

2 PAC-обучаемость и сжатие

2.1 PAC-learning

Определение 2. Класс гипотез \mathcal{H} является PAC-обучаемым над множеством объектов $Z = z_1, \dots, z_d$ для функции потерь $l : \mathcal{H} \times Z \rightarrow \mathbb{R}_+$, если существует функция $t_{\mathcal{H}} : (0, 1)^2 \rightarrow \mathbb{N}$ и алгоритм \mathcal{A} со свойством: для всех $\varepsilon, \delta \in (0, 1)$, для любого распределения \mathcal{D} над множеством объектов Z алгоритм \mathcal{A} возвращает такое $h \in \mathcal{H}$, что с вероятностью $1 - \delta$ выполняется:

$$\mathbb{E}_{z \sim \mathcal{D}} [l(h, z)] \leq \min_{h' \in \mathcal{H}} \mathbb{E}_{z \sim \mathcal{D}} [l(h', z)] + \varepsilon. \quad (2.1)$$

Пример для задачи классификации выражение (2.1) можно переписать в виде:

$$P[p(\{h(z) \neq f(z)\}) > \varepsilon] \leq \delta$$

2.2 Sample Compression scheme

Схема сжатия данных с параметром k состоит из двух отображений (κ, ρ) :

1. κ получает на вход выборку S , а на выходе получаем пару (S', I) , где $|S'| = k$;
2. ρ получает на вход пару (S', I) на выходе выдает гипотезу h .

Причем выполняется следующее условие:

1. $\kappa(Y, y) = ((Z, z), I)$;
2. $\rho(\kappa(Y, y))|_Y = y$.

2.3 Compression implais learning

Любую схему сжатия с параметром k можно рассматривать как алгоритм обучения $A = \rho \circ \kappa$. То что данный алгоритм PAC-обучаем доказывает следующая теорема.

Теорема 2. Алгоритм обучения $A = \rho \circ \kappa$ является PAC-обучаемым, то есть

$$P[p(\{h(z) \neq f(z)\}) > \varepsilon] \leq |I| \sum_{j=1}^k \binom{d}{j} (1 - \varepsilon)^{m-j},$$

где p распределение над Z .

Доказательство. Сначала заметим, что всего существует

$$\sum_{j=1}^k \binom{d}{j}$$

подмножеств T множества Z размера не более k . С другой стороны всего есть $|I|$ вариантов выбрать информацию сжатия $i \in I$. Из выше описанного получаем, что каждой паре (T, i) соответствует своя функция

$$h_{T,i} = \rho((T, i), i).$$

С построения $h_{T,i}$ следует, что $h_{T,i}$ не зависит от $Z \setminus T$, тогда получаем, что если

$$p(\{h_{T,i}(x) \neq f(x)\}) \geq \varepsilon,$$

то для всех $m - |T|$ выполняется получаем, что

$$\prod_{t=1}^{m-|T|} p(\{h_{T,i}(x) \neq f(x)\}) \leq (1 - \varepsilon)^{m-|T|}. \quad (2.2)$$

Получаем, что для любого $h_{T,i}$ выполняется неравенство (2.2).

И того получаем, что для произвольной $h_{T,i}$ выполняется неравенство:

$$P[p(\{h_{T,i}(z) \neq f(z)\}) > \varepsilon] \leq (1 - \varepsilon)^{m-|T|},$$

Рассмотрим множество функций при фиксированном $i \in I$:

$$\mathcal{H}_i = \{h_{T,i} : |T| \leq k\}, \quad (2.3)$$

тогда для алгоритма A для подмножества функций, которые получены при помощи сжатой информации i получаем:

$$P[p(\{h_{T,i}(z) \neq f(z)\}) > \varepsilon] \leq \sum_{j=1}^k \binom{d}{j} (1 - \varepsilon)^{m-j}, \quad (2.4)$$

где $h_{T,i}$ это лучший алгоритм из множества \mathcal{H}_i .

Теперь заметим, что финальная функция h принадлежит множеству:

$$\mathcal{H}_{\kappa,\rho} = \{h_{T,i} : |T| \leq k, i \in I\}. \quad (2.5)$$

Вспомним, что для каждого T таких функций $|I|$, из чего уже для произвольного h используя выражение (2.4) имеем следующее неравенство:

$$P[p(\{h(z) \neq f(z)\}) > \varepsilon] \leq |I| \sum_{j=1}^k \binom{d}{j} (1 - \varepsilon)^{m-j},$$

что и доказывает исходную теорему. \square

Список литературы

- [1] Floyd, S., Warmuth, M. (1995) Sample Compression, Learnability, and the Vapnik-Chervonenkis Dimension. // Machine Learning 21, 269–304. <https://doi.org/10.1023/A:1022660318680>
- [2] В.В. Вьюгин КОЛМОГОРОВСКАЯ СЛОЖНОСТЬ И АЛГОРИТМИЧЕСКАЯ СЛУЧАЙНОСТЬ (2012) // МФТИ.
- [3] Shay Moran, Amir Yehudayoff Sample Compression Schemes for VC Classes (2015) // <https://www.cs.bgu.ac.il/~adsmb182/wiki.files/meni-lecture.pdf>