

Неравенства концентрации вероятностной меры в трансдуктивном обучении и РАС-Байесовском анализе

Толстихин Илья Олегович

Диссертация на соискание ученой степени
кандидата физико-математических наук
05.13.17 — теоретические основы информатики

Научный руководитель — д. ф.-м. н. Воронцов Константин Вячеславович

Москва — 2014

Содержание

- 1. Неравенства концентрации вероятностной меры**
Новые неравенства для выборки без возвращения
- 2. Теория статистического обучения**
Локальные меры сложности в трансдуктивном обучении
- 3. Комбинаторная теория переобучения**
Точные оценки для подмножеств шара в Булевом кубе
- 4. PAC-Байесовский анализ**
PAC-Байесовское эмпирическое неравенство Бернштейна

Содержание

1. **Неравенства концентрации вероятностной меры**
Новые неравенства для выборки без возвращения
2. **Теория статистического обучения**
Локальные меры сложности в трансдуктивном обучении
3. **Комбинаторная теория переобучения**
Точные оценки для подмножеств шара в Булевом кубе
4. **РАС-Байесовский анализ**
РАС-Байесовское эмпирическое неравенство Бернштейна

Неравенства концентрации вероятностной меры

- ▶ Измеримое пространство $(\mathcal{X}, \mathcal{A})$
- ▶ Измеримое отображение $g: \mathcal{X}^n \rightarrow \mathbb{R}$
- ▶ Последовательность случайных величин $X_1, \dots, X_n \subset \mathcal{X}$
- ▶ Случайная величина $Q = g(X_1, \dots, X_n)$

Задача: получить верхние оценки для

$$Q - \mathbb{E}[Q] \quad \text{и} \quad \mathbb{E}[Q] - Q,$$

справедливые с большой вероятностью.

- ▶ **Суммы** $S_n = \frac{1}{n} \sum_{i=1}^n X_n$ ограниченных с.в. $X_1, \dots, X_n \subset [0, 1]$.
- ▶ **Супремум эмпирических процессов**

$$Q_n = \sup_{f \in \mathcal{F}} \frac{1}{n} \sum_{i=1}^n f(X_i),$$

где \mathcal{F} — счетный класс измеримых отображений $f: \mathcal{X} \rightarrow [-1, 1]$, таких что $\mathbb{E}[f(X_1)] = 0$.

Обзор: независимые случайные величины

Случай, когда с. в. X_1, \dots, X_n **независимы**, хорошо изучен.

Пусть $\delta \in [0, 1]$. Тогда с вер-ю не меньше $1 - \delta$:

- ▶ Для **сумм** S_n :

$$|S_n - \mathbb{E}[S_n]| \leq \sqrt{\frac{\log \frac{2}{\delta}}{2n}}; \quad (\text{W. Hoeffding, 1963})$$

$$|S_n - \mathbb{E}[S_n]| \leq \sqrt{\frac{2 \mathbb{D}[X_1] \log \frac{2}{\delta}}{n}} + \frac{2 \log \frac{1}{\delta}}{3n}. \quad (\text{С. Н. Бернштейн, 1911})$$

- ▶ Для **супремумов эмпирических процессов** Q_n :

$$|Q_n - \mathbb{E}[Q_n]| \leq \sqrt{\frac{2 \log(2/\delta)}{n}}; \quad (\text{С. McDiarmid, 1989})$$

$$Q_n - \mathbb{E}[Q_n] \leq \sqrt{\frac{2v \log(1/\delta)}{n}} + \frac{2 \log(1/\delta)}{3n}, \quad (\text{M. Talagrand, 1996})$$

где $v = \sup_{f \in \mathcal{F}} \mathbb{D}[f(X_1)] + 2\mathbb{E}[Q_n]$.

Основная мысль: учет дисперсии может вести к более точным оценкам.

Обзор: выборки без возвращения

Пусть элементы X_1, \dots, X_n выбраны **равномерно без возвращения** из некоторого конечного множества $\mathcal{C} = \{c_1, \dots, c_N\}$, где $N \geq n$.

Пример: процедуры скользящего контроля.

- ▶ **Суммы** S_n для $\mathcal{C} \subset [0, 1]$:

(Hoeffding, 1963) Неравенства Хефдинга и Бернштейна остаются справедливыми для S_n .

- ▶ **Супремумы эмпирических процессов** Q_n :

(El-Yaniv, Pechonyu, 2009) Для $\delta \in [0, 1]$ с вер-ю не меньше $1 - \delta$:

$$|Q_n - \mathbb{E}[Q_n]| \leq \sqrt{\left(\frac{N-n}{N-1/2}\right) \frac{1}{\Delta(n, N)} \frac{2 \log(2/\delta)}{n}},$$

где $\Delta(n, N) = 1 - \frac{1}{2 \max\{n, N-n\}} \approx 1$.

Проблема: отсутствие аналога неравенства Талагранна для выборок без возвращения.

Новые результаты

Пусть $(X_i)_{i=1}^n$ и $(Z_i)_{i=1}^n$ выбраны равномерно без и с возвращением соответственно из конечного множества $\mathcal{C} = \{c_1, \dots, c_N\}$.

$$Q_n = \sup_{f \in \mathcal{F}} \frac{1}{n} \sum_{i=1}^n f(X_i), \quad Q_n^{iid} = \sup_{f \in \mathcal{F}} \frac{1}{n} \sum_{i=1}^n f(Z_i), \quad \sigma_{\mathcal{F}}^2 = \sup_{f \in \mathcal{F}} \mathbb{D}[f(Z_1)].$$

Теорема (Толстихин, ИОИ 2012; Tolstikhin et al., COLT 2014)

Для всех $\delta \in [0, 1]$ с вер-ю не меньше $1 - \delta$:

$$|Q_n - \mathbb{E}[Q_n]| \leq 2 \sqrt{\frac{2\sigma_{\mathcal{F}}^2 \log(2/\delta)}{n}} \left(\frac{N}{n} \right).$$

Теорема (Tolstikhin et al., COLT 2014)

Для всех $\delta \in [0, 1]$ с вер-ю не меньше $1 - \delta$:

$$Q_n - \mathbb{E}[Q_n^{iid}] \leq \sqrt{\frac{2(\sigma_{\mathcal{F}}^2 + 2\mathbb{E}[Q_n^{iid}]) \log(1/\delta)}{n}} + \frac{\log(1/\delta)}{3n}.$$

Содержание

1. **Неравенства концентрации вероятностной меры**
Новые неравенства для выборки без возвращения
2. **Теория статистического обучения**
Локальные меры сложности в трансдуктивном обучении
3. **Комбинаторная теория переобучения**
Точные оценки для подмножеств шара в Булевом кубе
4. **РАС-Байесовский анализ**
РАС-Байесовское эмпирическое неравенство Бернштейна

Теория статистического обучения: индуктивная постановка

- ▶ Неизвестное вероятностное распределение P на $\mathcal{X} \times \mathcal{Y}$.
- ▶ Объекты обучающей выборки $S = \{(X_i, Y_i)\}_{i=1}^n$ н. о. р. из P .
- ▶ Эмпирический и средний риск

$$L_n(h) = \frac{1}{n} \sum_{i=1}^n \ell(h(X_i), Y_i), \quad L(h) = \mathbb{E}_{(X,Y) \sim P} [\ell(h(X), Y)]$$

для функции потерь $\ell: \mathcal{Y} \times \mathcal{Y} \rightarrow [0, 1]$ и отображений $h: \mathcal{X} \rightarrow \mathcal{Y}$.

Задача обучения: минимизация $L(h)$ по классу \mathcal{H} на основе S .

Минимизация эмпирического риска (МЭР):

$$\min_{h \in \mathcal{H}} L_n(h) = L_n(\hat{h}_n).$$

Нас интересуют верхние границы для $L(\hat{h}_n) - \inf_{h \in \mathcal{H}} L(h)$.

Теория Вапника-Червоненкиса (В. Н. Вапник, А. Я. Червоненкис, 1968):

Переход к рассмотрению равномерных по классу \mathcal{H} отклонений:

$$L(\hat{h}_n) - \inf_{h \in \mathcal{H}} L(h) \leq 2 \sup_{h \in \mathcal{H}} |L(h) - L_n(h)|.$$

Оценки в теории статистического обучения

Отказ от наложения дополнительных условий на распределение P и класс \mathcal{H} ведет к **медленным скоростям сходимости** $O(n^{-1/2})$:

- ▶ (В. Н. Вапник, А. Я. Червоненкис, 1968):
Бинарная функция потерь, VC-dimension
- ▶ (В. Н. Вапник, А. Я. Червоненкис, 1974, 1981):
Ограниченные функции потерь, метрическая энтропия
- ▶ (Koltchinskii, Panchenko, 1999; Bartlett, Mendelson, 2001)
Оценки на основе *глобальных Радемахеровских сложностей*

Эти результаты основаны на неравенствах Хефдинга и МакДиармида.

Однако, учет особенностей конкретных задач часто может вести к **быстрым скоростям сходимости** $o(n^{-1/2})$:

- ▶ (Mammen, Tsybakov, 1999):
Условия малого шума: $|\mathbb{P}\{Y = 1|X\} - 0.5| > s$ для $s > 0$.
- ▶ (Massart, 2000; Bartlett et al., 2005; Koltchinskii, 2006):
Локальный подход, локальные Радемахеровские сложности

Эти результаты основаны **на неравенстве Талагранна**.

Теория статистического обучения: трансдуктивная постановка

(В. Н. Вапник, 1998)

- ▶ n объектов \mathbf{X}_n выбраны равномерно **без возвращения** из конечной генеральной совокупности $\mathbf{X}_N = \{\mathbf{X}_i\}_{i=1}^N$.
- ▶ Получаем ответы \mathbf{Y}_n для объектов \mathbf{X}_n с помощью $\varphi: \mathcal{X} \rightarrow \mathcal{Y}$.
- ▶ Обозначим $\ell_h(\mathbf{X}) = \ell(h(\mathbf{X}), \varphi(\mathbf{X}))$ для $\ell: \mathcal{Y} \times \mathcal{Y} \rightarrow [0, 1]$.
- ▶ Получаем обучающую выборку $S = (\mathbf{X}_n, \mathbf{Y}_n)$ и объекты контрольной выборки $\mathbf{X}_u = \mathbf{X}_N \setminus \mathbf{X}_n$, где $u = N - n$.
- ▶ $\hat{L}_n(h)$, $L_u(h)$ и $L_N(h)$ — среднее выборочное значение риска h на выборках \mathbf{X}_n , \mathbf{X}_u и \mathbf{X}_N соответственно.

Задача обучения: поиск на основе S и \mathbf{X}_u отображения $h \in \mathcal{H}$ с малым средним риском на контрольной выборке \mathbf{X}_u .

$$\hat{h}_n = \arg \min_{h \in \mathcal{H}} \hat{L}_n(h), \quad h_u^* = \arg \min_{h \in \mathcal{H}} L_u(h), \quad h_N^* = \arg \min_{h \in \mathcal{H}} L_N(h).$$

Проблема: отсутствие оценок для $L_u(\hat{h}_n) - L_u(h_u^*)$, ведущих к быстрым скоростям сходимости **в общих предположениях.**

Новые результаты

Рассмотрим $h \in \mathcal{H}$ с малыми дисперсиями избыточных потерь:

$$\mathcal{H}(r) = \left\{ h \in \mathcal{H} : \mathbb{E} \left[(\ell_h(X) - \ell_{h_N^*}(X))^2 \right] \leq r \right\}.$$

Пусть $L_n^{\text{iid}}(h) = \frac{1}{n} \sum_{i=1}^n \ell_h(Z_i)$ для случайных величин $\{Z_i\}_{i=1}^n$, выбранных равномерно с возвращениями из \mathbf{X}_N .

Теорема (Tolstikhin et al., COLT 2014)

Пусть для некоторой константы $B > 0$ и для всех $h \in \mathcal{H}$ выполнено:

$$\mathbb{D} [\ell_h(X) - \ell_{h_N^*}(X)] \leq B \cdot (L_N(h) - L_N(h_N^*)).$$

Пусть, кроме того, существует подкоренная функция $\psi_n(r)$, такая что:

$$B \cdot \mathbb{E} \left[\sup_{h \in \mathcal{H}(r)} L_N(h) - L_n^{\text{iid}}(h) - (L_N(h_N^*) - L_n^{\text{iid}}(h_N^*)) \right] \leq \psi_n(r).$$

Пусть r_n^* — неподвижная точка $\psi_n(r)$. Тогда с вер-ю не меньше $1 - \delta$:

$$L_N(\hat{h}_n) - L_N(h_N^*) \leq \frac{901}{B} r_n^* + (16 + 25B) \frac{\log(1/\delta)}{3n}.$$

Новые результаты

Теорема (Tolstikhin et al., COLT 2014)

В условиях прошлой теоремы, с вер-ю не меньше $1 - \delta$:

$$L_u(\hat{h}_n) - L_u(h_u^*) \leq \frac{901N}{B} \left(\frac{r_n^*}{u} + \frac{r_u^*}{n} \right) + \frac{(32 + 50B)N \log(2/\delta)}{3nu}.$$

Известны используемые на практике случаи, когда $r_n^* = o(n^{-1/2})$:

- ▶ (Massart, 2000)

Для задач с бинарной функцией потерь и $VCD(\mathcal{H}) = d < \infty$ справедливо $r_n^* \sim \frac{d \log n}{n}$.

Условия теорем выполнены, например, в следующих случаях:

- ▶ (Lee, Bartlett, Williamson, 1998)

Для задач с равномерно ограниченным выпуклым классом \mathcal{H} и квадратичной функцией потерь $\ell(y', y'') = (y' - y'')^2$;

- ▶ (Mammen, Tsybakov, 1999)

Для задач с бинарной функцией потерь при $\varphi \in \mathcal{H}$.

Содержание

1. **Неравенства концентрации вероятностной меры**
Новые неравенства для выборки без возвращения
2. **Теория статистического обучения**
Локальные меры сложности в трансдуктивном обучении
3. **Комбинаторная теория переобучения**
Точные оценки для подмножеств шара в Булевом кубе
4. **РАС-Байесовский анализ**
РАС-Байесовское эмпирическое неравенство Бернштейна

Комбинаторная теория переобучения

Основная задача: получение точных оценок вер-ти переобучения

$$P \left\{ L_u(\mu(S)) - \hat{L}_n(\mu(S)) \geq t \right\}$$

для различных методов обучения $\mu: S \rightarrow \mathcal{H}$ и семейств \mathcal{H} .

Главные отличия от трансдуктивного обучения и VC-теории:

- ▶ Отказываемся от рассмотрения чрезмерно общих постановок.
- ▶ Отказываемся от часто завышенных неравенств концентрации.
- ▶ Учет «геометрии» множества **бинарных** векторов ошибок отображений из \mathcal{H} на **конечной** генеральной совокупности \mathbf{X}_N :

$$A = \left\{ ([h \text{ ошибается на } X_i])_{i=1}^N, h \in \mathcal{H} \right\} \subseteq \{0, 1\}^N.$$

Главные результаты и подходы:

- ▶ Оценки на основе порождающих и запрещающих множеств
- ▶ Оценки расслоения-связности
- ▶ **Теоретико-групповой подход** (А. И. Фрей, 2009)

Новые результаты

Для $a \in A$ и $\mathbf{X} \subseteq \mathbf{X}_N$ обозначим:

$$L(a, \mathbf{X}) = \frac{1}{|\mathbf{X}|} \sum_{X \in \mathbf{X}} I(a, X), \quad A(\mathbf{X}) = \arg \min_{a \in A} L(a, \mathbf{X}).$$

Рандомизированный метод МЭР μ на основе обучающей выборки \mathbf{X}_n выбирает вектор ошибок случайно и равномерно из $A(\mathbf{X}_n)$.

Симметрическая группа перестановок S_N и подгруппа симметрий A :

$$S(A) = \{\pi \in S_N : \pi A = A\}.$$

Γ и Ω : множества орбит действия $S(A)$ на A и $\{\mathbf{X} \subseteq \mathbf{X}_N : |\mathbf{X}| = n\}$.

Теорема (Толстихин, ИОИ 2010; Фрей, Толстихин, ДАН 2014, JMLDA 2014)

Для рандомизированного МЭР μ справедливо:

$$\begin{aligned} & P \{L(\mu(S_n), X_u) - L(\mu(S_n), X_n) \geq t\} = \\ & \sum_{\gamma \in \Gamma} \sum_{\omega \in \Omega} \frac{|\gamma|}{C_N^n} |\{\mathbf{X} \in \omega : a_\gamma \in A(\mathbf{X})\}| \frac{[L(a_\gamma, \mathbf{X}_N \setminus \mathbf{X}_\omega) - L(a_\gamma, \mathbf{X}_\omega) \geq t]}{|A(\mathbf{X}_\omega)|}, \end{aligned}$$


где a_γ и \mathbf{X}_ω — произвольные элементы орбит γ и ω .

Новые результаты


Теорема (Толстихин, ИОИ 2010; Фрей, Толстихин, ДАН 2014, JMLDA 2014)

Получены точные оценки для следующих модельных семейств A :


- ▶ Хэммингов шар;
- ▶ Центральный слой Хэммингова шара;
- ▶ d нижних слоев Хэммингова шара;




слой



шар



слой шара



нижние
слои шара

Содержание

- 1. Неравенства концентрации вероятностной меры**
Новые неравенства для выборки без возвращения
- 2. Теория статистического обучения**
Локальные меры сложности в трансдуктивном обучении
- 3. Комбинаторная теория переобучения**
Точные оценки для подмножеств шара в Булевом кубе
- 4. PAC-Байесовский анализ**
PAC-Байесовское эмпирическое неравенство Бернштейна

РАС-Байесовский анализ (Probably Approximately Correct)

РАС-Байесовский анализ изучает стохастические предикторы в индуктивной постановке теории статистического обучения:

- ▶ Рассмотрим вероятностное распределение ρ на \mathcal{H}
- ▶ Для каждого нового $X \in \mathcal{X}$ стохастический предиктор G_ρ :
 1. Выбирает $h \sim \rho$ независимо от X ;
 2. Возвращает ответ $h(X)$.
- ▶ Для краткости будем обозначать $\langle \cdot, \rho \rangle = \mathbb{E}_{h \sim \rho}[\cdot]$.
- ▶ Определим средний и эмпирический риск предиктора G_ρ :

$$L(G_\rho) = \langle L(h), \rho \rangle, \quad L_n(G_\rho) = \langle L_n(h), \rho \rangle.$$

- ▶ **Задача обучения:** поиск на основе обучающей выборки S распределения ρ с малым средним риском $L(G_\rho)$.

Пусть $\text{KL}(\rho \parallel \pi) = \left\langle \frac{\rho(h)}{\pi(h)}, \rho \right\rangle$ — дивергенция Кульбака–Лейблера между двумя распределениями ρ и π на \mathcal{H} .

Обзор: PAC-Байесовские неравенства

Для любого *не зависящего от S_n* распределения π на \mathcal{H} , любых $c > 1$ и $\delta > 0$ с вероятностью не меньше $1 - \delta$ (относительно реализации обучающей выборки S_n) следующие неравенства:

Н-во МакАллистера (McAllester, 1998)

$$L(G_\rho) \leq L_n(G_\rho) + \frac{1+c}{2} \sqrt{\frac{\text{KL}(\rho \|\pi) + \ln(1/\delta)}{2n}};$$

PAC-Байесовское н-во Бернштейна (Seldin et al., 2012)

$$L(G_\rho) \leq L_n(G_\rho) + (1+c) \sqrt{\langle \mathbb{D}_{(X,Y) \sim P}[\ell_h(X,Y)], \rho \rangle \frac{\text{KL}(\rho \|\pi) + \ln(1/\delta)}{n}};$$

PAC-Байесовское kl-неравенство (Seeger, 2002)

$$L(G_\rho) \leq L_n(G_\rho) + \sqrt{2L_n(G_\rho) \frac{\text{KL}(\rho \|\pi) + \ln \frac{n+1}{\delta}}{n}} + \frac{\text{KL}(\rho \|\pi) + \ln \frac{n+1}{\delta}}{n};$$

справедливы **одновременно для всех распределений ρ на \mathcal{H} .**

Обзор: применение PAC-Байесовских неравенств

$$P \left\{ \forall \rho \text{ на } \mathcal{H}: L(G_\rho) \leq L_n(G_\rho) + C \sqrt{\frac{\text{KL}(\rho \parallel \pi) + \ln(1/\delta)}{n}} \right\} \geq 1 - \delta$$

- ▶ Минимизация оценки по ρ ведет к новым алгоритмам обучения с гарантированной обобщающей способностью.
- ▶ (Germain et al., 2014)
Получение оценок для композиций классификаторов.
- ▶ (Langford, Shawe-Taylor, 2002)
Часто средний риск $L(h)$ отображений из \mathcal{H} удается оценить сверху средним риском $L(G_\rho)$ со специально подобранным ρ .
- ▶ PAC-Байесовские неравенства ведут к **наиболее точным** на сегодняшний день оценкам для линейных классификаторов.

Часто PAC-Байесовское неравенство Бернштейна существенно точнее kl-неравенства.

Проблема: дисперсия $\langle \mathbb{D}_{(X,Y) \sim P}[\ell_h(X, Y)], \rho \rangle$ нам неизвестна.

Новые результаты

Рассмотрим выборочную дисперсию потерь отображения h :

$$\mathbb{D}_n(h) = \frac{1}{n-1} \sum_{i=1}^n (\ell_h(X_i, Y_i) - L_n(h))^2.$$

Теорема (Tolstikhin, Seldin, NIPS 2014)

Для любого не зависящего от S_n распределения π на \mathcal{H} и любых $c > 1$, $\delta > 0$ с вер-ю не меньше $1 - \delta$:

$$\begin{aligned} & \langle \mathbb{D}_{(X,Y) \sim P}[\ell_h(X, Y)], \rho \rangle \\ & \leq \langle \mathbb{D}_n(h), \rho \rangle + (1+c) \sqrt{\frac{\langle \mathbb{D}_n(h), \rho \rangle (\text{KL}(\rho \parallel \pi) + \ln \frac{T}{\delta})}{2(n-1)}} + \frac{2c (\text{KL}(\rho \parallel \pi) + \ln \frac{T}{\delta})}{n-1} \end{aligned}$$


одновременно для всех ρ , где

$$T = \left\lceil \frac{1}{\ln c} \ln \left(\frac{1}{2} \sqrt{\frac{n-1}{\ln(1/\delta)}} + 1 + \frac{1}{2} \right) \right\rceil.$$

Новые результаты: эксперименты

Эксперименты на модельных выборках

- ▶ Задача регрессии $\mathcal{Y} = \mathbb{R}$ с классом линейных функций \mathcal{H} .
- ▶ Абсолютные потери $\ell(y', y'') = |y' - y''|$.



Эксперименты на выборках из репозитория UCI

Выборка	n	d	Тест	оценка PB-kl	оценка PB-EB
winequality	6497	11	0.106 ± 0.0022	0.175 ± 0.0006	0.162 ± 0.0006
parkinsons	5875	16	0.188 ± 0.0055	0.266 ± 0.0013	0.250 ± 0.0012
concrete	1030	8	0.111 ± 0.0038	0.242 ± 0.0010	0.264 ± 0.0011

Список публикаций по теме диссертации

1. **I. Tolstikhin**, G. Blanchard, M. Kloft. Localized Complexities for Transductive Learning. // *Conference on Learning Theory (COLT)*, 2014.
2. **I. Tolstikhin**, Y. Seldin. PAC-Bayes-Empirical-Bernstein inequality. // *Advances in Neural Information Processing Systems 26 (NIPS)*, 2013. pp. 109–117.
3. Фрей А. И., **Толстихин И. О.**. Комбинаторные оценки вероятности переобучения на основе покрытий множества алгоритмов. // *Доклады РАН*, Т. 455, №. 3, 2014. С. 265-268.
4. Фрей А. И., **Толстихин И. О.**. Комбинаторные оценки вероятности переобучения на основе кластеризации и покрытий множества алгоритмов. // *Machine Learning and Data Analysis*, V. 1, №. 7, 2014. pp. 761-778.
5. Толстихин И. О. Локализация оценок избыточного риска в комбинаторной теории переобучения. // *Межд. конф. ИОИ-9, Москва, Торус Пресс*, 2012, С. 54-57.
6. Толстихин И. О. Вероятность переобучения плотных и разреженных семейств алгоритмов. // *Межд. конф. ИОИ-8, Москва, МАКС Пресс*, 2010, С. 83-86.
7. Толстихин И. О. Точная оценка вероятности переобучения для одного специального семейства алгоритмов. // *Международ. конф. «Ломоносов 2010», Москва*, 2010, pp. 98-99.

Результаты, выносимые на защиту

1. Получено два новых неравенства типа Талаграна для выборок без возвращения.
2. В задаче трансдуктивного обучения получены первые оценки, основанные на локальных мерах сложности и ведущие к быстрым скоростям сходимости в общих предположениях.
3. В теоретико-групповом подходе комбинаторной теории переобучения предложено рассматривать орбиты действия группы симметрий на множестве разбиений генеральной выборки. На основе этого подхода получены точные оценки вероятности переобучения для трех модельных задач.
4. В PAC-Байесовском анализе теории статистического обучения получено новое PAC-Байесовское эмпирическое неравенство Бернштейна, полностью вычислимое на основе обучающей выборки и во многих случаях ведущее к существенно более точным оценкам по сравнению с другими известными неравенствами.