

Байесовский выбор модели и концентрация апостериорного распределения для гиперпараметров*

Н. П. БАЛДИН

*Лаборатория структурных методов
анализа данных в предсказательном моделировании
при Московском физико-техническом институте
(государственном университете)
email: baldin.np@gmail.com*

В. Г. СПОКОЙНЫЙ

*Институт прикладного анализа и стохастики
им. Вейерштрасса, Берлин, Германия,
Берлинский университет им. Гумбольдта, Германия,
Лаборатория структурных методов
анализа данных в предсказательном моделировании
при Московском физико-техническом институте
(государственном университете)
e-mail: spokoiny@wias-berlin.de*

УДК 519.22

Ключевые слова: максимум правдоподобия, квадратичная регуляризация, локальный брэкетинг.

Аннотация

Данная работа предлагает конструкцию априорного распределения гиперпараметра, которая может использоваться в задаче байесовского выбора модели. Конструкция основывается на идее несмещённой оценки риска в методе максимума правдоподобия с регуляризацией. Главный результат работы показывает одностороннюю концентрацию апостериорного распределения гиперпараметра: апостериорная масса концентрируется в области моделей сложности ниже, чем сложность модели, соответствующей сложности оракульной модели.

Abstract

N. P. Baldin, V. G. Spokoiny, Bayesian model selection and the concentration of the posterior of hyperparameters, Fundamentalnaya i prikladnaya matematika, vol. 18 (2013), no. 2, pp. 13–34.

The present paper offers a construction of a hyperprior that can be used for Bayesian model selection. This construction is inspired by the idea of the unbiased model selection in a penalized maximum likelihood approach. The main result shows a one-sided contraction of the posterior: the posterior mass is allocated on models of lower complexity than the oracle one.

*Работа выполнена при поддержке лаборатории структурных методов анализа данных в предсказательном моделировании, грант Правительства Российской Федерации 11.G34.31.0073.

1. Введение

1.1. Основные определения и обозначения

Пусть наблюдения \mathbf{Y} определены на некотором вероятностном пространстве и описываются некоторой мерой \mathbb{P}_f . Параметрическое предположение состоит в том, что данная мера принадлежит семейству $(\mathbb{P}_\theta, \theta \in \Theta \subseteq \mathbb{R}^p)$ с доминирующей мерой μ_0 . Принцип максимума правдоподобия предлагает оценивать вектор θ , параметризующий истинную меру, максимизируя функцию правдоподобия $L(\theta) = L(\mathbf{Y}, \theta) \stackrel{\text{def}}{=} \log \frac{d\mathbb{P}_\theta}{d\mu_0}(\mathbf{Y})$:

$$\tilde{\theta} \stackrel{\text{def}}{=} \operatorname{argmax}_{\theta \in \Theta} L(\theta).$$

Параметрическое предположение может оказаться неверным: $\mathbb{P}_f \notin \mathbb{P}_\theta$. В этом случае $\tilde{\theta}$ оценивает лучшую аппроксимацию истинной меры мерой параметрического семейства. Вектор, определяющий лучшую аппроксимацию, определяется как

$$\theta^* \stackrel{\text{def}}{=} \operatorname{argmax}_{\theta \in \Theta} \mathbb{E}_f L(\theta).$$

Математическое ожидание во всей работе берётся по истинной мере \mathbb{P}_f . Для простоты будем писать \mathbb{E} вместо \mathbb{E}_f . Некоторые полезные свойства оценки максимума правдоподобия можно найти, например, в [11].

Для повышения устойчивости оценки $\tilde{\theta}$ в модель искусственно вводится регуляризация, которую можно рассмотреть как штраф за сложность модели. Зафиксируем некоторое семейство функций $\operatorname{pen}(\theta, \varkappa)$ для $\varkappa \in \mathcal{K}$ и $\mathcal{K} \subseteq \mathbb{R}$, которые выполняют роль штрафа. Тогда логарифмическая функция правдоподобия со штрафом описывает \varkappa -модель

$$L_\varkappa(\theta) \stackrel{\text{def}}{=} L(\theta) - \operatorname{pen}(\theta, \varkappa).$$

Для \varkappa -модели оценка $\tilde{\theta}_\varkappa$ и величина θ_\varkappa^* , которую оценивает оценка, могут быть определены следующим образом:

$$\tilde{\theta}_\varkappa \stackrel{\text{def}}{=} \operatorname{argmax}_{\theta \in \Theta} L_\varkappa(\theta), \quad \theta_\varkappa^* \stackrel{\text{def}}{=} \operatorname{argmax}_{\theta \in \Theta} \mathbb{E} L_\varkappa(\theta).$$

В данной работе рассматривается специальный случай квадратичной пенализации. Соответствующая функция штрафа есть $\operatorname{pen}(\theta, \varkappa) = \varkappa \|G\theta\|^2/2$ с евклидовой нормой, где G^2 — некоторая диагональная матрица с элементами на диагонали $0 < g_1^2 \leq g_2^2 \leq \dots \leq g_p^2$. Частный случай такой регуляризации при $G^2 = I_p$ есть регуляризация Тихонова, изученная, например, в [7]. Там же исследованы различные методы регуляризации в обратных задачах. Главный вопрос после выбора фиксированного семейства функций штрафа $\operatorname{pen}(\theta, \varkappa)$, какую модель выбрать или, что эквивалентно, как выбрать параметр \varkappa .

Регуляризация вектора θ , как правило, эквивалентна предположению, что параметр θ есть случайный элемент на некотором вероятностном пространстве

с мерой Π_{\varkappa} , которая имитирует структуру штрафа. Распределение данных описывается как

$$\mathbf{Y} | \boldsymbol{\vartheta} \sim p(\mathbf{y} | \boldsymbol{\theta}) = \exp L(\boldsymbol{\theta}), \quad \boldsymbol{\vartheta} \sim \Pi_{\varkappa}(\cdot).$$

Объект изучения — это апостериорная мера, которая описывает условное распределение $\boldsymbol{\vartheta}$ при данных \mathbf{Y} . Используя формулу Байеса, получаем

$$\boldsymbol{\vartheta} | \mathbf{Y} \propto \exp\{L(\boldsymbol{\theta})\} \Pi_{\varkappa}(d\boldsymbol{\theta}).$$

Объект зависит от распределения Π_{\varkappa} , но при асимптотическом анализе зависимость несущественна. Априорное распределение $\Pi_{\varkappa}(\cdot)$ параметризуется другим вектором $\varkappa \in \mathcal{K} \subseteq \mathbb{R}$. Наиболее изучены два способа выбора значения \varkappa :

- оценить \varkappa ;
- предполагать некоторое распределение \varkappa с плотностью $\pi(\cdot)$, которое в конечном итоге будет зависеть от параметров, влияние которых на анализ мало.

В данной работе изучаются оба метода и исследуется их эквивалентность. Основным объектом изучения в работе есть

$$P(\boldsymbol{\theta} \in A, \varkappa \in B | \mathbf{Y}) \propto \int_A \exp(L(\boldsymbol{\theta})) \int_B \pi(\varkappa) \Pi_{\varkappa}(d\boldsymbol{\theta}) d\varkappa,$$

где $A \subseteq \Theta$ и $B \subseteq \mathcal{K}$.

1.2. Обзор известных результатов

В литературе встречаются несколько способов выбора функции $\text{rep}(\boldsymbol{\theta}, \varkappa)$. Информационный критерий Акаике, изученный в [1], использует удвоенное количество параметров модели как функцию штрафа. Другой популярный метод, предложенный в [12], основан на идее несмещённой оценки риска Штайна. Этот метод был изучен подробно в [5, 6] среди многих других. В этом случае функция $\text{rep}(\boldsymbol{\theta}, \varkappa)$ зависит от гладкости целевого параметра и дисперсии шума. Ещё один популярный метод основан на сглаживающих сплайнах (см. [8]).

К сожалению, методы, основанные на идее несмещённой оценки риска, на практике обнаруживают существенные недостатки. В частности, такие методы теряют устойчивость в задачах с плохой обусловленностью или с большим количеством различных моделей для выбора. Как следствие, подобные методы теряют концентрационные и оракульные свойства. Таким образом, выбор семейства функций регуляризации и выбор конкретной функции из рассматриваемого семейства являются главными вопросами в задачах регуляризации модели. Выбор подходящей функции штрафа в гауссовских моделях был изучен в [2, 3]. Эффективный метод для линейных гауссовских обратных задач был изучен в [4].

2. Выбор лучшей модели

Далее рассматривается конкретная модель $\mathbf{Y} = \mathbf{f} + \varepsilon \in \mathbb{R}^p$, где $\varepsilon \sim \mathcal{N}(0, \sigma^2 I_p)$, и функция штрафа $\text{pen}(\boldsymbol{\theta}, \varkappa) = \varkappa \|G\boldsymbol{\theta}\|^2/2$.

2.1. Выбор модели, основанный на несмещённой оценке риска

Оценка $\tilde{\boldsymbol{\theta}}_\varkappa$ внутри \varkappa -модели получается максимизацией $L_\varkappa(\boldsymbol{\theta})$:

$$\begin{aligned} \tilde{\boldsymbol{\theta}}_\varkappa &= \underset{\boldsymbol{\theta}}{\operatorname{argmax}} L_\varkappa(\boldsymbol{\theta}) = \underset{\boldsymbol{\theta}}{\operatorname{argmin}} \{ \sigma^{-2} \|\mathbf{Y} - \boldsymbol{\theta}\|^2 + \varkappa \|G\boldsymbol{\theta}\|^2 \} = \\ &= \sigma^{-2} (\sigma^{-2} I_p + \varkappa G^2)^{-1} \mathbf{Y} = \sigma^{-2} D_\varkappa^{-2} \mathbf{Y}, \end{aligned}$$

где $D_\varkappa^2 = \sigma^{-2} I_p + \varkappa G^2$. Величина, которую оценивает оценка $\tilde{\boldsymbol{\theta}}_\varkappa$ внутри \varkappa -модели, есть

$$\boldsymbol{\theta}_\varkappa^* = \underset{\boldsymbol{\theta}}{\operatorname{argmax}} \mathbb{E} L_\varkappa(\boldsymbol{\theta}) = \sigma^{-2} (\sigma^{-2} I_p + \varkappa G^2)^{-1} \mathbb{E} \mathbf{Y} = \sigma^{-2} D_\varkappa^{-2} \mathbf{f},$$

где $\mathbf{f} \stackrel{\text{def}}{=} \mathbb{E} \mathbf{Y}$. Разложение Тейлора $L_\varkappa(\boldsymbol{\theta})$ при фиксированном \varkappa ведёт к понятию эксцесса: $\mathcal{X}_\varkappa \stackrel{\text{def}}{=} L_\varkappa(\tilde{\boldsymbol{\theta}}_\varkappa) - L_\varkappa(\boldsymbol{\theta}_\varkappa^*)$,

$$\mathcal{X}_\varkappa = L_\varkappa(\tilde{\boldsymbol{\theta}}_\varkappa) - L_\varkappa(\boldsymbol{\theta}_\varkappa^*) = \frac{1}{2} \|D_\varkappa(\tilde{\boldsymbol{\theta}}_\varkappa - \boldsymbol{\theta}_\varkappa^*)\|^2 = \frac{1}{2} \|\sigma^{-2} D_\varkappa^{-1}(\mathbf{Y} - \mathbf{f})\|^2.$$

Качество оценивания внутри \varkappa -модели может быть измерено как математическое ожидание эксцесса

$$\mathbb{E} \mathcal{X}_\varkappa = \frac{1}{2\sigma^2} \operatorname{tr}(D_\varkappa^{-2}) = \frac{1}{2} \sum_{j=1}^p \frac{1}{1 + \sigma^2 \varkappa g_j^2}.$$

Для линейных моделей математическое ожидание эксцесса внутри \varkappa -модели не зависит от истинного вектора \mathbf{f} и может быть вычислено, если известна дисперсия шума. Заметим, что качество оценки определяется именно в терминах значения функции правдоподобия L_\varkappa в точках $\tilde{\boldsymbol{\theta}}_\varkappa$ и $\boldsymbol{\theta}_\varkappa^*$, а не расстоянием $\mathbb{E} \|\tilde{\boldsymbol{\theta}}_\varkappa - \boldsymbol{\theta}_\varkappa^*\|^2$.

Смещение b_\varkappa фиксированной \varkappa -модели может быть определено через расстояние Кульбака—Лейблера

$$\operatorname{KL}(\mathbb{P}_{\boldsymbol{\theta}_\varkappa^*}, \mathbb{P}_{\mathbf{f}}) = -\mathbb{E} L(\boldsymbol{\theta}_\varkappa^*) = \frac{1}{2\sigma^2} \|\mathbf{f} - \boldsymbol{\theta}_\varkappa^*\|^2.$$

Геометрический смысл заключается в том, что расстояние между мерой, параметризованной $\boldsymbol{\theta}_\varkappa^*$, и истинной мерой не должно быть слишком большим. Альтернативно можно определить модельное смещение величиной $-\mathbb{E} L_\varkappa(\boldsymbol{\theta}_\varkappa^*)$, которая отличается от расстояния Кульбака—Лейблера на величину $\text{pen}(\boldsymbol{\theta}_\varkappa^*, \varkappa)$:

$$b_\varkappa \stackrel{\text{def}}{=} -\mathbb{E} L_\varkappa(\boldsymbol{\theta}_\varkappa^*) = \operatorname{KL}(\mathbb{P}_{\boldsymbol{\theta}_\varkappa^*}, \mathbb{P}_{\mathbf{f}}) - \text{pen}(\boldsymbol{\theta}_\varkappa^*, \varkappa).$$

Общий риск оценивания \mathcal{R}_\varkappa можно определить как сумму математического ожидания эксцесса и смещения между моделями:

$$\mathcal{R}_\varkappa = \mathbb{E}X_\varkappa + b_\varkappa.$$

Естественно определить *оракульный* выбор \varkappa° как минимум риска \mathcal{R}_\varkappa :

$$\varkappa^\circ = \operatorname{argmin}_{\varkappa \in \mathcal{K}} \mathcal{R}_\varkappa.$$

Заметим, что предлагаемый метод существенно отличается от широко распространённого метода оценивания $\mathbb{E}\|\boldsymbol{\theta}_\varkappa - \mathbf{f}\|^2$ как раз из-за того, что рассматриваются значения функций правдоподобия. То есть идея состоит в исследовании искусственно созданных \varkappa -моделей, когда $\mathbb{E}L(\boldsymbol{\theta}_\varkappa^*)$ не сильно отличается от $\mathbb{E}L(\mathbf{f})$.

Иначе можно определять лучшую точку \varkappa через оптимизацию математического ожидания правдоподобия $\mathbb{E}L_\varkappa(\boldsymbol{\theta})$ по обоим параметрам как

$$\varkappa^* = \operatorname{argmax}_{\varkappa \in \mathcal{K}} \max_{\boldsymbol{\theta} \in \Theta} \mathbb{E}L_\varkappa(\boldsymbol{\theta}) = \operatorname{argmax}_{\varkappa \in \mathcal{K}} \mathbb{E}L_\varkappa(\boldsymbol{\theta}_\varkappa^*)$$

К сожалению, данная величина никак не учитывает «положительный эффект» от регуляризации внутри \varkappa -модели. Но если получится как-то внести в модель эту информацию и рассматривать $\mathbb{E}L_\varkappa(\boldsymbol{\theta}_\varkappa^*) - \mathbb{E}X_\varkappa$ как правдоподобие модели, то очевидно, что $\varkappa^* = \varkappa^\circ$, и тогда можно использовать все хорошо известные свойства оценки максимума правдоподобия.

2.2. Байесовский выбор модели

В байесовском выборе модели предполагается, что параметр $\boldsymbol{\theta}$ случайный. Рассматриваемая регуляризация эквивалентна гауссовскому распределению $\boldsymbol{\theta}$. Модель задаётся следующим распределением:

$$\mathbf{Y} \mid \boldsymbol{\theta} \sim \exp(L(\boldsymbol{\theta})), \quad \boldsymbol{\theta} \mid \varkappa \sim \Pi_\varkappa(\cdot).$$

Для апостериорного распределения $\boldsymbol{\theta}$ при условии данных \mathbf{Y} имеем

$$\mathbb{P}(\boldsymbol{\theta} \in A \mid \mathbf{Y}) \propto \int_A \exp\{L(\boldsymbol{\theta})\} \Pi_\varkappa(d\boldsymbol{\theta}) = \int_A \exp\{L(\boldsymbol{\theta})\} \pi_\varkappa(\boldsymbol{\theta}) d\boldsymbol{\theta}. \quad (2.1)$$

Неизвестный параметр \varkappa можно выбирать, максимизируя данное выражение относительно \varkappa :

$$\hat{\varkappa} = \operatorname{argmax}_{\varkappa \in \mathcal{K}} \int_A \exp\{L(\boldsymbol{\theta})\} \pi_\varkappa(\boldsymbol{\theta}) d\boldsymbol{\theta}.$$

Данный метод называется методом максимума апостериорной вероятности и изучался, например, в [9], где были рассмотрены асимптотические свойства апостериорного распределения, в том числе его концентрация вокруг истинного значения $\boldsymbol{\theta}^*$.

Другой метод основан на максимизации по \varkappa максимального значения по параметру θ подынтегрального выражения в (2.1):

$$\hat{\varkappa} = \operatorname{argmax}_{\varkappa \in \mathcal{K}} \max_{\theta} \{L(\theta) + \log \pi_{\varkappa}(\theta)\}.$$

Видно, что данная оценка $\hat{\varkappa}$ совпадает с

$$\operatorname{argmax}_{\varkappa \in \mathcal{K}} \max_{\theta} L_{\varkappa}(\theta)$$

при

$$\operatorname{pen}(\theta, \varkappa) = -\log \pi_{\varkappa}(\theta).$$

При полном байесовском подходе предполагается, что \varkappa тоже случайный элемент, определённый на некотором вероятностном пространстве, из некоторого распределения с плотностью $\pi(\cdot)$, которое в конечном итоге будет зависеть от параметров, влияние которых мало на анализ. Для такой модели апостериорное распределение есть

$$\begin{aligned} \mathbb{P}(\vartheta \in A, \varkappa \in B \mid \mathbf{Y}) &\propto \int_A \exp\{L(\theta)\} \int_B \pi_{\varkappa}(\theta) \pi(\varkappa) d\theta d\varkappa = \\ &= \int_A \int_B \exp\{L(\theta) + \log \pi_{\varkappa}(\theta) + \log \pi(\varkappa)\} d\theta d\varkappa. \end{aligned} \quad (2.2)$$

Для гауссовской модели

$$\begin{aligned} \mathbf{Y} \mid \vartheta &\sim \mathcal{N}(\theta, \sigma^2 I_p), \\ \vartheta \mid \varkappa &\sim \mathcal{N}(0, \varkappa^{-1} G^{-2}), \\ \varkappa &\sim \pi(d\varkappa) \end{aligned}$$

подынтегральное выражение в (2.2) — это совместная плотность $(\mathbf{Y}, \vartheta, \varkappa)$:

$$(\mathbf{Y}, \vartheta, \varkappa) \sim \exp\left(-\frac{1}{2\sigma^2} \|\mathbf{Y} - \theta\|^2 - \frac{\varkappa}{2} \|G\theta\|^2 - \frac{1}{2} \log \det(\varkappa^{-1} G^{-2}) + \log \pi(\varkappa)\right), \quad (2.3)$$

где член $(1/2) \log \det(\varkappa^{-1} G^{-2})$ — нормализация плотности $\pi_{\varkappa}(\theta)$.

Далее в работе показывается, что апостериорное распределение (2.2) при $A = \Theta$ концентрируется вокруг эмпирической версии оракульной оценки при подходящем априорном распределении $\pi(\varkappa)$. Как было отмечено, оценка максимума правдоподобия совпадает с оракульной оценкой, если сделать небольшую коррекцию функции правдоподобия. Естественным представляется использование байесовского подхода и осуществление данной коррекции путём предположения соответствующего априорного распределения.

3. Основные результаты

Исследуется априорное распределение $\pi(\varkappa)$, которое имитирует идею оракульного оценивания.

3.1. Построение априорного распределения

Рассмотрим распределение

$$\pi_0(\varkappa) = \varkappa^{-p/2} \exp(-\mathbb{E}\mathcal{X}_\varkappa).$$

Очевидно, что соответствующая логарифмическая плотность (2.3) равна $L_\varkappa(\boldsymbol{\theta})$ без учёта постоянного члена с матрицей G^2 . К сожалению, данное распределение не влечёт концентрации, что будет показано далее. Ниже рассматривается несколько модифицированное распределение

$$\pi(d\varkappa) \propto \pi_0(\varkappa) \exp(-\varepsilon \mathbb{E}\mathcal{X}_\varkappa + c \log \varkappa) d\varkappa,$$

где ε и c — некоторые положительные константы. Априорное распределение с параметрами $c = \varepsilon = 0$ не является достаточным для концентрации. Существует «худший» случай, когда риск становится «плоским». Для любой модели из рассматриваемого класса существует сигнал $f_i = \sigma$, который влечёт $\mathcal{R}_\varkappa = p/2$ независимо от \varkappa .

3.2. Односторонняя концентрация апостериорного распределения \varkappa

В этом разделе описывается главный результат для апостериорного распределения \varkappa . Обозначим $\Omega(\mathbf{x})$ случайное событие с вероятностью $\mathbb{P}(\Omega(\mathbf{x})) \geq 1 - Ce^{-x}$. Удобно ввести функцию

$$\mathcal{L}(\boldsymbol{\theta}, \varkappa) \stackrel{\text{def}}{=} L(\boldsymbol{\theta}) + \log \pi_\varkappa(\boldsymbol{\theta}) + \log \pi(\varkappa)$$

из (2.2). Также будем использовать обозначение $\boldsymbol{\nu} = (\boldsymbol{\theta}, \varkappa)$ для простоты изложения. Таким образом, будем писать $\mathcal{L}(\boldsymbol{\nu})$ вместо $\mathcal{L}(\boldsymbol{\theta}, \varkappa)$, если нет необходимости выделять компоненты вектора $\boldsymbol{\nu}$. Также введём обозначение

$$\mathcal{D}_0^2 = -\nabla^2 \mathbb{E}\mathcal{L}(\boldsymbol{\nu}^*),$$

где

$$\boldsymbol{\nu}^* = (\boldsymbol{\theta}^*, \varkappa^*) = \underset{\boldsymbol{\theta}, \varkappa}{\operatorname{argmax}} \mathbb{E}\mathcal{L}(\boldsymbol{\theta}, \varkappa),$$

и зададим локальную окрестность точки \varkappa^* :

$$\mathcal{K}_o(\mathbf{r}) \stackrel{\text{def}}{=} \{\varkappa : \|(\boldsymbol{\nu} - \boldsymbol{\nu}^*)^\top \mathcal{D}_0^2 (\boldsymbol{\nu} - \boldsymbol{\nu}^*)\| \leq \mathbf{r}\}.$$

Для удобства обозначим границы множества $\mathcal{K}_o(\mathbf{r}_0)$ через \varkappa_1 и \varkappa_2 , $\varkappa_1 < \varkappa_2$, и введём множества $\mathcal{K}_1 = \{\varkappa \in \mathbb{R}_+ : \varkappa \leq \varkappa_1\}$ и $\mathcal{K}_2 = \{\varkappa \in \mathbb{R}_+ : \varkappa \geq \varkappa_2\}$. Далее предполагается, что локальный радиус \mathbf{r}_0 зафиксирован определённым образом. Условия на выбор \mathbf{r}_0 будут указаны ниже в разделе D. Удобно рассмотреть матрицу \mathcal{D}_0^2 в блочном виде:

$$\mathcal{D}_0^2 = \begin{pmatrix} D_0^2 & A \\ A^\top & H_0^2 \end{pmatrix},$$

где $D_0^2 = D_{\varkappa^*}^2 = \sigma^{-2}I_p + \varkappa^*G^2$. Обозначим $d_0^2 = H_0^2 - A^\top D_0^{-2}A$, и пусть $\xi = d_0^{-1}\check{\nabla}_{\varkappa}$, где $\check{\nabla}_{\varkappa} = -D_0^{-2}A\nabla_{\theta}$ и $\nabla_{\theta} = \nabla_{\theta}\mathcal{L}(\nu^*)$.

Определим

$$\varkappa_{\epsilon} \stackrel{\text{def}}{=} \bar{\mathbb{E}}\varkappa, \quad \mathfrak{S}^2 \stackrel{\text{def}}{=} \text{Cov}(\varkappa) \stackrel{\text{def}}{=} \bar{\mathbb{E}}(\varkappa - \varkappa_{\epsilon})^2,$$

где $\bar{\mathbb{E}}$ — условное математическое ожидание:

$$\bar{\mathbb{E}}\mu \stackrel{\text{def}}{=} \mathbb{E}[\mu \mid \mathbf{Y}, \varkappa \in \mathcal{K}_1 \cup \mathcal{K}_o(\mathbf{r}_0)]$$

для случайной величины η . Обе величины зависят от данных и могут быть вычислены.

Далее формулируется результат в неасимптотической постановке, который утверждает, что \varkappa_{ϵ} близко к оценке $\tilde{\varkappa}$, \mathfrak{S}^2 примерно равно обратной дисперсии d_0^{-2} оценки $\tilde{\varkappa}$ и $\mathfrak{S}^{-1}(\varkappa_{\epsilon} - \tilde{\varkappa})$ при условии данных имеет примерно стандартно нормальное распределение. Под константой \mathbf{C} будем подразумевать абсолютную константу, не обязательно одну и ту же во всех результатах.

Теорема 3.1. *При условии (\mathcal{L}_0) на множестве $\mathcal{K}_o(\mathbf{r}_0)$ (см. раздел А) на множестве доминирующей вероятности $\Omega(\mathbf{x})$ с $\delta(\mathbf{r}_0) > 0$ из условия (\mathcal{L}_0) выполняется*

$$d_0^2(\varkappa_{\epsilon} - \tilde{\varkappa})^2 \leq \mathbf{C}\delta(p+1+\mathbf{x}), \quad |1 - d_0^2\mathfrak{S}^2| \leq \mathbf{C}\delta(p+1+\mathbf{x}).$$

Более того, для любого $\lambda \in \mathbb{R}$ с $\lambda^2 \leq \mathbf{x}$

$$|\log \bar{\mathbb{E}}[\exp\{\lambda d_0(\varkappa - \tilde{\varkappa})\}] - \lambda^2/2| \leq \mathbf{C}\delta(p+1+\mathbf{x}).$$

Для любого измеримого множества $A \subset \mathbb{R}$ и $\mathbf{q} = 1 + |\xi|^2$

$$\begin{aligned} \mathbb{P}(d_0(\varkappa - \tilde{\varkappa}) \in A \mid \mathbf{Y}, \varkappa \in \mathcal{K}_1 \cup \mathcal{K}_o(\mathbf{r}_0)) &\geq \\ &\geq \exp(-\mathbf{C}\delta(p+1+\mathbf{x}))\{\mathbb{P}(\gamma \in A) - \mathbf{C}\delta\mathbf{q}^{1/2}\} - \mathbf{C}e^{-\mathbf{x}}, \\ \mathbb{P}(d_0(\varkappa - \tilde{\varkappa}) \in A \mid \mathbf{Y}, \varkappa \in \mathcal{K}_1 \cup \mathcal{K}_o(\mathbf{r}_0)) &\leq \\ &\leq \exp(\mathbf{C}\delta(p+1+\mathbf{x}))\{\mathbb{P}(\gamma \in A) + \mathbf{C}\delta\mathbf{q}^{1/2}\} + \mathbf{C}e^{-\mathbf{x}}. \end{aligned}$$

Полученный результат описывает апостериорное распределение \varkappa в зоне $\varkappa < \varkappa^*$. Согласно последнему утверждению теоремы это распределение мажорируется сверху и снизу двумя нормальными распределениями, что можно рассматривать как одностороннюю теорему Бернштейна—фон Мизеса (см. [13]).

А. Общий подход

Приложение содержит условия и доказательства основной теоремы и вспомогательных утверждений. Напомним, что

$$\mathcal{L}(\boldsymbol{\theta}, \varkappa) \stackrel{\text{def}}{=} L(\boldsymbol{\theta}) + \log \pi_{\varkappa}(\boldsymbol{\theta}) + \log \pi(\varkappa) \tag{A.1}$$

из (2.2).

Рассмотрим разложение процесса $\mathcal{L}(\boldsymbol{\nu})$ ($\boldsymbol{\nu} = (\boldsymbol{\theta}, \varkappa)$) как сумму его математического ожидания и стохастической компоненты $\mathcal{L}(\boldsymbol{\nu}) = \mathbb{E}\mathcal{L}(\boldsymbol{\nu}) + \zeta(\boldsymbol{\nu})$. Обозначим $\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*) = \mathcal{L}(\boldsymbol{\nu}) - \mathcal{L}(\boldsymbol{\nu}^*)$, где

$$\boldsymbol{\nu}^* = (\boldsymbol{\theta}^*, \varkappa^*) = \operatorname{argmax}_{\boldsymbol{\theta}, \varkappa} \mathbb{E}\mathcal{L}(\boldsymbol{\theta}, \varkappa).$$

Разложение вблизи истинной точки $\boldsymbol{\nu}^*$ Тейлора даёт

$$\mathbb{E}\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*) \approx -\frac{1}{2}(\boldsymbol{\nu} - \boldsymbol{\nu}^*)^\top \mathcal{D}_0^2(\boldsymbol{\nu} - \boldsymbol{\nu}^*), \quad (\text{A.2})$$

где используется, что $\nabla \mathbb{E}\mathcal{L}(\boldsymbol{\nu}^*) = 0$ и $\mathcal{D}_0^2 = -\nabla^2 \mathbb{E}\mathcal{L}(\boldsymbol{\nu}^*)$. Введём

$$\tilde{\boldsymbol{\nu}} = (\tilde{\boldsymbol{\theta}}, \tilde{\varkappa}) = \operatorname{argmax}_{\boldsymbol{\theta}, \varkappa} \mathcal{L}(\boldsymbol{\theta}, \varkappa).$$

Член $\log \pi_\varkappa(\boldsymbol{\theta}) + \log \pi(\varkappa)$ в (A.1) детерминированный, поэтому стохастическая компонента $\zeta(\boldsymbol{\nu})$ функции $\mathcal{L}(\boldsymbol{\nu})$ совпадает со стохастической компонентой процесса $L(\boldsymbol{\theta})$ и не зависит от \varkappa . Более того, для гауссовской модели (2.3) стохастическая компонента линейная:

$$\zeta(\boldsymbol{\nu}) - \zeta(\boldsymbol{\nu}^*) = (\boldsymbol{\nu} - \boldsymbol{\nu}^*)^\top \nabla \zeta(\boldsymbol{\nu}^*), \quad \nabla \zeta(\boldsymbol{\nu}^*) = \begin{pmatrix} \sigma^{-2}(\mathbf{Y} - \mathbf{f}) \\ 0 \end{pmatrix}. \quad (\text{A.3})$$

Матрица \mathcal{D}_0^2 — гессиан со знаком минус математического ожидания $\mathbb{E}\mathcal{L}(\boldsymbol{\nu})$ в точке $(\boldsymbol{\nu}^*)$. Для гауссовской модели она имеет вид

$$\mathcal{D}_0^2 = \begin{pmatrix} \sigma^{-2}I_p + \varkappa^*G^2 & \sigma^{-2}G^2(\sigma^2I_p + \varkappa^*G^2)^{-1}\mathbf{f} \\ (\sigma^{-2}G^2(\sigma^{-2}I_p + \varkappa^*G^2)^{-1}\mathbf{f})^\top & (2\varkappa^{*2})^{-2}p - \frac{d^2}{d\varkappa^2} \log \pi(\varkappa) \end{pmatrix}.$$

Для дальнейшего анализа удобно использовать более компактную запись

$$\mathcal{D}_0^2 = \begin{pmatrix} D_0^2 & A \\ A^\top & H_0^2 \end{pmatrix}$$

где $D_0^2 = D_{\varkappa^*}^2 = \sigma^{-2}I_p + \varkappa^*G^2$.

Используя (A.2) и (A.3), можно разложить процесс $\mathcal{L}(\boldsymbol{\nu})$, введя $\boldsymbol{\nu}_\varkappa^* = (\boldsymbol{\theta}_\varkappa^*, \varkappa)$:

$$\mathbb{E}\mathcal{L}(\boldsymbol{\nu}) - \mathbb{E}\mathcal{L}(\boldsymbol{\nu}^*) = \mathbb{E}\mathcal{L}(\boldsymbol{\nu}) - \mathbb{E}\mathcal{L}(\boldsymbol{\nu}_\varkappa^*) + \mathbb{E}\mathcal{L}(\boldsymbol{\nu}_\varkappa^*) - \mathbb{E}\mathcal{L}(\boldsymbol{\nu}^*),$$

$$\mathbb{E}\mathcal{L}(\boldsymbol{\nu}) - \mathbb{E}\mathcal{L}(\boldsymbol{\nu}_\varkappa^*) = -\frac{1}{2}(\boldsymbol{\theta} - \boldsymbol{\theta}_\varkappa^*)^\top D_\varkappa^2(\boldsymbol{\theta} - \boldsymbol{\theta}_\varkappa^*), \quad (\text{A.4})$$

$$\mathbb{E}\mathcal{L}(\boldsymbol{\nu}_\varkappa^*) - \mathbb{E}\mathcal{L}(\boldsymbol{\nu}^*) \approx -\frac{1}{2}(\boldsymbol{\nu}_\varkappa^* - \boldsymbol{\nu}^*)^\top \mathcal{D}_0^2(\boldsymbol{\nu}_\varkappa^* - \boldsymbol{\nu}^*), \quad (\text{A.5})$$

где для $\mathbb{E}\mathcal{L}(\boldsymbol{\nu}) - \mathbb{E}\mathcal{L}(\boldsymbol{\nu}_\varkappa^*)$ использовано, что процесс гауссовский при фиксированном \varkappa .

Подход [10] предполагает выполнение нескольких достаточных условий. Для гауссовской модели условия существенно упрощаются. Локальная окрестность $\mathcal{K}_o(\mathbf{r})$ лучшей точки \varkappa^* зависит только от параметра \varkappa . Введём $\mathcal{Y}_o(\mathbf{r}) = \Theta \times \mathcal{K}_o(\mathbf{r})$. Локальное условие описывает свойства процесса $\mathcal{L}(\boldsymbol{\nu})$ для $\varkappa \in \mathcal{K}_o(\mathbf{r}_0)$ при некотором фиксированном значении \mathbf{r}_0 .

В. Локальное условие

(\mathcal{L}_0) для любого $\mathbf{r} \leq \mathbf{r}_0$ найдутся $\delta(\mathbf{r}) \leq 1/2$ и положительно определённая матрица \mathcal{D}_0^2 , такие что для любого $\boldsymbol{\varkappa} \in \mathcal{K}_o(\mathbf{r})$ справедливо

$$\left| \frac{-2\mathbb{E}\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)}{(\boldsymbol{\nu} - \boldsymbol{\nu}^*)^\top \mathcal{D}_0^2 (\boldsymbol{\nu} - \boldsymbol{\nu}^*)} - 1 \right| \leq \delta(\mathbf{r}). \quad (\text{B.1})$$

Локальное условие нужно, чтобы контролировать ошибку в разложении Тейлора (A.2) вблизи окрестности точки $\boldsymbol{\nu}^*$.

С. Локальный брэкетинг и большие уклонения

Основной шаг в подходе [10] — это локальный брэкетинг, или зажатие процесса $\mathcal{L}(\boldsymbol{\nu})$ в локальной окрестности точки $\boldsymbol{\nu}^*$ двумя квадратичными функциями:

$$\mathbb{L}_{\underline{\epsilon}}(\boldsymbol{\nu}, \boldsymbol{\nu}^*) \leq \mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*) \leq \mathbb{L}_{\epsilon}(\boldsymbol{\nu}, \boldsymbol{\nu}^*), \quad \boldsymbol{\nu} \in \mathcal{Y}_o(\mathbf{r}), \quad (\text{C.1})$$

где

$$\mathbb{L}_{\epsilon}(\boldsymbol{\nu}, \boldsymbol{\nu}^*) \stackrel{\text{def}}{=} (\boldsymbol{\nu} - \boldsymbol{\nu}^*)^\top \nabla \zeta(\boldsymbol{\nu}) - \frac{1}{2} (\boldsymbol{\nu} - \boldsymbol{\nu}^*)^\top \mathcal{D}_{\epsilon}^2 (\boldsymbol{\nu} - \boldsymbol{\nu}^*), \quad (\text{C.2})$$

$\mathcal{D}_{\epsilon}^2 = (1 - \delta)\mathcal{D}_0^2$. Разложение напрямую следует из условия (\mathcal{L}_0). Аналогично для $\underline{\epsilon} = -\epsilon$.

Матрицу \mathcal{D}_{ϵ}^2 можно диагонализировать. Используя замену переменных $\boldsymbol{\gamma} = \boldsymbol{\theta} - \boldsymbol{\theta}^* + D_0^{-2}A(\boldsymbol{\varkappa} - \boldsymbol{\varkappa}^*)$, запишем (C.2) как

$$\mathbb{L}_{\epsilon}(\boldsymbol{\nu}, \boldsymbol{\nu}^*) = (\boldsymbol{\gamma} - \boldsymbol{\gamma}^*)^\top \nabla_{\boldsymbol{\theta}} \zeta - \frac{1}{2} (\boldsymbol{\gamma} - \boldsymbol{\gamma}^*)^\top D_{\epsilon}^2 (\boldsymbol{\gamma} - \boldsymbol{\gamma}^*) + (\boldsymbol{\varkappa} - \boldsymbol{\varkappa}^*)^\top \check{\nabla}_{\boldsymbol{\varkappa}} \zeta - \frac{1}{2} (\boldsymbol{\varkappa} - \boldsymbol{\varkappa}^*)^\top d_{\epsilon}^2,$$

где $\check{\nabla}_{\boldsymbol{\varkappa}} = -D_0^{-2}A \nabla_{\boldsymbol{\theta}}$, $d_{\epsilon}^2 = (1 - \delta)d_0^2$, $d_0^2 = H_0^2 - A^\top D_0^{-2}A$ и $D_{\epsilon}^2 = (1 - \delta)D_0^2$. Обозначим \check{D}_{ϵ}^2 диагонализированную матрицу \mathcal{D}_{ϵ}^2 . Переобозначив $\boldsymbol{\nu} = (\boldsymbol{\gamma}, \boldsymbol{\varkappa})$, можно переписать $\mathbb{L}_{\epsilon}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)$ в более компактном виде:

$$\mathbb{L}_{\epsilon}(\boldsymbol{\nu}, \boldsymbol{\nu}^*) = (\boldsymbol{\nu} - \boldsymbol{\nu}^*)^\top \check{D}_{\epsilon} \boldsymbol{\xi}_{\epsilon} - \frac{1}{2} (\boldsymbol{\nu} - \boldsymbol{\nu}^*)^\top \check{D}_{\epsilon}^2 (\boldsymbol{\nu} - \boldsymbol{\nu}^*), \quad (\text{C.3})$$

где $\boldsymbol{\xi}_{\epsilon} = \check{D}_{\epsilon}^{-1} \nabla \zeta$ и $\boldsymbol{\xi}^* = d_{\epsilon}^{-1} \check{\nabla}_{\boldsymbol{\varkappa}}$. Аналогично для $\underline{\epsilon} = -\epsilon$.

Далее покажем, что распределение $d_{\epsilon}(\boldsymbol{\varkappa} - \boldsymbol{\varkappa}_{\epsilon})$ при данных \mathbf{Y} и при условии, что $\boldsymbol{\varkappa} \in \mathcal{K}_1 \cup \mathcal{K}_o(\mathbf{r}_0)$, примерно стандартное нормальное, где

$$\boldsymbol{\varkappa}_{\epsilon} = \boldsymbol{\varkappa}^* + d_{\epsilon}^{-1} \boldsymbol{\xi}^*.$$

Вместе с разложением $d_{\epsilon}(\tilde{\boldsymbol{\varkappa}} - \boldsymbol{\varkappa}^*) - \boldsymbol{\xi}^* \approx 0$ это показывает, что $d_{\epsilon}(\tilde{\boldsymbol{\varkappa}} - \boldsymbol{\varkappa}_{\epsilon}) \approx 0$, и теорема утверждает, что распределение $d_{\epsilon}(\boldsymbol{\varkappa} - \tilde{\boldsymbol{\varkappa}})$ примерно стандартное нормальное при условии данных \mathbf{Y} и при условии $\boldsymbol{\varkappa} \in \mathcal{K}_1 \cup \mathcal{K}_o(\mathbf{r}_0)$.

Для неотрицательной функции f локальный брэкетинг (C.1) даёт

$$\int_{\mathcal{Y}_o(\mathbf{r}_0)} \exp\{\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)\} f(d_{\epsilon}(\boldsymbol{\varkappa} - \boldsymbol{\varkappa}_{\epsilon})) d\boldsymbol{\nu} \leq \int_{\mathcal{Y}_o(\mathbf{r}_0)} \exp\{\mathbb{L}_{\epsilon}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)\} f(d_{\epsilon}(\boldsymbol{\varkappa} - \boldsymbol{\varkappa}_{\epsilon})) d\boldsymbol{\nu}.$$

Аналогично для $\varkappa_{\underline{\epsilon}} = \varkappa^* + d_{\underline{\epsilon}}^{-1} \xi_{\underline{\epsilon}}$

$$\int_{\gamma_0(\mathbf{r}_0)} \exp\{\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)\} f(d_{\underline{\epsilon}}(\varkappa - \varkappa_{\underline{\epsilon}})) d\boldsymbol{\nu} \geq \int_{\gamma_0(\mathbf{r}_0)} \exp\{\mathbb{L}_{\underline{\epsilon}}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)\} f(d_{\underline{\epsilon}}(\varkappa - \varkappa_{\underline{\epsilon}})) d\boldsymbol{\nu}.$$

Основной смысл данного брэккетинга в том, что $\mathbb{L}_{\underline{\epsilon}}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)$ и $\mathbb{L}_{\underline{\epsilon}}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)$ — квадратичные функции по $\boldsymbol{\nu}$ и, значит, соответствуют некоторым гауссовским распределениям.

Напомним, что $\Omega(\mathbf{x})$ обозначает случайное событие с вероятностью $\mathbb{P}(\Omega(\mathbf{x})) \geq 1 - \mathcal{C}e^{-x}$.

Теорема С.1. Для любого $\delta \geq \delta(\mathbf{r}_0)$ при условии (\mathcal{L}_0) на \mathcal{K}_0 для неотрицательной функции $f(\cdot)$ на \mathbb{R} на множестве доминирующей вероятности $\Omega(\mathbf{x})$ выполняется

$$\mathbb{E}[f(d_{\underline{\epsilon}}(\varkappa - \varkappa_{\underline{\epsilon}})) \mathbb{I}\{\varkappa \in \mathcal{K}_0(\mathbf{r}_0)\} \mid \mathbf{Y}] \leq \exp\{\Delta_{\underline{\epsilon}}^+(\mathbf{r}_0)\} \mathbb{E}f(\gamma), \quad (\text{C.4})$$

где

$$\Delta_{\underline{\epsilon}}^+(\mathbf{r}_0) = \Delta_{\underline{\epsilon}}(\mathbf{r}_0) + \frac{p+1}{2} \log \frac{1+\delta}{1-\delta} + \tau_{\underline{\epsilon}}(\mathbf{r}_0)$$

с $\Delta_{\underline{\epsilon}}(\mathbf{r}_0) \stackrel{\text{def}}{=} \|\xi_{\underline{\epsilon}}\|^2/2 - \|\xi_{\underline{\epsilon}}\|^2/2$, и для $\gamma \sim \mathcal{N}(0, 1)$

$$\tau_{\underline{\epsilon}}(\mathbf{r}_0) \stackrel{\text{def}}{=} -\log \mathbb{P}(|\gamma + \xi_{\underline{\epsilon}}| \leq \mathbf{r}_0 \mid \mathbf{Y}). \quad (\text{C.5})$$

Более того, на $\Omega(\mathbf{x})$ выполняется $\Delta_{\underline{\epsilon}}^+(\mathbf{r}_0) \leq \mathcal{C}\delta(p+1+x)$.

Доказательство. Определим

$$m_{\underline{\epsilon}}(\xi_{\underline{\epsilon}}) \stackrel{\text{def}}{=} -\frac{\|\xi_{\underline{\epsilon}}\|^2}{2} + \log(\det \check{\mathcal{D}}_{\underline{\epsilon}}) - (p+1) \log(\sqrt{2\pi}). \quad (\text{C.6})$$

Тогда с учётом (C.3) имеем

$$m_{\underline{\epsilon}}(\xi_{\underline{\epsilon}}) + \mathbb{L}_{\underline{\epsilon}}(\boldsymbol{\nu}, \boldsymbol{\nu}^*) = -\frac{\|\check{\mathcal{D}}_{\underline{\epsilon}}\{\boldsymbol{\nu} - \boldsymbol{\nu}^*\} - \xi_{\underline{\epsilon}}\|^2}{2} + \log(\det \check{\mathcal{D}}_{\underline{\epsilon}}) - (p+1) \log(\sqrt{2\pi}), \quad (\text{C.7})$$

что есть логарифмическая плотность нормального распределения со средним $\boldsymbol{\nu}_{\underline{\epsilon}} = \check{\mathcal{D}}_{\underline{\epsilon}}^{-1} \xi_{\underline{\epsilon}} + \boldsymbol{\nu}^*$ и матрицей ковариации $\check{\mathcal{D}}_{\underline{\epsilon}}^{-2}$. Используя замену переменных $u = d_{\underline{\epsilon}}(\varkappa - \varkappa^*) - \xi^*$ и (C.7), получаем для любой неотрицательной функции f

$$\begin{aligned} & \int \exp\{\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*) + m_{\underline{\epsilon}}(\xi_{\underline{\epsilon}})\} f(d_{\underline{\epsilon}}(\varkappa - \varkappa_{\underline{\epsilon}})) d\boldsymbol{\nu} \leq \\ & \stackrel{\gamma_0}{\leq} \int \exp\{\mathbb{L}_{\underline{\epsilon}}(\boldsymbol{\nu}, \boldsymbol{\nu}^*) + m_{\underline{\epsilon}}(\xi_{\underline{\epsilon}})\} f(d_{\underline{\epsilon}}(\varkappa - \varkappa_{\underline{\epsilon}})) d\boldsymbol{\nu} = \int \phi(u) f(u) du = \mathbb{E}f(\gamma). \end{aligned} \quad (\text{C.8})$$

Аналогично если $m_{\underline{\epsilon}}(\xi_{\underline{\epsilon}})$ определена в (C.6) с $\underline{\epsilon}$ вместо ϵ , то значение $m_{\underline{\epsilon}}(\xi_{\underline{\epsilon}}) + \mathbb{L}_{\underline{\epsilon}}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)$ при условии данных есть плотность нормального закона

со средним $\boldsymbol{\nu}_\epsilon = \check{D}_\epsilon^{-1}\boldsymbol{\xi}_\epsilon + \boldsymbol{\nu}^*$ и ковариационной матрицей \check{D}_ϵ^{-2} . Для любой неотрицательной функции f

$$\int_{r_0(\mathbf{r}_0)} \exp\{\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)\} f(d_\epsilon(\boldsymbol{x} - \boldsymbol{x}_\epsilon)) d\boldsymbol{\nu} \geq \exp\{-m_\epsilon(\boldsymbol{\xi}_\epsilon)\} \int \phi(u) f(u) \mathbb{I}\{d_\epsilon^{-1}(u + \boldsymbol{\xi}_\epsilon) \in \mathcal{K}_o(\mathbf{r}_0)\} du. \quad (\text{C.9})$$

Используя $d_\epsilon^2 \geq d_0^2$ и $|\boldsymbol{\xi}_\epsilon| \leq |\boldsymbol{\xi}|$, получаем

$$\{d_\epsilon^{-1}(u + \boldsymbol{\xi}_\epsilon) \in \mathcal{K}_o(\mathbf{r}_0)\} = \{|d_0 d_\epsilon^{-1}(u + \boldsymbol{\xi}_\epsilon)| \leq \mathbf{r}_0\} \supset \{|u + \boldsymbol{\xi}| \leq \mathbf{r}_0\}.$$

Специальный случай (C.9) при $f(u) \equiv 1$ по определению τ_ϵ даёт

$$\int_{r_0} \exp\{\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)\} d\boldsymbol{\nu} \geq \exp\{-m_\epsilon(\boldsymbol{\xi}_\epsilon) - \tau_\epsilon\}. \quad (\text{C.10})$$

При (C.8) и (C.10) получаем

$$\begin{aligned} \frac{\int_{r_0(\mathbf{r}_0)} \exp\{\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)\} f(d_\epsilon(\boldsymbol{x} - \boldsymbol{x}_\epsilon^*)) d\boldsymbol{\nu}}{\int \exp\{\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)\} d\boldsymbol{\nu}} &\leq \exp\{m_\epsilon(\boldsymbol{\xi}_\epsilon) - m_\epsilon(\boldsymbol{\xi}_\epsilon) + \tau_\epsilon(\mathbf{r}_0)\} \mathbb{E}f(\gamma) = \\ &= \exp\left\{\Delta_\epsilon(\mathbf{r}_0) + \frac{p+1}{2} \log \frac{1+\delta}{1-\delta} + \tau_\epsilon(\mathbf{r}_0)\right\} \mathbb{E}f(\gamma), \end{aligned}$$

что доказывает (C.4). \square

Далее покажем, что члены $\Delta_\epsilon(\mathbf{r}_0)$, $(p+1) \log((1+\delta)/(1-\delta))$ и $\tau_\epsilon(\mathbf{r}_0)$ малы с большой вероятностью при выполнении локального условия. Важно, что если забыть о них, приравнять матрицы \check{D}_ϵ и \check{D}_ϵ и векторы $\boldsymbol{\xi}_\epsilon$ и $\boldsymbol{\xi}_\epsilon$, то теорема говорит о примерно стандартном нормальном распределении для $\check{D}_\epsilon(\boldsymbol{\nu} - \boldsymbol{\nu}^*) - \boldsymbol{\xi}_\epsilon$ при условии данных \mathbf{Y} . Значение

$$\boldsymbol{x}_\epsilon \stackrel{\text{def}}{=} (p+1) \log \frac{1+\delta}{1-\delta}$$

может быть ограничено $1,1(p+1)\delta$, если $\delta \leq 0,5$. По определению $d_\epsilon^2 d_0^{-2} \leq 1 + \delta$. Тогда для $\gamma \sim \mathcal{N}(0, 1)$ и $\mathbf{r}_0^2 \geq \mathbf{C}$

$$\tau_\epsilon(\mathbf{r}_0) = -\log \mathbb{P}\{|d_0 d_\epsilon^{-1}(\gamma + \boldsymbol{\xi}_\epsilon)| \leq \mathbf{r}_0 \mid \mathbf{Y}\} \leq -\log \mathbb{P}\{\gamma^2 \leq 1 + \mathbf{C}\mathbf{x}\} \leq e^{-\mathbf{x}}.$$

В [10] было доказано в чуть более общей формулировке, что $\boldsymbol{\xi}_\epsilon^2 \leq \mathbf{C}\delta(p+1+\mathbf{x})$ на $\Omega(\mathbf{x})$. Суммируя, можно получить

$$\Delta_\epsilon^+(\mathbf{r}_0) \leq \mathbf{C}\delta(p+1+\mathbf{x}).$$

Нижняя граница находится с помощью нескольких вспомогательных утверждений о концах апостериорного распределения. В конечном итоге будет использован специальный случай этой границы с $f(u) = \exp(\lambda u)$ при фиксированном векторе $\lambda \in \mathbb{R}$. Удобно ввести локальное условное математическое

ожидание: для случайной величины η определим

$$\mathbb{E}^\circ \eta \stackrel{\text{def}}{=} \mathbb{E}[\eta \mathbb{I}\{\varkappa \in \mathcal{K}_\circ(\mathbf{r}_0)\} \mid \mathbf{Y}].$$

Тогда границу (С.4) можно записать как

$$\mathbb{E}^\circ f(\lambda d_\epsilon(\varkappa - \varkappa_\epsilon)) \leq \exp\{\Delta_\epsilon^+(\mathbf{r}_0)\} \mathbb{E}f(\gamma).$$

В следующем результате рассмотрен специальный случай с $f(u) = \exp(\lambda u)$ и $f(u) = \mathbb{I}(u \in A)$ для измеримого множества $A \subset \mathbb{R}$.

Следствие С.2. Для любого $\lambda \in \mathbb{R}$

$$\log \mathbb{E}^\circ \exp\{\lambda d_\epsilon(\varkappa - \varkappa_\epsilon)\} \leq \frac{\lambda^2}{2} + \Delta_\epsilon^+(\mathbf{r}_0). \quad (\text{C.11})$$

Более того, для $\lambda^2 \leq \mathbf{x}$ и для $\check{\varkappa} = \varkappa^* + d_0^{-2} \check{\nabla}_{\varkappa} \mathcal{L}(\boldsymbol{\nu}^*)$

$$\log \mathbb{E}^\circ \exp\{\lambda d_0(\varkappa - \check{\varkappa})\} \leq \frac{\lambda^2}{2} + \Delta_\epsilon^\oplus(\mathbf{r}_0), \quad (\text{C.12})$$

где

$$\Delta_\epsilon^\oplus(\mathbf{r}_0) \stackrel{\text{def}}{=} \Delta_\epsilon^+(\mathbf{r}_0) + \delta + 2\delta|\xi|.$$

На множестве $\Omega(\mathbf{x})$ выполняется $\Delta_\epsilon^\oplus(\mathbf{r}_0) \leq \mathbf{C} \delta(p + 1 + \mathbf{x})$.

Доказательство. Первое утверждение есть прямое следствие теоремы с учётом того, что

$$\mathbb{E} \exp(\lambda u) = \frac{\lambda^2}{2}$$

для $u \sim \mathcal{N}(0, 1)$.

Для доказательства второго утверждения воспользуемся тем, что

$$\exp\{\lambda d_0(\varkappa - \check{\varkappa})\} = \exp\{\lambda_1 d_\epsilon(\varkappa - \varkappa_\epsilon)\} \exp\{\lambda d_0(\varkappa_\epsilon - \check{\varkappa})\}, \quad (\text{C.13})$$

где $\lambda_1 = (1 - \delta)^{-1/2} \lambda$. Так как $\lambda^2 \leq 1$, имеем

$$\lambda_1^2 = (1 - \delta)^{-1} \lambda^2 \leq (1 + 2\delta) \lambda^2 \leq \lambda^2 + 2\delta.$$

Осталось ограничить $\lambda d_0(\varkappa_\epsilon - \check{\varkappa})$ для $\check{\varkappa} = \varkappa^* + d_0^{-2} \check{\nabla}_{\varkappa} \mathcal{L}(\boldsymbol{\nu}^*) = \varkappa^* + d_0^{-1} \xi$ и $\varkappa_\epsilon = \varkappa^* + d_\epsilon^{-1} \xi^*$. По определению d_ϵ при $\delta \leq 1/2$

$$|d_0(\varkappa_\epsilon - \check{\varkappa})| = |d_0 d_\epsilon^{-1} \xi^* - \xi| = |(d_0^2 d_\epsilon^{-2} - 1) \xi| \leq \left(\frac{1}{1 - \delta} - 1 \right) |\xi| \leq 2\delta |\xi|. \quad (\text{C.14})$$

Это вместе с (С.11) и (С.13) в случае $\lambda^2 \leq 1$ доказывает второе утверждение. \square

Аналогично предыдущему результату условие $\delta \rightarrow 0$ влечёт малость $\Delta_\epsilon^+(\mathbf{r}_0)$ в (С.11) и $\Delta_\epsilon^\oplus(\mathbf{r}_0)$ в (С.12).

Следствие С.3. Для любого измеримого множества $A \subset \mathbb{R}$ на множестве $\Omega_{\mathbf{x}}$ с $\boldsymbol{\delta}_\epsilon \stackrel{\text{def}}{=} d_0(\varkappa_\epsilon - \check{\varkappa})$, где $\check{\varkappa} = \varkappa^* + d_0^{-2} \check{\nabla}_{\varkappa} \mathcal{L}(\boldsymbol{\nu}^*)$ и $\mathbf{q} = 1 + |\xi|^2$, выполняется

$$\mathbb{P}^\circ(d_0(\varkappa - \check{\varkappa}) \in A) \leq \exp\{\Delta_\epsilon^+(\mathbf{r}_0)\} \mathbb{P}(d_0 d_\epsilon^{-1} \gamma + \boldsymbol{\delta}_\epsilon \in A) \quad (\text{C.15})$$

$$\leq \exp\{\Delta_\epsilon^+(\mathbf{r}_0)\} \{\mathbb{P}(\gamma \in A) + \mathbf{C} \delta \mathbf{q}^{1/2}\}. \quad (\text{C.16})$$

Доказательство. Первое утверждение (С.15) следует из теоремы при $f(u) = \mathbb{I}(d_0 d_\epsilon^{-1} u + \delta_\epsilon \in A)$. По определению при $\delta \leq 1/2$

$$\delta_\epsilon \leq 2\delta|\xi|. \quad (\text{С.17})$$

Для доказательства (С.16) используем неравенство Пинскера для расстояния Кульбака—Лейблера между двумя нормальными распределениями. Пусть γ — стандартная нормальная случайная величина на \mathbb{R} из распределения \mathbb{P}_0 .

Случайная величина $d_0 d_\epsilon^{-1} \gamma + \delta_\epsilon$ нормальная со средним δ_ϵ и дисперсией $b_\epsilon^{-1} \stackrel{\text{def}}{=} d_0^2 d_\epsilon^{-2}$. Обозначим это распределение \mathbb{P}_ϵ . Очевидно, что $b_\epsilon = d_0^{-2} d_\epsilon^2 = (1 - \delta)$. Используем следующую техническую лемму.

Лемма С.4. Пусть $|b_\epsilon - 1| \leq \delta \leq 1/2$. Тогда

$$2\mathcal{K}(\mathbb{P}_0, \mathbb{P}_\epsilon) = -2\mathbb{E}_0 \log \frac{d\mathbb{P}_\epsilon}{d\mathbb{P}_0}(\gamma) \leq (b_\epsilon - 1)^2 + (1 + \delta)|\delta_\epsilon|^2 = \delta^2 + (1 + \delta)|\delta_\epsilon|^2.$$

По определению

$$2 \log \frac{d\mathbb{P}_\epsilon}{d\mathbb{P}_0}(\gamma) = -\log b_\epsilon - (\gamma - \delta_\epsilon)^2 b_\epsilon + |\gamma|^2.$$

Далее,

$$2\mathcal{K}(\mathbb{P}_0, \mathbb{P}_\epsilon) = -2\mathbb{E}_0 \log \frac{d\mathbb{P}_\epsilon}{d\mathbb{P}_0}(\gamma) = \log(b_\epsilon) + (b_\epsilon - 1)^2 + \delta_\epsilon^2 b_\epsilon \leq \delta^2 + (1 + \delta)|\delta_\epsilon|^2. \quad \square$$

Используя данную лемму, (С.17) и неравенство Пинскера, получаем

$$\|\mathbb{P}_0 - \mathbb{P}_\epsilon\|_{TV} \leq \sqrt{\frac{1}{2}\mathcal{K}(\mathbb{P}_0, \mathbb{P}_\epsilon)} \leq c\delta \sqrt{1 + |\xi|^2} \leq c\delta q^{1/2},$$

где $q = 1 + |\xi|^2$. Эквивалентно для любого измеримого множества A

$$\mathbb{P}(d_0 d_\epsilon^{-1} \gamma + \delta_\epsilon \in A \mid \mathbf{Y}) \leq \mathbb{P}(\gamma \in A) + c\epsilon q^{1/2}.$$

Следующее утверждение описывает локальные концентрационные свойства апостериорного распределения. А именно, центрированный и скалированный вектор $\boldsymbol{\eta} \stackrel{\text{def}}{=} d_\epsilon(\boldsymbol{\varkappa} - \boldsymbol{\varkappa}_\epsilon)$ концентрируется на множестве $\{u: |u^2 - 1| \leq \sqrt{2x}\}$ с вероятностью \mathbb{P}° порядка $1 - 2e^{-x/4}$.

Следствие С.5. Пусть $x \leq 1/2$. Тогда

$$\mathbb{P}^\circ(|d_\epsilon(\boldsymbol{\varkappa} - \boldsymbol{\varkappa}_\epsilon)|^2 - 1 > \sqrt{2x}) \leq \exp\left(-\frac{x}{4} + \Delta_\epsilon^+(\mathbf{r}_0)\right), \quad (\text{С.18})$$

$$\mathbb{P}^\circ(|d_\epsilon(\boldsymbol{\varkappa} - \boldsymbol{\varkappa}_\epsilon)|^2 - 1 > -\sqrt{2x}) \leq \exp\left(-\frac{x}{2} + \Delta_\epsilon^+(\mathbf{r}_0)\right). \quad (\text{С.19})$$

Доказательство. Обозначим $\boldsymbol{\eta}_\epsilon \stackrel{\text{def}}{=} d_\epsilon(\boldsymbol{\varkappa} - \boldsymbol{\varkappa}_\epsilon)$. Используя экспоненциальное неравенство Чебышёва для положительного $\lambda \leq 1/2$, с учётом того, что

$-\log(1 - \lambda) \leq \lambda + \lambda^2$, получаем

$$\begin{aligned} \mathbb{P}^\circ(\eta_\epsilon^2 > 1 + \sqrt{2x}) &\leq \exp\left\{-\frac{\lambda}{2}(1 + \sqrt{2x})\right\} \mathbb{E}^\circ \exp\left(\frac{\lambda}{2}\eta_\epsilon^2\right) \leq \\ &\leq \exp\left\{-\frac{\lambda}{2}(1 + \sqrt{2x}) + \Delta_\epsilon^+(\mathbf{r}_0)\right\} \mathbb{E} \exp\left(\frac{\lambda}{2}\gamma^2\right) = \\ &= \exp\left\{-\frac{\lambda}{2}(1 + \sqrt{2x}) - \frac{1}{2}\log(1 - \lambda) + \Delta_\epsilon^+(\mathbf{r}_0)\right\} \leq \\ &\leq \exp\left\{-\lambda\sqrt{\frac{x}{2}} + \frac{\lambda^2}{2} + \Delta_\epsilon^+(\mathbf{r}_0)\right\}. \end{aligned}$$

Выбор $\lambda = \sqrt{x/2}$ даёт (С.18). Аналогично

$$\begin{aligned} \mathbb{P}(\eta_\epsilon^2 - 1 < -\sqrt{2x}) &\leq \exp\left\{-\frac{\lambda}{2}(\sqrt{2x} - 1)\right\} \mathbb{E} \exp\left(-\frac{\lambda}{2}\eta_\epsilon^2\right) \leq \\ &\leq \exp\left\{-\frac{\lambda}{2}(\sqrt{2x} - 1) + \Delta_\epsilon^+(\mathbf{r}_0)\right\} \mathbb{E} \exp\left(-\frac{\lambda}{2}\gamma^2\right) = \\ &= \exp\left\{-\frac{\lambda}{2}(\sqrt{2x} - 1) - \frac{1}{2}\log(1 + \lambda) + \Delta_\epsilon^+(\mathbf{r}_0)\right\} \leq \\ &\leq \exp\left\{-\lambda\sqrt{\frac{x}{2}} + \frac{\lambda^2}{4} + \Delta_\epsilon^+(\mathbf{r}_0)\right\}. \end{aligned}$$

В данном случае выбор $\lambda = \sqrt{2x}$ влечёт результат. \square

D. «Хвосты» апостериорного распределения

Следующий основной шаг в анализе — показать, что апостериорное распределение концентрируется в локальной окрестности истинной точки.

Напомним, что мы ввели множества $\mathcal{K}_1 = \{\varkappa \in \mathbb{R}_+ : \varkappa \leq \varkappa_1\}$ и $\mathcal{K}_2 = \{\varkappa \in \mathbb{R}_+ : \varkappa \geq \varkappa_2\}$. Рассмотрим случайную величину

$$\rho(\mathbf{r}_0) \stackrel{\text{def}}{=} \frac{\int_{\Theta \times \mathcal{K}_1 \cup \mathcal{K}_2} \exp\{\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)\} d\boldsymbol{\nu}}{\int_{\mathcal{Y}_0} \exp\{\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)\} d\boldsymbol{\nu}} = \sum_{i=1}^2 \frac{\int_{\mathcal{Y}_i} \exp\{\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)\} d\boldsymbol{\nu}}{\int_{\mathcal{Y}_0} \exp\{\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)\} d\boldsymbol{\nu}} = \rho_1(\mathbf{r}_0) + \rho_2(\mathbf{r}_0), \quad (\text{D.1})$$

где $\mathcal{Y}_i = \Theta \times \mathcal{K}_i$. Ясно, что $\mathbb{P}\{\varkappa \notin \mathcal{K}_0 \mid \mathbf{Y}\} \leq \rho(\mathbf{r}_0)$. Представляется естественным оценить отдельно $\rho_1(\mathbf{r}_0)$ и $\rho_2(\mathbf{r}_0)$ из-за несимметричности процесса по \varkappa . Используем (А.4) и (А.5) для доказательства следующего утверждения.

Теорема D.1. Пусть

$$6\sqrt{x + c_1(p+1)} \leq \mathbf{r}_0(1 + \varepsilon)$$

с некоторой константой c_1 , такой что $x + c_1 p \geq 2,5$. Тогда на множестве $\Omega(x)$ выполняется

$$\rho_1(\mathbf{r}_0) \leq \exp\left(\tau_{\underline{\epsilon}}(\mathbf{r}_0) + \frac{\sigma^2}{2} \|\nabla_{\boldsymbol{\theta}} \zeta\|^2\right) (1 + \delta)^{p+1} \frac{d_0}{\sqrt{2\pi}} \beta(\mathbf{r}_0), \quad (\text{D.2})$$

где $\tau_{\underline{\epsilon}}(\mathbf{r}_0)$ из (C.5) и

$$\beta(\mathbf{r}_0) = \frac{2}{(p+2)} \left(\frac{x_1}{x^*}\right)^{p/2} x_1.$$

Доказательство. Для интеграла в числителе в (D.1) для любой неотрицательной функции f на множестве $\Omega(x)$ выполняется

$$\begin{aligned} & \int_{\Upsilon_1} \exp\{\mathcal{L}((\boldsymbol{\theta}, \varkappa), (\boldsymbol{\theta}^*, \varkappa^*))\} f(\varkappa) d\boldsymbol{\theta} d\varkappa = \\ &= \int_{\mathcal{X}_1} \exp\{\mathcal{L}(\boldsymbol{\nu}_{\varkappa}^*, \boldsymbol{\nu}^*)\} f(\varkappa) \int_{\Theta} \exp\{\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}_{\varkappa}^*)\} d\boldsymbol{\theta} d\varkappa = \\ &= \int_{\mathcal{X}_1} \exp\{\mathcal{L}(\boldsymbol{\nu}_{\varkappa}^*, \boldsymbol{\nu}^*)\} f(\varkappa) \exp\left(-\log(\det D_{\varkappa}) + p \log(\sqrt{2\pi}) + \frac{1}{2} \|D_{\varkappa}^{-1} \nabla_{\boldsymbol{\theta}} \zeta\|^2\right) d\varkappa, \end{aligned} \quad (\text{D.3})$$

Мы использовали, что

$$\nabla_{\boldsymbol{\theta}} \mathcal{L} = \nabla_{\boldsymbol{\theta}} \zeta + \nabla_{\boldsymbol{\theta}} \mathbb{E} \mathcal{L} = \nabla_{\boldsymbol{\theta}} \zeta$$

в точке $(\boldsymbol{\theta}_{\varkappa}^*, \varkappa)$. Между двумя \varkappa -моделями используется стандартное разложение

$$\begin{aligned} \mathcal{L}(\boldsymbol{\nu}_{\varkappa}^*, \boldsymbol{\nu}^*) &= \zeta(\boldsymbol{\nu}_{\varkappa}^*, \boldsymbol{\nu}^*) + \mathbb{E} \mathcal{L}(\boldsymbol{\nu}_{\varkappa}^*, \boldsymbol{\nu}^*) = \\ &= (1 + \varepsilon)(\mathbb{E} \mathcal{X}_{\varkappa^*} - \mathbb{E} \mathcal{X}_{\varkappa}) - b_{\varkappa} + b_{\varkappa^*} + c \log \frac{\varkappa}{\varkappa^*} + \frac{\boldsymbol{\varepsilon}^\top}{\sigma^2} (\boldsymbol{\theta}_{\varkappa}^* - \boldsymbol{\theta}^*). \end{aligned}$$

Используем следствие 4.2 из [10] для того, чтобы подавить стохастическую компоненту квадратичной функцией $-b \|\boldsymbol{\theta}_{\varkappa}^* - \boldsymbol{\theta}^*\|^2$, где константа b должна удовлетворять условию $6\sqrt{x + c_1(p+1)} \leq \mathbf{r}_0 b$.

Заметим, что из $\mathcal{R}_{\varkappa} \geq \mathcal{R}_{\varkappa^*}$ следует, что

$$\mathbb{E} \mathcal{X}_{\varkappa^*} - \mathbb{E} \mathcal{X}_{\varkappa} \leq b_{\varkappa} - b_{\varkappa^*},$$

и по определению смещения b_{\varkappa}

$$\begin{aligned} b_{\varkappa} - b_{\varkappa^*} &= -\mathbb{E} L_{\varkappa}(\boldsymbol{\theta}_{\varkappa}^*) + \mathbb{E} L_{\varkappa^*}(\boldsymbol{\theta}_{\varkappa^*}^*) \leq \\ &\leq -\mathbb{E} L_{\varkappa}(\boldsymbol{\theta}_{\varkappa}^*) + \mathbb{E} L_{\varkappa}(\boldsymbol{\theta}_{\varkappa^*}^*) = -\|D_{\varkappa}(\boldsymbol{\theta}_{\varkappa}^* - \boldsymbol{\theta}_{\varkappa^*}^*)\|^2. \end{aligned}$$

Используя это и следствие 4.2 из [10] при условии $6\sqrt{x + c_1(p+1)} \leq \mathbf{r}_0(1 + \varepsilon)$, получаем, что можно выбрать

$$u(\boldsymbol{\nu}) = \frac{(1 + \varepsilon) \|(\boldsymbol{\theta}_{\varkappa}^* - \boldsymbol{\theta}_{\varkappa^*}^*)\|^2}{2}.$$

Тогда при $c = 0$

$$\mathbb{E}\mathcal{L}(\boldsymbol{\nu}_{\varkappa}^*, \boldsymbol{\nu}^*) + u(\boldsymbol{\nu}_{\varkappa}^*) \leq -\frac{(1 + \varepsilon)\|\boldsymbol{\theta}_{\varkappa}^* - \boldsymbol{\theta}_{\varkappa^*}^*\|^2}{2}.$$

Далее используем следствие, в котором вместо $b(\mathbf{r})$ стоит $(1 + \varepsilon)/2$. Этот результат показывает, что $\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)$ можно ограничить $u(\boldsymbol{\nu})$ при $c = 0$ с большой вероятностью.

Соотношение (C.10) для локального интеграла

$$\int_{\check{\mathcal{I}}_0} \exp\{\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)\} d\boldsymbol{\nu}$$

даёт

$$\begin{aligned} \rho_1(\mathbf{r}_0) &\leq \exp\{\tau_{\underline{\epsilon}}(\mathbf{r}_0) + m_{\underline{\epsilon}}(\boldsymbol{\xi}_{\underline{\epsilon}})\} \times \\ &\times \int_{\mathcal{K}_1} \exp\left(c \log \frac{\varkappa}{\varkappa^*} - \log \det D_{\varkappa} + p \log \sqrt{2\pi} + \frac{1}{2}\|D_{\varkappa}^{-1}\nabla_{\boldsymbol{\theta}}\boldsymbol{\zeta}\|^2\right) f(\varkappa) d\varkappa. \end{aligned}$$

Далее, используя

$$\exp\{m_{\underline{\epsilon}}(\boldsymbol{\xi}_{\underline{\epsilon}})\} = \exp\left(-\frac{\|\boldsymbol{\xi}_{\underline{\epsilon}}\|^2}{2}\right) (2\pi)^{-(p+1)/2} \det(\check{D}_{\underline{\epsilon}}) \leq (2\pi)^{-(p+1)/2} \det(\check{D}_{\underline{\epsilon}}),$$

получаем

$$\begin{aligned} \rho_1(\mathbf{r}_0) &\leq \exp\left(\tau_{\underline{\epsilon}}(\mathbf{r}_0) + \frac{\sigma^2}{2}\|\nabla_{\boldsymbol{\theta}}\boldsymbol{\zeta}\|^2\right) \times \\ &\times (1 + \delta)^{p+1} d_0 \int_{\mathcal{K}_1} \exp\left(c \log \frac{\varkappa}{\varkappa^*} + \log\left(\frac{\det D_{\varkappa^*}}{\det D_{\varkappa}}\right)\right) f(\varkappa) d\varkappa. \end{aligned}$$

Для последнего члена в интеграле имеем

$$\log\left(\frac{\det D_{\varkappa^*}}{\det D_{\varkappa}}\right) = \frac{1}{2} \sum_{i=1}^p \log\left(\frac{1 + \varkappa^* \sigma^2 g_i^2}{1 + \varkappa \sigma^2 g_i^2}\right) \leq \frac{p}{2} \log\left(\frac{1 + \varkappa^* \sigma^2 g_p^2}{1 + \varkappa \sigma^2 g_p^2}\right) \leq \frac{c}{2} \log \frac{\varkappa^*}{\varkappa}$$

с достаточным $c \geq p$. Таким образом, справедливо (D.2) с

$$\beta(\mathbf{r}_0) = \frac{2}{(p+2)} \left(\frac{\varkappa_1}{\varkappa^*}\right)^{p/2} \varkappa_1. \quad \square$$

Предыдущее утверждение предоставляет достаточное условие на значение \mathbf{r}_0 , влекущее концентрацию апостериорного распределения на $\mathcal{K}_o(\mathbf{r}_0)$.

Для следующего утверждения удобно ввести обозначения: для случайной величины μ определим

$$\hat{\mathbb{E}}\mu \stackrel{\text{def}}{=} \mathbb{E}[\mu \mathbb{I}\{\varkappa \in \mathcal{K}_o(\mathbf{r}_0)\} \mid \mathbf{Y}, \varkappa \in \mathcal{K}_o(\mathbf{r}_0) \cup \mathcal{K}_1].$$

Теорема D.2. Для любой неотрицательной функции $f(\cdot)$ на \mathbb{R} на множестве $\Omega(\mathbf{x})$ выполняется

$$\hat{\mathbb{E}}f(d_{\underline{\epsilon}}(\mathbf{x} - \mathbf{x}_{\underline{\epsilon}})) \geq \exp\{-\Delta_{\underline{\epsilon}}^-(\mathbf{r}_0)\} \mathbb{E}\{f(\gamma)\mathbb{I}(|\gamma| \leq C\mathbf{r}_0)\}, \quad (\text{D.4})$$

где

$$\Delta_{\underline{\epsilon}}^-(\mathbf{r}_0) = \Delta_{\underline{\epsilon}}(\mathbf{r}_0) + \frac{p+1}{2} \log \frac{1+\delta}{1-\delta} + \rho_1(\mathbf{r}_0).$$

На $\Omega(\mathbf{x})$ также выполняется $\Delta_{\underline{\epsilon}}^-(\mathbf{r}_0) \leq C\delta(p+1+\mathbf{x})$.

Доказательство. Из соотношения (C.8) с функцией $f(\cdot) \equiv 1$ и (D.3) следует, что на множестве $\Omega(\mathbf{x})$

$$\begin{aligned} \int_{r \setminus r_2} \exp\{\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)\} d\boldsymbol{\nu} &= \int_{r_0} \exp\{\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)\} d\boldsymbol{\nu} + \int_{r_1} \exp\{\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)\} d\boldsymbol{\nu} \leq \\ &\leq \{1 + \rho_1(\mathbf{r}_0)\} \int_{r_0} \exp\{\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)\} d\boldsymbol{\nu} \leq \\ &\leq \{1 + \rho_1(\mathbf{r}_0)\} \exp\{-m_{\underline{\epsilon}}(\boldsymbol{\xi}_{\underline{\epsilon}}) + \tau_{\underline{\epsilon}}(\mathbf{r}_0)\} \leq \exp\{-m_{\underline{\epsilon}}(\boldsymbol{\xi}_{\underline{\epsilon}}) + \tau_{\underline{\epsilon}}(\mathbf{r}_0) + \rho_1(\mathbf{r}_0)\}. \end{aligned}$$

Используя соотношение (C.9), получаем

$$\begin{aligned} \frac{\int_{r_0(\mathbf{r}_0)} \exp\{\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)\} f(d_{\underline{\epsilon}}(\mathbf{x} - \mathbf{x}_{\underline{\epsilon}})) d\boldsymbol{\nu}}{\int_{r \setminus r_2} \exp\{\mathcal{L}(\boldsymbol{\nu}, \boldsymbol{\nu}^*)\} d\boldsymbol{\nu}} &\geq \\ &\geq \frac{\exp\{-m_{\underline{\epsilon}}(\boldsymbol{\xi}_{\underline{\epsilon}})\} \int \phi(u) f(u) \mathbb{I}\{u \in \mathcal{B}_{\underline{\epsilon}}(\mathbf{r}_0)\} du}{\exp\{-m_{\underline{\epsilon}}(\boldsymbol{\xi}_{\underline{\epsilon}}) + \tau_{\underline{\epsilon}}(\mathbf{r}_0) + \rho_1(\mathbf{r}_0)\}} \geq \\ &\geq \exp\{-\Delta_{\underline{\epsilon}}^-(\mathbf{r}_0)\} \mathbb{E}[f(\gamma)\mathbb{I}\{\gamma \in \mathcal{B}_{\underline{\epsilon}}(\mathbf{r}_0)\}], \end{aligned}$$

где

$$\mathcal{B}_{\underline{\epsilon}}(\mathbf{r}_0) \stackrel{\text{def}}{=} \{u \in \mathbb{R} : |d_0 d_{\underline{\epsilon}}^{-1}(u + \boldsymbol{\xi}_{\underline{\epsilon}})| \leq \mathbf{r}_0\}.$$

Используя $|\boldsymbol{\xi}_{\underline{\epsilon}}|^2 = (1+\delta)^{-1} \|\boldsymbol{\xi}\|^2$, $d_{\underline{\epsilon}}^2 = (1+\delta)d_0^2$, получаем

$$\mathcal{B}_{\underline{\epsilon}}(\mathbf{r}_0) \supseteq \{u \in \mathbb{R} : |u| \leq C\mathbf{r}_0\}. \quad (\text{D.5})$$

Это доказывает (D.4). \square

В качестве следствия сформулируем утверждение о производящей функции моментов $d_{\underline{\epsilon}}(\mathbf{x} - \mathbf{x}_{\underline{\epsilon}})$, соответствующей экспоненциальной функции f . Потребуется дополнительное условие, что $\mathbf{r}_0^2 \geq C$ для достаточно большой C .

Следствие D.3. Пусть $\mathbf{r}_0^2 \geq C$. Для $\lambda \in \mathbb{R}$, $\lambda^2 \leq \mathbf{x}$,

$$\log \hat{\mathbb{E}} \exp(\lambda d_{\underline{\epsilon}}(\mathbf{x} - \mathbf{x}_{\underline{\epsilon}})) \geq \frac{\lambda^2}{2} - \Delta_{\underline{\epsilon}}^{\ominus} \Delta_{\underline{\epsilon}}^{\ominus} \stackrel{\text{def}}{=} \Delta_{\underline{\epsilon}}^-(\mathbf{r}_0) + e^{-\mathbf{x}}.$$

Более того, при $\lambda^2 \leq 1$

$$\log \hat{\mathbb{E}} \exp\{\lambda d_0(\mathbf{x} - \mathbf{y})\} \geq \frac{\lambda^2}{2} - \Delta_{\underline{\epsilon}}^{\ominus}(\mathbf{r}_0).$$

На множестве $\Omega(\mathbf{x})$ выполняется $\Delta_{\epsilon}^{\ominus}(\mathbf{r}_0) \leq \mathbf{C} \delta (p+1+\mathbf{x})$. Для любого измеримого $A \subset \mathbb{R}$ на множестве $\Omega_{\mathbf{x}}$ при $\delta_{\epsilon} = d_0(\mathbf{x}_{\epsilon} - \check{\mathbf{x}})$ выполняется

$$\begin{aligned} \mathbb{P}^{\circ}(d_0(\mathbf{x} - \check{\mathbf{x}}) \in A) &\geq \exp\{\Delta_{\epsilon}^{-}(\mathbf{r}_0)\} \mathbb{P}(d_0 d_{\epsilon}^{-1} \gamma + \delta_{\epsilon} \in A) - e^{-\mathbf{x}} \geq \\ &\geq \exp\{\Delta_{\epsilon}^{-}(\mathbf{r}_0)\} \{\mathbb{P}(\gamma \in A) - \mathbf{C} \delta \mathbf{q}^{1/2}\} - e^{-\mathbf{x}} \end{aligned}$$

для $\mathbf{q} = 1 + |\xi|^2$.

Первое утверждение следует из теоремы D.2. Единственный важный дополнительный шаг — вычисление интеграла $\mathbb{E}\{\exp(\lambda\gamma)\mathbb{I}(|\gamma| \leq \mathbf{r})\}$.

Лемма D.4. Пусть $\gamma \sim \mathcal{N}(0, 1)$ и $\mu \in (0, 1)$. Тогда для любого $\lambda \in \mathbb{R}$, $\lambda^2 \leq \mathbf{x}$,

$$\log \mathbb{E}\{\exp(\lambda\gamma)\mathbb{I}(|\gamma| > \mathbf{r})\} \leq -\frac{1-\mu}{2}\mathbf{r}^2 + \frac{1}{2\mu}\lambda^2 + \frac{1}{2}\log\left(\frac{1}{\mu}\right). \quad (\text{D.6})$$

Доказательство. Так как для $\mu < 1$

$$\mathbb{E}\{\exp(\lambda\gamma)\mathbb{I}(|\gamma| > \mathbf{r})\} \leq e^{-(1-\mu)\mathbf{r}^2/2} \mathbb{E} \exp\left\{\lambda\gamma + \frac{(1-\mu)\gamma^2}{2}\right\},$$

то

$$\begin{aligned} \mathbb{E} \exp\left\{\lambda\gamma + \frac{(1-\mu)\gamma^2}{2}\right\} &= \\ &= (2\pi)^{-1/2} \int \exp\left\{\lambda\gamma - \frac{\mu\gamma^2}{2}\right\} d\gamma = \mu^{-1/2} \exp\left(\frac{\mu^{-1}\lambda^2}{2}\right). \end{aligned}$$

Следовательно, справедливо (D.6). \square

Далее используем утверждение с $\mu = 1/2$.

Лемма D.5. Пусть $\gamma \sim \mathcal{N}(0, 1)$ и $\mathbf{r}^2 \geq 4(1+\mathbf{x})$. Тогда для $\lambda \in \mathbb{R}$, $\lambda^2 \leq \mathbf{x}$,

$$\mathbb{E}\{\exp(\lambda\gamma)\mathbb{I}(|\gamma| \leq \mathbf{r})\} \geq e^{\lambda^2/2}(1 - e^{-\mathbf{x}}). \quad (\text{D.7})$$

Доказательство. Из соотношения (D.6) при $\mu = 1/2$ с учётом того, что $\mathbb{E} \exp(\lambda\gamma) = e^{\lambda^2/2}$, $\lambda^2 \leq \mathbf{x}$ и $1 + \log(2) < 2$, получаем, что

$$e^{-\lambda^2/2} \mathbb{E}\{\exp(\lambda\gamma)\mathbb{I}(|\gamma| \leq \mathbf{r})\} \geq 1 - \exp\left(-\frac{\mathbf{r}^2}{4} + 1 + \frac{1}{2}\log(2)\right) \geq 1 - \exp(-\mathbf{x}).$$

Следовательно, верно (D.7). \square

Последняя оценка доказывает следствие D.3. Второе утверждение доказывается аналогично следствию C.2, последнее утверждение — аналогично следствию C.3.

Е. Доказательство теоремы 3.1

Удобно представить случайную величину \mathbf{x} в виде

$$\mathbf{x} = \mathbf{x}\mathbb{I}\{\mathbf{x} \in \mathcal{K}_0(\mathbf{r}_0)\} + \mathbf{x}\mathbb{I}\{\mathbf{x} \in \mathcal{K}_1\} + \mathbf{x}\mathbb{I}\{\mathbf{x} \in \mathcal{K}_2\} = \mathbf{x}^{\circ} + \mathbf{x}_1^{\epsilon} + \mathbf{x}_2^{\epsilon}.$$

Результат о больших уклонениях показывает, что апостериорная масса \varkappa_1^c мала при соответствующем выборе \mathbf{r}_0 . Далее покажем, что распределение \varkappa° примерно нормальное, и придём к главному результату. Определим

$$\bar{\varkappa} \stackrel{\text{def}}{=} \hat{\mathbb{E}}\varkappa, \quad \mathfrak{S}_\circ^2 \stackrel{\text{def}}{=} \text{Cov}(\bar{\varkappa}) \stackrel{\text{def}}{=} \hat{\mathbb{E}}(\varkappa - \bar{\varkappa})^2.$$

Достаточно показать, что на $\Omega(\mathbf{x})$ выполняются соотношения

$$(d_\epsilon(\bar{\varkappa} - \varkappa_\epsilon))^2 \leq 2\Delta_\epsilon^* |1 - d_\epsilon^2 \mathfrak{S}_\circ^2| \leq 2\Delta_\epsilon^*,$$

и для $\lambda \in \mathbb{R}$, $\lambda^2 \leq \mathbf{x}$, справедливо

$$\left| \log \hat{\mathbb{E}} \exp\{\lambda \mathfrak{S}_\circ^{-1}(\varkappa - \varkappa_\epsilon)\} - \frac{\lambda^2}{2} \right| \leq c\Delta_\epsilon^*. \quad (\text{E.1})$$

Рассмотрим $\eta \stackrel{\text{def}}{=} d_\epsilon(\varkappa - \varkappa_\epsilon)$. Следствия С.2 и D.3 утверждают для $\lambda \in \mathbb{R}$, $\lambda^2 \leq \mathbf{x}$, что

$$\lambda^2 \exp\{-\Delta^-\} \leq \hat{\mathbb{E}}(\lambda^\top \eta)^2 \leq \lambda^2 \exp\{\Delta^+\}, \quad (\text{E.2})$$

$$\frac{\lambda^2}{2} - \Delta^- \leq \log \hat{\mathbb{E}} \exp(\lambda \eta) \leq \frac{\lambda^2}{2} + \Delta^+, \quad (\text{E.3})$$

где $\Delta^- = \Delta_\epsilon^\ominus$ и $\Delta^+ = \Delta_\epsilon^\oplus$.

Определим первые два момента η :

$$\bar{\eta} \stackrel{\text{def}}{=} \hat{\mathbb{E}}\eta, \quad S_\circ^2 \stackrel{\text{def}}{=} \hat{\mathbb{E}}(\eta - \bar{\eta})^2 = d_\epsilon^2 \mathfrak{S}_\circ^2.$$

Воспользуемся следующим техническим утверждением.

Лемма E.1. *Предположим, что верно (E.2). Тогда при $\Delta^* = \max\{\Delta^+, \Delta^-\}$*

$$|\bar{\eta}| \leq \sqrt{2\Delta^*}, \quad |S_\circ^2 - 1| \leq 2\Delta^*. \quad (\text{E.4})$$

Доказательство. Пусть $u = 1$. При $\lambda = u$ для $\hat{\mathbb{E}}(u\eta)^2 = \hat{\mathbb{E}}(\lambda\eta)^2$ из (E.2) получаем, что

$$\hat{\mathbb{E}}(u\eta)^2 \leq \exp\{\Delta^+\}, \quad \hat{\mathbb{E}}(u\eta)^2 \geq \exp\{-\Delta^-\}.$$

Заметим, что

$$\hat{\mathbb{E}}(u\eta)^2 = u^2 S_\circ^2 + (u\bar{\eta})^2,$$

и поэтому

$$\exp\{-\Delta^-\} \leq u^2 S_\circ^2 + (u\bar{\eta})^2 \leq \exp\{\Delta^+\}. \quad (\text{E.5})$$

Аналогично для $u = \bar{\eta}/|\bar{\eta}|$

$$\hat{\mathbb{E}}(u(\eta - \bar{\eta}))^2 \geq \exp\{-\Delta^-\} \mathbb{E}(u(\eta - \bar{\eta}))^2 = (1 + \bar{\eta}^2) \exp\{-\Delta^-\},$$

откуда следует

$$u^2 S_\circ^2 \geq (1 + \bar{\eta}^2) \exp\{-\Delta^-\}.$$

Данное неравенство противоречит (E.5), если $\bar{\eta}^2 > 2\Delta^*$. Таким образом, справедливо (E.4). \square

Граница для первого момента при $\bar{\varkappa} = \hat{\mathbb{E}}\varkappa$ даёт

$$|d_{\underline{\epsilon}}(\bar{\varkappa} - \varkappa_{\underline{\epsilon}})| \leq \sqrt{2\Delta^*}. \quad (\text{E.6})$$

Используя границу для второго момента и $\mathfrak{S}_{\circ}^2 = \hat{\mathbb{E}}(\varkappa - \bar{\varkappa})^2$, получаем

$$|d_{\underline{\epsilon}}^2 \mathfrak{S}_{\circ}^2 - 1| \leq 2\Delta^*. \quad (\text{E.7})$$

Далее рассмотрим производящую функцию моментов для $\boldsymbol{\eta}^{\circ} \stackrel{\text{def}}{=} \mathfrak{S}_{\circ}^{-1}(\varkappa - \varkappa_{\underline{\epsilon}})$. Воспользуемся соотношениями

$$\lambda \boldsymbol{\eta}^{\circ} = \lambda_1 d_{\underline{\epsilon}}(\varkappa - \varkappa_{\underline{\epsilon}}) + \lambda_1 d_{\underline{\epsilon}}(\varkappa_{\underline{\epsilon}} - \varkappa_{\epsilon}) = \lambda_1 \boldsymbol{\eta} + \lambda_1^{\top} d_{\underline{\epsilon}}(\varkappa_{\underline{\epsilon}} - \varkappa_{\epsilon})$$

при $\lambda_1 = d_{\underline{\epsilon}}^{-1} \mathfrak{S}_{\circ}^{-1} \lambda$. Таким образом,

$$|\log \hat{\mathbb{E}} \exp\{\lambda \boldsymbol{\eta}^{\circ}\} - \log \hat{\mathbb{E}} \exp\{\lambda_1 \boldsymbol{\eta}\}| \leq |\lambda \mathfrak{S}_{\circ}^{-1}(\varkappa_{\underline{\epsilon}} - \varkappa_{\epsilon})|. \quad (\text{E.8})$$

Используя (E.7), для $\lambda_1^2 = \lambda^2 d_{\underline{\epsilon}}^{-2} \mathfrak{S}_{\circ}^{-2}$ получаем

$$(1 - \Delta^*) \lambda^2 \leq \lambda^2 d_{\underline{\epsilon}}^{-2} \mathfrak{S}_{\circ}^{-2} \leq (1 - \Delta^*)^{-1} \lambda^2.$$

Это неравенство, (E.6), (E.8) и (E.3) влекут

$$\left| \log \hat{\mathbb{E}} \exp\{\lambda \boldsymbol{\eta}^{\circ}\} - \frac{\lambda^2}{2} \right| \leq c \Delta^*.$$

Таким образом, справедливо (E.1).

Литература

- [1] Akaike H. Information theory and an extension of the maximum likelihood principle // Second International Symposium on Information Theory (Tsahkadors, 1971). — Budapest: Akadémiai Kiadó, 1973. — P. 267—281.
- [2] Birgé L., Massart P. Gaussian model selection // J. Eur. Math. Soc. — 2001. — Vol. 3, no. 3. — P. 203—268.
- [3] Birgé L., Massart P. Minimal penalties for Gaussian model selection // Probab. Theory Relat. Fields. — 2007. — Vol. 138, no. 1-2. — P. 33—73.
- [4] Cavalier L., Golubev Y. Risk hull method and regularization by projections of ill-posed inverse problems // Ann. Statist. — 2006. — Vol. 34, no. 4. — P. 1653—1677.
- [5] Donoho D. L., Johnstone I. M. Adapting to unknown smoothness via wavelet shrinkage // J. Am. Statist. Assoc. — 1995. — Vol. 90 (432). — P. 1200—1224.
- [6] Efromovich S., Pinsker M. (1984). Learning algorithm for nonparametric filtering // Autom. Remote Control. — 1984. — Vol. 45. — P. 1434—1440.
- [7] Engl H. W., Hanke M., Neubauer A. Regularization of Inverse Problems. — Dordrecht: Kluwer Academic, 1996.
- [8] Green P. J., Silverman B. (1994). Nonparametric Regression and Generalized Linear Models: A Roughness Penalty Approach. — London: Chapman & Hall, 1994.
- [9] Petrone S., Rousseau J., Scricciolo C. Bayes and empirical bayes: do they merge? // Biometrika. — 2012. — Vol. 99, no. 1. — P. 1—21.

- [10] Spokoiny V. Parametric estimation. Finite sample theory // *Ann. Statist.* — 2012. — Vol. 40, no. 6. — P. 2877–2909. — [arXiv:1111.3029](#).
- [11] Spokoiny V. *Basics of Modern Parametric Statistics*. — Berlin: Springer, 2013.
- [12] Stein C. M. Estimation of the mean of a multivariate normal distribution // *Ann. Statist.* — 1981. — Vol. 9, no. 6. — P. 1135–1151.
- [13] Van der Vaart A. W. *Asymptotic Statistics*. — Cambridge: Cambridge Univ. Press, 1998. — (Cambridge Ser. Statist. Probab. Math.).