

**Московский государственный университет
имени М.В. Ломоносова
Механико-математический факультет**

На правах рукописи

УДК 519.21, 519.234

Рафиков Евгений Геннадьевич

**ЭФФЕКТ КОНЦЕНТРАЦИИ МЕРЫ В СТАТИСТИЧЕСКИХ
ЗАДАЧАХ НЕПАРАМЕТРИЧЕСКОГО ОЦЕНИВАНИЯ.**

**01.01.05 — теория вероятностей и математическая
статистика**

**АВТОРЕФЕРАТ
диссертации на соискание учёной степени
кандидата физико-математических наук**

Москва 2007

Работа выполнена на кафедре теории вероятностей Механико-математического факультета Московского государственного университета имени М. В. Ломоносова.

Научный руководитель: доктор физико-математических наук,
профессор Ю. Н. Тюрин

Официальные оппоненты: доктор физико-математических наук,
доцент В. В. Ульянов

кандидат физико-математических наук,
доцент С. А. Пирогов

Ведущая организация: Математический институт Стеклова РАН

Защита диссертации состоится 16 марта 2007 года в 16 часов 15 минут на заседании диссертационного совета Д.501.001.85 в Московском государственном университете имени М. В. Ломоносова по адресу: 119992, ГСП-2, г. Москва, Ленинские горы, МГУ, Механико-математический факультет, аудитория 16-24.

С диссертацией можно ознакомиться в библиотеке Механико-математического факультета (Главное здание, 14 этаж).

Автореферат разослан 16 февраля 2007 года.

Учёный секретарь диссертационного
совета Д.501.001.85 в МГУ,
доктор физико-математических
наук, профессор

Т. П. Лукашенко

Общая характеристика работы

Актуальность темы.

Во многих задачах математической статистики наряду с асимптотическим поведением стохастического объекта важно также знать и его неасимптотическое поведение.

Известно, что если X_1, \dots, X_m — одномерные независимые и одинаково распределённые случайные величины, где $F(x)$ и $F_m(x)$ — соответствующие им настоящая и эмпирическая функции распределения, то имеет место предельное асимптотическое поведение:

Теорема (Колмогоров).

$$\Pr\left\{\sup_{x \in \mathbb{R}} |F_m(x) - F(x)| > t/\sqrt{m}\right\} \rightarrow 2 \sum_{k=1}^{\infty} (-1)^{k-1} e^{-2k^2t^2}, \quad \text{при } m \rightarrow \infty.$$

Из теоремы Колмогорова следует также и неасимптотическая оценка:

Утверждение.

$$\Pr\left\{\sup_{x \in \mathbb{R}} |F_m(x) - F(x)| > t\right\} \leq C \cdot e^{-2mt^2},$$

аналог которой в случае распределений в \mathbb{R}^d был получен Кифером (Kiefer):

Теорема (Кифер). Для произвольного $\alpha > 0$ существует положительная константа $K = K(\alpha, d)$, такая что для всех $t \in \mathbb{N}$ верно:

$$\Pr\left\{\sup_{x \in \mathbb{R}^d} |F_m(x) - F(x)| > t\right\} \leq K \cdot e^{-(2-\alpha) \cdot mt^2}.$$

Эмпирический процесс, который фигурирует в указанных выше результатах, является частным случаем более общего объекта:

$$\sup_{A \in \mathcal{A}} |\mathbf{P}_m(A) - \mathbf{P}(A)|, \tag{1}$$

Получение точных оценок для вероятностных хвостов (1) тесно связано с задачей о вероятностях больших уклонений, подробно изучавшейся Сановым¹. См. также монографию². Большая часть статистической теории обучений также

¹И.Санов, *О вероятностях больших уклонений случайных величин*, Мат. сборник, **42** (1957), p.11-44.

²A.Dembo, O.Zeitouni, *Large Deviations Techniques and Applications*, Springer (1998).

посвящена изучению этой задачи при определённых условиях на вероятностную меру $\mathsf{P}(\cdot)$ и набор множеств \mathcal{A} .^{3,4,5} Для фиксированного множества A и вероятностной меры $\mathsf{P}(\cdot)$ по закону больших чисел имеет место сходимость почти наверное $\mathsf{P}_m(A) - \mathsf{P}(A) \rightarrow 0$ при $m \rightarrow \infty$. Более того, известное неравенство Хёфдинга даёт следующую (неасимптотическую) оценку на скорость сходимости:

$$\Pr\{|\mathsf{P}_m(A) - \mathsf{P}(A)| > t\} \leq 2e^{-2mt^2}.$$

Если набор \mathcal{A} конечен, то естественно получаем обобщение предыдущего неравенства:

$$\Pr\{\sup_{A \in \mathcal{A}} |\mathsf{P}_m(A) - \mathsf{P}(A)| > t\} \leq 2|\mathcal{A}| \cdot e^{-2mt^2}.$$

Однако если семейство \mathcal{A} имеет бесконечную мощность, как это и бывает во многих интересных случаях, имеющих практическое значение, задача становится гораздо более сложной. Оказывается, что ключевую роль в оценках экспоненциального типа для этой задачи играет ряд чисто комбинаторных характеристик семейства \mathcal{A} , таких как *размерность Вапника-Червоненкиса* и *энтропия Вапника-Червоненкиса*.

Часть результатов в этой области посвящена тому, что на неизвестную меру $\mathsf{P}(\cdot)$ накладываются дополнительные естественные условия. Так, важным является случай, когда мера $\mathsf{P}(\cdot)$ и семейство \mathcal{A} таковы, что *множество значений мер* $\{\mathsf{P}(A), A \in \mathcal{A}\}$ отделено от некоторой окрестности $1/2$. Улучшению оценок на поведение вероятностных хвостов для (1) в этом случае посвящена первая часть нашей диссертации. В качестве числовой характеристики такой отдельности мы используем разновидность *информации Кульбака-Лейблера*, играющую важную роль в *теории информации*.^{6,7} Близкие характеристики, такие как *расстояние Кульбака-Лейблера*, используются для решения задачи *оценивания плотности*⁸, а также в *асимптотической теории оценивания*.⁹

Для получения экспоненциально быстрых оценок в изучаемом нами случае используется техника из *теории эмпирических процессов*, что также делает те-

³В.Вапник, А.Червоненкис, *Теория распознавания образов*, Наука (1974).

⁴В.Вапник, А.Червоненкис, *Восстановление зависимостей по эмпирическим данным*, Наука (1979).

⁵L.Devroye, L.Gyorfi, G.Lugosi, *A Probabilistic Theory of Pattern Recognition*, Springer (1996).

⁶А.Колмогоров, *Теория информации и теория алгоритмов*, Наука (1987).

⁷T.Cover, J.Thomas, *Elements of Information Theory*, Wiley (1991).

⁸Л.Деврой, Л.Дъёрфи, *Непараметрическое оценивание плотности. L1-подход*. Пер. с англ., Мир (1988).

⁹И.Ибрагимов, Р.Хасьминский, *Асимптотическая теория оценивания*, Наука (1979).

матику и приёмы, обсуждаемые в диссертации, близкими к таким областям как классическая *непараметрическая статистика*, семипараметрическая статистика, теория *M-оценивания*, теория Гауссовских процессов и равномерные законы больших чисел и повторного логарифма.

Вторая часть диссертации посвящена современным проблемам регрессионного анализа. Пусть $X \in \mathbb{R}^d$ and $Y \in \mathbb{R}$ — некоторые Борелевские множества. В зависимости от предположений о характере неизвестной зависимости между $x \in X$ и $y \in Y$ известен ряд классических постановок *задачи обучения по конечной выборке*.

Так в *теории приближений* считается, что имеется детерминированная неизвестная зависимость на произведении $X \times Y$. Точнее, предполагается, что для точек из известного конечного набора $\mathbf{z} = \{(x_1, y_1), \dots, (x_m, y_m), x_i \in X, y_i \in Y\}$ верно соотношение $y_i = f(x_i), i = 1, \dots, m$, где f принадлежит некоторому заранее известному функциональному классу \mathcal{H} . Задача состоит в нахождении *наилучшего приближения* к f внутри класса \mathcal{H} . Ошибка приближения обычно измеряется в L_p -норме по отношению к мере Лебега на X , где $1 \leq p < \infty$.

В случае, когда допускается какая-то случайность на характер зависимости между x -ами и y -ами, говорят о *теории оценивания функции регрессии*. Рассматривается класс моделей вида $y = f(x) + \epsilon$, где $f \in \mathcal{H}$, а ϵ — случайная величина. Например, считается, что для множества $\mathbf{z} = \{(x_1, y_1), \dots, (x_m, y_m), x_i \in X, y_i \in Y\}$ выполняются равенства $y_i = f(x_i) + \epsilon_i$, где x_1, \dots, x_m фиксированы, а ϵ_i — независимые одинаково распределённые случайные величины с $E\epsilon_i = 0$. Задача, как и выше, состоит в том, чтобы построить некоторое приближение $f_{\mathbf{z}}$ для f (или оценку f), оптимальное в смысле $E(\|f - f_{\mathbf{z}}\|^2)$ в одной из стандартных норм. Также рассматривается постановка задачи, когда "входы" x_1, \dots, x_m сами случайны и как-то распределены в соответствии с неизвестным вероятностным законом на X .¹⁰

В своей работе мы имеем дело с задачей, когда считается, что произведение $Z = X \times Y$ снабжено некоторой вероятностной Борелевской мерой ρ , а *обучающие примеры* \mathbf{z} — суть случайная ρ -выборка длины m . Задача заключается в оценивании *функции регрессии* y -ов по x -ам, $f_{\rho}(x) = E\{y|x\}$. Пусть ρ_X —

¹⁰L.Gyorfi, M.Kohler, A.Krzyzak, H.Walk, *A Distribution-Free Theory of Nonparametric Regression*, Springer Series in Statistics (2002).

это проекция меры ρ на X . Для описания качества оценивания мы используем общепринятую характеристику скорости убывания вероятностных хвостов

$$\Pr\{\|f_\rho - f_z\|_{L_2(\rho_X)} > t\}, \quad (2)$$

где $f_z(x)$ — это некоторая *функция-оценщик* функции регрессии $f_\rho(x)$. Для такой постановки типичными условиями на неизвестную меру ρ являются предположение на принадлежность $f_\rho(x)$ некоторому классу \mathcal{H} , а также условия на равномерную по x скорость убывания вероятностных хвостов по y .

В ряде случаев, когда известно поведение классических в *теории приближений* характеристик класса \mathcal{H} , таких как *энтропийные числа* и *Колмогоровские поперечники*, нами получены экспоненциальные оценки убывания (2) при согласованном поведении t и t . Они являются обобщением результатов, полученных в ряде недавних работ, основные из которых приведены в конце страницы.^{11,12}

Экспоненциальные оценки в первой части выражены в терминах *комбинаторных характеристик* семейства множеств в \mathbb{R}^d или, что то же самое, семейства функций на \mathbb{R}^d со значениями в $\{0, 1\}$, в то время как результаты второй части формулируются в терминах *метрических характеристик* классов действительнозначных функций на \mathbb{R}^d . Известно, что существует тесная связь между этими характеристиками, и наши результаты лишний раз подтверждают это.

Цель работы.

Цель диссертационной работы — получить обобщения классических результатов Колмогорова, Смирнова, Кифера, Вапника и Червоненкиса о количественном поведении отклонений эмпирических частот событий от вероятностей, а также показать, что в ряде случаев существуют оптимальные оценщики неизвестной функции регрессии и доказать, что имеют место оптимальные вероятностные границы для их разности в нескольких случаях, когда класс гипотез задаётся в классических терминах теории приближений.

¹¹F.Cucker, S.Smale, *On the mathematical foundations of learning*, Bulletin of AMS, **39** (2001), p.1-49.

¹²V. Temlyakov. *Approximation in Learning Theory*. IMI Preprints **05** (2005), p.1-43.

Научная новизна.

В работе получены как новые результаты, так и новые более простые доказательства ряда известных ранее утверждений. Основные результаты диссертации состоят в следующем.

1. Получена новая (неасимптотическая) оценка скорости сходимости эмпирических частот к вероятностям в терминах функции информации и размерности Валника-Червоненкиса, обобщающая результаты Колмогорова, Смирнова, Кифера, Хёфдинга, Чернова, Валника, Червоненкиса и Девроя.
2. Получено более простое доказательство результата Талагранда, обобщающее одномерное неравенство Чернова, а также дан частичный ответ к гипотезе Талагранда о поведении супремумов важного класса эмпирических процессов.
3. Получен ряд оценок на поведение вероятностных хвостов отклонения функции-оценщика от функции регрессии в случае, когда класс гипотез задаётся в терминах энтропийных чисел и Колмогоровских поперечников.
4. Построен класс универсальных оценщиков функции регрессии и приведены оценки вероятностных хвостов их отклонения.

Методы исследования.

В диссертации используются методы теории эмпирических процессов, теории приближений и результаты о концентрации вероятностной меры. А именно, используется техника симметризации, неравенства Чернова, Бернштейна, Талагранда, неравенства Карла, формула Стирлинга, моментные неравенства и лемма Варадана, информация Кульбака-Лейблера и ряд неравенств, связывающих метрические и комбинаторные характеристики функционального пространства.

Теоретическая и практическая ценность.

Диссертация носит теоретический характер. Её методы и результаты могут найти применение в вероятностной теории распознавания образов и в теории оценивания функции регрессии.

Апробация работы.

Результаты диссертации в разное время докладывались и обсуждались на следующих семинарах механико-математического факультета МГУ: «Непараметрическая статистика и временные ряды» (руководители - д.ф.-м.н., профессор Ю.Н. Тюрин, д.ф.-м.н., профессор В.Н. Тутубалин, к.ф.-м.н., доцент М.В. Болдин); «Большой Кафедральный Семинар кафедры теории вероятностей»; «Статистическая теория обучений и её применения» (руководитель - д.ф.-м.н., профессор С.В. Конягин); «Теория приближений и приложения» (руководители - д.ф.-м.н., профессор, чл.-корр. РАН Б.С. Кашин, д.ф.-м.н., профессор С.В. Конягин);

а также представлялись на следующих международных конференциях: «25-я Европейская Конференция по Математической Статистике» (Осло, 2005); «Математические основы теории обучений II» (Париж, 2006); «26-я Европейская Конференция по Математической Статистике» (Торунь, 2006); Российско-Скандинавский Симпозиум «Теоретическая и Прикладная Теория Вероятностей» (Петрозаводск, 2006).

Публикации.

Результаты диссертации опубликованы в 6 работах, список которых приведён в конце автореферата, см. [1-6].

Структура диссертации.

Диссертация состоит из введения, двух глав (разбитых на разделы), заключения и списка литературы, насчитывающего 34 наименования. Общий объём диссертации — 73 страницы.

Краткое содержание диссертации

Во **введении** приведён краткий исторический обзор по тематике работы, изложены цели и методы исследования, а также структура диссертации.

Пусть X_1, \dots, X_m — независимые одинаково распределённые в соответствии с некоторой вероятностной мерой $P(\cdot)$ случайные величины в Евклидовом про-

странстве \mathbb{R}^d . Обозначим через t длину выборки, а через $\mathsf{P}_m(\cdot)$ — соответствующую эмпирическую меру. **Первая глава** посвящена изучению поведения вероятностных хвостов эмпирического процесса

$$\sup_{A \in \mathcal{A}} |\mathsf{P}_m(A) - \mathsf{P}(A)|,$$

для случая, когда \mathcal{A} — семейство Борелевских множеств в \mathbb{R}^d с конечной размерностью Вапника-Червоненкиса $V = V(\mathcal{A})$. В предположении, что множество значений мер $\{\mathsf{P}(A), A \in \mathcal{A}\}$ отделено от некоторой окрестности $1/2$, мы улучшаем ряд известных классических оценок. Введём необходимые определения.

Определение. Наибольшее целое число V , для которого существует набор из V точек x_1, \dots, x_V , удовлетворяющих свойству

$$\#\left\{\{x_1, \dots, x_V\} \cap A : A \in \mathcal{A}\right\} = 2^V,$$

называется размерностью Вапника-Червоненкиса семейства \mathcal{A} .

Если не оговаривается противное, везде ниже под $V = V(\mathcal{A})$ мы понимаем конечную размерность Вапника-Червоненкиса набора множеств \mathcal{A} .

Определение. Для вещественных чисел $p, q \in (0, 1)$ расходимостью Кульбака-Лейблера $H(p, q)$ называют следующее выражение:

$$H(p, q) = p \cdot \ln \frac{p}{q} + (1 - p) \cdot \ln \frac{1 - p}{1 - q}.$$

Определение. Критическим значением $p_{\mathcal{A}}$ для системы множеств \mathcal{A} и меры $\mathsf{P}(\cdot)$ назовём ближайшую к $1/2$ из двух величин p_+ и p_- , где

$$p_+ = \inf_{A \in \mathcal{A}, \mathsf{P}(A) > 1/2} \mathsf{P}(A), \quad p_- = \sup_{A \in \mathcal{A}, \mathsf{P}(A) < 1/2} \mathsf{P}(A).$$

Неформально можно рассматривать $p_{\mathcal{A}}$ как ближайшее к $1/2$ значение меры $\mathsf{P}(A)$ на множествах $A \in \mathcal{A}$.

Теорема 1. Пусть $p_{\mathcal{A}}$ — критическое значение для семейства множеств \mathcal{A} с конечной размерностью Вапника-Червоненкиса V . Тогда для некоторых положительных констант $M = M(p_{\mathcal{A}}, V)$, $K = K(V)$ и $t_0 = t_0(p_{\mathcal{A}}, V)$ при $m \cdot t^2 > M$ и $t < t_0$ выполняется оценка

$$\Pr_{A \in \mathcal{A}} \left\{ \sup |\mathsf{P}_m(A) - \mathsf{P}(A)| > t \right\} \leq K \cdot (mt^2)^{2V+4} \cdot \exp \left\{ -m \cdot \min(H(p_{\mathcal{A}} + t, p_{\mathcal{A}}), H(p_{\mathcal{A}} - t, p_{\mathcal{A}})) \right\}.$$

Прокомментируем наш результат. *Размерность Вапника-Червоненкиса* V является чисто комбинаторной характеристикой системы Борелевских множеств \mathcal{A} и не зависит ни от какого распределения вероятностей. Она описывает *разнообразие* \mathcal{A} . Другими словами, V равно наибольшему возможному числу точек в \mathbb{R}^d , таких что для любого (из 2^V) подмножества этих точек найдётся представитель $A \in \mathcal{A}$, пересекающийся с точками в точности по этому подмножеству. Если такое множество из V точек можно найти для любого $V \in \mathbb{N}$, то *размерность Вапника-Червоненкиса* считается равной бесконечности. Отметим, что для бесконечной системы множеств \mathcal{A} её размерность $V(\mathcal{A})$ может быть как конечной, так и бесконечной. Рассмотрим несколько важных примеров.

Для набора *полупространств* в пространстве \mathbb{R}^d

$$\mathcal{A} = \{\{x : \langle w, x \rangle + w_0 \geq 0\} : w \in \mathbb{R}^d, w_0 \in \mathbb{R}\} \text{ имеем } V(\mathcal{A}) = d + 1,$$

для семейства *отрицательных ортантов*

$$\mathcal{A} = \{(-\infty, x_1] \times \cdots \times (-\infty, x_d) : (x_1, \dots, x_d) \in \mathbb{R}^d\} \text{ верно } V(\mathcal{A}) = d.$$

Семейство всех *выпуклых многогранников* в \mathbb{R}^d (при $d \geq 2$) даёт пример набора \mathcal{A} с бесконечной размерностью V .

Результат **Теоремы 1** обобщает классические неасимптотические оценки Колмогорова, Смирнова и Кифера (Kiefer) на скорость сходимости эмпирической функции распределения к настоящей, а также ряд результатов Вапника, Червоненкиса и других авторов о равномерной сходимости частот к вероятностям. Вапник и Червоненкис первыми доказали экспоненциальные вероятностные оценки для эмпирического процесса $\sup_{A \in \mathcal{A}} |\mathsf{P}_m(A) - \mathsf{P}(A)|$ в общем случае когда $V(\mathcal{A})$ конечно^{13, 14}.

Теорема (Вапник-Червоненкис). Пусть \mathcal{A} – класс Борелевских множеств в \mathbb{R}^d с конечной $V = V(\mathcal{A})$. Тогда для $mt^2 > 2$ верно неравенство:

$$\Pr\left\{\sup_{A \in \mathcal{A}} |\mathsf{P}_m(A) - \mathsf{P}(A)| > t\right\} \leq 4\left(\frac{2em}{V}\right)^V \cdot e^{-mt^2/8}.$$

¹³Б. Вапник, А. Червоненкис. *О равномерной сходимости относительных частот событий к их вероятностям*. Теория вероятностей и приложения, **16**, №. 2 (1971), стр. 264-280.

¹⁴Б. Вапник, А. Червоненкис. *Необходимые и достаточные условия для равномерной сходимости средних к математическим ожиданиям*. Теория вероятностей и приложения, **26**, №. 3 (1981), стр. 532-553.

Экспоненциальный по t множитель в этой оценке описывает вероятностный хвост отклонения для фиксированного множества $A \in \mathcal{A}$, а полиномиальный член характеризует разнообразие семейства \mathcal{A} . Отметим, что в упомянутых выше классических результатах и их обобщениях не делалось каких-то специальных предположений на неизвестную меру $\mathsf{P}(\cdot)$.

Такие оценки принято называть *свободными от распределения*. Они также известны в литературе как *границы Вапника-Червоненкиса*. Все такие результаты и их обобщения в общем виде можно записать так:

$$\Pr\left\{\sup_{A \in \mathcal{A}} |\mathsf{P}_m(A) - \mathsf{P}(A)| > t\right\} \leq K(t, V) \cdot (mt^2)^v \cdot e^{-m \cdot \phi(t)}, \text{ когда } mt^2 > C, \quad (3)$$

Здесь C — некоторая константа, не зависящая от t , v — функция от V , а $\phi(t) = \gamma t^2$, где $\gamma \in (0, 2]$.

Несколько авторам удалось улучшить константы из первых оценок Вапника и Червоненкиса. Отметим здесь лишь, что Деврой (L.Devroye)¹⁵ получил оптимальный множитель e^{-2mt^2} , а Талагранд (M. Talagrand)¹⁶ — также и неулучшаемый показатель $v = V - 1/2$. Наше предположение о том, что множество $\{\mathsf{P}(A) : A \in \mathcal{A}\}$ отделено от некоторой окрестности $1/2$, позволяет улучшить экспоненциальный множитель в оценках вида (3) и взять в качестве $\phi(t)$ выражение

$$\phi(t) = \min(H(p_{\mathcal{A}} + t, p_{\mathcal{A}}), H(p_{\mathcal{A}} - t, p_{\mathcal{A}})). \quad (4)$$

Новый вид оценки обобщает классический результат Чернова (Chernoff) для случая отдельного множества $A \in \mathcal{A}$.

Теорема (Чернов).

$$\Pr\{(\mathsf{P}_m(A) - \mathsf{P}(A)) > t\} \leq \exp\{-m \cdot H(\mathsf{P}(A) + t, \mathsf{P}(t))\}, \quad \forall A \in \mathcal{A}.$$

Талагранд выдвинул гипотезу о том, что наряду с $\phi(t)$ из выражения (4) в оценке (3) может быть сохранён оптимальный *полиномиальный множитель* $(mt^2)^{V-1/2}$. Таким образом, **Теорема 1** может рассматриваться как частичное решение *гипотезы Талагранда*. Условия отделимости $\{\mathsf{P}(A), A \in \mathcal{A}\}$ от $1/2$

¹⁵L. Devroye, *Bounds for the Uniform Deviation of Empirical Measures*, Journal of Multivariate Analysis, **12** (1982), p. 72-79.

¹⁶M. Talagrand, *Sharper Bounds for Gaussian and Empirical Processes*, The Annals of Probability, **22**, No 1 (1994), p. 28-76.

означает, что $p_{\mathcal{A}} \neq 1/2$. А значит для некоторого $t_0 > 0$ множества $\{p_{\mathcal{A}} + t\}$, $\{p_{\mathcal{A}} - t\}$, $0 < t < t_0$ не пересекаются с некоторой окрестностью $1/2$. Из свойств *расходимости Кульбака-Лейблера* следует, что для таких t экспоненциальный показатель в **Теореме 1** улучшен по сравнению с оптимальным в случае предположения *свободы от распределения*.

Талагранд показал, что выполняется следующая разновидность оценки (3), которую мы приводим для частного случая:

Теорема (Талагранд¹⁶). *Пусть \mathcal{A} — ограниченное семейство измеримых множеств в \mathbb{R}^d с конечной $V = V(\mathcal{A})$. Пусть также $\mathsf{P}(\cdot)$ — некоторая Борелевская вероятностная мера на \mathbb{R}^d , а $p_{\mathcal{A}}$ — критическое значение для \mathcal{A} и $\mathsf{P}(\cdot)$. Тогда если $p_{\mathcal{A}} \neq 1/2$, то для любого $\beta \in (0, 1)$ существуют положительные числа $M(\beta, p_{\mathcal{A}}, V)$, $K(V)$ и $t_0(\beta, p_{\mathcal{A}}, V)$, такие что при $m \cdot t^2 > M(\beta, p, V)$ и $t < t_0(\beta, p, V)$ верно неравенство:*

$$\Pr\left\{\sup_{A \in \mathcal{A}} |\mathsf{P}_m(A) - \mathsf{P}(A)| > t\right\} \leq K(V) \cdot (mt^2)^V e^{-m(1-\beta) \cdot \min(H(p_{\mathcal{A}}+t, p_{\mathcal{A}}), H(p_{\mathcal{A}}-t, p_{\mathcal{A}}))}.$$

Эта теорема нужна нам как вспомогательная для нашего основного результата. Мы приводим новое простое её доказательство. Отметим, что наибольшую сложность здесь представляет переход от множителя $m(1 - \beta)$ в показателе экспоненты просто к m , чтобы получилось прямое обобщение неравенств Чебышева и Чернова.

Поясним на примере, что объект, который мы оцениваем в **Теореме 1**, естественным образом возникает в *теории обучений*. Для этого рассмотрим *классическую задачу двухклассового распознавания* d -мерных объектов. Предположим, что заранее известен класс *решающих правил* \mathcal{H} , т.е. класс функций $f : \mathbb{R}^d \rightarrow \{0, 1\}$, а также *обучающая выборка* $\mathbf{z} = \{(x_1, y_1), \dots, (x_m, y_m)\}$ длины m . Здесь $x_j \in \mathbb{R}^d$, а $y_j \in \{0, 1\}$. Будем понимать под *неизвестным законом*, в соответствии с которым получены или собраны наблюдения $z_j = (x_j, y_j)$, некоторое *распределение вероятностей* $\mathsf{P}(\cdot)$ на произведении $\mathbb{R}^d \times \{0, 1\}$. Общая задача состоит в том, чтобы на основе выборки \mathbf{z} длины m из семейства \mathcal{H} выбрать в некотором смысле *наилучшее* решающее правило $f_{\mathbf{z}} \in \mathcal{H}$ с тем, чтобы использовать его для распознавания любых точек из \mathbb{R}^d . Например, выбрать решающее правило $f_{\mathbf{z}}$, которое по входному x -у как можно чаще выдаёт "правильный" y .

Естественный подход при выборе *оптимального* $f : \mathbb{R}^d \rightarrow \{0, 1\}$, $f \in \mathcal{H}$ состоит в минимизации *эмпирической ошибки*, определяемой как

$$\frac{1}{m} \sum_{j=1}^m \mathbf{I}_{\{f(x_j) \neq y_j\}}.$$

Обозначим функцию, или как ещё говорят, "распознаватель", на которой достигается этот минимум, как f_z . *Ошибка правила* $f \in \mathcal{H}$ назовём P -меру множества всех таких пар $(x, y) \in \mathbb{R}^d \times \{0, 1\}$, для которых $f(x) \neq y$. Возникает естественный вопрос о том, насколько *ошибка* такого "распознавателя" f_z близка к *минимально возможной ошибке* внутри класса \mathcal{H} . Пусть $\mathsf{P}_m(\cdot)$ — соответствующее выборке \mathbf{z} эмпирическое распределение. Тогда можно показать, что модуль интересующей нас разности оценивается сверху как

$$2 \cdot \sup_{A \in \mathcal{A}} |\mathsf{P}_m(A) - \mathsf{P}(A)|,$$

где семейство \mathcal{A} представляет из себя следующий набор множеств:

$$\{\{x : f(x) = 1\} \times \{0\}\} \bigcup \{\{x : f(x) = 0\} \times \{1\}\}, \quad f \in \mathcal{H}.$$

Для фиксированного множества A и для любой непрерывной меры $\mathsf{P}(\cdot)$ по закону больших чисел имеет место сходимость почти наверное $\mathsf{P}_m(A) - \mathsf{P}(A) \rightarrow 0$ при $m \rightarrow \infty$. Более того, неравенство Чебышева и Хёфдинга даёт следующую оценку на скорость сходимости:

$$\Pr\{|\mathsf{P}_m(A) - \mathsf{P}(A)| > t\} \leq 2e^{-2m \cdot t^2}.$$

Если семейство \mathcal{A} конечно, то естественно получаем обобщение предыдущего неравенства:

$$\Pr\left\{\sup_{A \in \mathcal{A}} |\mathsf{P}_m(A) - \mathsf{P}(A)| > t\right\} \leq 2|\mathcal{A}| \cdot e^{-2m \cdot t^2}.$$

Однако если набор \mathcal{A} имеет бесконечную мощность, как это и бывает во многих интересных случаях, имеющих прикладное значение, задача становится гораздо более сложной.

Вторая часть диссертации посвящена задаче оценивания функции регрессии. Пусть $X \subset \mathbb{R}^d$ и $Y \subset \mathbb{R}$ — Борелевские множества, и на их произведении $Z = X \times Y$ определена Борелевская вероятностная мера ρ . Обозначим через $f_\rho : X \rightarrow Y$ *функцию регрессии* y на x , т.е. $f_\rho(x) = \mathsf{E}\{y|x\}$.

Мы изучаем задачу оценивания функции $f_\rho(x)$ по *конечной* ρ -выборке $\mathbf{z} = \{z_1, \dots, z_m\} : z_i = (x_i, y_i), i = 1, \dots, m$. Иногда эту задачу называют *обучением функции регрессии*.

Функцию, построенную по выборке \mathbf{z} и оценивающую $f_\rho(x)$, будем обозначать как $f_{\mathbf{z}} : X \rightarrow Y$ и называть её *функцией-оценщиком*. Пусть ρ_X — проекция меры ρ на X . Естественной характеристикой *качества оценивания* функции f_ρ является скорость убывания вероятностных хвостов (при стремлении $\epsilon \rightarrow 0$ и $m \rightarrow \infty$)

$$\Pr\{\|f_{\mathbf{z}} - f_\rho\|_{L_2(X, \rho_X)}^2 > \epsilon\}. \quad (5)$$

Здесь и везде ниже под $\Pr(\cdot)$ понимается ρ^m -вероятность на произведении Z^m , где $Z = X \times Y$. На неизвестную меру ρ мы накладываем следующие условия (6) и (7):

$$\exists C_1, C_2 > 0, \text{ такие что } \forall t > 0 : \rho\{|y| > t\} < C_1 \cdot \exp\{-C_2 \cdot t^2\}, \quad (6)$$

$$f_\rho(x) \in \mathcal{H}, \text{ где } \mathcal{H} — \text{компактное подмножество в пространстве } C(X). \quad (7)$$

Свойство убывания вероятностных хвостов (6) также известно как *равномерная сабгауссость* по y . Для функции $f : X \rightarrow Y, f \in L_2(X, \rho_X)$ её *ошибкой* назовём выражение

$$\mathcal{E}(f) = \int_Z (f(x) - y)^2 \cdot d\rho.$$

Известно, что минимум *ошибки* достигается на функции регрессии $f_\rho(x)$:

$$\mathcal{E}(f_\rho) = \inf_{f \in L_2(\rho_X)} \mathcal{E}(f), \text{ при этом для } f \in L_2(X, \rho_X) : \mathcal{E}(f) - \mathcal{E}(f_\rho) = \|f - f_\rho\|_{L_2(X, \rho_X)}^2,$$

а значит для любого оценщика $f_{\mathbf{z}} \in L_2(X, \rho_X)$ вероятностные хвосты (5) можно записать как

$$\Pr\{\|f_{\mathbf{z}} - f_\rho\|_{L_2(X, \rho_X)}^2 > \epsilon\} = \Pr\{\mathcal{E}(f_{\mathbf{z}}) - \mathcal{E}(f_\rho) > \epsilon\}.$$

Определим *эмпирическую ошибку* $\mathcal{E}_{\mathbf{z}}(f)$ как

$$\mathcal{E}_{\mathbf{z}}(f) = \frac{1}{m} \sum_{i=1}^m (f(x_i) - y_i)^2$$

и обозначим через $f_{\mathcal{H}, \mathbf{z}}$ *минимум эмпирической ошибки* для пространства \mathcal{H} :

$$f_{\mathcal{H}, \mathbf{z}} = \arg \min_{f \in \mathcal{H}} \mathcal{E}_{\mathbf{z}}(f).$$

Обозначим также через $N(\mathcal{H}, \epsilon)$ мощность ϵ -сети для \mathcal{H} в пространстве $C(X)$.

Теорема 2. Пусть мера ρ удовлетворяет условиям (6) и (7). Тогда найдутся положительные константы $C_1(\mathcal{H}, \rho)$ и $C_2(\mathcal{H}, \rho)$, такие что для всех $\epsilon > 0$ справедливо неравенство:

$$\Pr\{\mathcal{E}(f_{\mathcal{H}, z}) - \mathcal{E}(f_\rho) > \epsilon\} \leq 2 N(\mathcal{H}, \epsilon/C_1(\mathcal{H}, \rho)) \cdot \exp\{-C_2(\mathcal{H}, \rho) \cdot m\epsilon^2\}.$$

Определение. Энтропийным числом $\epsilon_n(\mathcal{H})$ порядка n для функционального класса \mathcal{H} в пространстве $\mathcal{C}(X)$ называется следующая характеристика:

$$\epsilon_n(\mathcal{H}) := \inf\left\{\epsilon : \exists f_1, \dots, f_{2^n} \in \mathcal{H} : \mathcal{H} \subset \bigcup_{j=1}^{2^n} (f_j + \epsilon U(\mathcal{C}(X)))\right\},$$

где $U(\mathcal{C}(X))$ – единичный шар в пространстве $\mathcal{C}(X)$.

Для случая, когда \mathcal{H} задаётся скоростью убывания своих энтропийных чисел, мы имеем следующую оценку для вероятностных хвостов (5):

Теорема 3. Пусть мера ρ удовлетворяет условиям (6) и (7) и для некоторых $r > 0$, $C > 0$ и всех натуральных чисел $n \in \mathbb{N}$ выполняются неравенства $\epsilon_n(\mathcal{H}) \leq Cn^{-r}$. Тогда существуют положительные константы $C_1(r, \rho), C_2(r, \rho) > 0$, такие что

$$\Pr\{\mathcal{E}(f_{\mathcal{H}, z}) - \mathcal{E}(f_\rho) \geq \epsilon\} \leq e^{-C_1 \cdot m\epsilon^2}, \quad \text{как только } \epsilon \cdot m^{\frac{r}{1+2r}} > C_2.$$

Для доказательства предыдущих теорем мы используем несколько промежуточных результатов. Пусть для меры ρ выполняются условия (6) и (7). Тогда верны утверждения:

Лемма 4. Пусть функция $f \in \mathcal{H}$ имеет конечную ошибку $\mathcal{E}(f)$. Тогда для некоторой константы $C = C(\mathcal{H}, \rho) > 0$ и для всех $\epsilon > 0$ имеет место оценка:

$$\Pr\{\mathcal{E}(f) - \mathcal{E}_z(f) > \epsilon\} \leq 2 \exp\{-C \cdot m\epsilon^2\}.$$

Лемма 5. Существуют константы $C_j(\mathcal{H}, \rho) > 0$, $j = 1, 2$, такие что для $\epsilon > 0$ верно:

$$\Pr\{\sup_{f \in \mathcal{H}} |\mathcal{E}(f) - \mathcal{E}_z(f)| > \epsilon\} \leq 2 N(\mathcal{H}, \epsilon/C_1(\mathcal{H}, \rho)) \cdot \exp\{-C_2(\mathcal{H}, \rho) \cdot m\epsilon^2\}.$$

Многие авторы изучали вопросы качества и оптимальности оценивания f_ρ в случае, когда на меру ρ наложены более простые условия ограниченности вида

$|y| < M$ ρ -п.н. для некоторого фиксированного $M > 0$, см.^{17,18,19}. Наш основной вклад заключается в перенесении части их результатов на случай неограниченных y -ов.

Определение. Колмогоровским поперечником порядка n для семейства функций $\mathcal{H} \subset \mathcal{C}(X)$ называется число $d_n(\mathcal{H}, \mathcal{C}(X))$, определяемое как

$$d_n(\mathcal{H}, \mathcal{C}(X)) = \inf_{L_n} \sup_{f \in \mathcal{H}} \inf_{g \in L_n} \|f - g\|_{\mathcal{C}(X)},$$

где \inf_{L_n} берётся по всем n -мерным линейным подпространствам в $\mathcal{C}(X)$.

Колмогоровские поперечники часто используются в теории приближений и описывают наилучшие приближения n -мерными линейными подпространствами. Известно, что если $\mathcal{H} \subset \mathcal{C}(X)$ — компактное множество, то из условия на убывание Колмогоровских поперечников вида

$$d_n(\mathcal{H}, \mathcal{C}(X)) \leq C_1 \cdot n^{-r}, \quad n = 1, 2, \dots \quad (8)$$

следуют неравенства для энтропийных чисел²⁰:

$$\epsilon_n(\mathcal{H}, \mathcal{C}(X)) \leq C_2 \cdot n^{-r}, \quad n = 1, 2, \dots \quad (9)$$

Наш следующий результат усиливает оценки **Теоремы 3**:

Теорема 6. Пусть мера ρ удовлетворяет условиям (6) и (7). Предположим также, что существуют такие $C, r > 0$, что выполняются неравенства:

$$d_n(\mathcal{H}, \mathcal{C}(X)) \leq C \cdot n^{-r}, \quad n = 1, 2, \dots$$

Тогда существует такой оценщик f_z , что для некоторых констант $C_1(\mathcal{H}, \rho)$, $C_2(\mathcal{H}, \rho)$ выполняются неравенства:

$$\Pr\{\mathcal{E}(f_z) - \mathcal{E}(f_\rho) \geq \epsilon\} \leq e^{-C_1 \cdot m \epsilon^2}, \quad \text{как только } \epsilon \cdot m^{\frac{r}{1+2r}} \cdot \left(\frac{m}{\ln m}\right)^{\frac{r}{1+2r}} > C_2.$$

¹⁷F.Cucker, S.Smale, *On the mathematical foundations of learning*, Bulletin of AMS, **39** (2001), p.1-49.

¹⁸R.DeVore, G.Kerkyacharian, D.Picard, V.Temlyakov, *On Mathematical Methods of Learning*. IMI Preprints, **10** (2004), p.1-24.

¹⁹L.Gyorfi, M.Kohler, A.Krzyzak, H.Walk, *A Distribution-Free Theory of Nonparametric Regression*, Springer Series in Statistics (2002).

²⁰B.Carl, *Entropy numbers, s-numbers, and eigenvalue problems*, J. Funct. Anal., **41** (1981), p.290-306.

Опишем следствие из этой теоремы. Пусть $p > 0$ действительное число. Определим класс гладких порядка p действительнозначных функций \mathcal{H}_p^d на единичном кубе в \mathbb{R}^d следующим образом.

Определение. Представим действительное число $p > 0$ в виде $p = k + \beta$, где $k \in \mathbb{N}$, и $0 < \beta \leq 1$ и определим класс \mathcal{H}_p^d функций $f : [0, 1]^d \rightarrow \mathbb{R}$ следующими условиями. Скажем, что $f \in \mathcal{H}_p^d$ если и только если у f существуют все частные производные порядка k , все они удовлетворяют условию Гёльдера с параметром β на множестве $[0, 1]^d$, и $\|f\|_{\mathcal{C}(X)} \leq 1$.

Известно, что для пространства $\mathcal{H} = \mathcal{H}_p^d$ энтропийные числа и Колмогоровские поперечники удовлетворяют неравенствам (8) и (9) с показателем $r = p/d$, см.²¹, что даёт нам экспоненциальные оценки для случая, когда пространство гипотез для $f_\rho(x)$ представляет хорошо изученный класс гладких функций \mathcal{H}_p^d . Отметим, что оценщик из **Теоремы 6** представляет из себя более сложную конструкцию, чем рассматриваемый ранее $f_{\mathcal{H}, z}$, на котором достигается минимум эмпирической ошибки для класса \mathcal{H} .

Последняя часть наших результатов касается построения универсальных оценщиков.

Определение. Для подпространства L в пространстве непрерывных функций $\mathcal{C}(X)$ определим расстояние до функционального класса \mathcal{H} как

$$d(\mathcal{H}, L) := \sup_{f \in \mathcal{H}} \inf_{g \in L} \|f - g\|_\infty. \quad (10)$$

Пусть $\mathcal{L} = \{L_n\}_{n=1}^\infty$ — последовательность n -мерных ($n = 1, 2, \dots$) подпространств в $\mathcal{C}(X)$, и $0 < \alpha \leq \beta < \infty$ — действительные числа. Пусть также C, D — некоторые фиксированные положительные константы и $r \in [\alpha, \beta]$. Обозначим через \mathcal{H}_r произвольное ограниченное семейство функций в пространстве $\mathcal{C}(X)$, удовлетворяющее свойствам:

$$d(\mathcal{H}_r, L_n) \leq C \cdot n^{-r}, n = 1, 2, \dots; \quad \sup_{f \in \mathcal{H}_r} \|f\|_{\mathcal{C}(X)} \leq D.$$

Наконец обозначим

$$\mathcal{H}(\alpha, \beta) = \{\mathcal{H}_r, r \in [\alpha, \beta]\},$$

²¹В.Тихомиров, *Теория приближений*. Совр. проблемы математики. Фундаментальные направления, **14** (1987), (Итоги науки и техн.), ВИНТИ АН СССР.

Такое условие возникло в работе¹⁸ и является близким к естественным в теории приближений условиям на убывание Колмогоровских поперечников. Справедлива

Теорема 7. Предположим, что для меры ρ выполняются условия (6) и (7), где \mathcal{H} имеет вид $\mathcal{H} = \mathcal{H}(\alpha, \beta)$ и $0 < \alpha \leq \beta < \infty$. Тогда существует универсальный оценщик f_z и такие положительные константы $C_1(\mathcal{H}, \rho, \alpha), C_2(\mathcal{H}, \rho, \alpha)$, что если $f_\rho \in \mathcal{H}_r \subset \mathcal{H}(\alpha, \beta)$, для некоторого $r \in [\alpha, \beta]$, то верна оценка

$$\Pr\{\mathcal{E}(f_z) - \mathcal{E}(f_\rho) \geq \epsilon\} \leq e^{-C_1 \cdot m\epsilon^2}, \quad \text{как только } \epsilon \cdot m^{\frac{2r}{1+2r}} \cdot \left(\frac{m}{\ln m}\right)^{\frac{r}{1+2r}} > C_2.$$

Оценка этой теоремы слабее, чем предыдущий результат, однако и пространство \mathcal{H} теперь гораздо шире. Существование универсального семейства конечномерных подпространств $\mathcal{L} = \{L_n\}$, оптимального в смысле расстояния (10) к Колмогоровским поперечникам для всех \mathcal{H}_r , $r \in [\alpha, \beta]$ — непростой вопрос из теории приближений. Однако известно, что для случая $d = 1$ и пространств \mathcal{H}_p^1 в качестве такого семейства $\mathcal{L} = \{L_n\}$ можно взять конечномерные пространства тригонометрических полиномов, см.²¹ Отсюда получаем такое следствие:

Следствие. Предположим, что для меры ρ выполняются условия (6) и (7). Пусть также $0 < \alpha \leq \beta < \infty$ — фиксированные числа и \mathcal{H} имеет вид $\mathcal{H}(\alpha, \beta) = \{\mathcal{H}_r^1, \alpha \leq r \leq \beta\}$. Тогда существует универсальный для всех r оценщик f_z и такие положительные константы $C_1(\mathcal{H}, \rho, \alpha), C_2(\mathcal{H}, \rho, \alpha)$, что если $f_\rho \in \mathcal{H}_r$, то верно неравенство:

$$\Pr\{\mathcal{E}(f_z) - \mathcal{E}(f_\rho) \geq \epsilon\} \leq e^{-C_1 \cdot m\epsilon^2}, \quad \text{как только } \epsilon \cdot m^{\frac{2r}{1+2r}} \cdot \left(\frac{m}{\ln m}\right)^{\frac{r}{1+2r}} > C_2.$$

Известно, что $\mathcal{H}_r^1 \subset \mathcal{H}_s^1$ при $0 < s < r$. Отсюда ясно, что последнее условие на ϵ и m в предыдущем утверждении можно всегда заменить на такое: $\epsilon \cdot m^{\frac{2\alpha}{1+2\alpha}} \cdot \left(\frac{m}{\ln m}\right)^{\frac{\alpha}{1+2\alpha}} > C_2$.

Автор глубоко благодарен своему научному руководителю профессору Ю.Н. Тюрину за постоянное внимание к работе, а также Е.Д. Лившицу, профессору В.Н. Темлякову и профессору С.В. Конягину за многочисленные полезные и плодотворные обсуждения.

Список литературы

- [1] Рафиков Е. Г. Оценивание функции регрессии в случае неограниченных откликов. // Математические Заметки, 79 (2006), № 6, стр. 231-235.
- [2] Рафиков Е. Г. О скорости сходимости частот к вероятностям. // Обозрение прикладной и промышленной математики, 13 (2006), № 3, стр. 632-643.
- [3] Рафиков Е. Г. Обучение функции регрессии для неограниченных откликов. // Депонировано в ВИНИТИ РАН. 2006. N1621-B2006.
- [4] Rafikov E. About Regression Function Estimation in the Case of Unbounded Responses. // Тезисы докладов конференции «26-я Европейская Конференция по Математической Статистике», Торунь, 2006, стр. 345-346.
- [5] Rafikov E., Livshitz E. About Universal Estimators in Learning Theory. // Тезисы докладов конференции «25-я Европейская Конференция по Математической Статистике», Осло, 2005, стр. 237-238.
- [6] Rafikov E. About Rates of Convergence of Empirical Frequencies to the True Probabilities. // Тезисы докладов Российско-Скандинавский Симпозиума «Теоретическая и Прикладная Теория Вероятностей», Петрозаводск, 2006, стр. 41-43.