delta}\right)) \right\rceil \quad (2.11)$$

pre ľubovoľné  $\delta$  a  $\epsilon$ .

**Veta:** Nech  $C$  je konceptový a  $H$  je hypotézový priestor taký, že  $C$  má  $VC$  dimenziu aspoň 1. Predpokladajme, že  $L$  je ľubovoľný *pac* učaci algoritmus pre  $(C, H)$ . Potom pre zložitosť vzorky pre  $L$  platí

$$m_L > \max\left(\frac{VCdim(C) - 1}{32\epsilon}, \frac{1}{\epsilon} \ln\left(\frac{1}{\delta}\right)\right) \quad (2.12)$$

pre všetky  $\delta \leq 1/100$  a  $\epsilon \leq 1/8$ .

Označenie:

Píšeme  $f = O(g)$ , ak existuje nejaká konštanta  $k > 0$  taká, že pre všetky relevantné  $x$  platí  $f(x) \leq k.g(x)$ .

Píšeme  $f = \Omega(g)$ , ak existuje nejaká konštanta  $k > 0$  taká, že pre všetky relevantné  $x$  platí  $f(x) \geq k.g(x)$ .

Použitím tohto označenia sformulujeme vzťahy pre zložitosť vzorky.

- Ak  $L$  je *pac*, potom  $C$  musí mať konečnú  $VC$  dimenziu a platí

$$m_L(C, \delta, \epsilon) = \Omega\left(\frac{VCdim(C)}{\epsilon} + \frac{1}{\epsilon} \ln\left(\frac{1}{\delta}\right)\right) \quad (2.13)$$

- Ak  $H$  má konečnú  $VC$  dimenziu a  $L$  je konzistentný, potom  $L$  je *pac* a platí

$$m_L(C, \delta, \epsilon) = O\left(\frac{VCdim(C)}{\epsilon} \ln\left(\frac{1}{\epsilon}\right) + \frac{1}{\epsilon} \ln\left(\frac{1}{\delta}\right)\right) \quad (2.14)$$

- Ak  $H$  je konečný a  $L$  je konzistentný, potom  $L$  je *pac* a platí

$$m_L(C, \delta, \epsilon) = O\left(\frac{1}{\epsilon} \ln|H| + \frac{1}{\epsilon} \ln\left(\frac{1}{\delta}\right)\right) \quad (2.15)$$

V prípade, že  $C = H$ ,  $VC$  dimenzia  $d$  je konečná a  $L$  je konzistentný, máme dolné a horné hranice

$$\begin{aligned} m_L(H, \delta, \epsilon) &= \Omega\left(\frac{d}{\epsilon} + \frac{1}{\epsilon} \ln\left(\frac{1}{\delta}\right)\right); \\ m_L(H, \delta, \epsilon) &= O\left(\frac{d}{\epsilon} \ln\left(\frac{1}{\epsilon}\right) + \frac{1}{\epsilon} \ln\left(\frac{1}{\delta}\right)\right); \end{aligned}$$

Faktor  $\ln(1/\epsilon)$ , ktorý odlíšuje hornú hranicu od dolnej, je nevyhnutný. Výsledky Hausslera, Littlestonea a Warmutha, 1988, ukazujú, že pre každé  $d \geq 1$  existuje hypotézový priestor  $H_d$  a konzistentný učiaci algoritmus  $L$  pre  $H_d$  so zložitosťou vzorky rovnou hornej hranici. Na druhej strane je otvorený problém rozhodnúť, či pre každé  $d$  a pre každý koncepciový priestor  $C$  s  $VC$  dimensiou  $d$ , existuje *nejaký* hypotézový priestor  $H$  a *nejaký*  $(C, H)$  učaci algoritmus  $L$ , pre ktorý zložosť vzorky má dolnú hranicu.

## 2.6 Cvičenia:

1. Nech  $H$  je hypotézový priestor s vlastnosťou, že pre ľubovoľné  $t \in H$  a ľubovoľné  $0 < \delta, \epsilon < 1$ , existuje  $m_0(t, \delta, \epsilon)$  také, že

$$m \geq m_0(t, \delta, \epsilon) \implies \mu^m\{\mathbf{s} \in S(m, t); H[\mathbf{s}] \cap B_\epsilon\} > 1 - \delta$$

pre ľubovoľné rozdelenie pravdepodobnosti  $\mu$  na vstupnom priestore. Teda  $m_0$  môže závisieť len na cielovom koncepte. Ukážte, že  $H$  musí mať konečnú  $VC$  dimenziu a je preto potencionálne naučiteľný.

2. Dokážte, že pre ľubovoľné  $c > 0$  platí

$$\ln x \leq \left(\ln\left(\frac{1}{c}\right) - 1\right) + cx,$$

pre všetky  $x > 0$ .

3. Ukážte, že priestor charakteristických funkcií uzavretých a ohraničených polygónových oblastí v rovine  $\mathbf{R}^2$  nie je *pac* naučiteľný.
4. Prepokladajme, že  $H$  je ľubovoľný hypotézový priestor konečnej  $VC$  dimenzie  $d \geq 1$  a že  $L$  je ľubovoľný konzistentný učaci algoritmus pre  $H$ . Je dané nejaké rozdelenie pravdepodobnosti na príkladovom priestore. Akú veľkú tréningovú vzorku potrebujeme, aby s aspoň z 90% nou šancou sme získali hypotézu s chybou menšou než 5%?
5. Booleovská funkcia  $f$  sa nazýva *symetrická*, ak  $f(x)$  závisí len od počtu vstupov  $x$ , ktoré sú rovné 1. Napríklad, pre ľubovoľné  $n$  koncept parity definovaný na  $\{0, 1\}^n$  je symetrický. Nech  $n$  je kladné celé číslo a nech  $S_n$  označuje množinu všetkých symetrických funkcií na  $\{0, 1\}^n$ . Aká je  $VC$  dimenzia  $S_n$ ? Uvedte dolnú a hornú hranicu zložitosti vzorky pre ľubovoľný konzistentný *pac* učaci algoritmus pre  $S_n$ . Poznamenajme, že ľubovoľná hypotéza  $h$  v  $S_n$  môže byť reprezentovaná vektorom  $(h_0, h_1, \dots, h_n) \in \{0, 1\}^{n+1}$ , kde  $h_i$  je hodnota  $h$  na príkladoch majúcich presne  $i$  jedničiek. Navrhnite konzistentný učaci algoritmus pre  $S_n$ , ktorý reprezentuje priestor týmto spôsobom.
6. Nech  $H, G$  sú hypotézové priestory definované na tom istom príkladovom priestore  $X$ . Pre hypotézy  $h \in H, g \in G$ , definujme  $h \vee g$  takto

$$h \vee g = 1, \text{ ak } h(x) = 1 \text{ alebo } g(x) = 1; 0 \text{ inak} .$$

Nech  $H \vee G = \{h \vee g; h \in H, g \in G\}$ .

Dokážte, že

$$\Pi_{H \vee G} \leq \Pi_H(m)\Pi_G(m)$$

pre všetky  $m$ . Definujte  $H \wedge G$  obvyklým spôsobom, dokážte analogický výsledok pre tento priestor. Ak  $H$  a  $G$  sú potenciálne naučiteľné, čo je možné povedať o  $H \vee G$  a  $H \wedge G$ ?

7. Nech  $H$  je hypotézový priestor konečnej  $VC$  dimenzie  $d \geq 1$  a pre  $s \geq 1$  definujme  $H(s)$  induktívne takto:  $H(1) = H$  a  $H(k) = H \vee H(k-1)$ ,  $k \geq 2$ . Dokážte, že pre  $m > d$  platí

$$\Pi_{H(s)} \leq \left(\frac{em}{d}\right)^{sd}.$$

Potom ukážte, že  $VC$  dimenzia  $H(s)$  je najviac  $2s \lg(3s)$ .

## 2.7 Zložitosť vzorky konzistentných algoritmov

Fakt: **Ak hypotézový priestor  $H$  má konečnú  $VC$  dimenziu, tak je potencionálne naučiteľný.**

Inak povedané:

K ľubovoľným parametrom  $\delta$  - dôveryhodnosť,  $\epsilon$  - presnosť ( $0 < \delta, \epsilon < 1$ ), existuje vzorka dĺžky  $m_0 = m_0(H, \delta, \epsilon)$  taká, že

$$m \geq m_0 \implies \mu^m \{ \mathbf{s} \in S(m, t); H[\mathbf{s}] \cap B_\epsilon = 0 \} > 1 - \delta \quad (2.16)$$

pre ľubovoľné pravdepodobnostné rozdelenie  $\mu$  na  $X$  ľubovoľný cieľový koncept  $t \in H$ .

Teda z toho vyplýva, že

- Ľubovoľný konzistentný učiaci algoritmus  $L$  pre  $H$  je *pac* a ďalej
- Ľubovoľné  $m_L(H, \delta, \epsilon)$ , pre ktoré platí vyššie uvedená podmienka, je horná hranica na zložitosť vzorky  $m_L(H, \delta, \epsilon)$ .

Ukážeme, že existuje presnejší výraz pre  $m_0$ , a teda pre hornú hranicu na zložitosť vzorky ľubovoľného konzistentného učiaceho algoritmu  $L$  pre  $H$ .

Pripomeňme, že bolo dokázané, že ak  $H$  je konečný hypotézový priestor a  $L$  je konzistentný učiaci algoritmus pre  $H$ , tak  $L$  je *pac* a platí

$$m_L(H, \delta, \epsilon) \leq \left\lceil \frac{1}{\epsilon} \ln \left( \frac{|H|}{\delta} \right) \right\rceil \quad (2.17)$$

Horná hranica, ktorú odvodíme, závisí od  $VC$  dimenzie  $H$  a nie od mohutnosti  $H$ .

**Veta:** Predpokladajme, že  $H$  je hypotézový priestor s konečnou  $VC$  dimensiou  $d \geq 1$  a platí  $0 < \delta, \epsilon < 1$ . Nech

$$m_0 = m_0(H, \delta, \epsilon) = \left\lceil \frac{4}{\epsilon} (d \cdot \lg(\frac{12}{\epsilon}) + \lg(\frac{2}{\delta})) \right\rceil \quad (2.18)$$

Potom pre ľubovoľné  $m \geq m_0$  platí

$$\mu^m \{ \mathbf{s} \in S(m, t); H[\mathbf{s}] \cap B_\epsilon \neq \emptyset \} < \delta. \quad (2.19)$$

**Dôsledok:** Predpokladajme, že hypotézový priestor  $H$  má  $VC$  dimenziu  $d \geq 1$ . Potom ľubovoľný konzistentný učiaci algoritmus  $L$  pre  $H$  je *pac* so zložitosťou vzorky

$$m_L(H, \delta, \epsilon) \leq \left\lceil \frac{4}{\epsilon} (d \cdot \lg(\frac{12}{\epsilon}) + \lg(\frac{2}{\delta})) \right\rceil \quad (2.20)$$

Toto už je sľúbený výsledok.

**Príklad 1:** Nech  $H$  je priestor lúčov. Jeho  $VC$  dimenzia je  $VCdim(H) = 1$ , teda ak  $L$  je ľubovoľný konzistentný učiaci algoritmus pre priestor lúčov, máme

$$m_L(H, \delta, \epsilon) \leq \left\lceil \frac{4}{\epsilon} (d \cdot \lg(\frac{12}{\epsilon}) + \lg(\frac{2}{\delta})) \right\rceil \quad (2.21)$$

My sme priamo dokázali, že

$$m_0 = \left\lceil \frac{1}{\epsilon} \ln \left( \frac{1}{\delta} \right) \right\rceil. \quad (2.22)$$

Vidíme, že hranica vypočítaná priamo je lepšia než vyplývajúca z  $VC$  dimenzie. Avšak priame argumenty sú mnohokrát ľažké a v tomto prípade je zrejmé, že ak  $\delta$  a  $\epsilon$  sú toho istého radu, tak tieto hranice sa líšia len o konštantu.

**Príklad 2:** Reálny perceptrón  $P_n$  má  $VC$  dimenziu  $n + 1$ . Predpokladajme, že pre ľubovoľnú tréningovú vzorku pre hypotézu v  $P_n$  máme nájsť stav  $\omega$  perceptrónu taký, že  $h_\omega$  je konzistentná so vzorkou. Potom keď použijeme tréningovú vzorku dĺžky

$$\left\lceil \frac{4}{\epsilon} \left( (n+1) \cdot \lg \left( \frac{12}{\epsilon} \right) + \lg \left( \frac{2}{\delta} \right) \right) \right\rceil \quad (2.23)$$

máme zaručenú približne správnu hypotézu bez ohľadu na cieľovú hypotézu a pravdepodobnostné rozdelenie príkladov.

## 2.8 Dolné hranice pre zložitosť vzorky

Pripomeňme, že sme dokázali, že ak priestor  $H$  má nekonečnú  $VC$  dimenziu, tak nie je potenciálne naučiteľný.

**Veta:** Predpokladajme, že hypotézový priestor  $H$  má  $VC$  dimenziu  $d \geq 1$ . Potom existuje konzistentný pac učiaci algoritmus  $L$  pre  $H$  taký, že pre ľubovoľné  $\delta$  a  $\epsilon$  zložitosť vzorky splňuje

$$m_L(H, \delta, \epsilon) \geq d(1 - \epsilon).$$

Uvedený výsledok je súčasťou jednoduchý, ale je použiteľný len na konzistentné učiace algoritmy. Ďalej neposkytuje univerzálnu dolnú hranicu na zložitosť vzorky konzistentného učiaceho algoritmu; skôr sa zaoberá najhoršími možnými konzistentnými učiacimi algoritmami. Ukážeme silnejší výsledok Ehrenfeuchta et al. - 1989, ktorý poskytuje dolnú hranicu na zložitosť vzorky ľubovoľného pac učiaceho algoritmu pre hypotézový priestor konečnej  $VC$  dimenzie.

**Veta:** Pre ľubovoľný hypotézový priestor  $H$  s  $VC$  dimensiou  $d \geq 1$  a pre ľubovoľný pac učiaci algoritmus  $L$  pre  $H$  platí

$$m_L(H, \delta, \epsilon) > \frac{d-1}{32\epsilon} \quad (2.24)$$

pre  $\delta \leq \frac{1}{100}$  a  $\epsilon \leq \frac{1}{8}$ .

Ak by sme uvažovali, že zložitosť vzorky prekročí  $(d_0 - 1)/32\epsilon$ , kde  $d_0$  je ľubovoľné kladné číslo spĺňajúce  $VCdim(H) \geq d_0$ , tak by sme mohli dokázať nasledujúce tvrdenie:

**Tvrdenie:** Ak hypotézový priestor  $H$  má konečnú  $VC$  dimenziu, tak neexistuje žiadny pac učiaci algoritmus pre  $H$ .

Tieto výsledky podporujú tvrdenie, že  $VC$  dimenzia je dobrá miera "expresívnej sily" hypotézového priestoru  $H$ : väčšia  $VC$  dimenzia  $H$  znamená väčšiu zložitosť vzorky pre pac učenie  $H$ . V skutočnosti výsledky môžu byť zväčšene aj pre prípady, keď  $C$  je ľubovoľný konceptový priestor s  $VC$  dimenziou a aspoň  $d_0 \geq 1$  a  $H$  je ľubovoľný hypotézový priestor (nie nutne rovný  $C$ ).

Ak  $L$  je učiaci algoritmus pre  $(C, H)$ , vstupom do  $L$  musí byť tréningová vzorka dĺžky väčšej než  $(d_0 - 1)/32\epsilon$ , aby bola zaručená presnosť  $\epsilon \leq \frac{1}{8}$  s pravdepodobnosťou  $1 - \delta > 99/100$ . Ak  $C$  má nekonečnú  $VC$  dimenziu, tak nemôže existovať žiadny učiaci algoritmus pre  $(C, H)$ , ktorý je pac pre ľubovoľný hypotézový priestor  $H$ .

**Príklad:** Ak  $J$  je priestor všetkých zjednotení intervalov, tak pretože  $J$  má nekonečnú  $VC$  dimenziu, neexistuje žiadny pac učiaci algoritmus pre  $(J, H)$  pre ľubovoľný hypotézový priestor  $H$ . Vyššie uvedený výsledok je veľmi silný. Ukazuje nielen to, že neexistuje žiadny konzistentný alebo efektívny pac učiaci algoritmus, ale tiež, že pre dané neohraničené výpočtové zdroje žiadny algoritmus nemôže pac naučiť  $J$  nezávisle od toho ako by boli reprezentované výstupné hypotézy. Samozrejme, tieto závery platia pre ľubovoľný priestor nekonečnej  $VC$  dimenzie, takých ako priestor všetkých uzavretých množín alebo priestor charakteristických funkcií všetkých polygonálnych oblastí v  $\mathbf{R}^2$ .

Iný výsledok týkajúci sa dolných hraníc zaviedol Blumer et al., 1989. Tento výsledok obsahuje  $\delta$  a  $\epsilon$ , ale nezávisí od  $VC$  dimenzie hypotézového priestoru. Toto sa dá použiť na netriviálne hypotézové priestory, t. j. také priestory, ktoré obsahujú viac než dve hypotézy.

**Veta:** Predpokladajme, že  $L$  je ľubovoľný *pac* učiaci algoritmus pre netriviálny hypotézový priestor  $H$ . Potom

$$m_L(H, \delta, \epsilon) > \frac{(1 - \epsilon)}{\epsilon} \ln\left(\frac{1}{\delta}\right), \quad (2.25)$$

pre ľubovoľné  $0 < \delta, \epsilon < 1$ .

## 2.9 Porovnanie hraníc zložitosti vzoriek

Ako už bolo uvedené, mnohé predchádzajúce výsledky môžu byť zovšeobecnené pre prípad, keď konceptový a hypotézový priestor sú rôzne. Ukážeme hranice pre zložitosť vzorky v týchto všeobecnejších prípadoch.

**Veta:** Nech  $C$  je konceptový a  $H$  je hypotézový priestor a predpokladajme, že  $H$  má konečnú  $VC$  dimenziu aspoň 1. Ak  $L$  je ľubovoľný konzistentný učiaci algoritmus pre  $(C, H)$ , potom  $L$  je *pac* a pre zložitosť vzorky platí

$$m_L \leq \left\lceil \frac{4}{\epsilon} (VCdim(H) \lg\left(\frac{12}{\epsilon}\right) + \lg\left(\frac{2}{\delta}\right)) \right\rceil \quad (2.26)$$

pre ľubovoľné  $\delta$  a  $\epsilon$ .

**Veta:** Nech  $C$  je konceptový a  $H$  je hypotézový priestor taký, že  $C$  má  $VC$  dimenziu aspoň 1. Predpokladajme, že  $L$  je ľubovoľný *pac* učiaci algoritmus pre  $(C, H)$ . Potom pre zložitosť vzorky pre  $L$  platí

$$m_L > \max\left(\frac{VCdim(C) - 1}{32\epsilon}, \frac{1}{\epsilon} \ln\left(\frac{1}{\delta}\right)\right) \quad (2.27)$$

pre všetky  $\delta \leq 1/100$  a  $\epsilon \leq 1/8$ .

Označenie:

Píšeme  $f = O(g)$ , ak existuje nejaká konštanta  $k > 0$  taká, že pre všetky relevantné  $x$  platí  $f(x) \leq k.g(x)$ .

Píšeme  $f = \Omega(g)$ , ak existuje nejaká konštanta  $k > 0$  taká, že pre všetky relevantné  $x$  platí  $f(x) \geq k.g(x)$ .

Použitím tohto označenia sformulujeme vzťahy pre zložitosť vzorky.

- Ak  $L$  je *pac*, potom  $C$  musí mať konečnú  $VC$  dimenziu a platí

$$m_L(C, \delta, \epsilon) = \Omega\left(\frac{VCdim(C)}{\epsilon} + \frac{1}{\epsilon} \ln\left(\frac{1}{\delta}\right)\right) \quad (2.28)$$

- Ak  $H$  má konečnú  $VC$  dimenziu a  $L$  je konzistentný, potom  $L$  je *pac* a platí

$$m_L(C, \delta, \epsilon) = O\left(\frac{VCdim(C)}{\epsilon} \ln\left(\frac{1}{\epsilon}\right) + \frac{1}{\epsilon} \ln\left(\frac{1}{\delta}\right)\right) \quad (2.29)$$

- Ak  $H$  je konečný a  $L$  je konzistentný, potom  $L$  je *pac* a platí

$$m_L(C, \delta, \epsilon) = O\left(\frac{1}{\epsilon} \ln|H| + \frac{1}{\epsilon} \ln\left(\frac{1}{\delta}\right)\right) \quad (2.30)$$

V prípade, že  $C = H$ ,  $VC$  dimenzia  $d$  je konečná a  $L$  je konzistentný, máme dolné a horné hranice

$$m_L(H, \delta, \epsilon) = \Omega\left(\frac{d}{\epsilon} + \frac{1}{\epsilon} \ln\left(\frac{1}{\delta}\right)\right);$$

$$m_L(H, \delta, \epsilon) = \mathcal{O}\left(\frac{d}{\epsilon} \ln\left(\frac{1}{\epsilon}\right) + \frac{1}{\epsilon} \ln\left(\frac{1}{\delta}\right)\right);$$

Faktor  $\ln(1/\epsilon)$ , ktorý odlišuje hornú hranicu od dolnej, je nevyhnutný. Výsledky Hausslera, Littlestonea a Warmutha, 1988, ukazujú, že pre každé  $d \geq 1$  existuje hypotézový priestor  $H_d$  a konzistentný učiaci algoritmus  $L$  pre  $H_d$  so zložitosťou vzorky rovnou hornej hranici. Na druhej strane je otvorený problém rozhodnúť, či pre každé  $d$  a pre každý konceptový priestor  $C$  s  $VC$  dimensiou  $d$ , existuje *nejaký* hypotézový priestor  $H$  a *nejaký*  $(C, H)$  učaci algoritmus  $L$ , pre ktorý zložitosť vzorky má dolnú hranicu.

## 2.10 Cvičenia:

1. Nech  $H$  je hypotézový priestor s vlastnosťou, že pre ľubovoľné  $t \in H$  a ľubovoľné  $0 < \delta, \epsilon < 1$ , existuje  $m_0(t, \delta, \epsilon)$  také, že

$$m \geq m_0(t, \delta, \epsilon) \implies \mu^m \{s \in S(m, t); H[s] \cap B_\epsilon\} > 1 - \delta$$

pre ľubovoľné rozdelenie pravdepodobnosti  $\mu$  na vstupnom priestore. Teda  $m_0$  môže závisieť len na cielovom koncepte. Ukážte, že  $H$  musí mať konečnú  $VC$  dimenziu a je preto potencionálne naučiteľný.

2. Dokážte, že pre ľubovoľné  $c > 0$  platí

$$\ln x \leq \left(\ln\left(\frac{1}{c}\right) - 1\right) + cx,$$

pre všetky  $x > 0$ .

3. Ukážte, že priestor charakteristických funkcií uzavretých a ohraničených polygónových oblastí v rovine  $\mathbf{R}^2$  nie je pac naučiteľný.
4. Prepokladajme, že  $H$  je ľubovoľný hypotézový priestor konečnej  $VC$  dimenzie  $d \geq 1$  a že  $L$  je ľubovoľný konzistentný učaci algoritmus pre  $H$ . Je dané nejaké rozdelenie pravdepodobnosti na príkladovom priestore. Akú veľkú tréningovú vzorku potrebujeme, aby s aspoň z 90% nou šancou sme získali hypotézu s chybou menšou než 5%?
5. Booleovská funkcia  $f$  sa nazýva *symetrická*, ak  $f(x)$  závisí len od počtu vstupov  $x$ , ktoré sú rovné 1. Napríklad, pre ľubovoľné  $n$  koncept parity definovaný na  $\{0, 1\}^n$  je symetrický. Nech  $n$  je kladné celé číslo a nech  $S_n$  označuje množinu všetkých symetrických funkcií na  $\{0, 1\}^n$ . Aká je  $VC$  dimenzia  $S_n$ ? Uveďte dolnú a hornú hranicu zložitosti vzorky pre ľubovoľný konzistentný pac učaci algoritmus pre  $S_n$ . Poznamenajme, že ľubovoľná hypotéza  $h$  v  $S_n$  môže byť reprezentovaná vektorom  $(h_0, h_1, \dots, h_n) \in \{0, 1\}^{n+1}$ , kde  $h_i$  je hodnota  $h$  na príkladoch majúcich presne  $i$  jedničiek. Navrhnite konzistentný učaci algoritmus pre  $S_n$ , ktorý reprezentuje priestor týmto spôsobom.
6. Nech  $H, G$  sú hypotézové priestory definované na tom istom príkladovom priestore  $X$ . Pre hypotézy  $h \in H, g \in G$ , definujme  $h \vee g$  takto

$$h \vee g = 1, \text{ ak } h(x) = 1 \text{ alebo } g(x) = 1; 0 \text{ inak}.$$

Nech  $H \vee G = \{h \vee g; h \in H, g \in G\}$ .

Dokážte, že

$$\Pi_{H \vee G} \leq \Pi_H(m) \Pi_G(m)$$

pre všetky  $m$ . Definujte  $H \wedge G$  obvyklým spôsobom, dokážte analogický výsledok pre tento priestor. Ak  $H$  a  $G$  sú potenciálne naučiteľné, čo je možné povedať o  $H \vee G$  a  $H \wedge G$ ?

7. Nech  $H$  je hypotézový priestor konečnej  $VC$  dimenzie  $d \geq 1$  a pre  $s \geq 1$  definujme  $H(s)$  induktívne takto:  $H(1) = H$  a  $H(k) = H \vee H(k-1)$ ,  $k \geq 2$ . Dokážte, že pre  $m > d$  platí

$$\Pi_{H(s)} \leq \left(\frac{em}{d}\right)^{sd}.$$

Potom ukážte, že  $VC$  dimenzia  $H(s)$  je najviac  $2s \operatorname{dlg}(3s)$ .