

0.1 Симметризация (Symmetrization)

Договоримся, что в случае использования верхнего индекса у выборок, он будет обозначать их мощность. Верхний индекс для упрощения понимания позже будем опускать.

$$\begin{aligned} \mathbb{E}_X R(X, F) &= \mathbb{E}_{X, \varepsilon} \sup_{f \in F} \left| \frac{1}{\ell} \sum_{i=1}^{\ell} \varepsilon_i f(X_i) \right| = (\text{в нашей терминологии}) = \\ &= \frac{1}{C_L^\ell} \frac{1}{C_\ell^{\ell/2}} \sum_{X \cup \bar{X}} \sum_{X=X_1^{\ell/2} \cup X_2^{\ell/2}} \sup_{f \in F} \left| \frac{1}{\ell} \left(\sum_{x \in X_1^{\ell/2}} f(x) - \sum_{x \in X_2^{\ell/2}} f(x) \right) \right| = \\ &= \frac{1}{C_L^\ell} \frac{1}{C_\ell^{\ell/2}} \sum_{\substack{X_1^{\ell/2}, X_2^{\ell/2}: \\ X_1^{\ell/2} \cap X_2^{\ell/2} = \emptyset}} \sup_{f \in F} \left| \frac{1}{\ell} \left(\sum_{x \in X_1^{\ell/2}} f(x) - \sum_{x \in X_2^{\ell/2}} f(x) \right) \right|. \end{aligned}$$

Теперь оценим сверху математическое ожидание равномерного отклонения эмпирической ошибки от действительной ошибки при $\ell = k$:

$$\mathbb{E} Q(X, F) = \frac{1}{C_L^\ell} \sum_{X \cup \bar{X}} \sup_{f \in F} \left| \left(\frac{1}{L} \sum_{x \in \bar{X}} f(x) - \frac{1}{\ell} \sum_{x \in X} f(x) \right) \right| = \frac{1}{2C_L^\ell} \sum_{X \cup \bar{X}} \sup_{f \in F} \left| \frac{1}{\ell} \left(\sum_{x \in \bar{X}} f(x) - \sum_{x \in X} f(x) \right) \right| = \dots$$

Главная идея заключается в том, чтобы для каждого разбиения $X \cup \bar{X}$ представить $\sum_{x \in \bar{X}} f(x) - \sum_{x \in X} f(x)$ в виде суммы

$$\sum_{x \in X_1^{\ell/2}} f(x) - \sum_{x \in X_2^{\ell/2}} f(x) + \sum_{x \in \bar{X} \setminus X_1^{\ell/2}} f(x) - \sum_{x \in X \setminus X_2^{\ell/2}} f(x)$$

по всевозможным $X_1 \subset \bar{X}$, $X_2 \subset X$.

$$\begin{aligned} \dots &= \frac{1}{2C_L^\ell} \frac{1}{C_\ell^{\ell/2}} \frac{1}{C_\ell^{\ell/2}} \sum_{X \cup \bar{X}} \sup_{f \in F} \left| \frac{1}{\ell} \sum_{\substack{X_1 \subset \bar{X} \\ X_2 \subset X}} \left(\sum_{x \in X_1} f(x) - \sum_{x \in X_2} f(x) + \sum_{x \in \bar{X} \setminus X_1} f(x) - \sum_{x \in X \setminus X_2} f(x) \right) \right| \leq \\ &\leq \frac{2}{2C_L^\ell C_\ell^{\ell/2} C_\ell^{\ell/2}} \sum_{X \cup \bar{X}} \sum_{\substack{X_1 \subset \bar{X} \\ X_2 \subset X}} \frac{1}{\ell} \sup_{f \in F} \left| \sum_{x \in X_1} f(x) - \sum_{x \in X_2} f(x) \right| = \dots \end{aligned}$$

Остаётся заметить, что каждая пара (X_1, X_2) учитывается ровно $C_{L/2}^{\ell/2} = C_\ell^{\ell/2}$ раз, и мы получаем:

$$\dots = \frac{C_\ell^{\ell/2}}{C_L^\ell C_\ell^{\ell/2} C_\ell^{\ell/2}} \sum_{\substack{X_1^{\ell/2}, X_2^{\ell/2}: \\ X_1^{\ell/2} \cap X_2^{\ell/2} = \emptyset}} \frac{1}{\ell} \sup_{f \in F} \left| \sum_{x \in X_1} f(x) - \sum_{x \in X_2} f(x) \right| = R_\ell(F).$$

Итак

$$\mathbb{E} Q(X, F) = \frac{1}{C_L^\ell} \sum_{X \cup \bar{X}} \sup_{f \in F} \left| \left(\frac{1}{L} \sum_{x \in \bar{X}} f(x) - \frac{1}{\ell} \sum_{x \in X} f(x) \right) \right| \leq \mathbb{E} R(X, F).$$

0.2 Концентрация меры (concentration)

Теорема 0.1 (McDiarmid's inequality). Пусть функция $g: X = (X_1, \dots, X_\ell) \rightarrow \mathbb{R}$ удовлетворяет условию ограниченных сумм с константами c_1, \dots, c_ℓ . Тогда

$$\begin{aligned} \mathbb{P}\{Z - \mathbb{E}Z \geq t\} &\leq e^{-\frac{2t^2}{C}}; \\ \mathbb{P}\{|Z - \mathbb{E}Z| \geq t\} &\leq 2e^{-\frac{2t^2}{C}}, \end{aligned}$$

где $C = \sum_{i=1}^{\ell} c_i^2$.

Применим эту теорему к случайной величине $Q(X, F) - R(X, F)$, которая удовлетворяет условию ограниченных сумм с константами $c_i = \frac{1}{\ell} + \frac{1}{2\ell} = \frac{3}{2\ell}$, $i = 1, \dots, \ell$. Получим следующее утверждение:

Утверждение 0.1. С вероятностью не меньше $1 - \delta$

$$Q(X, F) \leq R(X, F) + \frac{3}{2} \sqrt{\frac{\ln 1/\delta}{2\ell}},$$

или, что то же самое,

$$\sup_{f \in F} \left| \frac{1}{L} \sum_{x \in X} f(x) - \frac{1}{\ell} \sum_{x \in X} f(x) \right| \leq \frac{1}{C^{\ell/2}} \sum_{X=X_1^{\frac{\ell}{2}} \cup X_2^{\frac{\ell}{2}}} \sup_{f \in F} \left| \frac{1}{\ell} \left(\sum_{x \in X_1^{\frac{\ell}{2}}} f(x) - \sum_{x \in X_2^{\frac{\ell}{2}}} f(x) \right) \right| + \frac{3}{2} \sqrt{\frac{\ln 1/\delta}{2\ell}}.$$

Доказательство. С вероятностью не меньше $1 - \delta$

$$\begin{aligned} Q(X, F) - R(X, F) + \mathbb{E}R(X, F) - \mathbb{E}Q(X, F) &\leq \frac{3}{2} \sqrt{\frac{3 \ln 1/\delta}{2\ell}}; \\ Q(X, F) &\leq R(X, F) + \underbrace{(\mathbb{E}Q(X, F) - \mathbb{E}R(X, F))}_{\leq 0} + \frac{3}{2} \sqrt{\frac{\ln 1/\delta}{2\ell}}. \end{aligned}$$

■