

Univerzita Pavla Jozefa Šafárika v Košiciach, Prírodovedecká fakulta

Strojové učenie Konzistentné algoritmy Gabriela Andrejková, Ľubomír Antoni



EURÓPSKA ÚNIA

Európsky sociálny fond
Európsky fond regionálneho rozvoja



OPERAČNÝ PROGRAM
ĽUDSKÉ ZDROJE



Tento projekt sa realizuje vďaka podpore z Európskeho sociálneho fondu a Európskeho fondu regionálneho rozvoja v rámci Operačného programu Ľudské zdroje

Cieľ:

- ▶ Potenciálna naučiteľnosť hypotézového priestoru
- ▶ Ľubovoľný konečný hypotézový priestor je potenciálne naučiteľný
- ▶ Nech H je potenciálne naučiteľný a L je učiaci algoritmus pre H . Môže byť L PAC?
- ▶ Rozhodovacie zoznamy (RZ)
- ▶ Algoritmus pre RZ, ktorý je konzistentný
- ▶ VCdim a potenciálna naučiteľnosť

Algoritmus pre učenie polpriamok (lúčov)

Pripomeňme algoritmus pre učenie v hyp. priestore reál. čísel.
 Pre každé reálne číslo Θ lúč r_Θ (polpriamka $\langle \Theta, +\infty \rangle$) je koncept
 definovaný na príkladovom priestore \mathfrak{R} (reálne čísla) funkciou

$$r_\Theta(y) \iff y \geq \Theta$$

Hypotézový priestor $H = \{r_\Theta | \Theta \in \mathfrak{R}\}$

Algoritmus učenia: za aktuálnu hypotézu vezmeme "najmenší"
 lúč obsahujúci všetky pozitívne príklady v tréningovej vzorke.
 Ak neexistujú kladné príklady, vtedy hovoríme o prázdnom lúči,
 označenie r_∞ .

Definícia: (**PAC - probably approximately correct**)

Algoritmus L je **PAC algoritmus**, pre hypotézový priestor H , ak

- k ľubovoľnému reálnemu číslu ϵ , $0 \leq \epsilon \leq 1$
- k ľubovoľnému reál. číslu δ , $0 \leq \delta \leq 1$
- existuje kladné celé číslo $m_0 = m_0(\delta, \epsilon)$ také ,že
- pre ľub. cieľový koncept $t \in H$, pre ľub. pravdepodobnostné rozdelenie μ na X ,
- pre všetky $m \geq m_0$ platí

$$\mu^m \{ \bar{s} \in S(m, t) \mid \text{err}_\mu(L(\bar{s}), t) < \epsilon \} > 1 - \delta$$

Veta:

Algoritmus L pre učenie lúčov je PAC.

Z dôkazu vyplýva hranica na počet príkladov tréningovej vzorky

$$m \geq m_0 = \frac{1}{\epsilon} * \ln \frac{1}{\delta}$$

Exaktné učenie

Keď **príkladový priestor X je konečný**, pojem “PAC - učenie” má ďalšie dodatočné obmedzenia.

Záverom úvah je, že učenie na konečnom priestore príkladovom je **“PEC - probably exactly correct”**.

Príklad: Štandardný učiaci algoritmus pre monočleny (Valiant) na $\{0, 1\}^n$ pre pevné n .

Učiaci algoritmus je PAC – vlastnosť algoritmu

Ak je algoritmus daný, môžeme

- ▶ sa pokúšať dokázať, že je PAC, ale tiež
- ▶ uvažovať o vlastnostiach H , na ktorom algoritmus pracuje.

Podstatná otázka: Je hypotézový priestor H naučiteľný?

Uvedieme **vlastnosť hypotézového priestoru H** , ktorá zaručí, že konzistentný algoritmus pre učenie, ak H je konceptový aj hypotézový priestor, bude **PAC**.

Ukážeme, že mnoho priestorov má túto vlastnosť.

Definícia: (Konzistentný učiaci algoritmus)

Nech H je hypotézový priestor, X je príkladový priestor.
 Učiaci algoritmus L pre H je **konzistentný**, ak pre ľubovoľnú
 tréningovú vzorku \bar{s} a cieľový koncept $t \in H$, výstupná hypotéza
 $h = L(\bar{s}) \in H$ súhlasí s t na príkladoch v \bar{s} , t. j. platí
 $h(x_i) = t(x_i)$, $1 \leq i \leq m$.

Pre dané $\bar{s} \in S(m, t)$ označíme

$$H[\bar{s}] = \{h \in H \mid h(x_i) = t(x_i), \quad 1 \leq i \leq m\},$$

$H[\bar{s}]$ je množina všetkých hypotéz konzistentných s \bar{s} .

Je každý konzistentný algoritmus PAC?

Algoritmus L je konzistentný $\Leftrightarrow L(\bar{s}) \in H[\bar{s}]$ pre každú tréningovú vzorku \bar{s} .

Dôležité sú množiny $H[\bar{s}]$ a ich vlastnosti.

Z toho vyplýva, že na to, aby konzistentný učiaci algoritmus bol PAC, postačí zadávať podmienky na množiny $H[\bar{s}]$.

Postačujúca podmienka na $H[\bar{s}]$.

Predpokladajme, že je dané pravdepodobnostné rozdelenie μ na X .
Na moment zafixujme cieľový koncept $t \in H$.

K danému $\epsilon \in (0, 1)$ položíme

$$B_\epsilon = \{h \in H \mid er_\mu(h, t) \geq \epsilon\},$$

čo je množina ϵ -zlých hypotéz pre t .

Konzistentný algoritmus pre H dáva výstup, ktorý je v $H[\bar{s}]$
a PAC vlastnosť vyžaduje, aby výstup, ktorý je dôveryhodný, nebol
 ϵ -zlý;

inak povedané – **je nepravdepodobné, že zlá hypotéza je korektná na tréningovej vzorke.**

Definícia: (Potenciálne naučiteľný hypotézový priestor)

Hovoríme, že hypotézový priestor H je **potenciálne naučiteľný**, ak k daným reálnym číslam $\delta, \epsilon, 0 < \delta, \epsilon < 1$ existuje kladné celé číslo $m_0 = m_0(\delta, \epsilon)$ také, že pre všetky $m \geq m_0$, platí

$$\mu^m \{ \bar{s} \in S(m, t) \mid H[\bar{s}] \cap B_\epsilon = \emptyset \} > 1 - \delta$$

pre ľubovoľné pravdepodobnostné rozdelenie μ na X a ľub. $t \in H$.

Veta:

Ak H je potenciálne naučiteľný a L je konzistentný učiaci algoritmus pre H , potom L je PAC.

Dôkaz: L je konzistentný, teda $L(\bar{s}) \in H[\bar{s}]$.

$$H[\bar{s}] = \{h \in H \mid h(x_i) = t(x_i), 1 \leq i \leq m\}, \quad B_\epsilon = \{h \in H \mid \text{er}_\mu(h, t) \geq \epsilon\}$$

$L(\bar{s}) \in H[\bar{s}]$ a zároveň $H(\bar{s}) \cap B_\epsilon = \emptyset$, teda chyba $L(\bar{s})$ je menšia ako ϵ .

$$\forall \delta \forall \epsilon \exists m_0 \forall m > m_0 \forall \mu \forall t \in H \mu^m \{\bar{s} \in S(m, t) \mid H[\bar{s}] \cap B_\epsilon = \emptyset\} > 1 - \delta$$

$$\forall \delta \forall \epsilon \exists m_0 \forall m > m_0 \forall \mu \forall t \in H \mu^m \{\bar{s} \in S(m, t) \mid \text{err}_\mu(L(\bar{s})) < \epsilon\} > 1 - \delta$$

$$\text{err}_\mu(L(\bar{s})) = \mu\{x \in X \mid t(x) \neq L(\bar{s})\} = 0 < \epsilon$$

Konečný prípad

Definícia potenciálnej naučiteľnosti je celkom zložitá (viac-menej je podobná PAC učeniu).

Potvrdíme potrebu definície - ukážeme jej významné aplikácie.

Veta:

Ľub. konečný hypotézový priestor H je potenciálne naučiteľný.

Dôkaz:

Nech H je konečný hypotézový priestor a δ , ϵ , t a μ sú dané.

Dokážeme, že pravdepodobnosť udalosti $H[\bar{s}] \cap B_\epsilon \neq \emptyset$ môže byť zvolená menšia než δ vybratím dostatočne veľkej dĺžky vzorky \bar{s} .

$$B_\epsilon = \{h \in H \mid er_\mu(h, t) \geq \epsilon\}$$

$$B_\epsilon = \{h \in H \mid \mu\{x \in X, h(x) \neq t(x)\} \geq \epsilon\}$$

Pretože B_ϵ obsahuje ϵ -zlé hypotézy, pre ľub. $h \in B_\epsilon$, platí

$$\mu\{x \in X \mid h(x) = t(x)\} = 1 - er_\mu(h, t) \leq 1 - \epsilon$$

Teda pre celú vzorku dĺžky m máme

$$\mu^m\{\bar{s} \mid h(x_i) = t(x_i), 1 \leq i \leq m\} \leq (1 - \epsilon)^m$$

Toto je pravdepodobnosť, že hypotéza h je ϵ -zlá pre celú vzorku.

Teda je to pravdepodobnosť, že nejaká ϵ -zlá hypotéza je v $H[\bar{s}]$.

Pravdepodobnosť, že nejaká ϵ -zlá hypotéza je v $H[\bar{s}]$, je vyjadriteľná

$$\mu^m \{ \bar{s} \mid H[\bar{s}] \cap B_\epsilon \neq \emptyset \}$$

a je preto menšia než $|H| \cdot (1 - \epsilon)^m$.

Toto bude menej ako δ (sledujeme definíciu) za predpokladu, že položíme $m \geq m_0 = \left\lceil \frac{1}{\epsilon} \cdot \ln \frac{|H|}{\delta} \right\rceil$

V tomto prípade

$$|H| \cdot (1 - \epsilon)^m \leq |H| \cdot (1 - \epsilon)^{m_0} < |H| \cdot \exp(-\epsilon \cdot m_0) \leq |H| \cdot e^{\ln \frac{\delta}{|H|}} = \delta$$

Dokázali sme, že pre ľub. δ , ϵ , t , μ existuje m_0

$$\forall_{m \geq m_0} \forall_t \quad \mu^m \{ \bar{s} \in S(m, t) \mid H[\bar{s}] \cap B_\epsilon \neq \emptyset \} < \delta$$

Ak vezmeme komplementárnu udalosť, dostaneme správny záver.

Veta pokrýva všetky bool. prípady, kde príkladový priestor je $\{0, 1\}^n$ (alebo podmnožina) s pevným n .

V ľubovoľnej takej situácii konzistentný algoritmus je automaticky PAC. Napríklad algoritmus pre učenie monočlenov a disjunkcií malých monočlenov sú PAC.

Dôkaz nám ďalej hovorí, koľko príkladov postačí na dosiahnutie predpísaných úrovní dôvery a presnosti.

$$m \geq m_0 = \left\lceil \frac{1}{\epsilon} \cdot \ln \frac{|H|}{\delta} \right\rceil$$

Pre algoritmus monočlenov vieme, že veľkosť $|M_n|$ hypotézového priestoru je 3^n . Preto

$$m_0 = \left\lceil \frac{1}{\epsilon} \ln \frac{|M_n|}{\delta} \right\rceil = \left\lceil \frac{1}{\epsilon} \left(n \cdot \ln 3 + \ln \frac{1}{\delta} \right) \right\rceil$$

je postačujúci počet príkladov na zabezpečenie, že s pravdepodobnosťou väčšou než $1 - \delta$ výstup algoritmu má chybu menšiu než ϵ .

Navyše pre ľub. konečný hypotézový priestor existuje konzistentný učiaci algoritmus: metóda učenia očíslovaním hypotéz, ktorú sme popísali.

Teda bezprostredným dôsledkom vety je, že k ľub. konečnému hypotézovému priestoru H existuje učiaci algoritmus, ktorý je PAC.

Úvahy:

- ▶ Vytvorili sme komplikovanú podmienku, aby sme dokázali, že je vždy splnená v konečnom prípade, ktorý je ale najdôležitejší v praxi.
- ▶ Avšak praktické predpoklady zavádzajú dodatočné ohraničenie, a síce že počet príkladov by mal byť "zvládnuteľný", a teda nie je nutné použiť metódu učenia sa očíslovaním.
- ▶ Ak napr. hypotézový priestor je množina B_n všetkých booleovských funkcií n premenných, $|B_n| = 2^{2^n}$, potom hranica pre veľkosť vzorky je $m_0 = \left\lceil \frac{2^n}{\epsilon} \ln \frac{2}{\delta} \right\rceil$. Čo ak $n = 50$?

- ▶ Jeden spôsob popisovania zložitých konceptov je ich vytváranie z menších jednotiek. Vid' vytváranie $D_{n,k}$.
- ▶ Metóda konštrukcie, ktorá môže byť aplikovaná na ľub. danú množinu vytvárajúcich blokov.

Definícia: (Rozhodovací zoznam)


Nech K je ľubovoľná množina bool. funkcií na $\{0, 1\}^n$, n je pevné. Booleovská funkcia f s tým istým def. oborom ako funkcie v K sa nazýva **rozhodovacím zoznamom** (podľa Rivesta) vytvoreným nad K , ak môže byť vyhodnotená nasledovne:

Nech je daný príklad y . Najprv vyhodnotíme $f_1(y)$ pre nejaké pevné $f_1 \in K$.

Ak $f_1(y) = 1$, priradíme do $f(y)$ pevnú hodnotu c_1 .

Ak $f_1(y) \neq 1$, vyhodnotíme $f_2(y)$ pre nejaké pevné $f_2 \in K$.

Ak $f_2(y) = 1$, priradíme do $f(y)$ pevnú hodnotu c_2 ,
inak vyhodnotíme $f_3(y)$, atď.



Obr.: Vyhodnotenie funkcie pomocou rozhodovacieho zoznamu

V inom zápise

if $f_1(y) = 1$ then set $f(y) = c_1$
 else if $f_2(y) = 1$ then set $f(y) = c_2$
 ...
 else if $f_r(y) = 1$ then set $f(y) = c_r$
 else set $f(y) = 0$

Definícia: (DL(K))

Hypotézový priestor rozhodovacích zoznamov na množine K , $DL(K)$, je množina konečných postupností $f = (f_1, c_1), (f_2, c_2), \dots, (f_r, c_r)$ takých, že $f_i \in K$, $c_i \in \{0, 1\}$, $1 \leq i \leq r$. Hodnoty f sú definované

$$f(y) = \begin{cases} c_j, & \text{ak } j = \min\{i \mid f_i(y) = 1\} \text{ existuje} \\ 0, & \text{inak} \end{cases}$$

Vyžadujeme, aby všetky členy v $DL(K)$ boli rôzne; opakovanie danej funkcie $g \in K$ môže byť odstránené a nemá účinok na vyhodnotenie.

Teda dĺžka $DL(K)$ vytvoreného nad konečnou množinou K je najviac $|K|$ a $|DL(K)|$ je ohraničená zhora konštantou $|K|$.

Príklad

Predpokladajme, že $K = M_{3,2}$ je priestor monočlenov dĺžky najviac 2 z 3 premenných. Rozhodovací zoznam

$$(\langle u_2 \rangle, 1), (\langle u_1 \bar{u}_3 \rangle, 0), (\langle \bar{u}_1 \rangle, 1)$$

môže byť spracovávaný nasledujúcim spôsobom na príkladovom priestore $\{0, 1\}^3$.

Najprv sú vybrané tie príklady, pre ktoré $\langle u_2 \rangle$ dáva hodnotu 1. Sú to 010, 011, 110, 111;

ďalej zostanú len tie, ktoré pre $u_1 \bar{u}_3$ dávajú 0, je to len 10;

ďalej tie, ktoré pre $\langle \bar{u}_1 \rangle$ dávajú hodnotu 1, sú to 000, 001.

Zostáva jediný príklad 101, ktorému je priradená hodnota 0.

Je dôležité poznamenať, že disjunkcia 2 funkcií v K je špeciálny prípad rozhodovacieho zoznamu založeného na K . Explicitne $f \vee g$ je reprezentovaná rozhodovacím zoznamom $(f, 1), (g, 1)$.

To znamená, že rozhodovací zoznam je zovšeobecnenie disjunkcie.

Napríklad, priestor $D_{n,k}$ je obsiahnutý v $DL(M_{n,k})$; v skutočnosti je vlastnou podmnožinou.

Iný dôsledok je, že pre dané n , ľubovoľná bool. funkcia n premenných je v nejakom $DL(M_{n,k})$ pre k dostatočne veľké. (Bezprostredne, toto je pravda pre $k = n$ podľa existencie disjunktnej normálnej formy.)

Konzistentný učiaci algoritmus pre $DL(K)$

Učiaci algoritmus pre $DL(K)$, ktorý pracuje, keď K je ľub. konečná množina.

Algoritmus je konzistentný, ale nie je bezpamäťový on-line algoritmus.

Samozrejme, učiaci algoritmus očíslovaním má podobné vlastnosti avšak ukážeme, že tento algoritmus je podstatným vylepšením.

Konzistentný učiaci algoritmus pre rozhodovacie DL(K)

Nech \bar{s} je tréningová vzorka ohodnotených príkladov (x_i, b_i) , $1 \leq i \leq m$. V každom kroku konštrukcie rozhodovacieho zoznamu niektoré príklady budú vymazané, iné zostanú.

Procedúra prebehne cez K hľadajúc funkciu $g \in K$ a hodnotu c takú, že pre ešte nezaradené príklady x_i platí, ak $g(x_i) = 1$, tak b_i je konštantná booleovská hodnota c .

Dvojica (g, c) je potom vybratá ako ďalší člen postupnosti definujúcej rozhodovací zoznam, a všetky príklady spĺňajúce g sú vymazané.

Procedúra je opakovaná, pokým všetky príklady z \bar{s} neboli vymazané.
 Nech $\{g_1, g_2, \dots, g_p\}$ je očíslovanie funkcií v K .

Algoritmus:

set $l = \{1, 2, \dots, m\}$;

$j := 1$;

repeat

if forall i in l , $g[j](x[i])=1$ implikuje $b[i]=c$ then

begin

select $(g[j], c)$;

delete from l all i for which $g[j](x[i])=1$;

$j := j + 1$;

end

else $j := j + 1$;

until l is empty set;

Príklad

$K = M_{5,2}$ a predpokladajme, že K je zaevidované v "slovníkovom poradí" nad literálmi $u_1 u_2 u_3 u_4 u_5 \overline{u_1} \overline{u_2} \overline{u_3} \overline{u_4} \overline{u_5}$.

Prvých niekoľko funkcií v slovníku je: monočleny dĺžky 1, atď.

$$\langle \rangle \langle u_1 \rangle \langle u_1 u_2 \rangle \langle u_1 u_3 \rangle \langle \overline{u_1} u_4 \rangle \langle \overline{u_2} u_3 \rangle$$

Predpokladajme, že tréningová vzorka je:

$$\begin{array}{llll} x_1 = 10000 & b_1 = 0, & x_4 = 10101 & b_4 = 1 \\ x_2 = 01110 & b_2 = 0, & x_5 = 01100 & b_5 = 1 \\ x_3 = 11000 & b_3 = 0, & x_6 = 10111 & b_6 = 1 \end{array}$$

Vyberieme prvú položku zo slovníka, ktorá splňuje požiadavky podmienky.

Príklad

- ▶ $\langle \rangle$ nepoužijeme,
- ▶ $\langle u_1 \rangle$ vylúčime príklady x_1 a x_4 majú $b_1 \neq b_4$
- ▶ $\langle u_1 u_2 \rangle$ je splnené len pre x_3 a $b_3 = 0$, teda vyberieme ako prvý term $(\langle u_1 u_2 \rangle, 0)$ do rozhodovacieho zoznamu a vymažeme príklad x_3 .

Príklad

Ďalšie kroky:

- ▶ $\langle u_1 u_3 \rangle$ je splnené pre x_4 a x_6 a $b_4 = b_6 = 1$, teda vyberieme $(\langle u_1 u_3 \rangle, 1)$; vymažeme x_4 a x_6
- ▶ $\langle u_1 \rangle$ je splnené pre x_1 , $b_1 = 0$, vyberieme $(\langle u_1 \rangle, 0)$
- ▶ $(\langle \bar{u}_1 u_4 \rangle, 0)$ vymaže x_2
- ▶ $(\langle \rangle, 1)$ vymaže x_5

Vytvorený rozhodovací zoznam je:

$$(\langle u_1 u_2 \rangle, 0), (\langle u_1 u_3 \rangle, 1), (\langle u_1 \rangle, 0), (\langle \bar{u}_1 u_4 \rangle, 0), (\langle \rangle, 1)$$

Rôzne usporiadania $M_{5,2}$ dávajú rôzne odpovede.

Nie je bezprostredne zrejmé, prečo hľadanie g a c je vždy úspešné.

Aby sme dokázali, že algoritmus pracuje správne, je nutné ukázať, že vždy keď je daná tréningová vzorka \bar{s} pre cieľový koncept v $DL(K)$, potom vždy bude nejaká dvojica (g, c) , ktorá vyhovuje niekoľkým príkladom.

O tréningovej vzorke danej vyššie nebolo na začiatku známe, či je kompatibilná s konceptom v $DL(M_{5,2})$, napriek tomu úspešné dokončenie algoritmu ukazuje, že je v skutočnosti v tomto tvare.

Konzistentný učiaci algoritmus pre $DL(K)$

Veta:

Predpokladajme, že K je hypotézový priestor obsahujúci identicky 1-kovú funkciu. Nech t je funkcia v $DL(K)$ a nech \bar{s} je konečná množina príkladov. Potom existuje $g \in K$ a $c \in \{0, 1\}$ také, že:

1. množina $S^g = \{x \in \bar{s} \mid g(x) = 1\}$ je neprázdna;
2. pre všetky $x \in S^g$, $t(x) = c$.

Dôkaz: Je dané $t \in DL(K)$, reprezentácia $t = (f_1, c_1), (f_2, c_2), \dots, (f_r, c_r)$

Ak $f_i(x) = 0$ pre všetky $x \in \bar{s}$ a všetky $i \in \{1, 2, \dots, r\}$, potom všetky príklady v \bar{s} sú negatívne príklady pre t . V tomto prípade g bude identicky 1-ková funkcia a $c = 0$.

Naopak, ak existuje nejaké i také, že množina $\{x_{i_1}, x_{i_2}, \dots\}$, $x_{i_j} \in \bar{S}$, pre ktoré $f_i(x_{i_j}) = 1$ nie je prázdna, potom nech g bude najmenším takým indexom, t.j. $g = \min\{i_1, i_2, \dots\}$.

Z definície rozhodovacieho zoznamu vyplýva, že $t(x) = c_g$ pre všetky x také, že $f_i(x) = 1$. V tomto prípade môžeme vybrať $g = f_i$ a $c = c_g$.

Z tohto vyplýva, že k ľub. tréningovej vzorke pre funkciu v $DL(K)$ existuje vhodný výber dvojice (g, c) pre "prvý člen" rozhodovacieho zoznamu. Aplikáciou tohto výsledku rekurzívne vidíme, že algoritmus popísaný vyššie bude vždy úspešný.

Vzťah VCdim a potenciálnej naučiteľnosti

Jednoduchý príklad priestoru H s nekonečnou VCdim:

Pre každú podmnožinu $A \subseteq \mathcal{R}$ definujeme charakteristickú funkciu χ_A

$$\chi_A(y) = 1, \text{ ak } y \in A; = 0 \text{ inak.}$$

Nech U je množina všetkých podmnožín \mathcal{R} , ktoré môžu byť vyjadrené ako konečné zjednotenie uzavretých intervalov. Nech

$$J = \{\chi_A | A \in U\}$$

je priestor zjednotených intervalov. Tento priestor má nekonečnú VCdim. Ukážeme.

Nech $\bar{x} = (x_1, x_2, \dots, x_m)$ je vzorka rôznych bodov v \mathcal{R} . Nech E_x označuje odpovedajúcu množinu príkladov.

K ľub. $S \subseteq E_x$ vieme skonštruovať množinu $A \in U$ takú, že $S \subseteq A$ a $(E_x \setminus S) \cap A = \emptyset$ takto:

Pre každé $x_i \in S$ nech A_i bude uzavretý interval, ktorý obsahuje x_i , ale nie iné prvky z E_x a nech A je zjednotenie všetkých takých A_i . Množina A je konečné zjednotenie uzavretých intervalov a χ_A je rovná 1 na S a 0 na $E_x \setminus S$. Inak povedané J rozbieja \bar{x} .

Pomocou rôznych S dosiahneme všetky možné ohodnotenia.

Vzťah VCdim a potenciálnej naučiteľnosti

Záver: Pretože to platí pre ľub. konečnú vzorku, ľub. dĺžky, z toho vyplýva, že $VCdim(J)$ je nekonečná.

Veta:

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

Veta: (Fundamentálna.)

Ak má hypotézový priestor konečnú VC dimenziu, tak je potenciálne naučiteľný.

Úlohy

1. Dokážte, že algoritmus pre $DL(K)$ je konzistentný.
2. Ukážte, že pre hypotézový priestor $D_{n,k}$ ($n \geq k > 1$) je postačujúce vziať hodnotu $m_0(\delta, \epsilon) = \left[\frac{k}{\epsilon} \cdot \ln 2n + \frac{1}{\epsilon} \cdot \ln \frac{1}{\delta} \right]$ v def. potenciálnej naučiteľnosti.
3. Dokážte, že pre všetky $n \geq k \geq 1$, $D_{n,k} \subset DL(M_{n,k})$. Odvodte, že ľubovoľná bool. funkcia môže byť reprezentovaná rozhodovacím zoznamom.
4. Skonstruujte bool. funkciu 3 premenných, ktorá nie je $D_{3,2}$, ale je v $DL(M_{3,2})$.
5. Skonstruujte bool. funkciu 3 premenných, ktorá nie je v priestore $DL(M_{3,2})$.

Úlohy

- Dokážte, že pre ľubovoľnú množinu K booleovských funkcií, $3^{|K|} \cdot |K|!$ je horná hranica na $|DL(K)|$.
- Komplement bool. funkcie h je bool. funkcia \bar{h} taká, že $\bar{h}(x) = 1 \Leftrightarrow h(x) = 0$. Dokážte, že pre ľub. množinu K bool. funkcií obsahujúcu identickú funkciu 1, platí

$$h \in DL(K) \Leftrightarrow \bar{h} \in DL(K).$$

Toto znamená, že $DL(K)$ je uzavretá vzhľadom na komplement.