

Chaining и энтропийное неравенство Dudley

Голубев Г.К.

CNRS, Université de Provence

Институт Проблем Передачи Информации им.
Харкевича
PreMoLab

Лекция посвящена двум темам:

- ① Chaining, который изобрел А. Н. Колмогоров.
- ② Статистическая теория автоматического обучения Вапника-Червоненкиса.

Цель лекции - показать, что chaining очень простой и мощный прием, который позволяет получать рекордные результаты в теории автоматического обучения.

Задача, которую мы сегодня обсуждаем исключительно просто формулируется: пусть имеется набор случайных величин

$$\{\xi_t, t \in T\}, \quad \xi_t \in \mathbf{R}^1,$$

T — конечное множество.

Наша задача — вычислить

$$\mathbf{E} \max_{t \in T} \xi_t.$$

Попробуем понять, насколько сложна эта задача. Именно, попробуем ответить на вопрос: насколько эта задача сложнее вычисления

$$\mathbf{E} \sum_{t \in T} \xi'_t = \sum_{t \in T} \mathbf{E} \xi'_t,$$

где ξ'_t некоторый набор других с. в.

ЛЕММА. Пусть ξ_t — гауссовские случайные величины с нулевым средним и $\mathbf{E} \xi_t^2 = \sigma_t^2 \leq \sigma$. Тогда

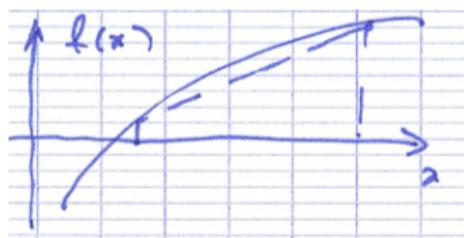
$$\mathbf{E} \max_{t \in T} \xi_t \leq \sqrt{2\sigma^2 \log(n)},$$

здесь $n = \#T$ — число элементов T .

Доказательство. Для любого $\lambda > 0$

$$\max_{t \in T} \xi_t = \lambda^{-1} \log \left[\max_{t \in T} e^{\lambda \xi_t} \right] \leq \lambda^{-1} \log \left[\sum_{t \in T} e^{\lambda \xi_t} \right].$$

Воспользуемся далее неравенством Йенсена: если $f(\cdot)$ вогнутая функция, то $E f(\xi) \leq f(E \xi)$.



Имеем

$$\begin{aligned} E \max_{t \in T} \xi_t &\leq \lambda^{-1} \log \left[\sum_{t \in T} E \exp(\lambda \xi_t) \right] \\ &\leq \lambda^{-1} \log \left[n \exp(\lambda^2 \sigma^2 / 2) \right] = \frac{\log(n)}{\lambda} + \frac{\sigma^2 \lambda}{2}. \end{aligned}$$

Поскольку это неравенство справедливо для любого λ , то чтобы улучшить верхнюю границу, минимизируем ее по λ . Находим

$$-\frac{\log(n)}{\lambda^2} + \frac{\sigma^2}{2} = 0, \quad \lambda = \sqrt{\frac{2 \log(n)}{\sigma^2}}.$$

Поэтому

$$\mathbf{E} \max_{t \in T} \xi_t \leq \log(n) \sqrt{\frac{\sigma^2}{2 \log(n)}} + \sqrt{\sigma^2 \log(n)/2} = \sqrt{2 \log(n) \sigma^2}.$$



Основная идея доказательства: если случайные величины $\xi'_t > 0$ имеют тяжелые хвосты, то

$$\max_{t \in T} \xi'_t \asymp \sum_{t \in T} \xi'_t.$$

Заметим также, что на самом деле не важно, что ξ_t это гауссовские с. в. Мы использовали только то, что

$$\mathbb{E} \exp(\xi_t \lambda) \leq \exp(\lambda^2 \sigma^2 / 2).$$

Величины, удовлетворяющие этому неравенству часто называют суб-гауссовскими.

Заметим, что сумма независимых суб-гауссовских величин также суб-гауссовская величина.

Помимо гауссовских случайных величин, какие еще величины являются суб-гауссовскими? Кажется, что и ограниченные случайные величины должны также быть суб-гауссовскими.

ЛЕММА. (Хёфдинг) Пусть ξ — с. в. с нулевым средним $\mathbf{E}\xi = 0$ и $\xi \in [a, b]$. Тогда

$$\mathbf{E} \exp(\lambda \xi) \leq \exp \left\{ \frac{\lambda^2(b-a)^2}{8} \right\}.$$

Доказательство. Рассмотрим функцию

$$\phi(\lambda) = \log \left[\int_a^b e^{\lambda x} p(x) dx \right] = \log [\mathbf{E} \exp(\lambda \xi)]$$

и заметим, что

$$\phi'(\lambda) = \int_a^b x \frac{e^{\lambda x} p(x)}{\int_a^b e^{\lambda u} p(u) du} dx.$$

$$\begin{aligned}\phi''(\lambda) &= \int_a^b x^2 \frac{e^{\lambda x} p(x)}{\int_a^b e^{\lambda u} p(u) du} dx \\ &- \left\{ \int_a^b x \frac{e^{\lambda x} p(x)}{\int_a^b e^{\lambda u} p(u) du} dx \right\}^2 = \text{Var}(Z),\end{aligned}$$

где Z — с. в. с плотностью

$$\frac{e^{\lambda x} p(x)}{\int_a^b e^{\lambda u} p(u) du}.$$

Заметим далее, что $Z \in [a, b]$ и что

$$\left[Z - \frac{a+b}{2} \right]^2 \leq \left(\frac{b-a}{2} \right)^2.$$

Поэтому

$$\text{Var}(Z) = \min_x \mathbf{E}[Z - x]^2 \leq \left(\frac{b-a}{2}\right)^2.$$

Чтобы завершить доказательство, проинтегрируем неравенство

$$\phi''(\lambda) \leq \left(\frac{b-a}{2}\right)^2,$$

учитывая, что $\phi(0) = 0$ и $\phi'(0) = 0$. Тогда находим

$$\phi(\lambda) \leq \frac{\lambda^2}{2} \left(\frac{b-a}{2}\right)^2. \quad \blacktriangle$$

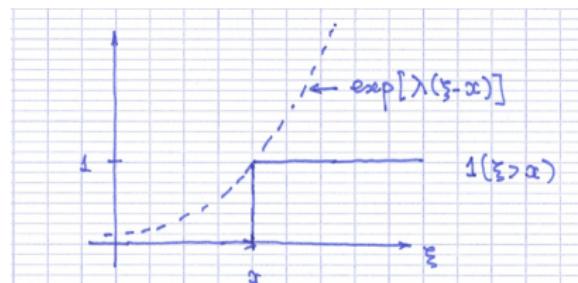
ТЕОРЕМА. (Хёффдинг) Пусть ξ_t , $t \in T$ — независимые с. в. и такие, что $\xi_t \in [a, b]$. Тогда

$$P\left\{\left|\frac{1}{n} \sum_{t \in T} (\xi_t - E\xi_t)\right| \geq x\right\} \leq 2 \exp\left\{-\frac{2nx^2}{(b-a)^2}\right\}.$$

Доказательство. Воспользуемся неравенством Чернова

$$P\{\xi > x\} \leq \exp(-\lambda x) E \exp(\lambda \xi),$$

которое справедливо для любой с. в. ξ и любого $\lambda > 0$.



Положим

$$\xi = \frac{1}{n} \sum_{t \in T} [\xi_t - \mathbf{E} \xi_t].$$

Тогда из неравенства Чернова и леммы Хёфдинга находим

$$\mathbf{P}\{\xi > x\} \leq \exp \left\{ \min_{\lambda} \left[-\lambda x + \frac{\lambda^2}{8} \frac{(b-a)^2}{n} \right] \right\}.$$

Оптимальное λ :

$$\lambda \frac{(b-a)^2}{4n} = x, \quad \lambda = \frac{4nx}{(b-a)^2}.$$

Поэтому

$$\mathbf{P}\{\xi > x\} \leq \exp \left\{ -\frac{2nx^2}{(b-a)^2} \right\}.$$

Аналогичное неравенство справедливо для с. в. $-\xi$.

Поэтому

$$\mathbf{P}\{|\xi| > x\} \leq 2 \exp \left\{ -\frac{2nx^2}{(b-a)^2} \right\}. \quad \blacktriangle$$

Принципиально важный метод в этом доказательстве — неравенство Чернова.

$$\mathbf{P}\{\xi > x\} \leq \exp \left\{ \min_{\lambda} \left[-\lambda x + \log \mathbf{E} e^{\lambda \xi} \right] \right\}$$

Наш первый метод получения верхних границ для $E \max_{t \in T} \xi_t$ дает хорошие результаты только в том случае, когда ξ_t близки к независимым с. в.

Задача, которую мы рассмотрим далее — это поиск метода, который позволял бы получать разумные результаты для зависимых с. в.

До сих пор мы имели дело с суб-гауссовскими с. в. Теперь рассмотрим несколько более общие семейства с. в., а именно, величины с ограниченной нормой Орлича.

Определение. Функция $\psi(x): \mathbf{R}^+ \rightarrow \mathbf{R}^+$ называется функцией Юнга, если $\psi(0) = 0$, $\psi(x)$ не убывает и выпукла.

Определение. Норма Орлича с. в. Z относительно функции Юнга ψ определяется как

$$\|Z\|_\psi = \inf \left\{ c > 0 : \mathbf{E} \psi \left(\frac{|Z|}{c} \right) \leq 1 \right\}.$$

Примеры:

для суб-гауссовых с. в. $\psi(x) = \exp(x^2/2) - 1$;

для суб-экспоненциальных с. в. $\psi(x) = \exp(x) - 1$;

для с. в. с ограниченным p -ым моментом $\psi(x) = x^p$.

ЛЕММА. Пусть ξ_t , $t \in T$, ($\#T = n$) такова, что $\|\xi_t\|_\psi \leq 1$. Тогда

$$\mathbf{E} \max_{t \in T} |\xi_t| \leq \psi^{-1}(n).$$

Здесь $\psi^{-1}(\cdot)$ — функция, обратная к $\psi(\cdot)$.

Доказательство аналогично доказательству первой леммы в лекции. Имеем

$$\max_{t \in T} |\xi_t| \leq \psi^{-1} \left(\max_{t \in T} \psi(|\xi_t|) \right) \leq \psi^{-1} \left(\sum_{t \in T} \psi(|\xi_t|) \right).$$

Так как ψ^{-1} вогнута и $\mathbf{E}\psi(|\xi_t|) \leq 1$, то применив неравенство Йенсена, завершаем доказательство. \blacktriangle

ТЕОРЕМА. Пусть на T задана полунорма $d(\cdot, \cdot)$ и ξ_t удовлетворяет условию Липшица относительно нормы Орлича $\|\cdot\|_\psi$:

$$\|\xi_t - \xi_s\|_\psi \leq d(t, s).$$

Обозначим:

D — диаметр T : $D \triangleq \max_{t, s \in T} d(t, s)$,

$N(T, d; \epsilon)$ — минимальное число шаров, необходимых для покрытия T .

Тогда

$$\mathbf{E} \max_{t, s \in T} |\xi_t - \xi_s| \leq 8 \int_0^D \psi^{-1}[N(T, d; \epsilon)] d\epsilon.$$

Доказательство. Будем использовать следующие обозначения:

$T_l \in \mathcal{T}$ — 2^{-l} -сеть, содержащая $N(\mathcal{T}, d; 2^{-l})$ точек,
 l_0 — максимальное целое число, такое что

$$N(\mathcal{T}, d; 2^{-l_0}) = 1,$$

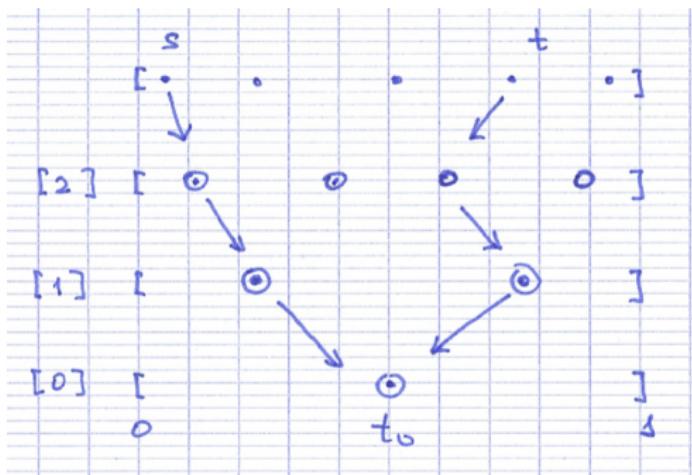
l_1 — минимальное целое число, такое что

$$N(\mathcal{T}, d; 2^{-l_1}) = n.$$

Для любой точки $t \in \mathcal{T}$ определим ее проекцию $\pi_l(t)$ на сеть T_l :

$$\pi_l(t) = \arg \min_{s \in T_l} d(t, s).$$

Пример: сети на $[0, 1]$.



Chaining: пусть $t \in T_{l_1}$, тогда

$$\xi_t - \xi_{t_0} = \xi_t - \xi_{\pi_{l_1-1}(t)} + \xi_{\pi_{l_1-1}(t)} - \xi_{\pi_{l_1-2}(\pi_{l_1-1}(t))} + \dots$$

Поэтому, воспользовавшись леммой о максимуме случайных величин, у которых норма Орлича ограничена сверху 1, для любых $t, s \in T_{l_1}$ имеем

$$\begin{aligned} \mathbf{E} \max_{t, s \in T} |\xi_t - \xi_s| &\leq 2 \sum_{j=l_1}^{l_0} \mathbf{E} \max_{t \in T_j} |\xi_t - \xi_{\pi_{j-1}(t)}| \\ &\leq 2 \sum_{j=l_1}^{l_0} \max_{t \in T_j} \|\xi_t - \xi_{\pi_{j-1}(t)}\|_\psi \times \mathbf{E} \max_{t \in T_j} \frac{|\xi_t - \xi_{\pi_{j-1}(t)}|}{\|\xi_t - \xi_{\pi_{j-1}(t)}\|_\psi} \\ &\leq 2 \sum_{j=l_1}^{l_0} 2^{-(j-1)} \times \psi^{-1} [N(T, d; 2^{-j})]. \end{aligned}$$

Чтобы завершить доказательство заметим, что

$$2^{-j} \psi^{-1}[N(T, d; 2^{-j})] \leq 2 \int_{2^{-j}}^{2^{-j+1}} \psi^{-1}[N(T, d; \epsilon)] d\epsilon.$$

Поэтому,

$$\begin{aligned} \mathbf{E} \max_{t, s \in T} |\xi_t - \xi_s| &\leq 8 \int_0^{2^{-l_0}} \psi^{-1}[N(T, d; \epsilon)] d\epsilon \\ &= 8 \int_0^D \psi^{-1}[N(T, d; \epsilon)] d\epsilon. \quad \blacktriangle \end{aligned}$$

Замечание. Если случайные величины ξ_t суб-гауссовские, то поскольку

$$\psi(x) = \exp(x^2/2) - 1, \quad \psi^{-1}(x) = \sqrt{2 \log(x + 1)}$$

и

$$d(t, s) = \sqrt{\mathbf{E}[\xi_t - \xi_s]^2},$$

приходим к энтропийному неравенству Дадли

$$\mathbf{E} \max_{t, s \in T} |\xi_t - \xi_s| \leq 8 \int_0^D \sqrt{2 \log N(T, d; \epsilon)} d\epsilon;$$

здесь $\log N(T, d; \epsilon)$ — метрическая энтропия.

Замечание. Более точную верхнюю границу для $\max_{t \in T} \xi_t$ дает

ТЕОРЕМА о мажорирующей мере. Пусть $B(t, \epsilon)$ — шар радиуса ϵ центром в t , μ — некоторая вероятностная мера на T .

$$\mathbf{E} \max_{t, s \in T} |\xi_t - \xi_s| \leq K_\psi \max_{t \in T} \int_0^D \psi^{-1} \left[\frac{1}{\mu[B(t, s)]} \right] d\epsilon;$$

здесь K_ψ — постоянная, зависящая только от функции Юнга $\psi(\cdot)$.

Статистическая теория обучения

Предположим, что у нас имеется n пар независимых одинаково распределенных случайных величин

$$(X_1, Y_1), \dots, (X_n, Y_n),$$

где $X_i \in \mathbf{R}^d$, $Y_i \in \{1, -1\}$.

Предположим, что мы знаем величину X_{n+1} .

Задача состоит в том, чтобы по имеющимся данным

$$\{X_{n+1}, (X_i, Y_i), i = 1, \dots, n\}$$

предсказать Y_{n+1} .

Пример: обнаружение спама в электронной почте.

Имеется n сообщений $\varepsilon_1, \dots, \varepsilon_n$, каждое из которых мы классифицировали либо как спам $\{\psi_i = -1\}$ либо как полезное сообщение $\{\psi_i = 1\}$.

Необходимо придумать метод (алгоритм), который без нашей помощи решал бы, является ли сообщение ε_{n+1} спамом или нет, т.е. предсказал бы Y_{n+1} .

С каждым сообщением ε_i свяжем вектор $X_i \in \mathbf{R}^d$, который содержит частоту появления слов в сообщении ε_i .

Заметим, что величина d в рассматриваемой задаче должна быть велика $d \approx 1000$.

Формальное решение. Предположим, что нам известно распределение случайной величины X при $Y = 1$ и $Y = -1$, которые мы будем обозначать как

$$\mathbf{P}_1(X) \quad \text{и} \quad \mathbf{P}_{-1}(X).$$

Будем считать, что эти меры имеют плотности относительно некоторой σ -конечной меры μ . Обозначим их

$$p_1(X) \quad \text{и} \quad p_{-1}(X).$$

Наша цель найти функцию $g(x)$, которая минимизирует вероятность ошибки

$$e(g) = \pi \mathbf{P}_1(g(X) = -1) + (1 - \pi) \mathbf{P}_{-1}(g(X) = 1),$$

здесь $\pi = \mathbf{P}\{Y = 1\}$.

ЛЕММА Неймана-Пирсона. *Наилучшее решающее правило имеет вид*

$$g^*(X) = \arg \min_g \{e(g)\} = \begin{cases} 1, & \frac{\pi p_1(x)}{\pi p_1(x) + (1-\pi)p_{-1}(x)} \geq \frac{1}{2} \\ -1, & \frac{\pi p_1(x)}{\pi p_1(x) + (1-\pi)p_{-1}(x)} \leq \frac{1}{2} \end{cases}$$

Оценить $p_1(\cdot)$ и $p_{-1}(\cdot)$ можно только при небольших размерностях d .

Если оценивание $p_{\pm 1}(x)$ типичная задача, которая решается в статистике, то в теории автоматического обучения используется принципиально другой подход. А именно, задается некоторый класс функций $G = \{g(x) : \mathbb{R}^n \rightarrow \{-1, +1\}\}$ и прогноз ищется в этом классе.

Оптимальное решение этой задачи

$$g^* = \arg \min_g \underbrace{\mathbf{P}\{g(X) \neq Y\}}_{R(g)}$$

это прогноз, который минимизирует среднюю вероятность ошибки.

Для его вычисления нам опять же нужны плотности $p_{\pm 1}(x)$.

Поэтому, чтобы избежать их оценивания, мы определяем

$$g_n^* = \arg \min_{g \in G} \underbrace{R_n(g)},$$

где

$$R_n(g) = \frac{1}{n} \sum_{i=1}^n \mathbf{1}\{g(X_i) \neq Y_i\}$$

эмпирический риск.

Например,

$$G = \left\{ g(x) = \text{sing}(\langle \theta, X - X_0 \rangle), \ X_0, \ \theta \in \mathbf{R}^d \right\}.$$

Нас интересует верхняя граница для $R(g^*)$. Заметим, что

$$R(g_n^*) = [R(g_n^*) - R_n(g_n^*)] + [R_n(g_n^*) - R_n(g^*)] + R_n(g^*).$$

Ясно, что $R_n(g_n^*) \leq R_n(g^*)$. Поэтому

$$R(g_n^*) \leq R(g^*) + [R_n(g^*) - R(g^*)] + [R(g_n^*) - R_n(g_n^*)].$$

Оценивание выражений в квадратных скобках в этом неравенстве – типичная задача в теории эмпирических процессов.

Воспользовавшись теоремой Хёфдинга, несложно оценить

$$\mathbb{P}\{|R_n(g^*) - R(g^*)| > \delta\}.$$

Определение. Эмпирический процесс — это набор с. в., индексируемых некоторым функциональным классом \mathcal{F} и таких, что каждая с. в. есть сумма независимых одинаково распределенных величин.

Для эмпирического процесса как правило используется обозначение

$$\{Pf - P_n f\}_{f \in \mathcal{F}},$$

где

$$Pf = \mathbf{E}f(Z_i), \quad P_n f = \frac{1}{n} \sum_{i=1}^n f(Z_i),$$

а Z_i — независимые, одинаково распределенные случайные величины.

В теории автоматического обучения класс функций \mathcal{F}_G определяется

$$f(X, Y) = \mathbf{1}\{g(X) \neq Y\}, \quad g \in G.$$

Поскольку $f(\cdot, \cdot) \in [0, 1]$, мы можем применить теорему Хёфдинга

$$\mathbf{P}\left\{|R_n(g^*) - R(g^*)| > \epsilon\right\} \leq 2 \exp\left\{-2n\epsilon^2\right\}$$

или, что эквивалентно, сказать, что с вероятностью не меньшей, чем $1 - \delta$

$$|R(g^*) - R_n(g^*)| \leq \sqrt{\frac{1}{2n} \log \frac{2}{\delta}}.$$

Для $R(g_n^*) - R_n(g_n^*)$ неравенство Хёфдинга напрямую применить нельзя поскольку g_n^* зависит от обучающей выборки.

Идея: использовать простое неравенство

$$R(g_n^*) - R_n(g_n^*) \leq \max_{g \in G} [R(g) - R_n(g)] = \max_{f \in \mathcal{F}_G} [Pf - P_n f].$$

Предположим, что G состоит из конечного числа элементов. Тогда очевидно, что и \mathcal{F}_G конечно и мы можем опять использовать неравенство Хёфдинга

$$\begin{aligned} \mathbf{P} \left\{ \max_{f \in \mathcal{F}_G} |Pf - P_n f| \geq \epsilon \right\} &\leq \sum_{f \in \mathcal{F}_G} \mathbf{P} \left\{ |Pf - P_n f| > \epsilon \right\} \\ &\leq 2N \exp \left\{ -2n\epsilon^2 \right\}. \end{aligned}$$

И, следовательно, с вероятностью не меньшей, чем $1 - \delta$

$$R(g_n^*) - R_n(g_n^*) \leq \sqrt{\frac{1}{2n} \log \left(\frac{2N}{\delta} \right)}.$$

Средние Радемахера

Радемахеровские случайные величины это н. о. р. с. в., принимающие значения $\{1, -1\}$ с равными вероятностями. Будем обозначать для краткости

$$R_n^\sigma f = \frac{1}{n} \sum_{i=1}^n \sigma_i f(Z_i),$$

σ_i — радемахеровские с. в.

Z_i — н.о.р.с.в. (В нашей задаче $Z_i = (X_i, Y_i)$ и $f(Z_i) = \mathbf{1}\{g(X_i) \neq Y_i\}$)

\mathbf{E}_σ — усреднение по радемахеровским с. в.

\mathbf{E} — усреднение по всем с. в.

Определение. Радемахеровское среднее класса \mathcal{F} определяется как

$$\mathcal{R}(\mathcal{F}_G) = \mathbf{E} \max_{f \in \mathcal{F}_G} R_n^\sigma(f)$$

и условное радемахеровское среднее определяется следующим образом:

$$\mathcal{R}_n(\mathcal{F}_G) = \mathbf{E}_\sigma \max_{f \in \mathcal{F}_G} R_n^\sigma(f).$$

ТЕОРЕМА Для любой функции $f \in \mathcal{F}_G$ с вероятностью не меньшей, чем $1 - \delta$

$$P(f) \leq P_n(f) + 2\mathcal{R}(\mathcal{F}_G) + \sqrt{\frac{\log(1/\delta)}{n}},$$

$$P(f) \leq P_n(f) + 2\mathcal{R}_n(\mathcal{F}_G) + \sqrt{\frac{2 \log(2/\delta)}{n}}.$$

Доказательство. Ключевую роль в нем играет следующий результат о концентрации меры.

ТЕОРЕМА(Mc. Diarmid) *Пусть Z_i — н. о. р. с. в.*

Предположим, что функция $F(\cdot) : \mathbb{R}^n \rightarrow \mathbb{R}$ такова, что для любого $i = 1, \dots, n$ и любых $x_1, \dots, x_n, x'_i \in \mathbb{R}$

$$|F(x_1, \dots, x_{i-1}, x_i, x_{i+1}, \dots, x_n) - F(x_1, \dots, x_{i-1}, x'_i, x_{i+1}, \dots, x_n)| \leq C.$$

Тогда

$$\mathbf{P} \left\{ |F(Z_1, \dots, Z_n) - \mathbf{E}F(Z_1, \dots, Z_n)| > \epsilon \right\} \leq 2 \exp \left\{ - \frac{2\epsilon^2}{nC^2} \right\}.$$

Доказательство нашей теоремы будет следовать следующему плану:

- ① с помощью теоремы Mc Diarmid свяжем

$$\max_{f \in \mathcal{F}_G} [Pf - P_n f] \quad \text{и} \quad \mathbf{E} \max_{f \in \mathcal{F}_G} [Pf - P_n f];$$

- ② используем симметризацию, чтобы связать $\mathbf{E} \max_{f \in \mathcal{F}_G} [Pf - P_n f]$ и радемахеровское среднее класса \mathcal{F}_G .

I. Пусть P_n^i — эмпирическая мера, в которой модифицирован i -ый элемент

$$Z_i \rightarrow Z'_i.$$

Тогда мы имеем, учитывая, что $f \in \{0, 1\}$

$$\left| \max_{f \in \mathcal{F}_G} (Pf - P_n f) - \max_{f \in \mathcal{F}_G} (Pf - P_n^i f) \right| \leq \max_{f \in \mathcal{F}_G} |P_n^i f - P_n f| \leq \frac{1}{n}.$$

Поэтому согласно теореме Mc. Diarmid с вероятностью не меньшей, чем $1 - \delta$

$$\max_{f \in \mathcal{F}_G} (Pf - P_n f) \leq \mathbf{E} \max_{f \in \mathcal{F}_G} (Pf - P_n f) + \sqrt{\frac{1}{2n} \log \frac{2}{\delta}}.$$

II. Лемма о симметризации

$$\mathbf{E} \max_{f \in \mathcal{F}_G} (Pf - P_n f) \leq 2 \mathbf{E} \max_{f \in \mathcal{F}_G} R_n^\sigma(f).$$

Доказательство. Введем независимую от Z выборку Z' , имеющую тоже самое вероятностное распределение, что и Z , и обозначим

$$P'_n f = \frac{1}{n} \sum_{i=1}^n f(Z'_i), \quad P' f = \mathbf{E} P'_n f.$$

Тогда, используя неравенство Йенсена, имеем

$$\begin{aligned}
 & \mathbf{E} \max_{f \in \mathcal{F}_G} [Pf - P_n f] = \mathbf{E} \max_{f \in \mathcal{F}_G} [\mathbf{E} P'_n f - P_n f] \\
 & \leq \mathbf{E} \max_{f \in \mathcal{F}_G} [P'_n f - P_n f] = \mathbf{E}_\sigma \mathbf{E} \max_{f \in \mathcal{F}_G} \frac{1}{n} \sum_{i=1}^n \sigma_i [f(Z_i) - f(Z'_i)] \\
 & \leq \mathbf{E}_\sigma \mathbf{E} \max_{f \in \mathcal{F}_G} \frac{1}{n} \sum_{i=1}^n \sigma_i f(Z_i) + \mathbf{E}_\sigma \mathbf{E} \max_{f \in \mathcal{F}_G} \left\{ -\frac{1}{n} \sum_{i=1}^n \sigma_i f(Z'_i) \right\} \\
 & \qquad \qquad \qquad = 2 \mathbf{E} \max_{f \in \mathcal{F}_G} R_n^\sigma f.
 \end{aligned}$$

Это неравенство завершает доказательство леммы и первого неравенства в теореме. Второе неравенство доказывается тем же самым способом, но неравенство концентрации Mc. Diarmid применяется для функции $F(Z_1, \dots, Z_n) = \mathcal{R}_n(\mathcal{F}_G)$.

Связь с исходным классом G .

Из предыдущей теоремы вытекает, что с вероятностью не меньшей, чем $1 - \delta$ для любого $g \in G$ выполняется следующее неравенство:

$$R(g) \leq R_n(g) + 2\mathcal{R}_n(\mathcal{F}_G) + \sqrt{\frac{2 \log(2/\delta)}{n}};$$

здесь

$$\mathcal{R}_n(\mathcal{F}_G) = \mathbf{E}_\sigma \max_{g \in G} \frac{1}{n} \sum_{i=1}^n \sigma_i \mathbf{1}\{g(X_i) \neq Y_i\}.$$

Радемахеровское среднее $\mathcal{R}_n(\mathcal{F}_G)$ и радемахеровское исходного класса G

$$\mathcal{R}_n(G) = \mathbf{E}_\sigma \max_{g \in G} \frac{1}{n} \sum_{i=1}^n \sigma_i g(X_i)$$

очень тесно связаны. Действительно,

$$\begin{aligned} \mathcal{R}_n(\mathcal{F}_G) &= \mathbf{E}_\sigma \max_{g \in G} \frac{1}{n} \sum_{i=1}^n \sigma_i \mathbf{1}\{g(X_i) \neq Y_i\} \\ &= \mathbf{E}_\sigma \max_{g \in G} \frac{1}{n} \sum_{i=1}^n \sigma_i \frac{1 - Y_i g(X_i)}{2} = \frac{1}{2} \mathbf{E}_\sigma \max_{g \in G} \sum_{i=1}^n \frac{1}{n} \sigma_i Y_i g(X_i) \\ &= \frac{1}{2} \mathbf{E}_\sigma \max_{g \in G} \frac{1}{n} \sum_{i=1}^n \sigma_i g(X_i). \end{aligned}$$

Поэтому для любого $g \in G$ с вероятностью не меньшей, чем $1 - \delta$

$$R(g) \leq R_n(g) + \mathcal{R}_n(G) + \sqrt{\frac{2 \log(2/\delta)}{n}}$$

и, в частности, отсюда вытекает, что

$$R(g_n) \leq \min_{g \in G} R(g) + \mathcal{R}_n(G) + 2 \sqrt{\frac{2 \log(2/\delta)}{n}}.$$

Напомним, что

$$g_n = \arg \min_{g \in G} \frac{1}{n} \sum_{i=1}^n \mathbf{1}\{g(X_i) \neq Y_i\}.$$

Для оценки $\mathcal{R}_n(\mathcal{F}_G)$ мы используем энтропийную границу Дадли.

ТЕОРЕМА.(Дадли)

$$\begin{aligned}\mathcal{R}_n(\mathcal{F}_G) &= \mathbf{E}_\sigma \max_{f \in \mathcal{F}} \frac{1}{n} \sum_{i=1}^n \sigma_i f(Z_i) \\ &\leq \frac{12}{\sqrt{n}} \int_0^\infty \sqrt{\log N(\mathcal{F}_G, d; \epsilon)} d\epsilon.\end{aligned}$$

Здесь

$$d^2(f_1, f_2) = \frac{1}{n} \sum_{i=1}^n [f_1(Z_i) - f_2(Z_i)]^2.$$

Во многих случаях вычислить энтропию помогает следующий результат.

ТЕОРЕМА (Haussler (1995)) *Если размерность Вапника-Червоненкиса класса \mathcal{F}_G не превосходит q , то*

$$N(\mathcal{F}_G, d; \epsilon) \leq Cq \left(\frac{4e}{\epsilon} \right)^q;$$

здесь и далее C обозначает универсальные постоянные, значения которых могут меняться в зависимости от неравенства, в котором они появляются.

Таким образом, из этого результата и теоремы Дадли получаем верхнюю границу

$$\mathcal{R}_n(\mathcal{F}_G) \leq C \sqrt{\frac{q}{n}}.$$

Поэтому, объединяя полученные неравенства, приходим к следующему результату:

при выполнении условий предыдущей теоремы с вероятностью не меньшей, чем $1 - \delta$ справедлива следующая верхняя граница для риска g_n^ :*

$$R(g_n^*) \leq \min_{g \in G} R(g) + \sqrt{\frac{Cq + 4 \log(2/\delta)}{n}},$$

здесь q – размерность Вапника-Червоненкиса класса G и

$$g_n^* = \arg \min_{g \in G} \frac{1}{n} \sum_{i=1}^n \mathbf{1}\{g(X_i) \neq Y_i\}.$$