

Упередженість (вигрешення) та складність класу вимог

У дев. PAC навчальності розподілу $\mathcal{D}$ були об'єктивні принципи
класу реалізованості $\min_{h \in \mathcal{H}} L_{\mathcal{D}, f}(h) = 0$ - це гарантує те, що
якщо клас вимог $\mathcal{H}$ гарно підходить до задачі ML. У дев. асим-
метричній PAC навчальності замість цього маємо оцінку виграшу
 $L_{\mathcal{D}}(h_S) \leq \min_{h \in \mathcal{H}} L_{\mathcal{D}}(h) + \epsilon$ - це означає, що помилка може
бути великою для "погано сучасних" $\mathcal{D} : \mathcal{H}$. У дійсно, ми по-
казали, що для задачі бінарної клас. найкращу помилку дає
для конкретного $\mathcal{D}$ Байєсівський предиктор $f_{\mathcal{D}}$, і що "поганим"
вибором $\mathcal{D}$ (коли мітка не залежить від даних) її можна
зробити будь-якою $\leq \frac{1}{2}$ (це дуже погано).

Підійдемо тепер з іншого боку: покажемо, що у цій
задачі $\forall$ алгоритма ML $\exists$ розподіл $\mathcal{D}$ що не є "поганим" вза-
галі кансуси (мітка визначається даними), але поганим
саме для цього алгоритма. Це означає, що не існує

універсальних алгоритмів ML: вибір алг. повинен ґрунтуватися на певних знаннях про задачу ML (тобто про концепції $\mathcal{D}$). Це пояснює назву:

Th. (про неіснування безкоштовного обіду, No-Free-Lunch (NFL) theorem).

Нехай A - деякий алгоритм бінарної класифікації на множині X , а m - довільне натуральне $< \frac{|X|}{2}$. Тоді існує розподіл $\mathcal{D}$ на $X \times \{0,1\}$ з наступними властивостями:

- $L_{\mathcal{D}}(f) = 0$ для деякої $f: X \rightarrow \{0,1\}$;
- результат застосування A до навчальних даних S з m екз-ів $X \times \{0,1\}$, що i.i.d. відносно до $\mathcal{D}$, має помилку $\geq \frac{1}{8}$ зі ймовірністю $\geq \frac{1}{4}$:
$$\mathbb{P}_{S \sim \mathcal{D}^m} (L_{\mathcal{D}}(A(S)) \geq \frac{1}{8}) \geq \frac{1}{4}.$$

Рем. Тутт пам. $L_{\mathcal{D}}$ - для 0-1 втрати $\ell_{0,1}$, як завжди у задачах класифікації. Перша умова означає, що $\forall$ клас $\text{in. } \mathcal{K}$, що містить f , задов. ^{припустимо} реалізованості. Тобто, наприклад, $\forall$ скінч. $\mathcal{K} \ni f \in \text{PAC навчання}$, і $\forall \text{ERM}_{\mathcal{K}}$ - алгоритм краще за A (для візн. виборів ε, δ з дев. PAC навчаннями).

► Нагадаймо загальний факт з теорії ймовірностей:

Л. (нерівність Маркова). Для $\forall$ випадкової величини $X \geq 0$ і $a > 0$

$$P(X \geq a) \leq \frac{E(X)}{a}.$$

► Ф-ція $x \mapsto P(X \geq x)$, зв., зростаюча, а її інтеграл - мон. зменшуваний X за ф-лою заданим. сум:

$$E(X) = \int_0^{+\infty} P(X \geq x) dx \geq \int_0^a P(X \geq x) dx \geq \int_0^a P(X \geq a) dx = a P(X \geq a). \quad \Delta(\text{Л.})$$

Соч. $\forall$ ван. вел. $0 \leq X \leq 1$ і $a \in (0, 1)$ $P(X > a) \geq \frac{E(X) - a}{1 - a}$.

$$\begin{aligned} \text{► } P(X > a) &= 1 - P(X \leq a) = 1 - P(1 - X \geq 1 - a) \geq [1 - X \geq 0, \text{ нерів.} \\ \text{Л.}] &\geq 1 - \frac{E(1 - X)}{1 - a} = \left[\frac{E(1) - E(X)}{1 - a} \right] = 1 - \frac{1 - E(X)}{1 - a} = \frac{E(X) - a}{1 - a}. \quad \Delta(\text{Соч.}) \end{aligned}$$

Застосовуючи Соч. до ван. величини $S \mapsto L_{\oplus}(A(S)) \in [0, 1]$ на $(X \times \{0, 1\})^m$ отримаємо групу мб. $\underline{T}_n$ за умови $E_{S \sim \mathcal{D}^m}(L_{\oplus}(A(S))) \geq \frac{1}{4}$. (для $a = \frac{1}{8}$), тому її і будемо перевіряти.

За умовою $\underline{T}_n$, $\exists C \subset X$ з $2m$ ел-тів, $\forall S$ з m ел-тів м.ч. містять не більше половини ел-тів C . Ідея: обрати $\mathcal{D}$ і f так, щоб $A(S)$ дає велику початку на іншій половині.

Перелічимо всі можливі $f: C \rightarrow \{0,1\} : f_1, \dots, f_T$, де $T = 2^{2m}$. $\mathcal{H}$ і визначено розподіл на $X \times \{0,1\}$, що перетворює його на дискретний ім. простір:

$$\mathbb{Q}_i(\{(x,y)\}) = \begin{cases} \frac{1}{|C|} = \frac{1}{2^m}, & x \in C \text{ і } y = f_i(x); \\ 0 & \text{у інш. ван.} \end{cases}$$

Покажемо, що для даного A $\exists$ таке i , що $E(L_{\mathbb{Q}_i}(A(S))) \geq \frac{1}{4}$.
 За зауваженням вище, такий $\mathbb{Q}_i$ буде задов. $S \sim \mathbb{Q}_i^m$ теоремі для $\forall f: X \rightarrow \{0,1\}$ такої, що $f|_C = f_i$ (бо $L_{\mathbb{Q}_i}(f) = 0$ за побудовою).
 За властивості $\mathbb{Q}_i$, вибірка S з m ел-тів X , що i.i.d. за $\mathbb{Q}_i$, міститиме $y \in C$ зі ім. 1. Тому дані вивчаємо SSS. Таких S всього $K = (2^m)^m$, перенумеруємо їх: $S_1, \dots, S_K$. $\forall \bar{y} = \overline{1, K}$, $i = \overline{1, T}$ розставимо мітки у $S_{\bar{y}} = \{(x_{y1}, \dots, x_{ym})\}$ вказ. до f_i отримавши $S_{\bar{y}}^i = \{(x_{y1}, f_i(x_{y1})), \dots, (x_{ym}, f_i(x_{ym}))\}$. Якщо розподіл $\in \mathbb{Q}_i$, то навч. дані мають вигляд $S_1^i, \dots, S_K^i$ зі ім. $\frac{1}{K}$ (констант), тому

$$E_{S \sim \mathbb{Q}_i^m} (L_{\mathbb{Q}_i}(A(S))) = \frac{1}{K} \sum_{\bar{y}=1}^K L_{\mathbb{Q}_i}(A(S_{\bar{y}}^i)).$$

Наблюдение за i знач. уже означивать не превышает средн. арифм.:

$$\begin{aligned} \max_{\bar{i} \in \overline{1, T}} E_{S \sim \mathcal{D}_{\bar{i}}^m} (L_{\mathcal{D}_{\bar{i}}} (A(S))) &\geq \frac{1}{T} \sum_{\bar{i}=1}^T E (L_{\mathcal{D}_{\bar{i}}} (A(S))) = [\text{попер. рівн.}, \\ & \text{знаємо пор. год. год.}] = \\ &= \frac{1}{K} \sum_{\bar{y}=1}^K \frac{1}{T} \sum_{\bar{i}=1}^T L_{\mathcal{D}_{\bar{i}}} (A(S_{\bar{y}}^{\bar{i}})) \geq \left[\begin{array}{l} \text{сер. ариф.} \\ \text{найменше} \end{array} \right] \geq \min_{\bar{y}=1, K} \frac{1}{T} \sum_{\bar{i}=1}^T L_{\mathcal{D}_{\bar{i}}} (A(S_{\bar{y}}^{\bar{i}})) \stackrel{\text{Питан } p \geq m}{=} \end{aligned}$$

$\forall \bar{y}$ нехай $\{y_1, \dots, y_p\}$ - ел-ти C , що не містяться у $S_{\bar{y}}$.

Наступні об'єкти вірні $\forall \bar{y}$, тому у $\textcircled{=}$ можна вважати, що

всі об'єкти найменше:

$$\begin{aligned} \textcircled{=} \frac{1}{T} \sum_{\bar{i}=1}^T \frac{1}{2^m} \sum_{x \in C} 1_{\{A(S_{\bar{y}}^{\bar{i}})(x) \neq f_{\bar{i}}(x)\}} &\stackrel{(m \leq p)}{\geq} \frac{1}{T} \sum_{\bar{i}=1}^T \frac{1}{2^p} \sum_{e=1}^p 1_{\{A(S_{\bar{y}}^{\bar{i}})(y_e) \neq f_{\bar{i}}(y_e)\}} \\ &\geq \left[\begin{array}{l} \text{знаємо пор. год. год.} \\ \text{сер. ариф.} \end{array} \right] \geq \frac{1}{2} \min_{e=1, m} \frac{1}{T} \sum_{\bar{i}=1}^T 1_{\{A(S_{\bar{y}}^{\bar{i}})(y_e) \neq f_{\bar{i}}(y_e)\}} \stackrel{\textcircled{=}}{=} \end{aligned}$$

$\forall \bar{i} \in \overline{1, T} \quad \exists! \bar{i}' \in \overline{1, T} : f_{\bar{i}}$ збігається з $f_{\bar{i}'}$ всюди на C
крім y_e (для фікс. e): $f_{\bar{i}}(c) = f_{\bar{i}'}(c)$ при $c \neq y_e$ і $f_{\bar{i}}(y_e) \neq f_{\bar{i}'}(y_e)$. При цьому $S_{\bar{y}}^{\bar{i}} = S_{\bar{y}}^{\bar{i}'}$, бо $y_e \notin S_{\bar{y}}$. Т.ч., числа від 1 до T розбиваються на пари $(\bar{i}, \bar{i}')$, в $\forall$ з яких

$$1_{\{A(S_{\bar{y}}^{\bar{i}})(y_e) \neq f_{\bar{i}}(y_e)\}} + 1_{\{A(S_{\bar{y}}^{\bar{i}'})(y_e) \neq f_{\bar{i}'}(y_e)\}} = 1,$$

можу сер. ар. перед $\ominus$ дор. $\frac{1}{2} \forall \ell \in \ominus \frac{1}{4}$, що і потрібно Δ
Вит. Загаломити формулювання і доведення на випадок $m < \frac{1}{\epsilon^2}$, $k \in \mathbb{N}$
Рем. У огляду з Ех. вище ми бачили, що істини в області $\mathcal{H}$

в ERM-алгоритмі клас усіх f -гін $\mathcal{H} \rightarrow \{0,1\}$ порано, бо може
 привести до перенавчання. Тепер ми можемо формально довести
 "поганість" цього класу:

Сев. Клас усіх $h: \mathcal{X} \rightarrow \{0,1\}$ у заданій класифікації на не-
 скінченній $\mathcal{X}$ не $\in$ PAC навчання.

$\Rightarrow$ $N^{\uparrow} \leftarrow (\text{припустимо, що})$ це не так, тобто для цього класу $\mathcal{H}$ виконає $m_{\mathcal{H}}$:

$(0,1)^2 \rightarrow N^{\leftarrow}$ з деб. PAC навч. і алгоритм A . Нехай $m \geq m_{\mathcal{H}}(\epsilon, \delta)$,
 де $\epsilon < \frac{1}{8}$ і $\delta < \frac{1}{4}$. Застосуємо до A і m NFL-теорему:

отримавши $\mathcal{D}$ і f (що гарантує виконання прип. реалізо-
 ваності). Тоді $P_{S \sim \mathcal{D}^m} (L_{\mathcal{D}}(A(S)) \geq \frac{1}{8}) \geq \frac{1}{4}$ за Тн. і $P_{S \sim \mathcal{D}^m} (L_{\mathcal{D}}(A(S)) \leq \epsilon < \frac{1}{8}) \geq 1 - \delta > \frac{6}{7}$ за деб. PAC навчальності, але ціна
 цих ім. повинна бути ≤ 1 $\downarrow$ (протиріччя). Δ

Рем. Звичайно, для скінч. $\mathcal{X}$ клас усіх гін скінченний (як

і всі $\mathcal{H}$, що містяться у ньому), мають формально є PAC навчанням. Втім, для нової маси оцінки

$$m_{\mathcal{H}}(\varepsilon, \delta) \leq \left\lceil \frac{1}{\varepsilon} \ln \frac{|\mathcal{H}|}{\delta} \right\rceil = \left\lceil \frac{1}{\varepsilon} \ln \frac{2^{|\mathcal{X}|}}{\delta} \right\rceil = \left\lceil \frac{\ln \frac{1}{\delta} + |\mathcal{X}| \ln 2}{\varepsilon} \right\rceil,$$

що для малих $\varepsilon = \delta$ суттєво перевищує $|\mathcal{X}|$! Тл.ч., цей клас у Бурб-аксіому випадку не є корисним.

Із задачею вибору "правильного" $\mathcal{H}$ для даної задачі пов'язане т.зв. розкладання помилки:

дов. Кожній у задачі ML на множині Z одано вибірку S з ел-тів i.i.d. відн. до розподілу $\mathbb{D}$ на Z , застосовано $ERM_{\mathcal{H}}$ -алгоритм для деякого класу гіпотез $\mathcal{H}$: отримано гіпотезу h_S . Тоді ii

- помилкою апроксимації (approximation error)

зветься $\varepsilon_{\text{app}} := \min_{h \in \mathcal{H}} L_{\mathbb{D}}(h);$

- помилкою оцінки (estimation error) зветься

$\varepsilon_{\text{est}} := L_{\mathbb{D}}(h_S) - \varepsilon_{\text{app}};$

де L_D обчислюється відносно φ -її втрам $\ell: \mathcal{X} \times \mathcal{Z} \rightarrow \mathbb{R}_+$.
Рез. Подібно $L_D(h_S) = \epsilon_{\text{app}} + \epsilon_{\text{ext}}$, де $\epsilon_{\text{app}} \geq 0$ не залежить від S (визначається класом $\mathcal{H}$). Зокрема, $\epsilon_{\text{app}} = 0$, якщо вик. припущення реалізованості, і $\epsilon_{\text{app}} \geq L_D(f_D)$, де f_D - байєсівський предиктор для D , як бачили вище. З іншої боку, $\epsilon_{\text{ext}} \geq 0$ - це помилка що оцінюється зверху у дов. (априорній) РАС навчальності. Вибір $\mathcal{H}$ визначається співвідношенням між цими помилками:

- маленькі ϵ_{app} означають великі (складні) $\mathcal{H}$. Зокрема, у задані клас. клас усіх гіпотез дає найменше можливе знач. $\epsilon_{\text{app}} = L_D(f_D)$, але, як показано вище, великі ϵ_{ext} не є РАС навчання (принаймні практично). Це проблема перенавчання: маленька упередженість, загато велика складність.

- маленькі ϵ_{ext} можна досягти для маленьких (простих) $\mathcal{H}$ в силу їх (ан)РАС навчальності та відносно малих оцінок

на m (порядка $\ln|K|$). Але вони можуть мати великі ϵ_{app} - не просто не містять (у заданій клас.) $f \in \mathcal{D}$, а й бути "далекими" від нього. Це проблема недонавчання (underfitting): пошта з іншим негативним описом $\mathcal{D}$.

В силу сказаного, вибір K зазвичай характеризується як компроміс між упередженістю (bias) і складністю (bias-complexity tradeoff).

Ех. Розглянемо вибір кількості параметрів d у задачі типу "класифікації друзів": бінарної класифікації з $X \subset \mathbb{R}^d$, де K_d складається з паралелепипедів $[a_1, b_1] \times \dots \times [a_d, b_d]$ (тобто їхні характеристики ϕ -гін). Більш того, нехай $X \subset \mathbb{R}^D$, де D - найбільша можлива кількість параметрів, а ϕ -гін з K_d задаються $[a_1, b_1] \times \dots \times [a_d, b_d] \times \mathbb{R} \times \dots \times \mathbb{R}, d < D$. Тоді $\epsilon_{app} = \min_{h \in K_d} L_{\mathcal{D}}(h)$ зменшується зі збільшенням d , бо клас інше зростає (характер цього зменш. за-

лопаті $\text{big } \Theta$). З іншого боку, як було показано на практиці, усі ці класи є PAC навчаними, і $m_{\mathcal{H}}(\epsilon, \delta) \leq \lceil \frac{2d}{\epsilon} \ln \frac{2d}{\delta} \rceil$. З результатів наст. розділу випливає, що всі такі априорно PAC навчані з $m_{\mathcal{H}}(\epsilon, \delta) \leq C \frac{2d + \ln \frac{1}{\delta}}{\epsilon^2}$ для деякого $C \in \mathbb{R}$. Це означає, що для досягнення цієї $m_{\mathcal{H}}(\epsilon, \delta) = \frac{2d}{\epsilon^2} \ln \frac{2d}{\delta}$ нам потрібно брати більші вибірки S для більших d .

VC - вимірність та критерій навчальності


Перелічимо деякі приклади PAC навчаних і ненавчаних класів:

Ек. 1. Усі скінч. класи $\mathcal{H}$ є PAC навчаними для $m_{\mathcal{H}}(\epsilon, \delta) \leq \lceil \frac{1}{\epsilon} \ln \frac{|\mathcal{H}|}{\delta} \rceil$; априорно PAC навчаними для $m_{\mathcal{H}}(\epsilon, \delta) \leq \lceil \frac{2}{\epsilon^2} \ln \frac{2|\mathcal{H}|}{\delta} \rceil$ (див. вище).


2. Клас усіх відображень $X \rightarrow \{0, 1\}$ для задані фін. клас. на неск. X не є PAC навчаним (а отже й априорно) (попер. розділ).

3. (Кескінченний) клас порогових (threshold) ф-цій

$\mathcal{H} = \{h_a: \mathbb{R} \rightarrow \{0,1\} \mid h_a(x) = 1_{\{x < a\}}\} \quad a \in \mathbb{R} \in \text{PAC навчання}$
 для задачі Bin. клас. на $X = \mathbb{R}$, Diuono,




нехай $\epsilon, \delta \in (0,1)$. Умова реалізованості означає, що
 $\exists a^* \in \mathbb{R}$ таке, що $x < a^*$ майже для всіх x з $f(x)=1$
 (де f - "правильна" ф-ція міток) і $x > a^*$ майже для всіх x
 з $f(x)=0$, зокрема $\forall$ вибірка S містить усі "+" зліва
 від a^* і "-" - справа зі ім. 1:



Розглянемо алг., що повертає найменше з x таке, що
 $f(x)=0$ (тобто $(x,0) \in S$), зокрема $a_s \geq a^*$; або $\forall a_s$,
 що Binome за всі x з $f(x)=1$ (тобто $(x,1) \in S$), якщо
 S не містить $(x,0)$. Отж., для кожного $L_S(h_{a_s})=0$,
 тобто Bin ERM $_{\mathcal{H}}$ (та лінійний за $m=|S|$).

Нехай $(a_0, a_1) \ni a^*$ такий, що (a_0, a^*) і (a^*, a_1) мають

$\mu_{\text{пр}} \varepsilon$ (або принаймні $\leq \varepsilon$; до може бути $-\infty, a_1 - +\infty$). Тоді для $a_s \in (a_0, a_1)$ точки $(x, y) \in \mathcal{X} \times \{0, 1\}$, де $h_{a_s}(x) \neq f(x)$ - це або $(x, 0)$ з $x < a_s$ і $x > a^*$ при $a_s \geq a^*$, або $(x, 1)$ з $x > a_s$ і $x < a^*$ при $a_s < a^*$ (крім точок типу 0). В дугу-



цьому разі їх міра, подібно помилка $L_{\mathcal{D}, f}(h_{a_s}) \leq \varepsilon$.
 Тому $\mathcal{D}^m(\{S \mid L_{\mathcal{D}, f}(h_{a_s}) > \varepsilon\}) \leq [\text{ном.}] \leq \mathcal{D}^m(\{S = \{x_i, y_i\}_{i=1}^m \mid$
 $\forall i: (x_i \notin (a_0, a^*) \wedge y_i = 1) \vee (x_i \notin [a^*, a_1) \wedge y_i = 0)\}) \leq [\text{субад.}] \leq$
 $\leq \mathcal{D}^m(\{S \mid \forall i: x_i \notin (a_0, a^*)\}) + \mathcal{D}^m(\{S \mid \forall i: x_i \notin [a^*, a_1)\}) \leq [\text{ном.}] \leq$
 $\leq \mathcal{D}^m((\mathbb{R} \setminus (a_0, a^*))^m) + \mathcal{D}^m((\mathbb{R} \setminus (a^*, a_1))^m) = 2(1 - \varepsilon)^m < 2e^{-\varepsilon m} \quad \textcircled{\leq}$

Як завжди, при $m > \frac{1}{\varepsilon} \ln \frac{2}{\delta}$ це $\leq \delta$, тому
 $\mathcal{D}^m(\{S \mid L_{\mathcal{D}, f}(h_{a_s}) \leq \varepsilon\}) \geq 1 - \delta$, що демонструє PAC навч.
 для $m_{\mathcal{H}}(\varepsilon, \delta) \leq \lceil \frac{1}{\varepsilon} \ln \frac{2}{\delta} \rceil$.

1. Аналогічним чином на практиці показати, що (неск.)
 клас характеристикних ф-цій d -вимірних кубів
 $\mathcal{H} = \{ \mathbb{1}_{\{x \in \mathcal{C}\}} \mid \mathcal{C} \geq 0 \} \in \text{PAC навч. для } \mathcal{X} \subset \mathbb{R}^d$ (у

задачі Шн. клас.), і $m_H(\epsilon, \delta) \leq \left\lceil \frac{1}{\epsilon} \ln \frac{1}{\delta} \right\rceil$ (незалежно від d)

□ Для (неск.) класу $\mathcal{H}$ d -вим. паралелеліній (відгрізків при $d=1$, прямокутників при $d=2$) $\mathcal{H} = \{1_{[a_1, b_1]} \times \dots \times 1_{[a_d, b_d]}\}$ $a_1 \leq b_1, \dots, a_d \leq b_d$ менше маємо PAC навчання у задачі Шн. клас. на $\mathcal{X} \subset \mathbb{R}^d$, але тепер $m_H(\epsilon, \delta) \leq \left\lceil \frac{2d}{\epsilon} \ln \frac{2d}{\delta} \right\rceil$ залежить від d (менше показати на практиці).

Як бачимо, нескінченні класи будуть як PAC навч., так і ні, а відповідна складність вибірки може залежати від "кількості параметрів" класу. Щоб узагальнити ці спостереження, нам знадобиться наступна серія понять, що потімведеється доведенням NFL-теорем у подальшій розділі. Знову розглядаємо задачу Шн. клас. на $\mathcal{X}$ мпописи $\mathcal{H}$.

Лев. Обмеження класу імплементу $\mathcal{H}$, тобто деякої мпописи виб. $h: \mathcal{X} \rightarrow \{0, 1\}$, на скінченну під-

множеству $C \subset X$ звется множина об'ємів $h|_C$ для
усієї $h \in \mathcal{H}$. Относно її з множиною

$$\mathcal{H}_C = \{(h(C_1), \dots, h(C_m)) \mid h \in \mathcal{H}\} \subset \{0, 1\}^{|C|},$$

де $C = \{C_1, \dots, C_m\}$.

def. Говорять, що клас гіпотез $\mathcal{H}$ розбиває (значення)
скін. множину $C \subset X$, якщо будь-яка ф-ція $C \rightarrow \{0, 1\} \in$
об'ємів якоїсь ф-ції з $\mathcal{H}$, тобто $\mathcal{H}_C = \{0, 1\}^{|C|}$.

Лем. У цьому випадку $|\mathcal{H}_C| = 2^{|C|}$. Повторюючи введення
NFL-теорему отримують:

Сл. Нехай $\mathcal{H}$ -клас гіпотез дійс. клас. на мн. X , що розбиває деяку
 $C \subset X$ з $2m$ ел-тів. Тоді $\forall$ алгоритма A , що перевіряє
гіпотези з $\mathcal{H}$ (зокрема, ERM $_{\mathcal{H}}$ -алг.), $\exists$ розподіл $\mathcal{D}$ на $X \times \{0, 1\}$
такий, що

$$- L_{\mathcal{D}}(h) = 0 \text{ для деякої } h \in \mathcal{H};$$

$$- P_{S \sim \mathcal{D}^m} (L_{\mathcal{D}}(A(S)) > \frac{1}{8}) > \frac{1}{7}.$$

Подобно у цього випадку $\mathcal{H}$ перенесемо "гачко" навірши на m -лі-мнх тренувальних вибітках.

def. Вимірність Вання-Червоненкіса (VC-dimension) класу $\mathcal{H}$ іношез бінарної класифікації на X зветься найб. потужністю $|C|$ скінч. множини $C \subset X$, яку розбиває $\mathcal{H}$. Позн. $VCdim(\mathcal{H})$.

Rem. Подібно $VCdim(\mathcal{H}) = d$ означає, що $\exists C \subset X: |C| = d$ і $\mathcal{H}$ розд. C ; і $\forall C \subset X$ з $|C| > d$ $\mathcal{H}$ не розд. C . Зокрема, $(\text{g-ocm. } |C| = d+1)$
 $VCdim(\mathcal{H}) = \infty$ означає існують скінч. C довільної потужності, що розбивається $\mathcal{H}$.




Рч. Якщо $VCdim(\mathcal{H}) = \infty$, то $\mathcal{H}$ не $\in PAC$ навірши
Внаслідок з поперед. Соч. ап-но до доведення неправдивості класу $\mathcal{H}$ іношез (Соч. з NFL-теорем) више. $\triangle$

Ех. 1. Якщо $\mathcal{H}$ скінч., то $\forall C \quad |\mathcal{H}_C| \leq |\mathcal{H}|$, тому C не може бути роздана при $|\mathcal{H}| < 2^{|C|}$. Т.ч., $VCdim(\mathcal{H}) \leq \log_2 |\mathcal{H}|$, але може бути суттєво меншою. Наприклад,

у Ех.3. ми показали, що $VCdim = 1$ для класу порогових ф-цій. Якщо обрати порог зі скінч. множини, тобто $\mathcal{H} = \{1_{\{x < a_i\}}\}_{i=1}^n$, то $|\mathcal{H}| = n$, але так само $VCdim(\mathcal{H}) = 1$.

2. Клас усіх $\mathcal{H} \rightarrow \{0, 1\}$ розбиває $\forall C \subset \mathcal{H}$, тому, для нього $VCdim = |\mathcal{H}|$, зокрема ω для неск. $\mathcal{H}$ (і отже може він неабелевий, як і деякі).

3. Клас $\mathcal{H} = \{1_{\{x < a\}}\}_{a \in \mathbb{R}}$ порогових ф-цій має VC -вимірність 1. Дійсно, $\forall C = \{x\}$ $h_{x-1}(x) = 0$ і $h_{x+1}(x) = 1$, але для $C = \{x, y\}$, де $x < y$, $\nexists$ а такого, що $h_a(x) = 0$, $h_a(y) = 1$:




Це вірно і якщо обрати a зі скінч. множини, як у Ех.1. (може всі і не всі 1-ел-ні множини розбиваються, але де-які - так).

4. Класс x , ф. Кругов $\mathcal{K} = \{1_{\{|x| \leq r\}} \mid r \geq 0\}$ метр мат
 VC-вм. 1 $\mathcal{K}$ все сиркуваны ! для 1-точковой $C = \{x\}$
 $\begin{pmatrix} 1 \\ 0 \end{pmatrix}$


матно 0 при $|x| > r$ и 1 при $r \geq |x|$, а
 для двоточковой $\{x, y\}$, $|x| \leq |y|$ немонотонно пара-
 мати $(0, 1)$:

5 γ_{mac} $\mathcal{K} = \{ \perp [a_1, b_1] \times \dots \times [a_d, b_d] \}^{\times q}$ $\mathcal{A}$ - базис, параметри-

негів має VC-виг. 2d. Дійсно, при $d=1$, можна
 для відрізків, завжди можна розділити на 2 ел-тів
 $C = \{x, y\}, x < y$:




але ніколи - з $C = \{x, y, z\}, x < y < z$; неможливо
 отримати значення $(1, 0, 1)$, бо $h(x)=1 \Rightarrow a \leq x, h(z)=$
 $= 1 \Rightarrow z \leq b$, але тоді $y \in [a, b] \Rightarrow h(y)=1$.




Для $d=2$, можна для прямокутників:
 можна з 4 точок вибрати

(напрямки, з коорд. $(\pm 1, 0)$, $(0, \pm 1)$) можна розбити:



(це так не для V мн. з 4 точок: наприклад, перемісно
отримати $\begin{smallmatrix} 0 & 1 & 0 & 1 \\ \cdot & \cdot & \cdot & \cdot \end{smallmatrix}$ - довести це!). Якщо не $|C|=5$,
виділимо точки з найб. і найм. значеннями координат
з координат. Тоді $\nexists$ прямокутника, що y має ≤ 4 точки
дає 1 (містить їх), а y ніякий - 0 (не містить):



Впр. Довести, що формально і узагальнити на довільне d .
Разом з чим, $VCdim(K)$ не завжди $\in$ "кількість
параметрів" K як у Ex. вище:

Впр. Показати, що клас функцій $R \rightarrow \{0,1\}$

$$K = \{x \mapsto \lceil \sin \theta x \rceil \mid \theta \in R\},$$

де вважаємо $\lceil -1 \rceil = 0$, має VC -вимірність ∞ , хоча її залежить
від 1 параметра.