

Федеральное государственное автономное образовательное  
учреждение высшего образования  
«Национальный исследовательский университет  
«Высшая школа экономики»  
Факультет математики

*на правах рукописи*

Иосипой Леонид Сергеевич  
**Снижение дисперсии оценок Монте-Карло**

Резюме диссертации  
на соискание ученой степени  
кандидата математических наук

Научный руководитель:  
кандидат физико-математических наук,  
профессор Д. В. Беломестный

Москва – 2021

# Введение

В данной работе изучается задача вычисления математического ожидания  $\pi(f) := \mathbb{E}[f(X)]$  некоторой функции  $f : X \rightarrow \mathbb{R}$  от случайного вектора  $X$  с плотностью распределения  $\pi(x)$  и значениями в множестве  $X \subset \mathbb{R}^d$  в предположении, что  $f \in L^2(\pi)$ . Мы будем предполагать, пока не сказано иное, что функция  $f(x)$  и плотность  $\pi(x)$  известны.

Сформулированную задачу можно рассмотреть как задачу вычисления интеграла от функции  $f(x) \cdot \pi(x)$  по множеству  $X$ . Мы будем предполагать, что функция  $f(x)$  и плотность  $\pi(x)$  достаточно сложные, и данный интеграл явно не вычисляется. Поэтому мы будем оценивать его с помощью алгоритмов численного интегрирования. Известно, что любые детерминированные (даже адаптивные) алгоритмы численного интегрирования «страдают» от так называемого «проклятия размерности», которое означает, что сложность данных алгоритмов экспоненциально растет с ростом размерности  $d$ , см., например, классическую работу Н. С. Бахвалова [B71] и современный обзор Е. Новака [N16]. В свою очередь, рандомизированные алгоритмы численного интегрирования, к которым относятся методы Монте-Карло, оказываются эффективнее других подходов к решению данной задачи, если размерность  $d$  является большой и/или функция  $f$  является сложно вычислимой, см., например, обзор Г. Роберта и Д. Розенталя [RR04] или книгу К. Роберта и Д. Каселлы [RC99].

В случае, когда можно получить независимую выборку  $X_1 \dots, X_n$  из распределения с плотностью  $\pi(x)$ , математическое ожидание  $\pi(f)$  можно оценить с помощью оценки Монте-Карло

$$\pi_n(f) := \frac{1}{n} \sum_{k=1}^n f(X_k).$$

Данная оценка является несмещенной, то есть  $\mathbb{E}[\pi_n(f)] = \pi(f)$ , и имеет дисперсию, равную  $\text{Var}(\pi_n(f)) = V(f)/n$ , где, здесь и далее,  $V(f)$  обозначает дисперсию функции  $f$  по отношению к  $\pi$ , то есть

$$V(f) := \text{Var}(f(X)), \quad X \sim \pi.$$

С помощью центральной предельной теоремы можно построить асимптотический доверительный интервал для  $\pi(f)$ , который будет иметь вид

$$\pi_n(f) \pm c \sqrt{\frac{V(f)}{n}}, \tag{1}$$

где  $c$  — квантиль нормального распределения. С точки зрения приложений, интересна задача улучшения точности оценки Монте-Карло  $\pi_n(f)$ , что в свою очередь означает уменьшение длины вышеупомянутого доверительного интервала. Этого можно добиться, увеличив размер выборки  $n$ , но в некоторых случаях данное решение может быть нецелесообразно (например,

в связи со сложностью генерирования случайных величин из плотности  $\pi(x)$  или сложностью вычисления значений функции  $f(x)$ ). Другим походом к уменьшению длины доверительного интервала является уменьшение величины  $V(f)$  за счет перехода к другой оценке Монте-Карло, у которой бы сохранялось среднее, а дисперсия была бы меньше. Такие методы называются методами снижения дисперсии.

По методам снижения дисперсии доступна обширная литература, см., например, классические книги И. Димова [D08], П. Глассермана [G13], Р. Рубинштейна и Д. Кроуза [RK16]. Стоит отметить, что большая часть методов снижения дисперсии явно используют структуру функции  $f(x)$  либо плотности  $\pi(x)$ , поэтому не применимы в самых общих постановках. Одним из немногих общих методов снижения дисперсии является метод контрольных функций. Его идея заключается в следующем. Допустим, нам дан класс функций  $\mathcal{G} \subset L^2(\pi)$ , который обладают свойством, что для любой  $g \in \mathcal{G}$  выполняется  $\pi(g) = 0$ . Такие функции называются контрольными. Тогда можно рассмотреть новую оценку Монте-Карло

$$\pi_n(f - \bar{g}) := \frac{1}{n} \sum_{k=1}^n (f(X_k) - \hat{g}(X_k)),$$

где  $\bar{g}$  — функция из  $\mathcal{G}$ , на которой достигается (или почти достигается) минимум дисперсии  $V(f - g) = \text{Var}(f(X) - g(X))$ ,  $X \sim \pi$ , то есть

$$\bar{g} \in \underset{g \in \mathcal{G}}{\operatorname{argmin}} V(f - g). \quad (2)$$

В случае, когда класс контрольных функций  $\mathcal{G}$  выбран хорошо, такой поход может значительно снизить дисперсию. Здесь возникают два ключевых вопроса. Как конструктивно построить класс контрольных функций  $g \in \mathcal{G}$  и как численно решить задачу (2), так как дисперсия  $V(f - g)$  не предполагается известной, а ее вычисление — более сложная задача, чем исходная.

Вопрос построения класса контрольных функций  $\mathcal{G}$  был изучен ранее в работе А. Миры, Р. Солги, Д. Импарато [MSI13] и работах К. Оутса, М. Джиролами, Н. Шопена [OGC17] и [OGC19], поэтому на нем подробно мы останавливаться не будем. Мы лишь упомянем, что популярным методом построения функций  $g \in \mathcal{G}$  является подстановка в

$$g_\Phi = \langle \Phi, \nabla \log \pi \rangle + \operatorname{div}(\Phi) \quad (3)$$

различных функций  $\Phi : X \rightarrow \mathbb{R}^d$ ; здесь  $\langle \cdot, \cdot \rangle$  — стандартное скалярное произведение в  $\mathbb{R}^d$ , а  $\operatorname{div}(\Phi)$  — дивергенция  $\Phi$ . При достаточно слабых условиях на  $\pi$  и  $\Phi$ , с помощью интегрирования по частям можно показать, что  $\pi(g_\Phi) = 0$ , см. Предложения 1 и 2 в [MSI13]. Контрольные функции вида (3) называются контрольными функциями Стейна.

Что касается вопроса о численном решении задачи (2), кажется естественным заменить истинную дисперсию  $V(f - g)$  на выборочную дисперсию  $V_n(f - g)$ , построенную по выборке

$X_1, \dots, X_n$ , то есть на

$$V_n(f - g) := \frac{1}{n-1} \sum_{k=1}^n (f(X_k) - g(X_k) - \pi_n(f - g))^2. \quad (4)$$

Кроме того, мы также заменим класс  $\mathcal{G}$  на его дискретную конечную аппроксимацию  $\mathcal{G}'$ , так как численная оптимизация по бесконечному множеству функций является сложной задачей, которую в общем случае решить невозможно. Возникает естественный вопрос: сколько мы «проиграем» за счет замены истинной дисперсии на эмпирическую и множества  $\mathcal{G}$  на его аппроксимацию  $\mathcal{G}'$ ? Ответ на этот вопрос является основной целью данной работы.

Настоящее резюме диссертации организовано следующим образом. В Разделе 1 будут сформулированы базовые определения, которые будут использоваться в следующих разделах. В Разделе 2, мы оценим с большой вероятностью разность

$$V(f - \hat{g}) - \inf_{g \in \mathcal{G}} V(f - g), \quad (5)$$

где

$$\hat{g} \in \operatorname{argmin}_{g \in \mathcal{G}'} V_n(f - g), \quad \mathcal{G}' \text{ является } \varepsilon\text{-сетью для } \mathcal{G},$$

а дисперсия  $V(f - \hat{g})$  является условной по выборке  $X_1, \dots, X_n$ , на которой вычислялась оценка  $\hat{g}$ . Подобные оценки часто встречаются в статистической литературе и называются оценками на «решетках» (в английской литературе *skeleton estimates* или *sieve estimates*), см., например, работы В. Вонг и К. Шен [WS95], Л. Девроя, Л. Гёрфи, Г. Лугоши [DGL96] или С. ван де Гир [G00]. Далее, в Разделе 3 мы рассмотрим случай, когда независимую выборку  $X_1, \dots, X_n$  из распределения с плотностью  $\pi(x)$  явно получить нельзя, но сама  $\pi(x)$  является известной (возможно, с точностью до нормировочной константы). В таких случаях часто можно воспользоваться алгоритмами Монте-Карло на основе марковских цепей (MCMC в английской литературе) и получить марковскую цепь  $\{X_k\}_{k=1}^\infty$ , которая сходится по распределению к распределению с плотностью  $\pi(x)$ . Для марковских цепей, при некоторых условиях, также верна центральная предельная теорема и, следовательно, с ее помощью можно построить асимптотический доверительный интервал

$$\pi_n(f) \pm c \sqrt{\frac{V^\infty(f)}{n}}, \quad (6)$$

где  $V^\infty(f)$  — асимптотическая дисперсия, которая определяется как

$$V^\infty(f) := \lim_{n \rightarrow \infty} n \cdot \mathbb{E} \left[ \left( \frac{1}{n} \sum_{k=1}^n f(X_k) - \pi(f) \right)^2 \right]. \quad (7)$$

Ввиду возможных попарных корреляций у цепи  $\{X_k\}_{k=1}^\infty$ , асимптотическая дисперсия  $V^\infty(f)$  не равна в общем случае дисперсии  $V(f)$ . Следовательно, в данном случае целесообразно подбирать контрольные функции  $g \in \mathcal{G}$ , оптимизируя уже асимптотическую дисперсию  $V^\infty(f-g)$ . Так как асимптотическая дисперсия так же, как и обычная дисперсия, не предполагается известной, мы ее заменим на ее оценку по выборке. Итак, в Разделе 3 мы оценим с большой вероятностью разность

$$V^\infty(f - \hat{g}) - \inf_{g \in \mathcal{G}} V^\infty(f - g), \quad (8)$$

где уже для некоторой оценки  $V_n^\infty$  асимптотической дисперсии  $V^\infty$

$$\hat{g} \in \operatorname{argmin}_{g \in \mathcal{G}'} V_n^\infty(f - g), \quad \mathcal{G}' \text{ является } \varepsilon\text{-сетью для } \mathcal{G},$$

а дисперсия  $V^\infty(f - \hat{g})$  является условной по выборке  $X_1, \dots, X_n$ , на которой вычислялась оценка  $\hat{g}$ . Данное обобщение оказывается нетривиальным по двум причинам. Во-первых, в связи с попарными корреляциями, оценивание асимптотической дисперсии возможно несколькими способами и требует специальных техник, таких как спектральные методы или разделение марковской цепи на слабо коррелирующие блоки, см. обзор методов оценки асимптотической дисперсии в работе Д. Флегала и Д. Джонса [FJ10]. Во-вторых, неасимптотический анализ оценки  $f - \hat{g}$  требует обобщения используемых в доказательстве неравенств концентрации на цепи Маркова, которое также не является тривиальным. Мы проведем данный анализ для достаточно широкого класса марковских цепей, который включает в себя многие МСМС алгоритмы. Наконец, в Разделе 4 мы рассмотрим приложения полученных результатов.

## Цель работы

Цель настоящей работы — изучение теоретических свойств описанного выше метода снижения дисперсии оценок Монте-Карло (метода контрольных функций) и, в частности, получение неасимптотических оценок на избыточный риск (5) и (8) в независимом и зависимом случае соответственно.

## 1. Обозначения и определения

Перед тем как сформулировать основные результаты, введем еще некоторые обозначения. Обозначим класс функций  $h(x) = f(x) - g(x)$  для  $g \in \mathcal{G}$  через  $\mathcal{H}$ :

$$\mathcal{H} := \{f - g : g \in \mathcal{G}\},$$

где  $\mathcal{G}$  — класс контрольных функции (то есть таких, что  $\pi(g) = 0$  для всех  $g \in \mathcal{G}$ ). Заметим, что у всех функций  $h \in \mathcal{H}$  будет одинаковое математическое ожидание, равное  $\pi(f)$ . Как уже упоминалось, вместо оптимизации по всему классу  $\mathcal{H}$  мы будем искать минимум в его конечной аппроксимации. Зафиксируем  $\varepsilon > 0$  и положим  $r = 1$  или  $r = 2$ . Предполагая, что класс  $\mathcal{H}$  вполне ограничен, обозначим через  $\mathcal{H}_{\varepsilon,r}$  произвольную минимальную по мощности  $\varepsilon$ -сеть множества  $\mathcal{H}$  в  $L^r(\pi)$ -норме, то есть такой минимальный набор функций  $\mathcal{H}_{\varepsilon,r} = \{h_1, \dots, h_m\} \subset \mathcal{H}$ , что для произвольной  $h \in \mathcal{H}$  существует  $h_* \in \mathcal{H}_{\varepsilon,r}$ , что расстояние между  $h$  и  $h_*$  в  $L^r(\pi)$ -норме не превосходит  $\varepsilon$ . Обозначим метрическую энтропию  $\mathcal{H}$  через  $H_{L^r(\pi)}(\mathcal{H}, \varepsilon) := \log |\mathcal{H}_{\varepsilon,r}|$ , где  $|\mathcal{H}_{\varepsilon,r}|$  — это мощность  $\mathcal{H}_{\varepsilon,r}$ . Далее, определим величину, которая будет использована в основных результатах данной работы:

$$\gamma_{L^r(\pi)}(\mathcal{H}, n) := \inf \{ \eta > 0 : H_{L^r(\pi)}(\mathcal{H}, \eta) \leq n\eta^r \}.$$

Обратим внимание, что  $\eta > 0$ , удовлетворяющее неравенству  $H_{L^r(\pi)}(\mathcal{H}, \eta) \leq n\eta^r$ , существует и конечно, так как метрическая энтропия  $H_{L^r(\pi)}(\mathcal{H}, \eta)$  является убывающей функцией по  $\eta$ , а отображение  $\eta \mapsto n\eta^r$  является строго возрастающим. Значение  $\gamma_{L^r(\pi)}(\mathcal{H}, n)$  будет использовано для того, чтобы оценить мощность класса  $\mathcal{H}_{\varepsilon,r}$ . Действительно, выбирая  $\varepsilon \geq \gamma_{L^r(\pi)}(\mathcal{H}, n)$  мы получим  $|\mathcal{H}_{\varepsilon,r}| \leq e^{n\varepsilon^r}$ . Легко также видеть из определения, что  $\gamma_{L^r(\pi)}(\mathcal{H}, n)$  является убывающей функцией по  $n$ .

Приведем теперь оценку на  $\gamma_{L^r(\pi)}(\mathcal{H}, n)$  в достаточно общем случае, когда  $\mathcal{H}$  является подмножеством взвешенного соболевского пространства. Напомним, что соболевское пространство  $W^{s,p}(\mathbf{X})$  определяется как  $W^{s,p}(\mathbf{X}) = \{h \in L^p(\lambda) : D^\alpha h \in L^p(\lambda), \forall |\alpha| \leq s\}$ , где  $\lambda$  является мерой Лебега,  $\alpha = (\alpha_1, \dots, \alpha_d)$  является мульти-индексом с  $|\alpha| = \alpha_1 + \dots + \alpha_d$ , а  $D^\alpha$  является дифференциальным оператором вида  $D^\alpha = \partial^{|\alpha|} / \partial x_1^{\alpha_1} \dots \partial x_d^{\alpha_d}$ . Здесь все производные понимаются в слабом смысле. Взвешенное соболевское пространство  $W^{s,p}(\mathbf{X}, \langle x \rangle^\beta)$  для полиномиальной весовой функции  $\langle x \rangle^\beta = (1 + \|x\|^2)^{\beta/2}$ ,  $\beta \in \mathbb{R}$ , определяется следующим образом:

$$W^{s,p}(\mathbf{X}, \langle x \rangle^\beta) = \{h \in L^p(\lambda) : h \cdot \langle x \rangle^\beta \in W^{s,p}(\mathbf{X})\}.$$

Норма в данном взвешенном соболевском пространстве определяется как

$$\|h\|_{W_\beta^{s,p}} = \sum_{|\alpha| \leq s} \|D^\alpha (h \cdot \langle x \rangle^\beta)\|_{L^p(\lambda)}.$$

Мы будем говорить, что  $\mathcal{H} \subset W^{s,p}(\mathbf{X}, \langle x \rangle^\beta)$  является ограниченным подмножеством пространства  $W^{s,p}(\mathbf{X}, \langle x \rangle^\beta)$ , если  $\mathcal{H}$  вполне ограничено и существует константа  $c > 0$ , такая что  $\|h\|_{W_\beta^{s,p}} \leq c$  для всех  $h \in \mathcal{H}$ . Верно следующее предложение.

**Предложение 1.** Пусть  $\mathcal{H}$  будет (непустым) ограниченным подмножеством  $W^{s,p}(\mathbb{R}^d, \langle x \rangle^\beta)$ , где  $1 < p < \infty$ ,  $\beta \in \mathbb{R}$  и  $s - d/p > 0$ . Пусть также для некоторого  $\kappa > 0$ ,  $\|\langle x \rangle^{\kappa-\beta}\|_{L^r(\pi)} < \infty$ . Тогда для  $r = 1, 2$ ,

$$\gamma_{L^r(\pi)}(\mathcal{H}, n) \lesssim \begin{cases} n^{-\frac{1}{r+d/s}} & \text{при } \kappa > s - d/p, \\ n^{-\frac{1}{r+(\kappa/d+1/p)^{-1}}} & \text{при } \kappa < s - d/p, \end{cases}$$

где символ  $\lesssim$  означает неравенство с точностью до некоторой константы, не зависящей от  $n$ .

Данный результат получен подстановкой в определение  $\gamma_{L^r(\pi)}(\mathcal{H}, n)$  оценки на энтропию ограниченных подмножеств  $W^{s,p}(\mathcal{X}, \langle x \rangle^\beta)$  из Следствия 4 работы Р. Никля и Б. Петшера [NP07]. Предложение 1 не является основным результатом диссертационной работы и приведено здесь в качестве примера возможных значений величины  $\gamma_{L^r(\pi)}(\mathcal{H}, n)$ , которая далее будет использоваться в основных результатах.

Везде далее распределение с плотностью  $\pi(x)$  и соответствующую ему вероятностную меру мы также будем обозначать буквой  $\pi$ , но это не приведет к двусмысленным трактовкам. Если не оговорено иное, символ  $\lesssim$  будет означать неравенство с точностью до некоторой абсолютной константы, а символ  $\asymp$  будет означать равенство с точностью до абсолютной константы.

## 2. Снижение дисперсии в независимом случае

Перед тем как сформулировать основные результаты для независимого случая, напомним, что для класса  $\mathcal{H} = \{f - g : g \in \mathcal{G}\}$  оценку, свойства которой мы будем изучать, можно записать как

$$\widehat{h}_{\varepsilon,r} \in \operatorname{argmin}_{h \in \mathcal{H}_{\varepsilon,r}} V_n(h),$$

где  $V_n(h)$  — эмпирическая дисперсия, определенная в (4), а  $\mathcal{H}_{\varepsilon,r}$  —  $\varepsilon$ -сеть множества  $\mathcal{H}$  в норме  $L^r(\pi)$ ,  $r = 1, 2$ . Подробные определения даны в Разделе 1. Здесь и далее мы будем предполагать, что функция  $\widehat{h}_{\varepsilon,r}$  существует (все утверждения и их доказательства легко переносятся на случай, когда минимум в классе  $\mathcal{H}_{\varepsilon,r}$  не достигается).

Теперь мы можем перейти к основным результатам раздела. Мы начнем со случая, когда функции  $h \in \mathcal{H}$  являются ограниченными и класс  $\mathcal{H}$  является замкнутым и выпуклым множеством.

**Теорема 2.** Пусть класс  $\mathcal{H}$  является замкнутым и выпуклым множеством. Пусть также  $\sup_{h \in \mathcal{H}} \sup_{x \in \mathcal{X}} |h(x)| \leq b$  для некоторого  $b > 0$  и пусть  $\pi(h) = c$  для всех  $h \in \mathcal{H}$  и некоторой

$c \in \mathbb{R}$ . Тогда для некоторого  $\varepsilon > 0$  (значение которого определено в доказательстве) и любого  $\delta \in (0, 1)$ , с вероятностью не менее  $1 - \delta$ ,

$$V(\widehat{h}_{\varepsilon,1}) - \inf_{h \in \mathcal{H}} V(h) \lesssim b^2 \gamma_{L^1(\pi)}(\mathcal{H}, n) + \frac{b^2 \log(1/\delta)}{n},$$

где первая дисперсия является условной по выборке  $X_1, \dots, X_n$ , на которой считалась оценка  $\widehat{h}_{\varepsilon,1}$ , а символ  $\lesssim$  означает неравенство с точностью до некоторой абсолютной константы.

Теперь сформулируем подобный результат, когда вместо выпуклости класса  $\mathcal{H}$ , мы потребуем, чтобы  $\mathcal{H}$  содержал функцию, тождественно равную константе. Так как по построению  $\pi(h) = \pi(f)$  для всех  $h \in \mathcal{H}$ , эта константа должна быть равна  $\pi(f)$  и, следовательно, в этом случае  $\inf_{h \in \mathcal{H}} V(h) = 0$ .

**Теорема 3.** Пусть класс  $\mathcal{H}$  содержит константную функцию, то есть  $h^*(x) \equiv c$  для некоторой  $h^* \in \mathcal{H}$  и некоторого  $c \in \mathbb{R}$ . Пусть также  $\sup_{h \in \mathcal{H}} \sup_{x \in X} |h(x)| \leq b$  для некоторого  $b > 0$  и пусть  $\pi(h) = c$  для всех  $h \in \mathcal{H}$  и некоторой  $c \in \mathbb{R}$ . Тогда для некоторого  $\varepsilon > 0$  (значение которого определено в доказательстве) и любого  $\delta \in (0, 1)$ , с вероятностью не менее  $1 - \delta$ ,

$$V(\widehat{h}_{\varepsilon,1}) \lesssim b^2 \gamma_{L^1(\pi)}(\mathcal{H}, n) + \frac{b^2 \log(1/\delta)}{n}$$

и

$$V(\widehat{h}_{\varepsilon,2}) \lesssim b^2 (\gamma_{L^2(\pi)}(\mathcal{H}, n))^2 + \frac{b^2 \log(1/\delta)}{n},$$

где дисперсии являются условными по выборке  $X_1, \dots, X_n$ , на которой считались оценки  $\widehat{h}_{\varepsilon,1}$  и  $\widehat{h}_{\varepsilon,2}$ , а символ  $\lesssim$  означает неравенство с точностью до некоторой абсолютной константы.

Предполагая дополнительно к условиям Теоремы 2 или Теоремы 3, что  $\mathcal{H}$  является ограниченным подмножеством некоторого взвешенного соболевского пространства  $W^{s,p}(X, \langle x \rangle^\beta)$ , и используя результат Предложения 1, мы получим окончательную оценку с большой вероятностью вида:

$$V(\widehat{h}_{\varepsilon,1}) - \inf_{h \in \mathcal{H}} V(h) \lesssim n^{-\alpha}, \quad \alpha \in (0, 1), \quad (9)$$

где значение параметра  $\alpha$  будет зависеть от размерности  $d$  и параметров соболевского пространства  $s, p$  и  $\beta$ . Подобные порядки сходимости называются «быстрыми» в статистической литературе, так как позволяют получать скорость сходимости быстрее стандартных порядков  $1/\sqrt{n}$  при параметрическом оценивании. В качестве следствия стоит отметить, что порядок длины асимптотического доверительного интервала (1) с помощью данной процедуры снижения дисперсии можно уменьшить с  $n^{-1/2}$  до  $n^{-1/2-\alpha/2}$ , если класс  $\mathcal{H}$  выбран так, что  $\inf_{h \in \mathcal{H}} V(h) \lesssim n^{-\alpha}$ .

Насколько автору известно, Теорема 2 и Теорема 3 являются первыми доступными в литературе результатами об оценках, полученных минимизацией эмпирической дисперсии  $V_n(h)$ . Отличительной особенностью данных результатов является тот факт, что эмпирическая дисперсия  $V_n(h)$  не является суммой независимых случайных величин  $h(X_1), \dots, h(X_n)$ , как часто бывает в теории эмпирических процессов. Вместо этого,  $V_n(h)$  является  $U$ -статистикой. «Быстрые» порядки в задачах минимизации  $U$ -статистик были ранее получены, насколько известно автору, только в работе С. Клеменсона, Г. Лугоши, Н. Ваятиса [CLV08] (и некоторых других последующих работах авторов), где рассматривалась задача ранжирования случайных величин. В доказательствах Теоремы 2 и Теоремы 3 автором используется другая техника, основанная на дискретизации множества  $\mathcal{H}$  и концентрации  $U$ -статистик, что позволяет избежать многих технических проблем, которые присутствовали в [CLV08].

Приведем теперь здесь два следствия Теоремы 3, в которых мы явно вычислим значение параметра  $\alpha$  из оценки (9). Для простоты мы рассмотрим одномерный случай  $X = \mathbb{R}$  и в качестве контрольных функций мы возьмем контрольные функции Стейна (3), которые в одномерном случае можно записать как

$$g_\phi(x) := \phi(x) \cdot (\log \pi(x))' + \phi'(x) = \frac{1}{\pi(x)} (\phi(x)\pi(x))',$$

где  $\phi : \mathbb{R} \rightarrow \mathbb{R}$  — функции из некоторого класса  $\Phi$ , который мы определим позднее. Обозначим класс  $s$  раз непрерывно дифференцируемых функций на  $\mathbb{R}$  через  $C^s(\mathbb{R})$  и класс функций из  $C^s(\mathbb{R})$ , производные которых растут не быстрее некоторого полинома через  $C_{poly}^s(\mathbb{R})$ , через

$$C_{poly}^s(\mathbb{R}) := \{\phi \in C^s(\mathbb{R}) : \exists m \in \mathbb{N}, \text{ такой что } |\phi^{(k)}(x)| \lesssim |x|^m \text{ при } |x| \rightarrow \infty, \forall k = 0, \dots, s\}.$$

В следующем следствии мы рассмотрим случай, когда плотность  $\pi$  убывает экспоненциально.

**Следствие 4.** Пусть  $\pi(x) \propto e^{-c|x|^q}$  для некоторых  $c \in \mathbb{R}$  и  $q \in \mathbb{N}$ . Пусть также  $f \in C_{poly}^s(\mathbb{R})$  для некоторого  $s \in \mathbb{N}$ . Зафиксируем произвольное  $\Phi \subset C_{poly}^{s+1}(\mathbb{R})$ , такое что соответствующий класс  $\mathcal{H} = \{f - g_\phi : \phi \in \Phi\}$  является ограниченным, содержит константную функцию и  $\sup_{h \in \mathcal{H}} \sup_{x \in X} |h(x)| \leq b$  для некоторого  $b > 0$ . Тогда для некоторого  $\varepsilon > 0$  и любого  $\delta \in (0, 1)$ , с вероятностью не менее  $1 - \delta$ ,

$$V(\hat{h}_{\varepsilon,1}) \lesssim \left(\frac{1}{n}\right)^{\frac{1}{1+1/s}} + \frac{\log(1/\delta)}{n},$$

где символ  $\lesssim$  означает неравенство с точностью до некоторой константы, не зависящей от  $n$ , но, возможно, зависящей от других параметров задачи.

Рассмотрим теперь случай, когда плотность  $\pi$  убывает полиномиально. Для этого сначала обозначим класс функций из  $C^s(\mathbb{R})$ , производные которых растут не быстрее полинома

порядка  $m \in \mathbb{N}$ , через

$$C_{poly < m}^s(\mathbb{R}) := \{\phi \in C^s(\mathbb{R}) : |\phi^{(k)}(x)| \lesssim |x|^m \text{ при } |x| \rightarrow \infty, \forall k = 0, \dots, s\}.$$

**Следствие 5.** Пусть  $\pi(x) \propto (1+x^2)^{-q}$  для  $q \in \mathbb{N}$ . Пусть также  $f \in C_{poly < m}^s(\mathbb{R})$  для некоторых  $s, m \in \mathbb{N}$ . Зафиксируем произвольное  $\Phi \subset C_{poly}^{s+1}(\mathbb{R})$ , такое что соответствующий класс  $\mathcal{H} = \{f - g_\phi : \phi \in \Phi\}$  является ограниченным, содержит константную функцию и  $\sup_{h \in \mathcal{H}} \sup_{x \in X} |h(x)| \leq b$  для некоторого  $b > 0$ . Тогда для некоторого  $\varepsilon > 0$  и любого  $\delta \in (0, 1)$ , с вероятностью не менее  $1 - \delta$ ,

$$V(\widehat{h}_{\varepsilon, 1}) \lesssim \begin{cases} \left(\frac{1}{n}\right)^{\frac{1}{1+1/s}} + \frac{\log(1/\delta)}{n} & \text{при } s < 2q - m + 1/p - 3, \\ \left(\frac{1}{n}\right)^{\frac{1}{1+(2q-m+1/p-3)^{-1}}} + \frac{\log(1/\delta)}{n} & \text{при } s > 2q - m + 1/p - 3, \end{cases}$$

где символ  $\lesssim$  означает неравенство с точностью до некоторой константы, не зависящей от  $n$ , но, возможно, зависящей от других параметров задачи.

Следствие 4 и Следствие 5 демонстрируют интересный эффект. Если хвосты  $\pi$  убывают экспоненциально и производные  $f$  растут не быстрее некоторого полинома, то чем более гладкой является  $f$ , тем более быстрые порядки мы получаем. Если же убывание  $\pi$  и рост  $f$  являются полиномиальными, то существует критическая точка для гладкости  $f$ , после которой порядки сходимости не улучшаются.

### 3. Снижение дисперсии в зависимом случае

В этом разделе мы сформулируем аналоги Теоремы 2 и Теоремы 3 в зависимом случае. Пусть  $\{X_k\}_{k=0}^\infty$  будет марковской цепью (в этом разделе мы нумеруем последовательность для удобства с 0) с переходным ядром  $P$  и начальным значением  $X_0 = x_0$  для некоторого  $x_0 \in X$ . Мы будем предполагать, что марковское ядро  $P$  имеет единственную инвариантную меру  $\pi$ .

Как упоминалось во Введении, известно несколько оценок для асимптотической дисперсии  $V^\infty(h)$ , см. работу Д. Флегала и Д. Джонса [FJ10]. Для простоты изложения мы рассмотрим только спектральную оценку, так как она является наиболее общей. Тем не менее, результаты, аналогичные приведенным ниже, можно получить и для других оценок. Начнем с определения. Пусть  $\mathcal{H} = \{f - g : g \in \mathcal{G}\}$ , где  $\mathcal{G}$  — класс контрольных функций, см. Раздел 1. Обозначим автоковариационную функцию процесса  $\{h(X_k)\}_{k=0}^\infty$  через

$$\rho(s) := \mathbb{E}[(h(X_0) - \pi(h))(h(X_s) - \pi(h))],$$

где предполагается, что  $X_0 \sim \pi$ . Обозначим также выборочную автоковариационную функцию через

$$\hat{\rho}_n(s) := \frac{1}{n} \sum_{k=0}^{n-s-1} (h(X_k) - \pi_n(h))(h(X_{k+s}) - \pi_n(h)).$$

Легко видеть, что асимптотическую дисперсию  $V^\infty(h)$ , определенную в (7), можно переписать как

$$V^\infty(h) = \sum_{s=-\infty}^{+\infty} \rho(|s|).$$

Спектральная оценка асимптотической дисперсии основана на взвешенных выборочных автоковариационных функциях:

$$V_n^\infty(h) := \sum_{s=-(b_n-1)}^{b_n-1} w_n(s) \hat{\rho}_n(|s|), \quad (10)$$

где  $w_n$  — скользящее окно, а  $b_n$  — ширина окна. Ширина окна  $b_n$  при любом значении  $n$  является натуральным числом, а скользящее окно  $w_n$  является ядром вида  $w_n(s) = w(s/b_n)$ , где  $w$  — симметричная неотрицательная функция с носителем  $[-1, 1]$ , равная

$$w(s) = \begin{cases} 2s + 2, & -1 \leq s < -1/2, \\ 1, & -1/2 \leq s \leq 1/2, \\ -2s + 2, & 1/2 < s \leq 1. \end{cases}$$

Возможен и другой выбор  $w(s)$ , см. подробнее в [FJ10]. В данном разделе мы будем изучать свойства оценки

$$\hat{h}_{\varepsilon,2} := \operatorname{argmin}_{h \in \mathcal{H}_{\varepsilon,2}} V_n^\infty(h),$$

где  $\mathcal{H}_{\varepsilon,2}$  —  $\varepsilon$ -сеть множества  $\mathcal{H}$  в норме  $L^2(\pi)$ , см. подробные определения в Разделе 1.

Напомним, что для двух марковских ядер  $P$  и  $Q$  на  $X \times \mathcal{X}$ , где  $\mathcal{X}$  — борелевская  $\sigma$ -алгебра на  $X$ , их произведение тоже является марковским ядром и определяется для  $x \in X$  и  $A \in \mathcal{X}$  как  $PQ(x, A) = \int P(x, dy)Q(y, A)$ . Кроме того, ядро  $P^n$  определяется рекуррентным соотношением  $P^n = PP^{n-1}$ . Пусть теперь  $W : X \rightarrow [1, \infty)$  — измеримая функция.  $W$ -норма произвольной функции  $h : X \rightarrow \mathbb{R}$  определяется как  $\|h\|_W = \sup_{x \in X} \{ |h(x)|/W(x) \}$ . Для двух вероятностных мер  $\mu$  и  $\nu$  на  $(X, \mathcal{X})$ , удовлетворяющих  $\mu(W) < \infty$  и  $\nu(W) < \infty$ ,  $W$ -нормой разности  $\mu - \nu$  является по определению  $\|\mu - \nu\|_W = \sup_{\|h\|_W \leq 1} |\mu(h) - \nu(h)|$ .

Перейдем теперь к предположениям, необходимым для формулировки основных результатов раздела. Нашим первым предположением будет геометрическая эргодичность  $\{X_k\}_{k=0}^\infty$ .

**(GE)** Марковское ядро  $P$  имеет единственную инвариантную меру  $\pi$ . Кроме того, для некоторой измеримой функции  $W : X \rightarrow [1, \infty)$ , такой что  $\pi(W) < \infty$ , и некоторых чисел  $\varsigma > 0$ ,  $\rho \in (0, 1)$  выполняется для всех  $x \in X$  и всех  $n \in \mathbb{N}$

$$\|P^n(x, \cdot) - \pi\|_W \leq \varsigma W(x) \rho^n.$$

Известно, что условие (GE) влечет центральную предельную теорему для последовательности  $\{h(X_k)\}_{k=0}^\infty$ ,  $h \in \mathcal{H}$ , если дополнительно  $\pi(h^{2+\kappa}) < \infty$  для некоторого  $\kappa > 0$ , см. работу И. А. Ибрагимова и Ю. В. Линника [IL71] или Д. Джонса [J04]. Чтобы асимптотический доверительный интервал (6) был корректно определен, далее мы будем предполагать, что  $\mathcal{H} \subset L^{2+\kappa}$  для некоторого  $\kappa > 0$ .

Напомним, что  $L^2$ -метрикой Канторовича (в зарубежной литературе —  $L^2$ -метрикой Васерштейна) между вероятностными мерами  $\mu$  и  $\nu$  называется величина

$$W_2(\mu, \nu) = \inf_{\zeta} \left( \int_{X \times X} \|x - y\|^2 d\zeta(x, y) \right)^{1/2},$$

где  $\|\cdot\|$  — евклидова норма в  $\mathbb{R}^d$ , а инфимум взят по всем вероятностным мерам  $\zeta$  на декартовом произведении  $X \times X$ , у которых маргинальными мерами являются  $\mu$  и  $\nu$  соответственно. Расстояние Кульбака-Лейблера между мерами  $\mu$  и  $\nu$  определяется как

$$\text{KL}(\mu \parallel \nu) = \begin{cases} \int \log\left(\frac{d\mu}{d\nu}\right) d\mu, & \text{если } \mu \ll \nu, \\ \infty, & \text{иначе.} \end{cases}$$

Мы будем говорить, что вероятностная мера  $\mu$  удовлетворяет (информационному) транспортному неравенству  $T_2(C)$ , если существует  $C > 0$ , такая что для любой вероятностной меры  $\nu$  выполняется

$$W_2(\mu, \nu) \leq \sqrt{2C \text{KL}(\mu \parallel \nu)}.$$

Для доказательства основных результатов нам необходима концентрация величины  $V_n^\infty(h)$ . Важно отметить, что  $V_n^\infty(h)$  является квадратичной формой по  $\{h(X_j)\}_{j=0}^{n-1}$ . Нами была доказана гауссовская концентрация  $V_n^\infty(h)$  в случае, когда функций  $h \in \mathcal{H}$  являются липшицевыми, а марковское ядро  $P$  является сжимающим отображением в  $L^2$ -метрике Канторовича.

**(L)** Функции  $h \in \mathcal{H}$  являются  $L$ -липшицевыми, то есть  $|h(x) - h(y)| \leq L\|x - y\|$  для некоторого  $L > 0$  и всех  $x, y \in X$ .

**(CW)** Марковское ядро  $P(x, \cdot)$  удовлетворяет  $T_2(C)$  для всех  $x \in X$  и некоторого  $C > 0$ . И, кроме того, существует  $r \in (0, 1)$ , такое что  $W_2(P(x, \cdot), P(y, \cdot)) \leq r\|x - y\|$  для всех  $x, y \in X$ .

Теперь мы можем сформулировать следующую теорему.

**Теорема 6.** *Предположим (GE), (L) и (CW). Положим  $b_n = 2 \log(n) / \log(1/\rho)$ . Тогда для некоторого  $\varepsilon > 0$  (значение которого определено в доказательстве), любого начального значения  $x_0 \in X$  и любого  $\delta \in (0, 1)$ , с вероятностью не менее  $1 - \delta$ ,*

$$V^\infty(\hat{h}_{\varepsilon,2}) - \inf_{h \in \mathcal{H}} V^\infty(h) \lesssim A_1 \log(n) \gamma_{L^2(\pi)}(\mathcal{H}, n) + A_2 \frac{\log(n) \log(1/\delta)}{\sqrt{n}},$$

где первая асимптотическая дисперсия является условной по выборке  $X_1, \dots, X_n$ , на которой вычислялась оценка  $\hat{h}_{\varepsilon,1}$ , символ  $\lesssim$  означает неравенство с точностью до некоторой абсолютной константы и

$$A_1 = \frac{\sqrt{C}L^2}{(1-r)\log(1/\rho)}, \quad A_2 = \frac{\sqrt{\varsigma}(\pi(W) + W(x_0))}{\sqrt{1-\rho}\log(1/\rho)} \left( \frac{\sqrt{C}L^2}{1-r} + \sup_{h \in \mathcal{H}} \|h\|_{W^{1/2}}^2 \right).$$

Предполагая дополнительно к условиям Теоремы 6, что  $\mathcal{H}$  является ограниченным подмножеством некоторого взвешенного соболевского пространства  $W^{s,p}(X, \langle x \rangle^\beta)$ , и подставляя результат Предложения 1, мы получим окончательную оценку с большой вероятностью вида:

$$V^\infty(\hat{h}_{\varepsilon,2}) - \inf_{h \in \mathcal{H}} V^\infty(h) \lesssim n^{-\alpha}, \quad \alpha \in (0, 1/2),$$

где значение параметра  $\alpha$  будет зависеть от размерности  $d$  и параметров соболевского пространства  $s, p$  и  $\beta$ . В статистической литературе такие порядки сходимости называются «медленными».

Порядок сходимости может быть улучшен до  $n^{-\alpha}$  для  $\alpha \in (0, 1)$ , если дополнительно предположить, что  $\mathcal{H}$  содержит константную функцию. Так как  $\pi(h) = \pi(f)$  для всех  $h \in \mathcal{H}$ , эта константа должна быть равна  $\pi(f)$  и, следовательно, в этом случае  $\inf_{h \in \mathcal{H}} V^\infty(h) = 0$ .

**Теорема 7.** *Предположим (GE), (L) и (CW). Предположим также, что  $\mathcal{H}$  содержит константную функцию, то есть  $h^*(x) \equiv c$  для некоторой  $h^* \in \mathcal{H}$  и некоторого  $c \in \mathbb{R}$ . Положим  $b_n = 2 \log(n) / \log(1/\rho)$ . Тогда для некоторого  $\varepsilon > 0$  (значение которого определено в доказательстве), любого начального значения  $x_0 \in X$  и любого  $\delta \in (0, 1)$ , с вероятностью не менее  $1 - \delta$ ,*

$$V^\infty(\hat{h}_{\varepsilon,2}) \lesssim A_1 \log(n) (\gamma_{L^2(\pi)}(\mathcal{H}, n))^2 + A_2 \frac{\log(n) \log(1/\delta)}{n},$$

где асимптотическая дисперсия является условной по выборке  $X_1, \dots, X_n$ , на которой вычислялась оценка  $\hat{h}_{\varepsilon,1}$ , символ  $\lesssim$  означает неравенство с точностью до некоторой абсолютной константы и

$$A_1 = \frac{CL^2}{(1-r)^2 \log(1/\rho)}, \quad A_2 = \frac{CL^2}{(1-r)^2 \log(1/\rho)} + \frac{\varsigma(\pi(W) + W(x_0))}{(1-\rho)^{1/2} \log(1/\rho)} \sup_{h \in \mathcal{H}} \|h\|_{W^{1/2}}^2.$$

Предполагая теперь, что  $\mathcal{H}$  является ограниченным подмножеством  $W^{s,p}(\mathcal{X}, \langle x \rangle^\beta)$ , мы получим оценку с большой вероятностью вида:

$$V^\infty(\widehat{h}_{\varepsilon,2}) \lesssim n^{-\alpha}, \quad \alpha \in (0,1).$$

В свою очередь, порядок длины асимптотического доверительного интервала (6) с помощью данной процедуры снижения дисперсии можно уменьшить с  $n^{-1/2}$  до  $n^{-1/2-\alpha/2}$ .

В доказательстве Теоремы 6 и Теоремы 7 использовалось следующее неравенство концентрации, которое, как кажется автору, представляет самостоятельный интерес.

**Предложение 8.** Пусть  $\{X_k\}_{k=0}^\infty$  является марковской цепью с переходным ядром  $P$  и начальным значением  $X_0 = x_0$  для некоторого  $x_0 \in \mathcal{X}$ . Предположим, что существует  $C > 0$ , такое что  $P(x, \cdot)$  удовлетворяет  $T_2(C)$  для всех  $x \in \mathcal{X}$ . Предположим также, что существует число  $r \in (0,1)$ , такое что для всех  $x, y \in \mathcal{X}$  выполняется

$$W_2(P(x, \cdot), P(y, \cdot)) \leq r \|x - y\|.$$

Для произвольной  $L$ -липшицевой функции  $h : \mathcal{X} \rightarrow \mathbb{R}$  обозначим  $Z_n(h) = (h(X_0), \dots, h(X_{n-1}))^\top$ . Тогда для любой матрицы  $A$  размера  $n \times n$  и любого  $t > 0$ ,

$$\mathbb{P}\left(|Z_n(h)^\top A Z_n(h) - \mathbb{E}[Z_n(h)^\top A Z_n(h)]| > t\right) \leq 2 \exp\left(-\frac{t^2}{cK^2 (\mathbb{E}\|AZ_n(h)\|^2 + t\|A\|)}\right),$$

где  $K^2 = CL^2/(1-r)^2$ , а  $c > 0$  — некоторая абсолютная константа.

Доказательство данного утверждения состоит из двух этапов. Сначала, используя результат из статьи Х. Джеллоута, А. Гийена и Л. Ву [DGW04], мы показываем, что совместное распределение  $\{X_k\}_{k=0}^{n-1}$  принадлежит классу  $T_2(C/(1-r)^2)$ , что, в свою очередь, влечет гауссовскую концентрацию для всех липшицевых функций. Далее, используя технику из работы Р. Адамчака [A15], мы доказываем концентрацию для квадратичных форм.

## 4. Алгоритм Ланжевена

Простым примером МСМС алгоритма, для которого выполняются условия (GE) и (CW) является алгоритм Ланжевена (в английской литературе Unadjusted Langevin Algorithm или ULA). Пусть плотность  $\pi(x)$  известна с точностью до нормировочной константы и выражается в виде  $\pi(x) \propto e^{-U(x)}$  для некоторой неотрицательной функции  $U(x)$ , которую принято называть потенциалом. В алгоритме Ланжевена марковская цепь  $\{X_k\}_{k \geq 0}$  строится с помощью следующего рекуррентного соотношения

$$X_{k+1} = X_k - \gamma \nabla U(X_k) + \sqrt{2\gamma} Z_{k+1}, \tag{11}$$

где  $\{Z_k\}_{k \geq 1}$  — последовательность независимых стандартных нормальных векторов в  $\mathbb{R}^d$ , а  $\gamma > 0$  — шаг алгоритма. Данный алгоритм является дискретизацией первого порядка (по схеме Эйлера-Маруямы) стохастического дифференциального уравнения Ланжевена:

$$dY_t = -\nabla U(Y_t)dt + \sqrt{2}dB_t,$$

где  $\{B_t\}_{t \geq 0}$  —  $d$ -мерное броуновское движение. При некоторых условиях, единственным стационарным распределением динамики Ланжевена  $\{Y_t\}_{t \geq 0}$  является  $\pi$ , а марковская цепь  $\{X_k\}_{k \geq 0}$  сходится к единственному стационарному распределению  $\pi_\gamma$ , которое близко к распределению  $\pi$  в некоторых метриках, таких как расстояние по вариации или  $L^2$ -метрике Канторовича. Подробное описание алгоритма и теоремы сходимости доступны в работах Г. Робертса и Р. Твиди [RT96], А. Далаляна [D17], А. Дурмуса и Э. Мулине [DM17]. В случае, когда плотность  $\pi(x)$  не является известной, для использования алгоритма Ланжевена можно воспользоваться методами из статей Д. В. Беломестного и автора [BI19] и [BI20].

Рассмотрим следующие условия на потенциал  $U(x)$ , которые будут гарантировать выполнение условий (GE) и (CW):

**(U1)** Потенциал  $U$  является дважды непрерывно дифференцируемым  $U \in C^2(\mathbb{R}^d)$  и имеет липшицевый градиент, то есть существует  $L > 0$ , такое что для всех  $x, y \in \mathbb{R}^d$

$$\|\nabla U(x) - \nabla U(y)\| \leq L\|x - y\|.$$

**(U2)** Потенциал  $U$  является строго выпуклым, то есть существует константа  $m > 0$ , такая что для всех  $x, y \in \mathbb{R}^d$  выполняется

$$U(y) \geq U(x) + \langle \nabla U(x), y - x \rangle + \frac{m}{2}\|x - y\|^2.$$

**Предложение 9.** Пусть выполнены условия (U1) и (U2). Тогда при любом  $\gamma \in (0, 2/(m+L))$ , марковское ядро  $P_\gamma$ , соответствующее цепи  $\{X_k\}_{k \geq 0}$  из (11), удовлетворяет условиям (GE) и (CW) при некотором  $\rho \in (0, 1)$ ,

$$W(x) = \|x\|^2, \quad C = 2\gamma \quad \text{и} \quad r = \sqrt{1 - 2\gamma m L / (m + L)}.$$

Данный факт является непосредственным следствием результатов из двух работ А. Дурмуса и Э. Мулине [DM17] и [DM19].

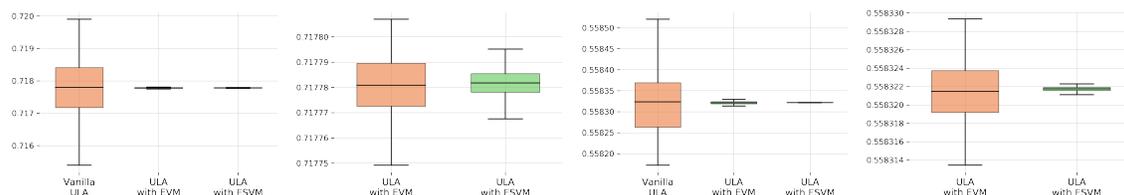
**Байесовская логистическая регрессия.** Рассмотрим также численный пример для алгоритма Ланжевена. Мы сравним два описанных метода выбора контрольных функций: минимизацию эмпирической дисперсии (EVM метод), см. (4), и минимизацию спектральной дисперсии (ESVM метод), см. (10). Сравнение будем проводить на двух наборах данных для

задачи классификации из базы данных UCI. Первый набор данных называется Pima и содержит  $N = 768$  наблюдений в размерности  $d = 9$ . Второй набор данных называется EEG и содержит  $N = 14980$  наблюдений в размерности  $d = 15$ .

В логистической регрессии вероятность  $i$ -ого ответа  $y_i \in \{-1, 1\}$  для  $i = 1, \dots, N$ , вычисляется как  $p(y_i | \mathbf{x}_i, \theta) = (1 + e^{-y_i \langle \theta, \mathbf{x}_i \rangle})^{-1}$ , где  $\mathbf{x}_i \in \mathbb{R}^d$  — это вектор признаков (факторов) и  $\theta \in \mathbb{R}^d$  — вектор неизвестных регрессионных коэффициентов. Сначала мы разобьем данные на обучающую выборку  $\mathcal{T}^{\text{train}} = \{(y_i, \mathbf{x}_i)\}_{i=1}^{N-K}$  и тестовую выборку  $\mathcal{T}^{\text{test}} = \{(y'_i, \mathbf{x}'_i)\}_{i=1}^K$ , выбрав случайно  $K = 100$  наблюдений из данных (и удалив их из обучающей выборки). Далее, мы наложим априорное стандартное нормальное распределение на параметр  $\theta$ , обозначим его  $p_0(\theta)$ , и используем алгоритм ULA для получения выборки из апостериорного распределения  $p(\theta | \mathcal{T}^{\text{train}}) \propto p_0(\theta) \prod_{(y_i, \mathbf{x}_i) \in \mathcal{T}^{\text{train}}} p(y_i | \mathbf{x}_i, \theta)$ . С помощью полученной выборки  $\{\theta_k\}_{k=0}^{n-1}$  мы оценим предсказание для фиксированной точки из тестовой выборки  $(y', \mathbf{x}')$ , то есть  $p(y' | \mathbf{x}') = \int_{\mathbb{R}^d} p(y' | \mathbf{x}', \theta) p(\theta | \mathcal{T}^{\text{train}}) d\theta$ , вычислив оценку  $n^{-1} \sum_{k=0}^{n-1} f(\theta_k)$  для  $f(\theta) = p(y' | \mathbf{x}', \theta)$ . Чтобы избавиться от случайности, мы также оценим среднее предсказаний по всему тестовому набору  $\mathcal{T}^{\text{test}}$ , вычислив оценку для  $f(\theta) = K^{-1} \sum_{(y_i, \mathbf{x}_i) \in \mathcal{T}^{\text{test}}} p(y_i | \mathbf{x}'_i, \theta)$ . Кроме того, аналогичные оценки мы посчитаем для EVM и ESVM методов, в которых мы будем использовать контрольные функции Стейна, см. (3), где  $\Phi(x) \equiv b$  для некоторого  $b \in \mathbb{R}^d$ .

Графики с разбросом полученных оценок даны на Рис. 1. Обратим внимание, что оба метода EVM и ESVM дают значительный выигрыш в дисперсии, но метод ESVM работает лучше, так как учитывает марковскую структуру цепи.

Рис. 1: Оценивание среднего предсказания в байесовской логистической регрессии. Первые два графика относятся к набору данных Pima, а последние два — к набору данных EEG. В первых графиках для каждого набора данных отражены 3 «ящичка с усами» для 100 оценок полученных соответственно обычным алгоритмом ULA, алгоритмом ULA с EVM и алгоритмом ULA с ESVM, а следующий график — увеличение масштаба для последних двух алгоритмов.



# Основные результаты диссертационной работы

В рамках диссертационной работы получены следующие основные результаты:

- 1) Неасимптотические оценки на избыточный риск (5) в независимом случае для произвольного класса контрольных функций  $\mathcal{G}$ . Данные результаты сформулированы в Теореме 2 и Теореме 3. Кроме того, продемонстрировано, какие получаются оценки в случае контрольных функций Стейна, см. Следствие 4 и Следствие 5.
- 2) Неасимптотические оценки на избыточный риск (8) в зависимом случае для произвольного класса контрольных функций  $\mathcal{G}$ . Данные результаты сформулированы в Теореме 6 и Теореме 7. Кроме того, в данной работе впервые было предложено минимизировать вместо эмпирической дисперсии (4) спектральной оценку асимптотической дисперсии (10). Данное решение лучше работает на практике в случае зависимых случайных величин.
- 3) Концентрационное неравенство для квадратичной формы от марковской цепи, когда ее марковское ядро является сжимающим отображением в  $L^2$ -метрике Канторовича, см. Предложение 8.

Данные результаты имеют теоретический и практический характер. Методы, развитые в представленной работе, могут быть использованы для дальнейшего исследования алгоритмов снижения дисперсии оценок Монте-Карло. Кроме этого, полученные результаты могут быть полезны в рамках исследования ряда прикладных задач байесовской статистики.

## Личный вклад автора

Содержание диссертации и основные результаты, перечисленные в списке выше, отражают персональный вклад автора в опубликованные работы. В статьях с соавторами вклад диссертанта был определяющим во всех перечисленных выше результатах за исключением результата Предложения 8. Утверждения, не перечисленные в списке выше, но присутствующие в настоящем тексте, являются либо простыми следствиями результатов, не принадлежащих автору и его соавторам, либо были получены соавторами и приведены здесь лишь для полноты изложения.

## Апробация результатов

Результаты диссертационной работы докладывались на следующих конференциях и научно-исследовательских семинарах:

- Конференция «Информационные технологии и системы» в ИППИ РАН, Санкт-Петербург, сентябрь 2016 года. Тема доклада: «Концентрация нормы изотропного логарифмически вогнутого случайного вектора».
- Аспирантский коллоквиум кафедры теории вероятностей в МГУ, Москва, декабрь 2017 года. Тема доклада: «Снижение дисперсии оценки Монте-Карло».
- Конференция «New frontiers in high-dimensional probability and statistics» в НИУ ВШЭ, Москва, февраль 2018 года. Тема доклада: «Снижение дисперсии оценок Монте-Карло с помощью минимизации выборочной дисперсии».
- Конференция «Ломоносов» в МГУ, Москва, апрель 2018 года. Тема доклада: «Снижение дисперсии оценок Монте-Карло с помощью минимизации выборочной дисперсии».
- Городской семинар по теории вероятностей и математической статистике в ПОМИ РАН, Санкт-Петербург, сентябрь 2018 года. Тема доклада: «Снижение дисперсии оценок Монте-Карло с помощью минимизации выборочной дисперсии».
- Зимняя школа «New frontiers in high-dimensional probability and statistics 2» в НИУ ВШЭ, Москва, февраль 2019 года. Тема доклада: «MCMC алгоритмы для распределений с известной характеристической функцией».
- Семинар центра прикладной математики в Политехнической школе (École polytechnique), Париж, июнь 2019 года. Тема доклада: «Снижение дисперсии оценок Монте-Карло с помощью минимизации выборочной дисперсии».
- Конференция «European Meeting of Statisticians» (EMS), проводимая обществом Бернулли по математической статистике и вероятности, Палермо, июль 2019 года. Тема доклада: «Снижение дисперсии для марковских цепей с помощью минимизации выборочной дисперсии».
- Конференция «Structural Inference in High-Dimensional Models 2», Санкт-Петербург, сентябрь 2019 года. Тема доклада: «MCMC алгоритмы для распределений с тяжелыми хвостами».
- Третья Санкт-Петербургская зимняя молодежная конференция по теории вероятностей и математической физике в ПОМИ РАН, Санкт-Петербург, декабрь 2019 года. Тема доклада: «Снижение дисперсии для зависимых последовательностей».

## Публикации

Результаты диссертационной работы составляют содержание трех опубликованных статей.

- [1] Беломестный Д., Иосипой Л., Животовский Н. *Снижение дисперсии оценки Монте-Карло методом минимизации эмпирической дисперсии*. Doklady Mathematics, 98:2, 494–497, 2018.
- [2] Беломестный Д., Иосипой Л. *Об оценке плотности распределения с помощью ряда Фурье*. Large-Scale Systems Control, 82, 28–43, 2019.
- [3] Беломестный Д., Иосипой Л., Мулине Э., Наумов А., Самсонов С. *Снижение дисперсии для марковских цепей с помощью минимизации эмпирической дисперсии с применением к МСМС алгоритмам*. Statistics and Computing, 30:4, 973–997, 2020.

# Список литературы

- [A15] R. Adamczak. *A note on the Hanson-Wright inequality for random vectors with dependencies*. Electron. Commun. Probab., 20:71, 1–13, 2015.
- [B71] N.S. Bakhvalov. *On the approximate calculation of multiple integrals*. Vestnik MGU, Ser. Math. Mech. Astron. Phys. Chem., 4, 3–18, 1959.
- [BI19] D. Belomestny, L. Iosipoi. *On density estimation via Fourier series*. Large-Scale Systems Control, 82, 28–43, 2019.
- [BI20] D. Belomestny, L. Iosipoi. *Fourier transform MCMC, heavy tailed distributions, and geometric ergodicity*. ArXiv preprint, arXiv:1909.00698, 2020.
- [CLV08] S. Cléménçon, G. Lugosi, N. Vayatis. *Ranking and Empirical Minimization of U-statistics*. Ann. Statist., 36:2, 844–874, 2008.
- [D17] A. Dalalyan. *Theoretical guarantees for approximate sampling from smooth and log-concave densities*. Journal of the Royal Statistical Society Series B (Statistical Methodology), 79:3, 651–676, 2017.
- [DGL96] L. Devroye, L. Györfi, G. Lugosi. *A Probabilistic Theory of Pattern Recognition*. Springer, New York, 1996.
- [DGW04] H. Djellout, A. Guillin, L. Wu. *Transportation cost-information inequalities and applications to random dynamical systems and diffusions*. Ann. Probab., 32:3B, 2702–2732, 2004.
- [D08] I. Dimov. *Monte Carlo methods for applied scientists*. World Scientific, 2008.
- [DM17] A. Durmus, É. Moulines. *Non-asymptotic convergence analysis for the unadjusted Langevin algorithm*. Ann. Appl. Probab., 27:3, 1551–1587, 2017.

- [DM19] A. Durmus, É. Moulines. *High-dimensional Bayesian inference via the Unadjusted Langevin Algorithm*. *Bernoulli*, 4A, 2854–2882, 2019.
- [FJ10] J. Flegal, G. Jones. *Batch means and spectral variance estimators in Markov chain Monte Carlo*. *Ann. Statist.*, 38:2, 1034–1070, 2010.
- [G00] S. van de Geer. *Empirical Processes in M-Estimation*. Cambridge, 2000.
- [G13] P. Glasserman. *Monte Carlo methods in financial engineering*. Springer Science & Business Media, 2013.
- [IL71] I. A. Ibragimov, Y. V. Linnik. *Independent and Stationary Sequences of Random Variables*. Wolters-Noordhoff, Groningen, 1971.
- [J04] G. Jones. *On the Markov chain central limit theorem*. *Probab. Surveys*, 1, 299–320, 2004.
- [MSI13] A. Mira, R. Solgi, D. Imparato. *Zero variance Markov chain Monte Carlo for Bayesian Estimators*. *Statistics and Computing*, 23:5, 653–662, 2013.
- [NP07] R. Nickl, B. Pötscher. *Bracketing Metric Entropy Rates and Empirical Central Limit Theorems for Function Classes of Besov- and Sobolev-Type*. *Journal of Theoretical Probability*, 20:2, 177–199, 2007.
- [N16] E. Novak. *Some Results on the Complexity of Numerical Integration*. *Monte Carlo and Quasi-Monte Carlo Methods*. Springer Proceedings in Mathematics & Statistics, 163, 161–183, 2016.
- [OGC17] C. Oates, M. Girolami, N. Chopin. *Control functionals for Monte Carlo integration*. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 79:3, 695–718, 2017.
- [OGC19] C. Oates, M. Girolami, N. Chopin. *Convergence rates for a class of estimators based on Stein’s identity*. *Bernoulli*, 25:2, 1141–1159, 2019.
- [RC99] C. Robert, G. Casella. *Monte Carlo Statistical Methods*. Springer, New York, 1999.
- [RT96] G. Roberts, R. Tweedie. *Exponential convergence of Langevin distributions and their discrete approximations*. *Bernoulli*, 2:4, 341–363, 1996.
- [RR04] G. Roberts, J. Rosenthal. *General state space Markov chains and MCMC algorithms*. *Probab. Surveys*, 1, 20–71, 2004.

- [RK16] R. Rubinstein, D. Kroese. *Simulation and the Monte Carlo method*. John Wiley & Sons, 2016.
- [WS95] W.H. Wong, X. Shen. *Probability Inequalities for Likelihood Ratios and Convergence Rates of Sieve MLES*. *Ann. Statist.*, 23:2, 339–362, 1995.