

VC-dimenze

Zdeněk Dvořák

18. listopadu 2019

Definice 1. *Nechť \mathcal{F} je systém množin. Pro množinu X definujme $X \cap \mathcal{F}$ jako systém množin $\{F \cap X : F \in \mathcal{F}\}$, a řekneme, že \mathcal{F} rozbíjí X , jestliže $X \cap \mathcal{F}$ obsahuje všechny podmnožiny X . Vapnik-Chervonenkisova dimenze (VC-dimenze) systému \mathcal{F} je maximální k takové, že existuje množina velikosti k , kterou \mathcal{F} rozbíjí.*

Příklady:

- Systém všech polorovin v rovině má VC-dimenzi 3. Snadno ověříme, že existuje 3-bodová množina, kterou lze rozbít (stačí, aby její prvky nebyly na společné přímce). Naopak, uvažme libovolnou 4-prvkovou množinu X . Obsahuje-li bod $x \in X$, který je ve vnitřku konvexního obalu zbývajících tří bodů, pak žádná polorovina neprotíná X přesně v $X \setminus \{x\}$. Leží-li tři z bodů X na přímce v pořadí x_1, x_2, x_3 , pak žádná polorovina neprotíná X v podmnožině obsahující x_1 a x_3 a neobsahující x_2 . Zbývá tedy možnost, že body X jsou v konvexní pozici; nechť body X v pořadí na konvexním obalu X jsou x_1, x_2, x_3, x_4 . Pak žádná polorovina neprotíná X právě v $\{x_1, x_3\}$.
- Systém všech osově orientovaných obdélníků v rovině má VC-dimenzi nejvýše 5: Uvažme libovolnou 6-prvkovou množinu X , a nechť x_1 je její nejlevější bod. Bez újmy na obecnosti můžeme předpokládat, že existuje $X' \subseteq X \setminus \{x_1\}$ tž. všechny body z X' mají alespoň tak velkou y -ovou souřadnici jako x_1 a $|X'| \geq 3$. Nechť $x_2 \in X'$ má největší y -ovou souřadnici a $x_3 \in X'$ má největší x -ovou souřadnici. Pak neexistuje osově orientovaný obdélník obsahující x_1, x_2, x_3 a neobsahující bod(y) z $X' \setminus \{x_2, x_3\}$.
- Systém všech konvexních mnohoúhelníků v rovině má nekonečnou VC-dimenzi: Jestliže X je libovolná množina bodů v konvexní poloze, pak konvexní obal $X' \subseteq X$ protíná X právě v X' .

Lemma 1. *Každý systém množin \mathcal{F} rozbíjí alespoň $|\mathcal{F}|$ podmnožin $\bigcup \mathcal{F}$.*

Důkaz. Indukcí dle $|\mathcal{F}|$. Jestliže \mathcal{F} je prázdný, tvrzení je triviální. Jestliže $|\mathcal{F}| = 1$, stačí si povšimnout, že \mathcal{F} rozbíjí prázdnou množinu. Předpokládejme tedy, že $|\mathcal{F}| = 2$, a speciálně $\bigcup \mathcal{F} \neq \emptyset$. Zvolme prvek $c \in \bigcup \mathcal{F}$, který neleží ve všech množinách systému \mathcal{F} , a označme $\mathcal{F}_1 = \{F \in \mathcal{F} : c \in F\}$ a $\mathcal{F}_2 = \{F \in \mathcal{F} : c \notin F\}$. Dle volby c máme $|\mathcal{F}_1| < |\mathcal{F}|$ a $|\mathcal{F}_2| < |\mathcal{F}|$. Povšimněme si, že jestliže $c \in X$, pak ani \mathcal{F}_1 ani \mathcal{F}_2 nerozbíjí X .

Pro $i = 1, 2$ označme jako \mathcal{R}_i systém podmnožin $\bigcup \mathcal{F}_i$ rozbitých \mathcal{F}_i ; dle indukčního předpokladu máme $|\mathcal{R}_i| \geq |\mathcal{F}_i|$. Dále nechť $\mathcal{R}_3 = \{X \cup \{c\} : X \in \mathcal{R}_1 \cap \mathcal{R}_2\}$. Dle pozorování na konci minulého odstavce máme $\mathcal{R}_3 \cap \mathcal{R}_1 = \emptyset$, $\mathcal{R}_3 \cap \mathcal{R}_2 = \emptyset$ a $|\mathcal{R}_3| = |\mathcal{R}_1 \cap \mathcal{R}_2|$. Navíc, jestliže $X' \in \mathcal{R}_3$, pak $X' \cap \mathcal{F}_1$ obsahuje všechny podmnožiny X' obsahující c a $X' \cap \mathcal{F}_2$ obsahuje všechny podmnožiny X' neobsahující c , a proto \mathcal{F} rozbíjí X' . Každá množina, kterou rozbíje \mathcal{F}_1 nebo \mathcal{F}_2 , je také rozbita \mathcal{F} . Počet množin rozbitých \mathcal{F} je tedy alespoň $|\mathcal{R}_1 \cup \mathcal{R}_2| + |\mathcal{R}_3| = (|\mathcal{R}_1| + |\mathcal{R}_2| - |\mathcal{R}_1 \cap \mathcal{R}_2|) + |\mathcal{R}_1 \cap \mathcal{R}_2| \geq |\mathcal{F}_1| + |\mathcal{F}_2| = |\mathcal{F}|$. \square

Důsledek 2. *Má-li systém množin \mathcal{F} VC-dimenzi nejvýše k , pak pro každou množinu X platí*

$$|X \cap \mathcal{F}| \leq \sum_{i=0}^k \binom{|X|}{i},$$

a tedy je-li $k, |X| \geq 2$, pak $|X \cap \mathcal{F}| \leq |X|^k$.

Důkaz. VC-dimenze $X \cap \mathcal{F}$ je menší nebo rovna VC-dimenzi \mathcal{F} , a je tedy nejvýše k . Tedy $X \cap \mathcal{F}$ může rozbíjet pouze množiny velikosti nejvýše k , kterých je $\sum_{i=0}^k \binom{|X|}{i}$. Dle Lemma 1 dostáváme požadovaný odhad na $|X \cap \mathcal{F}|$. \square

Definice 2. *Nechť μ je míra, Y je měřitelná množina konečné míry a \mathcal{F} je systém měřitelných množin. Nechť $\varepsilon > 0$ je reálné číslo. Pak $N \subseteq Y$ je ε -sít, jestliže pro každé $F \in \mathcal{F}$ tž. $\mu(F \cap Y) \geq \varepsilon \mu(Y)$ platí $F \cap N \neq \emptyset$.*

Příklad: Nechť Y je osově orientovaný čtverec o hraně délky 1 a \mathcal{F} je systém všech osově orientovaných obdélníků obsažených v F . Pak N je ε -sít, jestliže N protíná každý obdélník $D \subseteq Y$ obsahu alespoň ε . Povšimněme si, že obdélník obsahu alespoň ε obsažený v F musí mít obě hrany délky alespoň ε . Jako N tedy lze zvolit pravidelnou síť bodů ve vzdálenosti ε od sebe; pak máme $|N| = \varepsilon^{-2}$. Jak uvidíme ve Větě 4, existuje i asymptoticky menší ε -sít.

Bez důkazu využijeme následující vlastnost binomického rozdělení.

Lemma 3. *Nechť $0 < p \leq p_1 \leq 1$ jsou reálná čísla. Nechť X_1, \dots, X_t jsou nezávislé náhodné proměnné, každá z nich 1 s pravděpodobností p_1 a 0 jinak. Pak $\Pr[X_1 + \dots + X_t \geq \lfloor pt \rfloor]$ je alespoň $1/2$.*

Věta 4. *Nechť μ je míra, Y je měřitelná množina konečné míry a \mathcal{F} je systém měřitelných množin VC-dimenze nejvýše $k \geq 2$. Nechť $0 < \varepsilon \leq 1$ je reálné číslo tž. $k/\varepsilon \geq 15000$. Nechť N je množina $\lceil 3\frac{k}{\varepsilon} \log \frac{k}{\varepsilon} \rceil$ bodů, zvolených nezávisle z pravděpodobnostního rozdělení π na Y definovaného vztahem $\pi(X) = \mu(X)/\mu(Y)$ pro každou měřitelnou $X \subseteq Y$. Pak s nenulovou pravděpodobností je N ε -sít.*

Důkaz. Bez újmy na obecnosti můžeme předpokládat, že $\mu(Y) = 1$ (a tedy $\pi = \mu$) a že všechny prvky \mathcal{F} jsou podmnožiny Y míry alespoň ε (jinak nahradíme \mathcal{F} systémem $Y \cap \mathcal{F}$ a zahodíme z něj množiny míry menší než ε , které nemají vliv na to, zda N je ε -sít). Nechť $t = \lceil 3\frac{k}{\varepsilon} \log \frac{k}{\varepsilon} \rceil$ a nechť x_1, \dots, x_t jsou body zvolené při volbě N (hodnoty se mohou opakovat). Zvolme nezávisle ze stejného rozdělení dalších t bodů y_1, \dots, y_t (opět s opakováními). Nechť M je multimnožina bodů y_1, \dots, y_t .

Nechť $p \geq \varepsilon$ je infimum z $\mu(F)$ pro $F \in \mathcal{F}$ a $m = \lfloor pt \rfloor$. Pro každé $F \in \mathcal{F}$ má každý bod y_1, \dots, y_t pravděpodobnost alespoň p , že bude patřit do F , z Lemma 3 je tedy $|F \cap M| \geq m$ s pravděpodobností alespoň $1/2$. Máme tedy

$$\Pr[(\exists F \in \mathcal{F}) F \cap N = \emptyset \wedge |F \cap M| \geq m] \geq \frac{1}{2} \Pr[(\exists F \in \mathcal{F}) F \cap N = \emptyset]. \quad (1)$$

Nechť Q je multimnožina $2t$ prvků z Y . Jako A_Q označme jev, že $Q = \{x_1, \dots, x_t, y_1, \dots, y_t\}$. Vyberme si libovolnou množinu F , a odhadněme podmíněnou pravděpodobnost že nastane jev $B_F \equiv F \cap N = \emptyset \wedge |F \cap M| \geq m$ za předpokladu, že platí A_Q . Nechť Q obsahuje q prvků z F . Jestliže $q < m$, pak je tato pravděpodobnost nulová. Jinak B_F nastane právě tehdy, když žádný z těchto q prvků není mezi t volbami pro x_1, \dots, x_t . Máme tedy

$$\begin{aligned} \Pr[B_F | A_Q] &= \frac{(2t - q)(2t - q - 1) \dots (t + 1 - q)}{(2t)(2t - 1) \dots (t + 1)} \\ &\leq \frac{(2t - m)(2t - 1 - m) \dots (t + 1 - m)}{(2t)(2t - 1) \dots (t + 1)} \\ &< \left(1 - \frac{m}{2t}\right)^t \leq e^{-m/2}. \end{aligned}$$

Dle Důsledku 2 máme $|Q \cap \mathcal{F}| \leq |Q|^k = (2t)^k$. Proto

$$\Pr[(\exists F \in \mathcal{F}) B_F | A_Q] = \Pr[(\exists F' \in Q \cap \mathcal{F}) B_{F'} | A_Q] < (2t)^k e^{-m/2}.$$

Jelikož tato nerovnost platí pro každé Q , máme

$$\Pr[(\exists F \in \mathcal{F})B_F] < (2t)^k e^{-m/2}.$$

Spolu s (1) tedy dostáváme

$$\Pr[(\exists F \in \mathcal{F})F \cap N = \emptyset] < 2(2t)^k e^{-m/2}.$$

Jelikož $m = \lfloor pt \rfloor \geq \varepsilon t - 1$, dostáváme že množina N není ε -sít s pravděpodobností méně než

$$2(2t)^k e^{1/2 - \varepsilon t/2} = e^{\log 2 + 1/2 + k \log(2t) - \varepsilon t/2} \leq e^{k \log(4t) - \varepsilon t/2} \leq 1.$$

Proto N je s nenulovou pravděpodobností ε -sít. \square

Pro systém množin \mathcal{F} označme jako $\tau(\mathcal{F})$ velikost nejmenší množiny $X \subseteq \bigcup \mathcal{F}$, která protne všechny prvky F (tedy např. jsou-li prvky F hrany grafu, pak $\tau(\mathcal{F})$ je velikost nejmenšího vrcholového pokrytí). Jako $\tau^*(\mathcal{F})$ označme zlomkovou verzi tohoto parametru, tedy minimum z

$$\sum_{v \in \bigcup \mathcal{F}} x_v$$

přes hodnoty $x_v \geq 0$ tž

$$\sum_{v \in F} x_v \geq 1$$

pro každou množinu $F \in \mathcal{F}$.

Důsledek 5. *Nechť \mathcal{F} je systém množin s konečným sjednocením. Má-li \mathcal{F} VC-dimenzi nejvýše $k \geq 2$, pak $\tau(\mathcal{F}) = O(k\tau^*(\mathcal{F}) \log(k\tau^*(\mathcal{F})))$.*

Důkaz. Označme $Y = \bigcup \mathcal{F}$ a $\tau^* = \tau^*(\mathcal{F})$. Nechť x_v pro $v \in Y$ jsou hodnoty proměnných v optimálním řešení lineárního programu definujícího $\tau^*(\mathcal{F})$. Pro $X \subseteq Y$ definujme $\mu(X) = \sum_{v \in X} x_v$. Pak μ je míra na Y a $\mu(Y) = \tau^*$. Navíc $\mu(F) \geq 1$ pro každé $F \in \mathcal{F}$. Dle Věty 4 existuje $1/\tau^*$ -sít N velikosti $O(k\tau^* \log(k\tau^*))$; pak N protíná všechny množiny z \mathcal{F} . \square

Příklad: Mějme dánu množinu osově orientovaných obdélníků \mathcal{F} v rovině a konečnou množinu X bodů, které protnou všechny z nich. Chceme najít nejmenší podmnožinu $S_{\text{opt}} \subseteq X$, která protne všechny obdélníky z \mathcal{F} . Vyřešením lineárního programu a použitím Důsledku 5 pro systém $Y \cap \mathcal{F}$ dokážeme najít alespoň podmnožinu velikosti $O(|S_{\text{opt}}| \log |S_{\text{opt}}|)$.

Nechť G je graf, v jeho vrchol, a r přirozené číslo. Pak jako $B_G(v, r)$ označme množinu vrcholů G ve vzdálenosti nejvýše r od v , a položme $\mathcal{B}_G = \{B_G(v, r) : v \in V(G), 0 \leq r \leq |V(G)|\}$.

Lemma 6. *Jestliže G neobsahuje K_t jako minor, pak \mathcal{B}_G má VC-dimenzi nejvýše $t - 1$.*

Důkaz. Pro spor předpokládejme, že nějaká podmnožina $X = \{v_1, \dots, v_t\}$ vrcholů G je rozbitá \mathcal{B}_G . Speciálně pro $1 \leq i < j \leq t$ existují $v_{ij} \in V(G)$ a $r_{ij} \in \{1, \dots, |V(G)|\}$ tž. $B_G(v_{ij}, r_{ij}) \cap X = \{v_i, v_j\}$. Zvolme tyto vrcholy v_{ij} tž. r_{ij} je minimální. V G existují nejkratší cesty $P_{ij,1}$ a $P_{ij,2}$ z v_{ij} do v_i a v_j , délky nejvýše r_{ij} . Z minimality r_{ij} vyvodíme, že $P_{ij,1}$ a $P_{ij,2}$ se protínají pouze ve v_{ij} ; označme jejich sjednocení P_{ij} – to je tedy cesta mezi v_i a v_j obsahující v_{ij} (ve vzdálenosti nejvýše r_{ij} od obou konců této cesty). Pro $i > j$ definujeme $P_{ij} = P_{ji}$, $v_{ij} = v_{ji}$ a $r_{ij} = r_{ji}$.

Nechť se vrchol $y \neq v_{ij}$ nachází na cestě P_{ij} mezi v_i a v_j . Pak tvrdíme, že $d(v_i, y) < d(v_j, y)$: kdyby $d(v_j, y) \leq d(v_i, y) = r$, pak si povšimněme, že $r < r_{ij}$: podcesta $P_{ij,1}$ z v_{ij} do v_i je nejkratší, její délka je tedy nejvýše r_{ij} , a její podcesta z y do v_i délky r je ještě kratší. Pak ale $B_G(y, r) \cap X = \{v_i, v_j\}$, ve sporu s minimalitou r_{ij} . Tedy

(\star) všechny vrcholy před v_{ij} jsou blíže k v_i než k v_j , a symetricky vrcholy za v_{ij} jsou blíže k v_j než k v_i .

Nechť se vrchol x nachází v průniku dvou takových cest $P_{i_1j_1}$ a $P_{i_2j_2}$. Ze symetrie můžeme předpokládat $d(x, v_{i_s}) \leq d(x, v_{j_s})$ pro $s \in \{1, 2\}$, a dle (\star) tedy x leží na nejkratší cestě z $v_{i_sj_s}$ do v_{i_s} ; proto $d(v_{i_sj_s}, x) + d(x, v_{i_s}) = d(v_{i_sj_s}, v_{i_s})$. Dále ze symetrie můžeme předpokládat, že $d(x, v_{i_1}) \leq d(x, v_{i_2})$. Trojúhelníková nerovnost pak dává

$$d(v_{i_2j_2}, v_{i_1}) \leq d(v_{i_2j_2}, x) + d(x, v_{i_1}) \leq d(v_{i_2j_2}, x) + d(x, v_{i_2}) = d(v_{i_2j_2}, v_{i_2}) \leq r_{i_2j_2}.$$

Proto $v_{i_1} \in B_G(v_{i_2j_2}, r_{i_2j_2}) \cap X = \{v_{i_2}, v_{j_2}\}$. Jestliže $d(x, v_{i_2}) < d(x, v_{j_2})$, pak $d(x, v_{i_1}) < d(x, v_{j_2})$, a tedy $i_1 \neq j_2$ a $i_1 = i_2$. Jestliže $d(x, v_{i_2}) = d(x, v_{j_2})$, pak můžeme předpokládat $i_1 = i_2$ ze symetrie. Položme $i = i_1 = i_2$. Kdyby $d(x, v_i) = d(x, v_{j_s})$ pro nějaké $s \in \{1, 2\}$, pak

$$d(v_{ij_{3-s}}, v_{j_s}) \leq d(v_{ij_{3-s}}, x) + d(x, v_{j_s}) = d(v_{ij_{3-s}}, x) + d(x, v_i) = d(v_{ij_{3-s}}, v_i) \leq r_{ij_{3-s}}$$

a dostáváme $v_{j_s} \in B_G(v_{ij_{3-s}}, r_{ij_{3-s}}) \cap X$, což je spor. Máme tedy následující:

($\star\star$) Jestliže $x \in V(P_{i_1j_1}) \cap V(P_{i_2j_2})$, pak $i_1 = i_2$ a $d(x, v_{i_s}) < d(x, v_{j_s})$ pro $s \in \{1, 2\}$.

Pro $i = 1, \dots, t$ položme

$$X_i = \{x \in V(P_{ij}) : j \in [t] \setminus \{i\}, d(x, v_i) \leq d(x, v_j), \text{ a když } d(x, v_i) = d(x, v_j), \text{ pak } i < j\}.$$

Dle (\star) indukují množiny X_i souvislé podgrafy v G a dle ($\star\star$) jsou množiny X_i navzájem disjunktní. Jejich kontrakcí dostaneme minor K_t v G , což je spor. \square

Uvažujme následující zobecnění dominující množiny. Nechť $r : V(G) \rightarrow \mathbf{Z}_0^+$ je libovolná funkce. Pak jako $\text{dom}_r(G)$ označme velikost nejmenší množiny $X \subseteq V(G)$ tž. $d(v, X) \leq r(v)$ pro každé $v \in V(G)$.

Důsledek 7. *Pro každé t existuje algoritmus s polynomiální časovou složitostí, který pro libovolný graf G neobsahující K_t jako minor a libovolnou funkci $r : V(G) \rightarrow \mathbf{Z}_0^+$ vrátí číslo d takové, že $d \leq \text{dom}_r(G) = O(td \log(td))$.*

Důkaz. Uvažme systém množin $\mathcal{F} = \{B_G(v, r(v)) : v \in V(G)\}$. Máme $\mathcal{F} \subseteq \mathcal{B}_G$, a dle Lemma 6 má \mathcal{F} VC-dimenzi nejvýše $t - 1$. Dále si povšimněme, že $\text{dom}_r(G) = \tau(\mathcal{F})$. Dle Důsledku 5 můžeme tedy položit $d = \tau^*(\mathcal{F})$ (d lze určit v polynomiálním čase vyřešením lineárního programu). \square