

# Геометрия классов в задачах статистического обучения

Никита Животовский

Московский физико-технический институт  
Институт проблем передачи информации

14 марта 2015 г.

- Задан класс функций  $\mathcal{F}$  на некотором вероятностном пространстве  $(\Omega, \mu)$ .
- Некоторая случайная величина  $Y$ , которую необходимо приблизить с помощью  $\mathcal{F}$ .
- Функция потерь  $\ell$ , означающая штраф за использование  $f(X)$  вместо  $Y$ .
- Обучающая выборка  $(X_i, Y_i)_{i=1}^n$ , распределенная согласно произведению  $n$  совместных распределений  $\mu$  и  $Y$  на исходах  $(\Omega \times \mathbb{R})^n$ .

## Замечания:

- Для построения приближений можно использовать только обучающую выборку, информацию о классе и функции потерь.
- Функция потерь  $\ell : \mathbb{R} \rightarrow \mathbb{R}_+$ . Таким образом, штраф за предсказание  $f(X)$  вместе  $Y$  равен  $\ell(f(X) - Y)$ .

## Замечания:

- Для построения приближений можно использовать только обучающую выборку, информацию о классе и функции потерь.
- Функция потерь  $\ell : \mathbb{R} \rightarrow \mathbb{R}_+$ . Таким образом, штраф за предсказание  $f(X)$  вместе  $Y$  равен  $\ell(f(X) - Y)$ .

## Цель

По обучающей выборке построить некоторое правило  $\hat{f}$ , такое что  $\mathbb{E}\ell(\hat{f}(X) - Y)$  оптимален.

- Случайная величина  $Y$  является фиксированной функцией  $T : \Omega \rightarrow \mathbb{R}$  или эквивалентно  $Y = T(X)$ .
- Функция потерь квадратичная:  $\ell(t) = t^2$ .

Тогда цель построить такое отображение  $\hat{f}$ , что величина

$$\mathbb{E}\ell(f(X) - T(X)) = \mathbb{E}(f(X) - T(X))^2 = \int_{\Omega} (f(t) - T(t))^2 d\mu(t)$$

как можно меньше.

Построение  $\hat{f}$  производится на основании  $(X_i, T(X_i))_{i=1}^n$ .

- Имеет место соотношение

$$Y = g(X) + \varepsilon,$$

где  $\varepsilon$  — независимый от  $X$  гауссовский шум, а  $g \in \mathcal{F}$ .

- Функция потерь квадратичная:  $\ell(t) = t^2$ .

- Имеет место соотношение

$$Y = g(X) + \varepsilon,$$

где  $\varepsilon$  — независимый от  $X$  гауссовский шум, а  $g \in \mathcal{F}$ .

- Функция потерь квадратичная:  $\ell(t) = t^2$ .

### Замечание

В этом случае  $Y$  относится уже к более сложному вероятностному пространству чем  $(\Omega, \mu)$ .

В качестве эталона необходима функция, заданная на  $(\Omega, \mu)$ .

## Определение

Байесовское решающее правило  $f^*$ , определяемое случайной величиной  $\mathbb{E}[Y|X]$ , минимизирует  $\mathbb{E}(f^*(X) - Y)^2$  среди случайных величин, заданных на  $(\Omega, \mu)$ .

В примере  $Y = g(X) + \varepsilon$ ,  $g \in \mathcal{F}$  при условии независимости шума  $f^* = g$ .

## Замечание

Однако риск  $f^*$  равен дисперсии шума. Таким образом, в этой задаче ни для какого  $\hat{f}$  нельзя сделать величину  $\mathbb{E}(\hat{f}(X) - Y)^2$  сколь угодно близкой к нулю.

Оптимальное решающее правило должно обладать риском, близким к риску байесовского решающего правила.

## Определение

Избыточным риском правила  $\hat{f}$  называется величина

$$\mathbb{E}\ell(\hat{f}(X) - Y) - \mathbb{E}\ell(f^*(X) - Y),$$

где  $f^*$  — байесовское решающее правило.

Предположим, что  $Y \in \mathcal{F}$ .

## Определение (Valiant' 84)

Класс  $\mathcal{F}$  называется PAC-обучаемым, если существует обучающий алгоритм  $\psi_n : (\Omega, \mathbb{R})^n \rightarrow \mathcal{F}$ , такой что с вероятностью  $1 - \delta$  (по отношению к обучающей выборке длины  $n$ ) взяв достаточно большое  $n^*$ , зависящее от чисел  $\varepsilon$  и  $\delta$ , получим, что для  $n \geq n^*$

$$\mathbb{E}\ell(\hat{f}(X) - Y) - \mathbb{E}\ell(f^*(X) - Y) \leq \varepsilon,$$

где  $\hat{f} = \psi_n((X_i, Y_i)_{i=1}^n)$ .

## Замечание

Отметим независимость от распределения данных.

## No free lunch theorem

### Теорема (Folklore)

- Если про класс  $\mathcal{F}$  ничего неизвестно или он слишком большой, то для любого обучающего алгоритма найдется плохое вероятностное распределение, что избыточный риск не будет стремиться к нулю.
- Если  $f^* \notin \mathcal{F}$  и обучающий алгоритм принимает значения в  $\mathcal{F}$ , то опять же избыточный риск не будет стремиться к нулю.

## Approximation–Estimation tradeoff

Обозначим риск  $R(f) = \mathbb{E}\ell(f(X) - Y)$ . Пусть  $\hat{f}$  выбирается алгоритмом обучения, тогда

$$R(\hat{f}) - R(f^*) = (R(\hat{f}) - R(f_{\mathcal{F}}^*)) + (R(f_{\mathcal{F}}^*) - R(f^*)),$$

где  $f_{\mathcal{F}}^* = \arg \inf_{f \in \mathcal{F}} R(f)$ .

### Определение

- Выражение в первой скобке называется ошибкой оценивания (*estimation error*).
- Выражение во второй — ошибкой аппроксимации (*approximation error*).

## Определение (Kearns, Shapire' 91)

- Агностический случай (*Agnostic case*) —  $f^* \notin \mathcal{F}$ .
- Реализуемый случай (*Realizable case*) —  $Y \in \mathcal{F}$ .

В агностическом случае избыточным риском называют

$$R(\hat{f}) - R(f_{\mathcal{F}}^*) = \mathbb{E}\ell(\hat{f}(X) - Y) - \mathbb{E}\ell(f_{\mathcal{F}}^*(X) - Y)$$

## Замечание

- В реализуемом случае ошибка аппроксимации равна нулю.
- Так определенный избыточный риск совпадает с ранее введенным в реализуемом случае.

## Определение

Агностическая PAC-обучаемость класса  $\mathcal{F}$  заключается в стремлении с большой вероятностью к нулю избыточного риска.

Ставится более общая задача:

## Цель

Пусть  $\hat{f}$  — результат обучения некоторой процедуры на  $(X_i, Y_i)_{i=1}^n$ . Найти наименьшую функцию  $\mathcal{E}$ , такую что с вероятностью не меньшей  $1 - \delta$  относительно обучающей выборки длины  $n$

$$R(\hat{f}) \leq R(f_{\mathcal{F}}^*) + \mathcal{E},$$

где функция  $\mathcal{E}$  может зависеть от свойств  $\mathcal{F}$  и  $\ell$ , чисел  $n$  и  $\delta$ , свойств  $Y$  и так далее.

Обозначим  $R_n(f) = \frac{1}{n} \sum_{i=1}^n \ell(f(X_i) - Y_i)$  — *эмпирический риск*.

## Определение

*Алгоритм обучения называется минимизатором эмпирического риска, если по обучающей выборке он выбирает*

$$\hat{f} = \arg \min_{f \in \mathcal{F}} R_n(f).$$

## Определение

- *Класс потерь:*

$$\ell \circ \mathcal{F} = \{(X, Y) \rightarrow \ell(f(X) - Y) : f \in \mathcal{F}\}.$$

- *Класс избыточных потерь:*

$$(\ell \circ \mathcal{F})^* = \{(X, Y) \rightarrow \ell(f(X) - Y) - \ell(f_{\mathcal{F}}^*(X) - Y) : f \in \mathcal{F}\}.$$

Пусть  $\hat{f}$  минимизирует эмпирический риск, тогда

$$R(\hat{f}) - R(f_{\mathcal{F}}^*) =$$

$$R(\hat{f}) - R_n(\hat{f}) + R_n(f_{\mathcal{F}}^*) - R(f_{\mathcal{F}}^*) + R_n(\hat{f}) - R_n(f_{\mathcal{F}}^*) \leq$$

$$R(\hat{f}) - R_n(\hat{f}) + R_n(f_{\mathcal{F}}^*) - R(f_{\mathcal{F}}^*) \leq$$

$$2 \sup_{f \in \mathcal{F}} |R(f) - R_n(f)| =$$

$$2 \sup_{g \in \ell \circ \mathcal{F}} |\mathbb{P} g - \mathbb{P}_n g|,$$

где  $\mathbb{P}$  и  $\mathbb{P}_n$  означают математические ожидания соответственно по истинной и эмпирической мерам.

## Замечание

- Равномерная сходимость частот к вероятностям в классе потерь гарантирует обучаемость с помощью метода минимизации эмпирического риска
- Скорость сходимости избыточного риска контролируется процессом  $\sup_{g \in \ell \circ \mathcal{F}} |P g - P_n g|$ .

Обратимся опять к ситуации, когда  $Y = T(X)$ , однако не будем предполагать, что  $T \in \mathcal{F}$ . В этом случае требуем с вероятностью  $1 - \delta$ :

$$R(\hat{f}) - R(f_{\mathcal{F}}^*) = \mathbb{E} \ell(\hat{f}(X) - T(X)) - \mathbb{E} \ell(f_{\mathcal{F}}^*(X) - T(X)) \leq \mathcal{E}(T, \delta),$$

## Теорема (Alon, Ben-David, Cesa-Bianchi, Haussler'97 Mendelson'08)

Пусть  $\hat{f}$  минимизирует эмпирический риск.

- 1 Если для класса  $\ell \circ \mathcal{F}$  не выполнен равномерный закон больших чисел, то

$$\lim_{n \rightarrow \infty} \sup_{\mu} \sup_{T: \|T\|_{\infty} \leq 1} \mathcal{E}(T, \delta) \neq 0,$$

более того, предел не равен нулю даже если  $T \in \mathcal{F}$  для всех  $T$  с  $\|T\|_{\infty} \leq 1$ .

- 2 Если для  $\ell \circ \mathcal{F}$  выполнен равномерный закон больших чисел, но не выполнена равномерная центральная предельная теорема, то  $\sup_{\mu} \sup_{T: \|T\|_{\infty} \leq 1} \mathcal{E}(T, \delta)$  сходится к нулю не быстрее чем  $\frac{1}{\sqrt{n}}$

## Замечание

- В двух приведенных ситуациях классы (классы потерь) слишком большие. Геометрические свойства  $\mathcal{F}$  и  $\ell \circ \mathcal{F}$  практически не влияют на  $\mathcal{E}(T, \delta)$ . Все контролируется лишь поведением  $\sup_{g \in \ell \circ \mathcal{F}} |\mathbb{P} g - \mathbb{P}_n g|$ .
- Выполнение равномерной центральной предельной теоремы не гарантирует порядков быстрее  $\frac{1}{\sqrt{n}}$ . В частности, существует пример, когда  $\mathcal{F}$  состоит всего из двух функций, но геометрия  $(\ell \circ \mathcal{F})^*$  не позволяет улучшить  $\frac{1}{\sqrt{n}}$ .

## Определение (Folklore)

- *Быстрые порядки (fast rates) — сходимость  $\mathcal{E}$  к нулю быстрее чем  $\frac{1}{\sqrt{n}}$ .*
- *Медленные порядки (slow rates) — сходимость  $\mathcal{E}$  со скоростью  $\frac{1}{\sqrt{n}}$ .*

## Замечание

- В двух приведенных ситуациях классы (классы потерь) слишком большие. Геометрические свойства  $\mathcal{F}$  и  $\ell \circ \mathcal{F}$  практически не влияют на  $\mathcal{E}(T, \delta)$ . Все контролируется лишь поведением  $\sup_{g \in \ell \circ \mathcal{F}} |\mathbb{P} g - \mathbb{P}_n g|$ .
- Выполнение равномерной центральной предельной теоремы не гарантирует порядков быстрее  $\frac{1}{\sqrt{n}}$ .

Откуда могут браться порядки сходимости избыточного риска быстрее  $\frac{1}{\sqrt{n}}$ ?

### Теорема (Неравенство Бернштейна)

Пусть  $X_i$  — независимые случайные величины, такие что  $|X_i| \leq M$  и  $\mathbb{E}X_i^2 = \sigma^2$ . Тогда всех  $\varepsilon > 0$

$$\mathbb{P} \left( \frac{1}{n} \sum_{i=1}^n X_i \geq \varepsilon \right) \leq \exp \left( - \frac{n\varepsilon^2}{2\sigma^2 + \frac{2}{3}M\varepsilon} \right)$$

### Замечание

В областях с малой дисперсией хвост ведет себя как  $\exp(-n\varepsilon)$ .

## Определение (Tsybakov' 04)

Пусть  $f^* \in \mathcal{F}$ . Для пары  $(\ell, P)$ , где  $P$  — совместное распределение  $\Omega, Y$ , выполнено условие малого шума (*Low noise condition, Margin assumption*) с параметрами  $(\beta, B)$ , если для всех  $f \in \mathcal{F}$

$$\mathbb{E}(\ell(f(X) - Y) - \ell(f^*(X) - Y))^2 \leq B(R(f) - R(f^*))^\beta.$$

Условие легко понять, если взглянуть на класс избыточных потерь  $(\ell \circ \mathcal{F})^*$ .

Условие малого шума эквивалентно тому, что для  $g \in (\ell \circ \mathcal{F})^*$ :

$$P g^2 \leq B(P g)^\beta.$$

Пусть  $|\mathcal{F}| = N, f^* \in \mathcal{F}, \ell$  ограничена единицей и выполнено условие малого шума. Тогда, объединив неравенство Буля и неравенство Бернштейна, получаем, что с вероятностью не меньшей  $1 - \delta$  для любой  $g \in (\ell \circ \mathcal{F})^*$ :

$$\mathbf{P} g \leq \mathbf{P}_n g + \sqrt{\frac{8B(\mathbf{P} g)^\beta \log(\frac{N}{\delta})}{n}} + \frac{4 \log(\frac{N}{\delta})}{3n}.$$

Для минимизатора эмпирического риска  $\mathbf{P}_n g \leq 0$ . Решение относительно  $\mathbf{P} g$  дает порядок для избыточного риска:

$$R(\hat{f}) - R(f^*) \leq C \left( \frac{\log(\frac{N}{\delta})}{n} \right)^{\frac{1}{2-\beta}}$$

При  $\beta$ , пробегающих отрезок  $[0, 1]$  порядки будут непрерывно меняться от  $\frac{1}{\sqrt{n}}$  до  $\frac{1}{n}$ .

## Определение (Massart' 06)

Условия малого шума Цыбакова при  $\beta = 1$  называется условием малого шума Massара (*Massart's low noise condition*).

Пусть  $Y$  принимает значения 0 или 1, функция потерь — индикатор ошибки. Тогда  $f^* = \mathbb{1}\{\eta(x) > \frac{1}{2}\}$ , где  $\eta(x) = \mathbb{E}[Y|X = x]$ .

## Утверждение

Условие малого шума Massара эквивалентно тому, что  $|2\eta(x) - 1| > h$  для некоторой константы  $h$ .

## Замечание

Формулировка в терминах свойств  $\mathbb{E}[Y|X]$  есть и для условий Цыбакова.

Пусть в задаче бинарной классификации класс  $\mathcal{F}$  имеет размерность Вапника–Червоненкиса, равную  $V$ . Обозначим  $\mathcal{P}(h, \mathcal{F})$  все распределения на  $\Omega$  и  $Y$  такие, что выполнено условие малого шума и  $f^* \in \mathcal{F}$ .

### Теорема (Massart, Nedelec' 06)

Пусть  $\hat{f}$  — минимизатор эмпирического риска. Тогда

$$\sup_{P \in \mathcal{P}(h, \mathcal{F})} \mathbb{E}(R(\hat{f}) - R(f^*)) \leq C \sqrt{\frac{V}{n}}, \text{ если } h \leq \sqrt{\frac{V}{n}}$$

и

$$\sup_{P \in \mathcal{P}(h, \mathcal{F})} \mathbb{E}(R(\hat{f}) - R(f^*)) \leq C \frac{V}{nh} \left( 1 + \log \left( \frac{nh^2}{V} \right) \right), \text{ иначе.}$$

## Теорема (Massart, Nedelec' 06)

Верна и нижняя оценка:

$$\inf_{\tilde{f}} \sup_{P \in \mathcal{P}(h, \mathcal{F})} \mathbb{E}(R(\tilde{f}) - R(f^*)) \geq \min \left( \sqrt{\frac{V}{n}}, \frac{V}{nh} \right).$$

### Замечание

- Единственное требование к классу  $f^* \in F$ .
- Условия малого шума по сути являются свойством распределений и никак не зависят от структуры классов  $\mathcal{F}, \ell \circ \mathcal{F}$  и  $(\ell \circ \mathcal{F})^*$ .
- Условия вида конечная мощность  $\mathcal{F}$ , конечная энтропия или VC размерность необходимы лишь для гарантирования порядков  $\frac{1}{\sqrt{n}}$ .

## Цель

Выяснить насколько быстро стремится к нулю избыточный риск в случае, когда  $f^* \notin \mathcal{F}$  ?

Для минимизатора эмпирического риска  $\hat{f}$ :

$$R(\hat{f}) - R(f^*) \leq 2 \sup_{g \in \ell \circ \mathcal{F}} |\mathbb{P} g - \mathbb{P}_n g|,$$

Анализ процесса  $\sup_{g \in \ell \circ \mathcal{F}} |\mathbb{P} g - \mathbb{P}_n g|$  производится с помощью симметризации.

## Определение (Gine, Zinn' 84, Kolchinskii' 01)

Пусть  $(\sigma_i)_{i=1}^n$  независимые случайные величины, принимающие равновероятно значения  $+1$  и  $-1$ . Радемахеровская сложность класса потерь  $(\ell \circ \mathcal{F})$ :

$$\mathcal{R}(\ell \circ \mathcal{F}) = \frac{1}{n} \mathbb{E} \sup_{g \in \ell \circ \mathcal{F}} \left| \sum_{i=1}^n \sigma_i g(X_i, Y_i) \right|.$$

### Лемма

$$\mathbb{E} \sup_{g \in \ell \circ \mathcal{F}} |\mathbb{P} g - \mathbb{P}_n g| \leq 2\mathcal{R}(\ell \circ \mathcal{F}),$$

а если функции  $g \in \ell \circ \mathcal{F}$  ограничены константой  $C$ , то

$$\mathbb{E} \sup_{g \in \ell \circ \mathcal{F}} |\mathbb{P} g - \mathbb{P}_n g| \geq \frac{1}{2} \mathcal{R}(\ell \circ \mathcal{F}) - \frac{C}{2\sqrt{n}}.$$

## Теорема (Ledoux, Talagrand' 91)

*Принцип сжатия (contraction).* Если  $\varphi : \mathbb{R} \rightarrow \mathbb{R}$ , такая что  $\varphi(0) = 0$  и Липшицева с константой  $L$ , то

$$\mathcal{R}(\varphi \circ \mathcal{F}) \leq L\mathcal{R}(\mathcal{F}).$$

Для ограниченных классов  $\mathcal{F}$  и ограниченной целевой функции  $Y$  и  $\ell(t) = t^2$  можно контролировать сложность класса потерь сложностью базового класса  $\mathcal{F}$ .

С помощью анализа Радемахеровских средних можно легко получить основные результаты теории Вапника–Червоненкиса.

## Недостатки Радемахеровского анализа:

- Используется только  $L_2$ -геометрия классов  $\mathcal{F}$  или  $\ell \circ \mathcal{F}$  (например, метрическая энтропия Дадли), которые характеризуют в лучшем случае лишь выполнение равномерной ЦПТ.
- Радемахеровский анализ не позволяет получить порядков быстрее чем  $\frac{1}{\sqrt{n}}$ .
- Радемахеровские средние не чувствительны к выпуклости классов  $\mathcal{F}$  и  $\ell \circ \mathcal{F}$ .
- Анализ существенно опирается на концентрацию меры, которая хорошо работает лишь в задачах с ограниченными классами потерь или при сильных ограничениях, например, на  $Y - f_F^*(X)$ .

Возможность достижения порядков быстрее чем  $\frac{1}{\sqrt{n}}$  зависит от связи математических ожиданий и дисперсий в классе избыточных потерь.

### Определение (Bartlett, Mendelson' 06)

Говорят, что для класса  $\mathcal{F}$  или  $(\ell \circ \mathcal{F})^*$  выполнено условие Бернштейна с параметрами  $(\beta, B)$ , если для всех  $f \in \mathcal{F}$

$$\mathbb{E}(\ell(f(X) - Y) - \ell(f_{\mathcal{F}}^*(X) - Y))^2 \leq B(R(f) - R(f_{\mathcal{F}}^*))^{\beta}.$$

### Замечание

По сравнению с условием малого шума мы не требуем, что  $f^* \in \mathcal{F}$  и заменяем  $f^*$  на  $f_{\mathcal{F}}^*$ .

- Условие Бернштейна чисто геометрическое условие в отличие от условия малого шума.
- Условие очень чувствительно к структуре  $\mathcal{F}$ , так как удаление или добавление лишь одной функции может изменить  $f_{\mathcal{F}}^*$ .
- Легко проверить, что условие Бернштейна влечет единственность  $f_{\mathcal{F}}^*$ .
- В общем случае не является необходимым для получения порядков избыточного риска быстрее чем  $\frac{1}{\sqrt{n}}$ .

Рассмотрим задачу ограниченной регрессии:

$|Y| \leq 1$ ,  $\sup_{f \in \mathcal{F}} |f(X)| \leq 1$  и  $\ell(t) = t^2$  с замкнутым и выпуклым  $\mathcal{F}$ .

$$\begin{aligned} R(f) - R(f_{\mathcal{F}}^*) &= \mathbb{E} ((Y - f(X))^2 - (Y - f_{\mathcal{F}}^*(X))^2) = \\ &\quad - 2A + \mathbb{E} (f(X) - f_{\mathcal{F}}^*(X))^2 \geq \\ &\quad \mathbb{E} (f(X) - f_{\mathcal{F}}^*(X))^2, \end{aligned}$$

где  $A = \mathbb{E}(Y - f_{\mathcal{F}}^*(X))(f(X) - f_{\mathcal{F}}^*(X)) \leq 0$  так как  $\mathcal{F}$  — выпуклое множество.

$$\mathbb{E} ((f(X) - Y)^2 - (f_{\mathcal{F}}^*(X) - Y)^2)^2 \leq 16 \mathbb{E} (f(X) - f_{\mathcal{F}}^*(X))^2.$$

### Утверждение (Lee, Bartlett, Williamson' 97)

*В описанном примере выполнено условие Бернштейна с параметрами (1, 16).*

В предыдущем примере условие Бернштейна выполнено одновременно для любой целевой функции  $Y$ , ограниченной равномерно единицей.

Рассмотрим задачу с

$$Y = 0, \mathcal{F} = \{f_1, f_2\}, \ell(t) = t^2,$$

$$f_1 = \mathbb{1}[0, 1], \quad f_2 = \mathbb{1}[-1, 0],$$

$$P[X = 1] = \frac{1}{2} - \frac{1}{\sqrt{n}}, \quad P[X = -1] = \frac{1}{2} + \frac{1}{\sqrt{n}}.$$

Легко убедиться, что константа  $B = \sqrt{n}/2$  и условие Бернштейна не выполнено. Одновременно можно показать, что избыточный риск минимизатора эмпирического риска сходится к нулю со скоростью  $\frac{1}{\sqrt{n}}$ .

Причина медленных порядков сходимости предыдущего примера:

- Плохая геометрия класса  $\mathcal{F}$ . Для  $\text{conv}(\mathcal{F})$  условие Бернштейна выполнено.
- Плохая целевая функция  $Y$ : находится слишком близко к области, где существует две проекции на класс  $\mathcal{F}$ .
- Помещая  $Y$  в  $\mathcal{F}$ , условие Бернштейна автоматически переходит в условие малого шума Цыбакова, которое в данном случае выполнено без требования выпуклости  $\mathcal{F}$ .

### Замечание

*Порядки сходимости избыточного риска к нулю существенно зависят от того, насколько расположение  $Y$  благоприятствует  $\mathcal{F}$ .*

## Замечание

Понятие быстрых порядков как сходимостей, например,  $\frac{1}{n}$  и медленных порядков как сходимостей  $\frac{1}{\sqrt{n}}$  упирается в тот факт, что уже необходимы сильные условия на класс, а именно возможность достигнуть хотя бы  $\frac{1}{\sqrt{n}}$ .

Рассматриваем задачи с  $\ell(t) = t^2$ .

## Определение (Mendelson' 15)

Оптимистичные порядки(*optimistic rate*) — наилучшие порядки избыточного риска, достижимые в ситуации когда  $Y$  благоприятствует  $\mathcal{F}$  следующим образом:

$$\mathbb{E}(f_{\mathcal{F}}^*(X) - Y)(f(X) - f_{\mathcal{F}}^*(X)) \geq 0.$$

## Замечание

Условие  $\mathbb{E}(f_{\mathcal{F}}^*(X) - Y)(f(X) - f_{\mathcal{F}}^*(X)) \geq 0$  выполнено в двух важных ситуациях:

- $Y \in L_2$ ,  $\mathcal{F} \subset L_2$  и является замкнутым и выпуклым.
- $Y = f^*(X) + \varepsilon$ , где  $\varepsilon$  — независимый центрированный шум и  $f^* \in \mathcal{F}$ .

В предыдущем примере оптимистичные порядки равны  $\frac{1}{n}$ .

## Теорема (Juditsky, Rigollet, Tsybakov' 08)

Пусть  $|\mathcal{F}| = M$ . Ни одна обучающая процедура, принимающая значения в классе  $\mathcal{F}$ , не может дать порядки для избыточного риска лучше чем  $\sqrt{\frac{\log(M)}{n}}$ .

## Цель

*Есть ли способы обойти неблагоприятные  $Y$  и получать оптимистичные порядки при минимальных ограничениях  $Y$  и геометрию класса  $\mathcal{F}$ ?*

Решения:

- Рассматривать агрегационные процедуры, принимающие значения вне базового класса  $\mathcal{F}$ .
- Рассмотрение неточных оракульных нервенств (non-sharp), то есть вместо величины  $R(f) - R(f_{\mathcal{F}}^*)$  рассматривать  $R(f) - CR(f_{\mathcal{F}}^*)$  для  $C > 1$ .

## Определение

Пусть  $\mathcal{F}$  содержится в  $\mathcal{F}^*$ , нужно построить обучающий алгоритм  $\psi_n : (\Omega \times \mathbb{R})^n \rightarrow \mathcal{F}^*$  такой, что с большой вероятностью

$$R(\hat{f}) - R(f_{\mathcal{F}}^*) \leq \mathcal{E}_{MSA},$$

где функция  $\mathcal{E}_{MSA}$  как можно быстрее сходится к нулю с ростом  $n$  и  $\hat{f} = \psi_n((X_i, Y_i)_{i=1}^n)$ .

## Замечание

- Данная задача называется *MS-агрегацией (Model Selection Aggregation)*.
- Обычно рассматриваются конечные словари  $\mathcal{F}$ .

Ранее обсуждалось, что если  $|\mathcal{F}| = M$  и  $\mathcal{F} = \mathcal{F}^*$ , то нельзя получить порядки быстрее  $\sqrt{\frac{\log(M)}{n}}$

## Теорема (Tsybakov' 04)

Для любой агрегационной процедуры  $\mathcal{E}_{MSA}$  стремится к нулю не быстрее  $\frac{\log(M)}{n}$ .

### Замечание

- Теорема формулируется при некоторых технических ограничениях.
- Данная нижняя оценка соответствует нашим представлениям об оптимистичных порядках. Осталось привести примеры процедур, которые могли бы давать порядки  $\frac{1}{n}$  вне зависимости от  $Y$ .

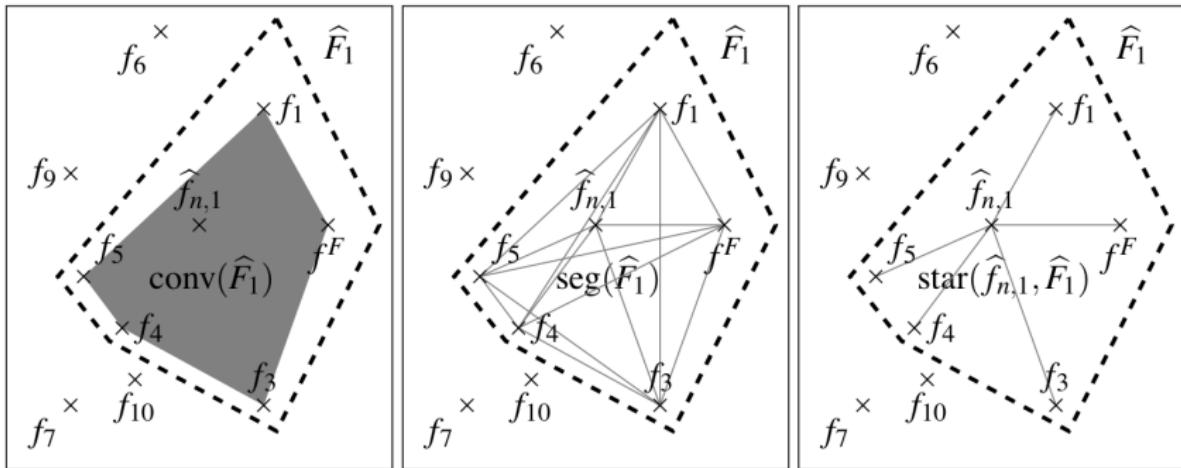
Замкнутые выпуклые классы  $\mathcal{F}$  в задачах ограниченной регрессии являются классами, для которых условие Бернштейна выполнено для всех ограниченных  $Y$ .

### Замечание (Lecue, Mendelson' 08)

Оказывается, что использование минимизатора эмпирического риска на  $\text{conv}(\mathcal{F})$  не позволяет перейти к оптимальным порядкам. Улучшая геометрию, мы чрезмерно увеличиваем сложность.

### Идея

Нужно брать выпуклую оболочку не от всего словаря, а от некоторого его подмножества, балансируя выигрыш в геометрии с увеличивающейся сложностью.



## Теорема (Lecue, Mendelson' 08, Lecue' 11, Audibert' 09)

В задачах ограниченной регрессии для любого словаря  $\mathcal{F}$ , состоящего из  $M$  функций, и любых  $Y$  с вероятностью  $1 - \delta$

$$R(\hat{f}) \leq R(f_{\mathcal{F}}^*) + c \left( 1 + \log \left( \frac{2}{\delta} \right) \right) \frac{\log(M)}{n}.$$

Классический способ получения оценок избыточного риска основан на анализе Радемахеровских средних, но этот подход не позволяет учесть геометрические свойства класса.

Техники, основанные на локализации, позволяют получать быстрые порядки.

## Определение

- $Z, Z_1, \dots, Z_n$  — независимые случайные величины определенные на  $(\mathcal{Z}, \mathcal{P}_{\mathcal{Z}})$ .
- $G$  — класс функций,  $V(G)$  — звездное замыкание:

$$V(G) = \{\alpha g : 0 \leq \alpha \leq 1, g \in G\}$$

- Локализованное звездное замыкание:

$$V(G)_{\lambda} = \{h \in V(G) : Ph \leq \lambda\}$$

## Определение

- $\|P - P_n\|_H = \sup_{h \in H} |(P - P_n)h|.$
- $\sigma(H) = \sup_{h \in H} \sqrt{P h^2}.$
- $\|H\|_\infty = \sup_{h \in H} \|h\|_{L_\infty}.$

## Теорема (Bartlett, Mendelson' 06)

Пусть  $G$  — класс действительных функций на  $\mathcal{Z}$ ,  
удовлетворяющих условию  $P g^2 \leq B P g$  для некоторой  $B > 0$ .  
Пусть  $\lambda^* > 0$  такое, что

$$\mathbb{E} \|P - P_n\|_{V(G)_{\lambda^*}} \leq \frac{1}{8} \lambda^*.$$

## Теорема (Bartlett, Mendelson' 06, Lecue' 13)

Тогда с вероятностью не меньшей  $1 - \delta$ :

$$|\mathbb{P} g - \mathbb{P}_n g| \leq \frac{1}{2} \max(\mathbb{P} g, \rho_n(\delta)),$$

где

$$\rho_n(\delta) = \max \left( \lambda^*, \frac{c_0(B + \|G\|_\infty) \log(\frac{4}{\delta})}{n} \right)$$

Пусть свойство  $|\mathbb{P} g - \mathbb{P}_n g| \leq \frac{1}{2} \max(\mathbb{P} g, \rho_n(\delta))$  выполнено для всех  $g \in (\ell \circ \mathcal{F})^*$  с вероятностью  $1 - \delta$ . Тогда если  $\hat{f}$  — минимизирует эмпирический риск, а  $\hat{g}$  — его избыточные потери, то

$$R(\hat{f}) - R(f_{\mathcal{F}}^*) = \mathbb{P} \hat{g} \leq 2 \mathbb{P}_n \hat{g} + \rho_n(\delta) \leq \rho_n(\delta).$$

Остается научиться считать  $\lambda^*$ . Это возможно благодаря пилингу (peeling):

$$V(G)_\lambda \subset \bigcup_{i=0}^{\infty} \{ \theta h : 0 \leq \theta \leq 2^{-i}, h \in G_{2^{i+1}\lambda} \},$$

поэтому

$$\mathbb{E} \| P - P_n \|_{V(G)_{\lambda^*}} \leq \sum_{i=0}^{\infty} 2^{-i} \mathbb{E} \| P - P_n \|_{G_{2^{i+1}\lambda}}.$$

Задача сводится к оценке

$$\mathbb{E} \| P - P_n \|_{G_{2^{i+1}\lambda}}.$$

Способ получения быстрых порядков — рассмотрение неточных оракульных неравенств:  $R(f) - CR(f_{\mathcal{F}}^*)$  для  $C > 1$ .

Оказывается, что источником быстрых порядков в данной задаче также является условие Бернштейна:

$$\mathsf{P} g^2 \leq B \mathsf{P} g,$$

но не для класса избыточных потерь  $(\ell \circ \mathcal{F})^*$ , а для класса потерь  $(\ell \circ \mathcal{F})$ .

### Замечание

Данное условие уже не зависит от геометрии класса, а существенно опирается лишь на функцию потерь. Тривиальным образом выполнено, например, для бинарной функции потерь.

## Цель

Адаптироваться к неблагоприятной целевой функции  $Y$  при условии, что класс  $\mathcal{F}$  бесконечный.

## Теорема (Rakhlin, Sridharan, Tsybakov' 13)

- Разбиваем обучающую выборку длины  $3n$  на 3 части.
- С помощью первой части выборки строим  $\varepsilon$ -сеть класса  $\mathcal{F}$  по метрике  $d(f, g) = \sqrt{\frac{1}{n} \sum_{i=1}^n (f(X_i) - g(X_i))^2}$ .
- С помощью второй части выборки строим минимизаторы эмпирического риска, на подмножествах  $\mathcal{F}$  соответствующих диаграмме Вороного, порожденной  $\varepsilon$ -сетью.

## Теорема (Rakhlin, Sridharan, Tsybakov' 13)

- С помощью третьей части выборки агрегируем построенные минимизаторы эмпирического риска любым из приведенных ранее методов для конечных словарей.

Тогда в задаче ограниченной регрессии, ожидаемый избыточный риск построенной процедуры для специально подобранныго  $\epsilon$  обладает следующими свойствами:

Regime	Aggregation-of-leaders
Finite: $ \mathcal{F}  = M$	$\frac{\log M}{n}$
Parametric: $VC(\mathcal{F}) = v \leq n$	$\frac{v \log(en/v)}{n}$
Nonparametric: $\mathcal{H}_2(\mathcal{F}, \epsilon) = \epsilon^{-p}$ , $p \in (0, 2)$	$n^{-\frac{2}{2+p}}$
$p \in [2, \infty)$	$n^{-\frac{1}{p}}$

Спасибо за внимание!

Список литературы по адресу:  
[nikita.zhivotovskiy@phystech.edu](mailto:nikita.zhivotovskiy@phystech.edu)