

# Точные оценки вероятности переобучения

## Задачи по спецкурсу

### «Теория надёжности обучения по прецедентам»

К. В. Воронцов ([www.ccas.ru/voron](http://www.ccas.ru/voron))

18 марта 2009 г.

**Точные оценки вероятности переобучения** — это новое направление исследований в теории статистического обучения, в котором доказанных теорем (пока) гораздо меньше, чем открытых проблем, а многие нерешённые задачи настолько просты, что вполне по силам студентам 3 курса. Чтобы понимать, о чём эти задачи, необходимо (и достаточно) проработать статьи [1, 2] или ходить на спецкурс<sup>1</sup>.

**О структуре данного документа.** Все задачи разделены на секции по направлениям исследований, каждая секция разделена на параграфы. Обозначения и предположения, вводимые в начале каждого параграфа, распространяются на все задачи внутри данного параграфа. Перед каждым блоком задач даётся минимум необходимых пояснений, включая мотивации, которые привели к данной постановке.

**О формальностях.** Для сдачи спецкурса необходимо набрать определённое количество баллов, которое будет объявлено на лекциях. Стоимость каждой задачи в баллах указана в скобках после номера задачи.

**Страница курса:** вики-ресурс [www.MachineLearning.ru/wiki](http://www.MachineLearning.ru/wiki), страница «Теория надёжности обучения по прецедентам (курс лекций, К.В.Воронцов)». Адрес этого документа: [www.MachineLearning.ru/wiki/images/6/6b/Voron09problems.pdf](http://www.MachineLearning.ru/wiki/images/6/6b/Voron09problems.pdf).

---

<sup>1</sup>Весной 2009: ВМиК МГУ, ауд. 606, по понедельникам 16:20.

## Содержание

<b>1</b>	<b>Классические оценки в слабой вероятностной аксиоматике</b>	<b>3</b>
§1.1	Закон больших чисел . . . . .	3
§1.2	Некоторые статистические критерии . . . . .	3
§1.3	Оценки вероятности переобучения . . . . .	3
<b>2</b>	<b>Исследования свойства связности</b>	<b>4</b>
§2.1	Цепочки, порождаемые линейными классификаторами . . . . .	4
§2.2	Графы связности, порождаемые линейными классификаторами . . . . .	5
§2.3	Общий случай: связные семейства . . . . .	5
<b>3</b>	<b>Экспериментальные исследования (практикум)</b>	<b>5</b>
§3.1	Эмпирическое исследование вероятности переобучения . . . . .	6
§3.2	Визуализация графов связности . . . . .	7
<b>4</b>	<b>Нижние и асимптотические оценки</b>	<b>7</b>
§4.1	Точные нижние оценки . . . . .	7
§4.2	Асимптотические оценки . . . . .	8
<b>5</b>	<b>Обобщения цепочек и окрестностей</b>	<b>8</b>
§5.1	Обобщения монотонных цепочек . . . . .	8
§5.2	Обобщения единичной окрестности . . . . .	9
§5.3	Реальные семейства алгоритмов . . . . .	9
<b>6</b>	<b>Семейства, задаваемые перечислением векторов ошибок</b>	<b>10</b>
§6.1	Оценки по ненаблюдаемым данным . . . . .	10
§6.2	Оценки по наблюдаемым данным . . . . .	11

## 1 Классические оценки в слабой вероятностной аксиоматике

Задачи этой секции направлены на то, чтобы потренироваться в доказательстве оценок вероятности больших отклонений или вероятности переобучения, пользуясь только слабой вероятностной аксиоматикой.

**Напоминание.** *Слабая вероятностная аксиоматика* содержит единственную аксиому: дана конечная выборка  $\mathbb{X} = \{x_1, \dots, x_L\}$ , и все её разбиения  $X \cup \bar{X} = \mathbb{X}$  на наблюдаемую (обучающую) выборку  $X$  длины  $\ell$  и скрытую (контрольную) выборку  $\bar{X}$  длины  $k$  равновероятны.

### §1.1 Закон больших чисел

Для любого алгоритма  $a$ , допускающего  $m = n(a, \mathbb{X})$  ошибок на полной выборке, справедлива точная оценка вероятности большого отклонения частоты ошибок [3]:

$$\mathbb{P}[\delta(a, X) \geq \varepsilon] = \sum_{s=s_0}^{s_1(\varepsilon)} h_L^{\ell, m}(s) \equiv H_L^{\ell, m}(s_1(\varepsilon)). \quad (1.1)$$

Это выражение можно рассматривать как оценку скорости сходимости в законе больших чисел для слабой аксиоматики, если положить  $\ell, k \rightarrow \infty$ .

**Задача 1.1. (5)** *Провести обзор известных верхних оценок «левого хвоста» гипергеометрического распределения. Какие из оценок наиболее точны? Сравнить с оценкой из книг [4, стр. 236] или [5, стр. 225]. Какие из оценок являются аналогами неравенств Чернова, Бернштейна, Хёффдинга [6]? Показать, что из этих оценок следует стремление левой части (1.1) к нулю при  $\ell, k \rightarrow \infty$ .*

### §1.2 Некоторые статистические критерии

Многие статистические критерии, предназначенные для проверки гипотез однородности, независимости, случайности, стационарности (критерии Смирнова, Вилкоксона, ранговые и перестановочные критерии и т. д.), выводятся именно комбинаторными методами. Их (пере)формулировка и (пере)доказательство в слабой аксиоматике практически очевидны. Задачи данного параграфа не предполагают перехода к асимптотическим оценкам, как это обычно принято в математической статистике.

**Задача 1.2. (1)** *Критерий Вилкоксона-Манна-Уитни.*

**Задача 1.3. (1)** *Критерий серий Вальда-Вольфовица.*

**Задача 1.4. (1)** *Критерий знаков.*

### §1.3 Оценки вероятности переобучения

Следующие две задачи заключаются в том, чтобы аккуратно воспроизвести в слабой аксиоматике результаты Бакса и Силла, которые оценивали другой функционал (функционал равномерной сходимости). Позволяет ли слабая аксиоматика упростить доказательства? Улучшить оценку?

**Задача 1.5. (3)** Следуя [7], показать, что если множество векторов ошибок  $\{(a)_\mathbb{X} : a \in \mathbb{A}\}$  кластеризуется по расстоянию Хэмминга на  $S(r)$  кластеров радиуса  $r$  каждый, то

$$\mathbb{P}[\delta_\mu(X) \geq \varepsilon + \frac{r}{\ell}] \leq S(r) \cdot \max_{m=1, \dots, L} H_L^{\ell, m}(s_1(\varepsilon)).$$

**Задача 1.6. (3)** Следуя [8, 9] показать, что если семейство  $A$  связно, то

$$\mathbb{P}[\delta_\mu(X) \geq \varepsilon] \leq \frac{1}{\sqrt{\pi L}} |A| \max_{m=1, \dots, L} H_L^{\ell, m}(s_1(\varepsilon)).$$

## 2 Исследования свойства связности

Достаточно просто должны доказываться утверждения о том, что при непрерывном изменении вектора параметров вдоль непрерывной траектории почти всегда образуется цепочка векторов ошибок. Что значит «почти», надо уточнять.

### §2.1 Цепочки, порождаемые линейными классификаторами

Пусть  $\mathbb{X}$  — множество, состоящее из  $L$  точек в  $\mathbb{R}^n$ ;  $\mathbb{Y} = \{-1, +1\}$  — множество меток классов;  $\mathbb{A}$  — семейство  $n$ -мерных линейных классификаторов:

$$\mathbb{A} = \{a : \mathbb{X} \rightarrow \mathbb{Y} \mid a(x) = \text{sign}(x_1 w_1 + \dots + x_n w_n), w \in \mathbb{R}^n\}, \quad (2.1)$$

где  $w \in \mathbb{R}^n$  — вектор параметров. Предполагая, что существует функция истинной классификации  $y : \mathbb{X} \rightarrow \mathbb{Y}$ , введём бинарную функцию потерь  $I(a, x) = [a(x) \neq y(x)]$ .

**Задача 2.1. (1)** Доказать, что множество векторов ошибок  $\{a(x, w + t\delta) : t \in \mathbb{R}\}$  при некоторых дополнительных ограничениях образует цепочку. Сформулировать эти ограничения. Какова максимальная возможная длина цепочки?

Говорят, что множество объектов  $\mathbb{X}$  линейно разделимо, если существует направляющий вектор разделяющей гиперплоскости  $w^* \in \mathbb{R}^n$ , при котором алгоритм  $a(x, w^*)$  не допускает ошибок на  $\mathbb{X}$ .

**Задача 2.2. (1)** В каких случаях множество векторов ошибок  $\{a(x, w^* + t\delta) : t \geq 0\}$ , где  $\delta \in \mathbb{R}^n$  — фиксированный вектор, образует монотонную цепочку с  $m = 0$ ?

**Задача 2.3. (1)** В каких случаях множество векторов ошибок  $\{a(x, w^* + t\delta) : t \in \mathbb{R}\}$  где  $\delta \in \mathbb{R}^n$  — фиксированный вектор, образует унимодальную цепочку с  $m = 0$ ?

Пусть  $\mathbb{A}$  — произвольное семейство классификаторов, не обязательно линейное:

$$\mathbb{A} = \{a : \mathbb{X} \rightarrow \mathbb{Y} \mid a(x) = \text{sign}(f(x, w)), w \in \mathbb{R}^n\}. \quad (2.2)$$

Следующая задача показывает, что, рассматривая множества векторов ошибок, порождаемых семействами классификаторов, не обязательно вводить множество меток классов и функцию истинной классификации.

**Задача 2.4. (1)** Доказать, что если взять множество алгоритмов  $\mathbb{W} = \mathbb{R}^n$  и индикатор ошибок  $I(w, x) = [\varphi(w, x) \geq 0]$ , то можно так подобрать непрерывную функцию  $\varphi(w, x)$ , что множество векторов ошибок  $\{(w)_\mathbb{X} : w \in \mathbb{W}\}$  совпадёт с множеством векторов ошибок  $\{(a)_\mathbb{X} : a \in \mathbb{A}\}$ . Какие дополнительные предположения необходимо для этого принять? Насколько они обременительны?

## §2.2 Графы связности, порождаемые линейными классификаторами

Рассматривается множество всех векторов ошибок, порождаемых линейными классификаторами (2.1) на заданной выборке  $\mathbb{X}$  в пространстве размерности  $n = 2$ .

В графе связности вершинами являются все векторы ошибок  $\{(a)_{\mathbb{X}} : a \in \mathbb{A}\}$ ; рёбрами соединяются векторы, имеющие хэммингово расстояние 1.

**Задача 2.5. (1)** Привести пример выборки  $\mathbb{X}$ , для которой граф связности представляет собой двумерную решетку (у каждой вершины не более четырёх рёбер). Привести примеры выборок, для которых в графе связности имеются вершины с числом рёбер более четырёх.

**Задача 2.6. (1)** Доказать, что для любого  $L$  существует выборка длины  $L$ , для которой в графе связности имеется вершина с числом рёбер  $L - 1$ .

**Задача 2.7. (10)** Верна ли гипотеза, что линейный классификатор в пространстве размерности  $n$  порождает граф связности, у которого среднее число инцидентности вершин стремится к  $2n$  при  $L \rightarrow \infty$ ?

## §2.3 Общий случай: связные семейства

В работах Силла [9, 8] доказывалось, что семейства функций, непрерывных по параметрам, порождают связные графы векторов ошибок.

Пусть  $\mathbb{A} = \mathbb{R}^h$  и функция потерь имеет вид  $I(a, x) = [\varphi(a, x) \geq 0]$ , где функция  $\varphi(a, x)$  непрерывна по  $a$ . Рассмотрим множества алгоритмов  $A_r \subset \mathbb{A}$ , в которых изменение вектора ошибок происходит одновременно на  $r$  объектах:

$$A_r = \{a \in A \mid \forall \varepsilon > 0 \exists a' \in A: \|a - a'\| \leq \varepsilon, \rho(a, a') = r\},$$

где  $\|\cdot\|$  — евклидова норма в  $\mathbb{R}^n$ ,  $\rho(a, a')$  — хэммингово расстояние между векторами ошибок алгоритмов  $a$  и  $a'$ .

**Задача 2.8. (3)** Можно ли утверждать, что  $A_1 \neq \emptyset$ ,  $A_2 = \dots = A_L = \emptyset$  почти всегда? При каких ограничениях это действительно так? Насколько эти ограничения обременительны?

**Задача 2.9. (3)** Пусть генеральная выборка  $\mathbb{X}$  длины  $L$  получена случайно и независимо из непрерывного распределения  $p(x)$  на  $\mathbb{X}$ . Можно ли утверждать, что с вероятностью 1 (т. е. для почти всех выборок)  $A_2 = \dots = A_L = \emptyset$ ?

## 3 Экспериментальные исследования (практикум)

Реализация следующих программ и экспериментирование с ними поможет не только проверять правильность теоретических оценок, но и замечать новые интересные факты, выдвигать и проверять новые гипотезы.

Графики желателно генерировать в виде chd-файлов в формате ChartLib.

### §3.1 Эмпирическое исследование вероятности переобучения

**Задача 3.1. (5)** Написать программу, позволяющую:

- генерировать последовательности векторов ошибок  $a_1, \dots, a_D$  в виде бинарной матрицы ошибок размера  $L \times D$  (в матрице ошибок не должно быть одинаковых столбцов — векторов ошибок); легко заменять генераторы данных;
- вычислять точные верхние и нижние оценки вероятности переобучения, если соответствующие формулы известны;
- вычислять эмпирические оценки вероятности переобучения методом Монте-Карло, т. е. по случайному подмножеству из  $N$  разбиений  $(X, \bar{X})$ ; требуется вычислять две оценки, соответствующие двум стратегиям выбора алгоритма в случаях неоднозначного минимума эмпирического риска:
  - верхняя оценка  $\bar{Q}_\varepsilon$  соответствует стратегии «худший из лучших» (метод  $\mu_x$ );
  - нижняя оценка  $\underline{Q}_\varepsilon$  соответствует стратегии «лучший из лучших» (метод  $\mu_l$ ).
- строить графики, в которых по оси  $X$  откладывается порядковый номер алгоритма  $d$ , по оси  $Y$ :
  - эмпирические оценки  $\bar{Q}_\varepsilon$  и  $\underline{Q}_\varepsilon$  для подпоследовательности  $a_1, \dots, a_d$ ;
  - точные значения  $\bar{Q}_\varepsilon$  и  $\underline{Q}_\varepsilon$  для  $a_1, \dots, a_d$  (если формулы известны);
  - число ошибок  $n(a_d, \mathbb{X})$ ;
  - доля разбиений, на которых  $\mu_x X = a_d$ ;
  - доля разбиений, на которых  $\mu_l X = a_d$ .
- строить графики, в которых по оси  $Y$  откладываются точные (если известны) и эмпирические значения  $\bar{Q}_\varepsilon$  и  $\underline{Q}_\varepsilon$ , по оси  $X$ :
  - число ошибок лучшего алгоритма  $m$ ;
  - длина обучения  $\ell$ ;
  - длина контроля  $k$ .

Следующие три задачи направлены на экспериментальную проверку теоретических оценок и исследование перечисленных выше зависимостей. Число разбиений  $N$  должно быть достаточно большим (например, десять тысяч), чтобы совпадение теоретических и эмпирических оценок было очевидно.

**Задача 3.2. (3)** Исследовать  $\bar{Q}_\varepsilon, \underline{Q}_\varepsilon$  монотонной цепочки.

**Задача 3.3. (3)** Исследовать  $\bar{Q}_\varepsilon, \underline{Q}_\varepsilon$  унимодальной цепочки.

**Задача 3.4. (3)** Исследовать  $\bar{Q}_\varepsilon, \underline{Q}_\varepsilon$  единичной окрестности лучшего алгоритма.

Следующий эксперимент направлен на проверку гипотезы, что монотонная цепочка и цепочка случайных инверсий [1] ведут себя практически одинаково с точки зрения переобучения. Если это подтвердится, то можно будет ограничиться изучением монотонных цепочек, как достаточно точной модели реальных цепочек.

**Задача 3.5. (3)** Сравнить, представив на одном графике, точные значения  $\bar{Q}_\varepsilon$  для монотонной цепочки, их эмпирические оценки и эмпирические оценки  $\bar{Q}_\varepsilon$  для цепочки случайных инверсий при одинаковых  $m$ . Увеличиваются ли различия между  $\bar{Q}_\varepsilon$  монотонной цепочки и цепочки случайных инверсий с ростом  $\ell$  и  $m$ ?

### §3.2 Визуализация графов связности

**Задача 3.6. (5)** Написать программу, позволяющую:

- генерировать двумерные модельные задачи классификации на два класса;
- строить точечный график выборки;
- строить бинарную матрицу ошибок, порождаемую всевозможными двумерными линейными классификаторами на заданной выборке (в матрице ошибок не должно быть одинаковых столбцов — векторов ошибок);
- отображать граф связности в виде плоского точечного графика, со всеми рёбрами, желательно без самопересечений.

**Задача 3.7. (3)** Отобразить выборки и графы связности для Задач 2.5 и 2.6.

## 4 Нижние и асимптотические оценки

В [2] получены точные верхние оценки вероятности переобучения для четырёх частных случаев: монотонной цепочки, унимодальной цепочки, единичной окрестности лучшего алгоритма и пары алгоритмов. Эти результаты можно развивать по нескольким направлениям.

### §4.1 Точные нижние оценки

Точные *верхние* оценки вероятности переобучения  $\bar{Q}_\epsilon$  получены при условии, что в случаях неоднозначного выбора алгоритма, доставляющего минимальное значение эмпирическому риску, выбирается наихудший алгоритм (стратегия «худший из лучших»). Точные *нижние* оценки  $\underline{Q}_\epsilon$  могут быть получены аналогичным образом, если придерживаться стратегии «лучший из лучших».

Если окажется, что верхние и нижние оценки достаточно близки, то впредь можно будет ограничиваться получением верхних оценок.

**Задача 4.1. (2)** Выписать точные нижние оценки вероятности переобучения для монотонной цепочки. Исследовать зависимость разности точной верхней и точной нижней оценок от длины выборки  $L$ .

**Задача 4.2. (2)** Выписать точные нижние оценки вероятности переобучения для унимодальной цепочки. Исследовать зависимость разности точной верхней и точной нижней оценок от длины выборки  $L$ .

**Задача 4.3. (2)** Выписать точные нижние оценки вероятности переобучения для пары алгоритмов. Исследовать зависимость разности точной верхней и точной нижней оценок от длины выборки  $L$ .

## §4.2 Асимптотические оценки

Точные оценки вероятности переобучения имеют громоздкий вид и сложны для вычислений. Наверняка эти комбинаторные выражения можно упростить. В асимптотике  $L \rightarrow \infty$  будем предполагать, что  $\frac{\ell}{L} \rightarrow \text{const}$ ,  $\frac{m}{L} \rightarrow \text{const}$ .

**Задача 4.4. (3)** Найти асимптотическое выражение точной верхней оценки вероятности переобучения для монотонной цепочки.

**Задача 4.5. (3)** Найти асимптотическое выражение точной верхней оценки вероятности переобучения для унимодальной цепочки.

**Задача 4.6. (3)** Найти асимптотическое выражение точной верхней оценки вероятности переобучения для единичной окрестности лучшего алгоритма.

## 5 Обобщения цепочек и окрестностей

Семейства алгоритмов, рассмотренные в [2], являются искусственными примерами, цель которых — продемонстрировать применимость общего подхода. Для перехода от модельных примеров к реальным семействам будем постепенно усложнять задачи, учитывая следующие соображения:

- реальные семейства, как правило, являются связными и расслоенными;
- вероятность переобучения определяется окрестностью лучшего алгоритма;
- сначала попробуем получить оценки для окрестностей «простого вида»;
- возможно, они окажутся достаточно точными и в более общих случаях;

Во всех задачах данной секции требуется выписать точные оценки  $P_a$  и  $Q_\varepsilon$ .

### §5.1 Обобщения монотонных цепочек

Обобщения монотонных цепочек направлены на постепенный переход к параметрическим семействам алгоритмов большей размерности. Конечная цель — понять, как размерность пространства параметров влияет на вероятность переобучения. С ростом размерности она должна увеличиваться, однако не так быстро, как предсказывают VC-оценки.

**Задача 5.1. (3)** Пара параллельных монотонных цепочек — это множество векторов ошибок, состоящее из двух монотонных цепочек  $a_0, \dots, a_d$  и  $a'_0, \dots, a'_d$  таких, что  $\rho(a_t, a'_t) = 1$  и  $n(a_t, \mathbb{X}) = n(a'_{t-1}, \mathbb{X}) = m + t$ .

**Задача 5.2. (6)** Монотонная сетка — это множество векторов ошибок  $a_{st}$ ,  $(s, t) \in \{0, \dots, d\}^2$ , такое, что  $\rho(a_{st}, a_{s,t+1}) = 1$ ,  $\rho(a_{st}, a_{s+1,t}) = 1$ ,  $n(a_{st}, \mathbb{X}) = m + s + t$ .

**Задача 5.3. (1)** Построить пример двумерной модельной задачи классификации, в которой множество векторов ошибок является монотонной сеткой.

**Задача 5.4. (10)** Монотонная  $h$ -мерная сетка — это множество векторов ошибок  $a_J$ , индексируемых  $h$ -мерным целочисленным вектором  $J = (j_1, \dots, j_h) \in \{0, \dots, d\}^h$ , такое, что  $\rho(a_J, a_{J'}) = 1$  для всех пар индексов  $J, J'$ , отличающихся на единицу только в одной координате, и  $n(a_J, \mathbb{X}) = m + j_1 + \dots + j_h$ . Учтеь, что «верхушка» сетки может срезаться условием  $m + j_1 + \dots + j_h \leq L$ .



## §5.2 Обобщения единичной окрестности

Единичная окрестность лучшего алгоритма является первым шагом к рассмотрению многомерного семейства с расслоением. Следующим шагом логично было бы увеличить радиус окрестности.

Задача 5.5 является искусственной. Пока не ясно, существуют ли реальные семейства, устроенные таким образом. Однако решение задачи представляется относительно несложным, а разработка техники её решения — полезной.

**Задача 5.5. (3)** Множество векторов ошибок является хэмминговым шаром радиуса  $r$  с центром в некотором векторе  $a_{\text{ц}}$ . Известно, что  $n(a_{\text{ц}}, X^L) = m_{\text{ц}} \geq r$ . При этом наилучший алгоритм, очевидно, допускает  $m = m_{\text{ц}} - r$  ошибок.

В следующей задаче требуется уточнять саму постановку. Идея в том, что в пространствах фиксированной размерности окрестность наилучшего алгоритма не может включать в себя все возможные векторы ошибок. В результате из хэммингова шара (точнее, из его верхнего полушария) выделяется некоторое «многообразие меньшей размерности».

**Задача 5.6. (20)** Множество векторов ошибок  $A$  является подмножеством хэммингова шара радиуса  $r$  с центром в некотором векторе  $a_0$  с известной частотой ошибок  $m = n(a_0, \mathbb{X})$ . Подмножество определяется двумя ограничениями. Во-первых, в  $A$  нет векторов лучше  $a_0$ :  $n(a, \mathbb{X}) \geq n(a_0, \mathbb{X})$  для любого вектора  $a \in A$  (таким образом, выделяется верхнее полушарие хэммингова шара). Во-вторых, для любого вектора  $a \in A$  существует не более  $d$  векторов  $a' \in A$  на единичном расстоянии от него  $\rho(a, a') = 1$ . Как  $Q_\varepsilon$  зависит от  $d$  и  $m$ ?

## §5.3 Реальные семейства алгоритмов

**Задача 5.7. (10)** Параметрическое семейство  $A$  линейных алгоритмов классификации над  $n$  вещественными признаками  $f_1(x), \dots, f_n(x)$  с параметрами  $w_1, \dots, w_n$ :

$$a(x) = \text{sign} \left( \sum_{j=1}^n w_j f_j(x) \right).$$

**Задача 5.8. (5)** Предыдущая задача при  $n = 2$ .

**Задача 5.9. (10)** Параметрическое семейство  $A$  конъюнкций над  $n$  вещественными признаками  $f_1(x), \dots, f_n(x)$ : с параметрами  $w_1, \dots, w_n$ :

$$a(x) = \bigwedge_{j=1}^n [f_j(x) \leq w_j].$$

**Задача 5.10. (5)** Предыдущая задача при  $n = 2$ .

**Задача 5.11. (20)** Рассматривается семейство линейных алгоритмов классификации над  $n$  вещественными признаками. На норму вектора параметров накладывается дополнительное ограничение регуляризации  $\|w\| \leq \tau$ . Как при этом меняется вероятность переобучения?

## 6 Семейства, задаваемые перечислением векторов ошибок

В этой секции рассматриваются семейства  $A$ , заданные не слишком длинной совокупностью векторов ошибок, в общем случае произвольных. «Не слишком длинной» означает, что оценки должны вычисляться за приемлемое время при условии, что векторы ошибок в явном виде хранятся в памяти компьютера.

### §6.1 Оценки по ненаблюдаемым данным

В следующих задачах векторы ошибок предполагаются известными полностью. На практике это невозможно, т. к. при фиксированном разбиении  $(X, \bar{X})$  скрытая (контрольная) выборка неизвестна. Тем не менее, получение оценок  $Q_\varepsilon$  и в этих случаях представляет интерес. Во-первых, это позволит ускорить расчёты экспериментов, заменив эмпирические оценки по методу Монте-Карло точными оценками. Во-вторых, из этих оценок, возможно, будут проще получаться верхние оценки для некоторых семейств алгоритмов.

Простейшим примером такого явно заданного семейства является двухэлементное семейство, для которого точная оценка получена в [1, 2].

**Задача 6.1. (3)** Выписать точные оценки  $P_a$  и  $Q_\varepsilon$  для семейства из трёх произвольных алгоритмов  $A = \{a_1, a_2, a_3\}$ , считая, что заданы восемь параметров

$$m_{abc} = \#\{x \in \mathbb{X} : I(a_1, x) = a, I(a_2, x) = b, I(a_3, x) = c\}, \quad a, b, c \in \{0, 1\}.$$

**Задача 6.2. (2)** В задаче 6.1 рассмотреть частный случай — трёхэлементное семейство без расслоения:  $m_{110} = m_{101} = m_{011} = m_{100} = m_{010} = m_{001} = m$ . Построить зависимость  $Q_\varepsilon$  от хэммингова расстояния между векторами ошибок (которое равно  $4m$ ) при нескольких (небольших) значениях  $m_{111}$ .

**Задача 6.3. (2)** В задаче 6.1 рассмотреть частный случай — трёхэлементное семейство с расслоением:  $m_{011} = m_{001} = m$ ,  $m_{110} = m_{101} = m_{100} = m_{010} = 0$ . Построить зависимость  $Q_\varepsilon$  от хэммингова расстояния между векторами ошибок  $\rho(a_1, a_2) = \rho(a_2, a_3) = m$  при нескольких (небольших) значениях  $m_{111}$ .

**Задача 6.4. (10)** Задан конечный набор векторов ошибок  $A_d = \{a_1, \dots, a_d\}$ . Найти рекуррентную формулу, эффективно вычисляющую  $Q_\varepsilon$  для  $A_d$ , предполагая, что  $Q_\varepsilon$  уже вычислено для  $A_{d-1}$ , и добавляется (полностью известный) вектор  $a_d$ . Искомая формула не должна содержать явного суммирования по всем  $C_L^\ell$  разбиениям.

Подсказка 1: при добавлении нового алгоритма он «забирает» некоторые обучающие выборки  $X$  у предыдущих алгоритмов  $a_t$ , ( $t < d$ ), соответственно уменьшая их  $P_t$ , и на столько же увеличивая свою  $P_d$ .

Подсказка 2: разрешается на каждой итерации сохранять некоторую агрегированную информацию  $\mathcal{I}_{d-1} = \mathcal{I}(a_1, \dots, a_{d-1})$  о совокупности всех предыдущих векторов, которая позволяла бы упростить вычисление  $Q_\varepsilon$  и заодно вычислить  $\mathcal{I}_d$ . Что это за информация?

Подсказка 3: разрешается предполагать, что векторы  $a_t$  добавляются в порядке небывания числа ошибок  $n(a_t, \mathbb{X})$ , или в каком-либо другом удобном порядке.

Решение следующей задачи существенно зависит от предыдущей. С одной стороны, это попытка уйти от непосредственного использования данных, содержащихся в векторах из  $A$ . С другой стороны, это ещё одна попытка учесть размерность пространства параметров, альтернативная задачам 5.4 и 5.6.

**Задача 6.5. (15)** *Получить оценки для  $Q_\varepsilon$ , если на каждом шаге  $t$  известен не сам добавляемый вектор  $a_t$ , а только число ошибок  $n(a_t, \mathbb{X})$  и число векторов из  $A_{t-1}$ , имеющих единичное хэммингово расстояние до  $a_t$ .*

## §6.2 Оценки по наблюдаемым данным

В этих задачах предполагается, что векторы ошибок известны не полностью, а только на наблюдаемой выборке  $X$  при заданном разбиении  $(X, \bar{X})$ , причём их можно явным образом перебирать и использовать их данные в вычислениях. На практике возможность явного перебора реализуется не всегда, а только в переборных методах обучения. Примеры таких методов:

- выбор лучшей модели по отложенным данным (hold-out model selection);
- стохастический поиск (например, генетические алгоритмы);
- поиск информативных конъюнкций в логических классификаторах;
- отбор признаков в линейной регрессии с фиксированными коэффициентами.

Предполагается, что получение оценок вероятности переобучения позволит некоторым образом улучшить эти методы.

Начнём с простейшего случая — семейства из двух алгоритмов.

**Задача 6.6. (10)** *Для двухэлементного семейства алгоритмов  $A = \{a_1, a_2\}$  при некотором разбиении  $(X, \bar{X})$ , выбранном случайно и равномерно, в наблюдаемой подвыборке  $X$  оказалось:*

- $s_0$  объектов, на которых ошиблись оба алгоритма;
- $s_1$  объектов, на которых ошибся только алгоритм  $a_1$ ;
- $s_2$  объектов, на которых ошибся только алгоритм  $a_2$ .

*Оценить сверху вероятность переобучения  $Q_\varepsilon$  для метода минимизации эмпирического риска. Как  $Q_\varepsilon$  зависит от  $s_1 + s_2$  — наблюдаемого расстояния между алгоритмами? Как  $Q_\varepsilon$  зависит от  $|s_1 - s_2|$  — наблюдаемой величины расслоения алгоритмов?*

**Задача 6.7. ( $\infty$ )** *Для  $d$ -элементного семейства алгоритмов  $A = \{a_1, \dots, a_d\}$  при некотором разбиении  $(X, \bar{X})$ , выбранном случайно и равномерно, известны векторы ошибок  $(a_1)_X, \dots, (a_d)_X$ . Оценить сверху вероятность переобучения  $Q_\varepsilon$  для метода минимизации эмпирического риска. Как  $Q_\varepsilon$  зависит от расстояния между алгоритмами? Использование каких характеристик схожести алгоритмов позволяет записать более точную оценку  $Q_\varepsilon$ ?*

## Список литературы

- [1] *Воронцов К. В.* Эффекты расслоения и сходства в семействах алгоритмов и их влияние на вероятность переобучения // *Pattern Recognition and Image Analysis*. — 2009 (в печати). — Vol. ??, no. ?? — Pp. ??-??  
<http://www.MachineLearning.ru/wiki/images/0/0e/Voron09roai2008.pdf>.
- [2] *Воронцов К. В.* Точные оценки вероятности переобучения // ?? — 2009 (в печати). — Vol. ??, no. ?? — Pp. ??-??  
<http://www.MachineLearning.ru/wiki/images/1/18/Voron09exact.pdf>.
- [3] *Воронцов К. В.* Комбинаторная вероятность и точность оценок обобщающей способности (Combinatorial probability and the tightness of generalization bounds) // *Pattern Recognition and Image Analysis*. — 2008. — Vol. 18, no. 2. — Pp. 243–259.  
<http://www.ccas.ru/frc/papers/voron08pria.pdf>.
- [4] *Вапник В. Н., Червоненкис А. Я.* Теория распознавания образов. — М.: Наука, 1974.
- [5] *Вапник В. Н.* Восстановление зависимостей по эмпирическим данным. — М.: Наука, 1979.
- [6] *Lugosi G.* On concentration-of-measure inequalities. — Machine Learning Summer School, Australian National University, Canberra. — 2003.  
<http://citeseer.ist.psu.edu/lugosi98concentrationmeasure.html>.
- [7] *Bax E. T.* Similar classifiers and VC error bounds: Tech. Rep. CalTech-CS-TR97-14: 6 1997.  
<http://citeseer.ist.psu.edu/bax97similar.html>.
- [8] *Sill J.* Generalization bounds for connected function classes. — [citeseer.ist.psu.edu/127284.html](http://citeseer.ist.psu.edu/127284.html).  
<http://citeseer.ist.psu.edu/127284.html>.
- [9] *Sill J.* Monotonicity and connectedness in learning systems: Ph.D. thesis / California Institute of Technology. — 1998.  
<http://etd.caltech.edu/etd/available/etd-09222005-110351/>.