

Ю.И.Ингстер, Н. А. Степанова

АДАПТИВНАЯ СЕЛЕКЦИЯ КОМПОНЕНТ РАЗРЕЖЕННОЙ ФУНКЦИИ РЕГРЕССИИ

§1. ВВЕДЕНИЕ

В этой статье мы изучаем проблему селекции компонент разреженного сигнала в непрерывной регрессионной модели. Мы предполагаем, что функция многих переменных $f \in \mathcal{F}_d \subset L_2([0, 1]^d) = L_2^d$ наблюдается в гауссовском белом шуме интенсивности ε . Модель описывается уравнением

$$X_\varepsilon = f + \varepsilon W, \quad (1)$$

где W – гауссовский белый шум, заданный на $[0, 1]^d$, $\varepsilon > 0$ – интенсивность шума и \mathcal{F}_d – некоторое подмножество квадратично-интегрируемых на $[0, 1]^d$ гладких функций. В этой модели “наблюдение” представляет собой функцию $X_\varepsilon: L_2^d \rightarrow \mathcal{G}$, принимающую значения на множестве \mathcal{G} нормальных случайных величин, такую, что если $\xi = X_\varepsilon(\phi)$, $\eta = X_\varepsilon(\psi)$, где $\phi, \psi \in L_2^d$, то $\mathbf{E}(\xi) = (f, \phi)$, $\mathbf{E}(\eta) = (f, \psi)$ и $\mathbf{Cov}(\xi, \eta) = \varepsilon^2(\phi, \psi)$. Для каждой функции $f \in L_2^d$ наблюдение X_ε определяет гауссовскую меру $\mathbf{P}_{\varepsilon, f}$ со средним f и ковариационным оператором $\varepsilon^2 I$, где I – тождественный оператор (см. [8, 16]). В настоящей работе изучается случай растущей размерности, то есть $d = d_\varepsilon \rightarrow \infty$ при $\varepsilon \rightarrow 0$. Предполагается, что f имеет аддитивную разреженную структуру, и задача состоит в точной селекции компонент функции f .

Проблема селекции (отбора факторов) при построении множественной регрессии – классическая задача математической статистики.

Ключевые слова: аддитивная регрессия, разреженный сигнал, точное восстановление, адаптивная селекция.

Работа первого автора поддержана грантом РФФИ 11-01-00577 и грантом Канадского совета в области естественнонаучных и прикладных исследований (NSERC) во время визита первого автора в Карлтон Университет зимой 2012 года.

Работа второго автора поддержана грантом NSERC.

В применении к непараметрическим моделям она изучалась различными авторами в самых разнообразных предположениях (см., например, [2, 7, 15] и ссылки там же). В отличие от предыдущих исследований в этой области, основанных большей частью на статистической теории оценивания, наш подход к данной проблеме тесно связан с теорией проверки гипотез и ведет к построению асимптотически минимаксного селектора, являющегося адаптивным по отношению к индексу разреженности.

Предположение аддитивности и разреженности функции f связано с наличием эффекта “проклятия размерности”. Данный эффект возникает при оценивании и обнаружении сигнала, зависящего от многих переменных, и проявляется в существенном ухудшении качества оценок и тестов с увеличением размерности. Одной из известных моделей, позволяющих эффективно бороться с проклятием размерности, является функциональная модель дисперсионного анализа. Данная модель предполагает, что функция регрессии многих переменных $f \in L_2^d$ представима в виде (см., например, [14])

$$f(\mathbf{x}) = \sum_{u \subset \{1, \dots, d\}} f_u(\mathbf{x}_u), \quad \int_0^1 f_u(\mathbf{x}_u) dx_j = 0 \text{ п.в. для всех } j \in u,$$

где $\mathbf{x}_u = \{x_j, j \in u\}$ — $|u|$ -мерный подвектор вектора $\mathbf{x} \in [0, 1]^d$, и суммирование ведется по всем 2^d подмножествам множества $\{1, \dots, d\}$. Важным частным случаем этой модели является аддитивная модель с функцией регрессии вида

$$f(\mathbf{x}) = \mu + \sum_{j=1}^d f_j(x_j), \quad \int_0^1 f_j(x_j) dx_j = 0, \\ \mu \in \mathbb{R}, \quad \mathbf{x} = (x_1, \dots, x_d) \in [0, 1]^d,$$

ставшая популярной после работы Стоуна [18].

Другая идея, эффективно используемая при работе с непараметрическими регрессионными моделями, состоит в предположении, что функция регрессии имеет разреженную структуру. Условие разреженности обеспечивает идентифицируемость статистических моделей и дает возможность для их более простой интерпретации. Кроме того,

оно ведет к уменьшению вычислительных затрат и поэтому весьма популярно в современной статистической литературе (см. [15] и ссылки там же).

В настоящей работе изучается непараметрическая аддитивная модель с разреженной функцией регрессии. Кроме условий регулярности, накладываемых на функцию регрессии f и необходимых для получения содержательной непараметрической задачи, мы предполагаем, что f имеет *разреженную структуру* вида

$$f(\mathbf{x}) = \sum_{j=1}^d \eta_j f_j(x_j), \quad \mathbf{x} = (x_1, \dots, x_d) \in [0, 1]^d, \quad (2)$$

где $\eta_j \in \{0, 1\}$ – параметры, соответствующие наличию j -й компоненты сигнала ($\eta_j = 1$) или ее отсутствию ($\eta_j = 0$). Предполагается, что η_j удовлетворяют условию $\sum_{j=1}^d \eta_j = d^{1-\beta}$ для некоторого $\beta \in (0, 1)$.

Величина $d^{1-\beta}$ есть число ненулевых сигналов f_j в разложении (2). Параметр β будем называть *индексом разреженности*. Чем больше значение β , тем меньше активных компонент содержит сигнал f . Аддитивные функции с разреженной структурой вида (2) были введены в работе [5] в связи с задачей обнаружения сигнала. Мы же рассматриваем эти функции в контексте задачи селекции.

Для более точной постановки задачи введем множество

$$\mathcal{H}_{d,\beta} = \left\{ \eta = (\eta_1, \dots, \eta_d) : \eta_j \in \{0, 1\}, 1 \leq j \leq d, \sum_{j=1}^d \eta_j = d^{1-\beta} \right\}.$$

Требуется по наблюдению X_ε в модели (1) с функцией регрессии f вида (2) оценить вектор $\eta = (\eta_1, \dots, \eta_d) \in \mathcal{H}_{d,\beta}$. Другими словами, требуется определить наличие или отсутствие компонент f_j , составляющих сигнал f . Эту задачу можно рассматривать как задачу *селекции*. Чтобы задача селекции была содержательной, сигналы f_j не должны быть слишком “слабыми”. Более точно, для каждого $j = 1, \dots, d$, сигнал f_j должен быть *обнаружим* в задаче проверки гипотезы $H_{0j} : f_j \equiv 0$ против альтернативы $H_{1j} : f_j \in \mathcal{F}(r_\varepsilon)$, где $\mathcal{F}(r_\varepsilon) = \{f \in \mathcal{F} : \|f\|_2 \geq r_\varepsilon\}$, \mathcal{F} – некоторое подмножество L_2^1 и $\|f\|_2$ – норма в пространстве L_2^1 . Обнаружение f_j представляется возможным в случае, когда параметр

$r_\varepsilon > 0$, характеризующий альтернативу, превосходит некоторое положительное число r_ε^* , называемое *критическим радиусом*. Цель настоящей работы состоит в определении критического радиуса r_ε^* и в построении асимптотически минимаксного *селектора* для вектора $\eta = (\eta_1, \dots, \eta_d) \in \mathcal{H}_{d,\beta}$, гарантирующего *точное воспроизведение* сигнала $f(\mathbf{x}) = \sum_{j=1}^d \eta_j f_j(x_j)$. Наше исследование дополняет результаты, полученные в работе [6] относительно точного воспроизведения разреженного нормального вектора.

Точная постановка задачи состоит в следующем. Для каждой компоненты f_j сигнала f будем рассматривать задачу проверки гипотезы $H_{0j} : f_j \equiv 0$ против альтернативы $H_{1j} : f_j \in \mathcal{F}(r_\varepsilon)$. Гипотезы H_{0j} и H_{1j} являются асимптотически различимыми (неразличимыми), если $r_\varepsilon/r_\varepsilon^* \rightarrow \infty$ ($r_\varepsilon/r_\varepsilon^* \rightarrow 0$) при $\varepsilon \rightarrow 0$. Асимптотическая различимость (неразличимость) означает, что минимаксная ошибка обнаружения сигнала для альтернативы H_{1j} стремится к нулю (единице) при $\varepsilon \rightarrow 0$. В случае, когда H_{0j} и H_{1j} асимптотически различимы, мы говорим, что сигнал f_j *обнаружим*. Если гипотезы H_{0j} and H_{1j} асимптотически различимы (неразличимы) в случае, когда $\liminf r_\varepsilon/r_\varepsilon^* > 1$ ($\limsup r_\varepsilon/r_\varepsilon^* < 1$), то критический радиус r_ε^* называется *точным*. Знание (точного) критического радиуса позволяет сделать содержательной задачу проверки гипотезы $H_{0j} : f_j \equiv 0$ против альтернативы $H_{1j} : f_j \in \mathcal{F}(r_\varepsilon)$ путем выбора параметра r_ε , превосходящего критический радиус r_ε^* . В противном случае, сигнал f_j слишком слаб для того, чтобы быть обнаружимым.

Пусть далее $\mathcal{F}_d(r_\varepsilon)$ есть множество функций вида $f = \sum_{j=1}^d \eta_j f_j \in \mathcal{F}_d$, где $f_j \in \mathcal{F}(r_\varepsilon)$ для каждого $j = 1, \dots, d$. Вернемся к модели (1) и предположим, что каждая компонента f_j сигнала $f \in \mathcal{F}_d(r_\varepsilon)$ обнаружима. Как и в работе [6], мы определяем качество селектора $\eta^* = \eta^*(X_\varepsilon)$, воспроизводящего вектор η , с помощью *расстояния Хэмминга*:

$$|\eta^* - \eta| = \sum_{j=1}^d |\eta_j^* - \eta_j|.$$

Обозначим через $\mathbf{E}_{f,\eta}$ математическое ожидание по мере $\mathbf{P}_{\varepsilon,f}$ с функцией f вида (2). Требуется найти *селектор* $\eta^* = \eta^*(X_\varepsilon)$, удовлетворяющий условию

$$\limsup_{\varepsilon \rightarrow 0} \sup_{\eta \in \mathcal{H}_{d,\beta}} \sup_{f \in \mathcal{F}_d(r_\varepsilon)} \mathbf{E}_{f,\eta} |\eta^* - \eta| = 0, \quad (3)$$

и показать, что при нарушении условия обнаружимости,

$$\liminf_{\varepsilon \rightarrow 0} \inf_{\tilde{\eta}} \sup_{\eta \in \mathcal{H}_{d,\beta}} \sup_{f \in \mathcal{F}_d(r_\varepsilon)} \mathbf{E}_{f,\eta} |\tilde{\eta} - \eta| > 0, \quad (4)$$

то есть, что в этом случае точная селекция невозможна. При справедливости соотношения (3) будем говорить, что селектор η^* позволяет *точно воспроизводить* сигнал $f(\mathbf{x}) = \sum_{j=1}^d \eta_j f_j(x_j)$, наблюдаемый в гауссовском белом шуме. Если при этом справедливо неравенство (4), то процедура селекции, основанная на η^* , является *наилучшей* (в минимаксном смысле).

Наряду с задачей точной селекции, можно рассматривать задачу *почти точной* селекции, когда требуется найти селектор η^* , для которого (ср. с (3)) $\sup_{\eta \in \mathcal{H}_{d,\beta}} \sup_{f \in \mathcal{F}_d(r_\varepsilon)} \mathbf{E}_{f,\eta} |\eta^* - \eta| = o(d^{1-\beta})$, что соответствует правильному выбору *почти всех* значимых компонент. В адаптивной постановке данная задача требует отдельного изучения, и в настоящей работе не рассматривается.

§2. ПРЕДВАРИТЕЛЬНЫЕ СВЕДЕНИЯ

2.1. Соболевские шары. Рассмотрим класс функций, определяемый в терминах соболевской полуnormы порядка $\sigma > 0$. Для начала предположим, что $\sigma > 0$ – целое число, и что функция $f(x)$, $x \in [0, 1]$, имеет производные до порядка σ включительно, причем производная $f^{(\sigma-1)}$ абсолютно непрерывна, и $\int_0^1 (f^{(\sigma)}(x))^2 dx < \infty$. Для такой функции зададим полуnormу $\|f\|_{\sigma,2}$ равенством

$$\|f\|_{\sigma,2}^2 = \int_0^1 (f^{(\sigma)}(x))^2 dx, \quad (5)$$

и обозначим через \mathcal{F}_σ соболевский шар единичного радиуса, то есть,

$$\mathcal{F}_\sigma = \{f \in L_2^1 : \|f\|_{\sigma,2} \leq 1\}.$$

В случае нецелочисленного параметра $\sigma > 0$, все производные $f^{(m)}$ порядка $0 \leq m \leq [\sigma]$ предполагаются 1-периодическими, то есть,

$f^{(m)}(0) = f^{(m)}(1)$, и полунорма $\|f\|_{\sigma,2}^2$ задается с помощью разложения f в ряд Фурье. Именно, пусть $\{\phi_k(x)\}_{k \in \mathbb{Z}}$ – стандартный базис Фурье в пространстве $L_2^1 = L_2[0, 1]$:

$$\phi_0(x) = 1, \quad \phi_l(x) = \sqrt{2} \cos(2\pi lx), \quad \phi_{-l}(x) = \sqrt{2} \sin(2\pi lx), \quad l > 0.$$

Для функции $f(x) = \sum_{l \in \mathbb{Z}} \theta_l \phi_l(x) \in L_2^1$ с коэффициентами Фурье $\theta_l = (f, \phi_l)$ положим

$$\|f\|_{\sigma,2}^2 = \sum_{l \in \mathbb{Z}} c_l^2 \theta_l^2, \tag{6}$$

где

$$c_l^2 = c_l^2(\sigma) = (2\pi|l|)^{2\sigma}, \quad \sigma > 0, \quad l \in \mathbb{Z}.$$

При целочисленном параметре $\sigma > 0$, в предположении периодичности, данное определение совпадает с определением (5). Соболевский класс \mathcal{F}_σ произвольного порядка $\sigma > 0$ определяется как

$$\mathcal{F}_\sigma = \{f \in L_2^1 : \|f\|_{\sigma,2} \leq 1\},$$

где $\|f\|_{\sigma,2}$ задано в (6). Мы также будем иметь дело с подмножеством множества \mathcal{F}_σ , из которого удален шар в пространстве L_2^1 радиуса $r_\varepsilon > 0$:

$$\mathcal{F}_\sigma(r_\varepsilon) = \{f \in \mathcal{F}_\sigma : \|f\|_2 \geq r_\varepsilon\}.$$

Здесь и далее параметр гладкости $\sigma > 0$ предполагается известным.

2.2. Формулировка задачи в терминах последовательностей.

Рассматриваемую задачу можно представить в несколько иной, более удобной с технической точки зрения, форме. Следуя работе [5], рассмотрим класс аддитивных функций d переменных с разреженной структурой, определяемый следующим образом:

$$\mathcal{F}_{d,\beta,\sigma} = \left\{ f : f(\mathbf{x}) = \sum_{j=1}^d \eta_j f_j(x_j), \int_0^1 f_j(x_j) dx_j = 0, \right. \\ \left. f_j \in \mathcal{F}_\sigma, \eta = (\eta_j) \in \mathcal{H}_{d,\beta} \right\}.$$

Регрессионную модель (1), в которой сигнал f принадлежит функциональному классу $\mathcal{F}_{d,\beta,\sigma}$, можно переписать в терминах квадратично-суммируемых последовательностей. Для этого в пространстве L_2^d рассмотрим базис $\{\phi_l(\mathbf{x})\}_{l \in \mathbb{Z}^d}$ вида

$$\phi_l(\mathbf{x}) = \prod_{k=1}^d \phi_{l_k}(x_k), \quad \mathbf{x} = (x_1, \dots, x_d) \in [0, 1]^d, \quad l = (l_1, \dots, l_d) \in \mathbb{Z}^d.$$

Для функции $f(\mathbf{x}) = \sum_{l \in \mathbb{Z}^d} \theta_l \phi_l(\mathbf{x}) \in L_2^d$ с коэффициентами Фурье $\theta_l = (f, \phi_l)$, $l \in \mathbb{Z}^d$, и числа $\sigma > 0$, положим

$$\|f\|_{d,\sigma,2}^2 = \sum_{l \in \mathbb{Z}^d} c_l^2 \theta_l^2,$$

где

$$c_l^2 = c_l^2(\sigma) = \sum_{j=1}^d (2\pi|l_j|)^{2\sigma}, \quad l = (l_1, \dots, l_d) \in \mathbb{Z}^d.$$

Далее, для вектора $l \in \mathbb{Z}^d$, у которого j -ая компонента равняется k , а остальные принимают нулевое значение, определим функцию

$$\phi_{j,k}(\mathbf{x}) = \phi_l(\mathbf{x}) = \phi_k(x_j)$$

и обозначим $\theta_{j,k} = (f, \phi_{j,k})$. Тогда соболевская полунорма функции $f = \sum_{j=1}^d \eta_j f_j \in \mathcal{F}_{d,\beta,\sigma}$ переписывается в виде

$$\|f\|_{d,\sigma,2}^2 = \sum_{j=1}^d \eta_j \|f_j\|_{\sigma,2}^2 = \sum_{j=1}^d \eta_j \sum_{k \in \mathbb{Z}} (2\pi|k|)^{2\sigma} \theta_{j,k}^2.$$

Имея ортонормированную систему $\{\phi_{j,k}(\mathbf{x}) : 1 \leq j \leq d, k \in \mathbb{Z}\}$, рассмотрим статистики

$$X_{j,k} = \eta_j \theta_{j,k} + \varepsilon \xi_{j,k}, \quad \xi_{j,k} \stackrel{i.i.d.}{\sim} \mathcal{N}(0, 1), \quad 1 \leq j \leq d, \quad k \in \mathbb{Z}, \quad (7)$$

где $X_{j,k} = X_\varepsilon(\phi_{j,k})$ – эмпирические коэффициенты Фурье, $\theta_{j,k} = (f, \phi_{j,k}) = \int_0^1 \phi_k(x_j) f_j(x_j) dx_j$ – k -й коэффициент Фурье j -й компоненты

f_j сигнала f , а “вектор” $(\eta_1\theta_1, \dots, \eta_d\theta_d)$ состоит из последовательностей $\eta_j\theta_j = (\eta_j\theta_{j,k})_{k \in \mathbb{Z}}$ и принадлежит множеству

$$\Theta_{d,\beta,\sigma} = \left\{ (\eta_1\theta_1, \dots, \eta_d\theta_d) : (\eta_j) \in \mathcal{H}_{d,\beta}, \theta_j = (\theta_{j,k}) \in l_2(\mathbb{Z}), \right. \\ \left. \sum_{k \in \mathbb{Z}} (2\pi|k|)^{2\sigma} \theta_{j,k}^2 \leq 1, 1 \leq j \leq d \right\}.$$

Легко видеть, что это – достаточные статистики в рассматриваемой задаче. Они имеют нормальное распределение $N(\eta_j\theta_{j,k}, \varepsilon^2)$, которое зависит от коэффициентов Фурье $\theta_{j,k}$ относительно системы $\{\phi_{j,k}\}$ и не зависит от выбора самой системы. Поэтому вместо задачи точного воспроизведения сигнала $f \in \mathcal{F}_{d,\beta,\sigma}$ в модели (1) мы можем изучать эквивалентную ей задачу точной селекции координат вектора $(\eta_1\theta_1, \dots, \eta_d\theta_d) \in \Theta_{d,\beta,\sigma}$ в модели (7).

Для нахождения условий, при которых точное воспроизведение сигнала $f = \sum_j \eta_j f_j \in \mathcal{F}_{d,\beta,\sigma}$ возможно, нам понадобится рассмотреть одномерную задачу (одну и ту же для каждого $j = 1, \dots, d$) проверки гипотезы $H_{0j} : f_j \equiv 0$ против альтернативы $H_{1j} : f_j \in \mathcal{F}_\sigma(r_\varepsilon)$, где

$$\mathcal{F}_\sigma(r_\varepsilon) = \mathcal{F}_\sigma(r_\varepsilon) = \{f : f \in \mathcal{F}_\sigma, \|f\|_{\sigma,2} \leq 1, \|f\|_2 \geq r_\varepsilon\}.$$

В терминах последовательностей данные гипотезы переписываются в виде

$$H_{0j} : \theta_j = 0, \quad H_{1j} : \theta_j \in \Theta_\sigma(r_\varepsilon),$$

где $\theta_j = (\theta_{j,k})_{k \in \mathbb{Z}}$ и

$$\Theta_\sigma(r_\varepsilon) = \left\{ \theta = (\theta_k)_{k \in \mathbb{Z}} \in l_2(\mathbb{Z}) : \sum_{k \in \mathbb{Z}} (2\pi|k|)^{2\sigma} \theta_k^2 \leq 1, \sum_{k \in \mathbb{Z}} \theta_k^2 \geq r_\varepsilon^2 \right\}.$$

Прежде чем перейти к изучению проблемы точного воспроизведения сигнала в функциональной модели регрессии, мы приведем аналогичный результат для более простого векторного случая.

2.3. Селекция компонент разреженного нормального вектора. Пусть $\eta = (\eta_1, \dots, \eta_d) \in \mathcal{H}_{d,\beta}$ и пусть $a = a(d, \beta)$ есть известный положительный параметр. Предположим, что имеется d -мерный нормальный вектор наблюдений $X = (X_1, \dots, X_d)$ возрастающей размерности (то есть $d \rightarrow \infty$) вида

$$X = \mu + \xi, \quad \xi \sim N(0, I_d), \tag{8}$$

с разреженным вектором средних значений $\mu = a\eta = (a\eta_1, \dots, a\eta_d)$ и единичной ковариационной матрицей I_d . В данных предположениях задача селекции состоит в оценивании вектора η при наличии “мешающего” параметра a . Очевидно, эта задача является содержательной только тогда, когда число a не очень “мало”.

Пусть $\hat{\eta} = \hat{\eta}(X) = (\hat{\eta}_1(X), \dots, \hat{\eta}_d(X))$ есть селектор, построенный по вектору наблюдений X . Обозначим через $|\hat{\eta} - \eta|$ расстояние Хэмминга между селектором $\hat{\eta}$ и вектором η , то есть, $|\hat{\eta} - \eta| = \sum_{j=1}^d |\hat{\eta}_j - \eta_j|$. Предположим, что качество селекции измеряется с помощью максимального риска

$$R(\hat{\eta}) = \sup_{\eta \in \mathcal{H}_{a,\beta}} \mathbf{E}_\eta |\hat{\eta} - \eta|.$$

В этих и чуть более общих предположениях проблема точной селекции изучалась в работе [6], где показано, что точная селекция осуществима при условии $\liminf_{d \rightarrow \infty} \frac{a}{\sqrt{\log d}} > \sqrt{2}(1 + \sqrt{1 - \beta})$, и недостижима, когда $\limsup_{d \rightarrow \infty} \frac{a}{\sqrt{\log d}} < \sqrt{2}(1 + \sqrt{1 - \beta})$.

Можно показать, что при выполнении условия $\liminf_{d \rightarrow \infty} \frac{a}{\sqrt{\log d}} > \sqrt{2}(1 + \sqrt{1 - \beta})$, точная селекция в векторной модели (8) обеспечивается оценкой $\hat{\eta}$ вектора η вида

$$\begin{aligned} \hat{\eta} &= \hat{\eta}(X) = (\hat{\eta}_1(X), \dots, \hat{\eta}_d(X)), \\ \hat{\eta}_j(X) &= \mathbb{I}(X_j > \sqrt{(2 + \delta) \log d}), \quad j = 1, \dots, d, \end{aligned} \quad (9)$$

где δ – некоторое (малое) положительное число. Если же параметр a удовлетворяет условию $\limsup_{d \rightarrow \infty} \frac{a}{\sqrt{\log d}} < \sqrt{2}(1 + \sqrt{1 - \beta})$, то справедливо неравенство

$$\liminf_{\varepsilon \rightarrow 0} \inf_{\tilde{\eta}} \sup_{\eta \in \mathcal{H}_{a,\beta}} \mathbf{E}_\eta |\tilde{\eta} - \eta| > 0,$$

то есть, в этом случае точная селекция невозможна. Данный факт устанавливается путем оценивания снизу минимаксного риска $\inf_{\tilde{\eta}} \sup_{\eta \in \mathcal{H}_{a,\beta}} \mathbf{E}_\eta |\tilde{\eta} - \eta|$ байесовским риском, который, при подходящем выборе априорного распределения вектора $\eta \in \mathcal{H}_{a,\beta}$, строго положителен (см. [6, п. 4]).

§3. ОСНОВНЫЕ РЕЗУЛЬТАТЫ

В этом параграфе мы сформулируем условия, при которых точная селекция в функциональной задаче регрессии становится возможной, и построим селектор, обеспечивающий точную селекцию (см. теорему 1). Построенный нами селектор *адаптивен* по отношению к индексу разреженности β и неулучшаем в смысле минимаксного подхода (см. теорему 2). Вместо непрерывной регрессионной модели мы будем рассматривать более удобную с технической точки зрения эквивалентную ей модель в пространстве последовательностей. Напомним, что число переменных функции $f \in \mathcal{F}_{d,\beta,\sigma}$ предполагается растущим и удовлетворяющим условию $d = d_\varepsilon \rightarrow \infty$ при $\varepsilon \rightarrow \infty$.

3.1. Точное воспроизведение разреженного сигнала. Рассмотрим эллипсоид в пространстве $l_2(\mathbb{Z})$ с удаленной из него малой окрестностью точки $\theta = 0$:

$$\Theta_\sigma(r_\varepsilon) = \left\{ \theta = (\theta_k)_{k \in \mathbb{Z}} \in l_2(\mathbb{Z}) : \sum_{k \in \mathbb{Z}} (2\pi|k|)^{2\sigma} \theta_k^2 \leq 1, \sum_{k \in \mathbb{Z}} \theta_k^2 \geq r_\varepsilon^2 \right\}.$$

Обозначим через $\theta^*(r_\varepsilon) = (\theta_k^*(r_\varepsilon))_{k \in \mathbb{Z}}$ решение экстремальной задачи

$$\frac{1}{2\varepsilon^4} \sum_{k \in \mathbb{Z}} \theta_k^4 \rightarrow \inf_{\theta \in \Theta_\sigma(r_\varepsilon)}, \tag{10}$$

и через $u_\varepsilon^2(r_\varepsilon) = u_\varepsilon^2(\Theta_\sigma(r_\varepsilon))$ ее значение, то есть

$$u_\varepsilon^2(r_\varepsilon) = \frac{1}{2\varepsilon^4} \inf_{\theta \in \Theta_\sigma(r_\varepsilon)} \sum_{k \in \mathbb{Z}} \theta_k^4 = \frac{1}{2\varepsilon^4} \sum_{k \in \mathbb{Z}} (\theta_k^*(r_\varepsilon))^4.$$

Функция $u_\varepsilon^2(r_\varepsilon)$ играет важную роль в минимаксной теории проверки гипотез, поэтому ее появление в задаче селекции вполне естественно. Отметим, что $u_\varepsilon(r_\varepsilon)$ является неубывающей функцией аргумента r_ε и обладает своего рода свойством “непрерывности” (см., например, [9, п. 3.2], [12, §5.2.3]). Именно, для любого $\epsilon > 0$ существуют $\Delta > 0$ и $\varepsilon_0 > 0$ такие, что для всех $\delta \in (0, \Delta)$ и $\varepsilon \in (0, \varepsilon_0)$,

$$u_\varepsilon(r_\varepsilon) \leq u_\varepsilon((1 + \delta)r_\varepsilon) \leq (1 + \epsilon)u_\varepsilon(r_\varepsilon).$$

Кроме того, для рассматриваемого класса σ -гладких функций известны вид экстремальной последовательности $(\theta_k^*(r_\varepsilon))_{k \in \mathbb{Z}}$ (см., например,

теорему 2 в [13]) и точная асимптотика вида (см. [12, §4.3.2], а также теорему 4 в [13])

$$u_\varepsilon(r_\varepsilon) \sim C(\sigma)r_\varepsilon^{2+1/(2\sigma)}\varepsilon^{-2}, \quad \varepsilon \rightarrow 0, \quad (11)$$

где $C(\sigma) > 0$ – известная константа, зависящая от σ и выражаемая в терминах гамма-функции.

По аналогии с векторным случаем (см. п. 2.3) естественно ожидать, что точное воспроизведение разреженного сигнала $f(\mathbf{x}) = \sum_{j=1}^d \eta_j f_j(x_j)$ в функциональной регрессионной модели возможно при $\|f_j\|_2 \geq r_\varepsilon$, $j = 1, \dots, d$, где для параметра $r_\varepsilon > 0$ справедливо

$$\liminf_{\varepsilon \rightarrow 0} \frac{u_\varepsilon(r_\varepsilon)}{\sqrt{\log d}} > \sqrt{2}(1 + \sqrt{1 - \beta}). \quad (12)$$

Вернемся к модели (7) в пространстве последовательностей и рассмотрим случайные величины

$$t_j = t_j(\beta) = \sum_{k \in \mathbb{Z}} \omega_k(r_\varepsilon^*(\beta)) \left[\left(\frac{X_{j,k}}{\varepsilon} \right)^2 - 1 \right], \quad j = 1, \dots, d, \quad (13)$$

где для любого $r_\varepsilon > 0$ весовые функции $\omega_k(r_\varepsilon)$ определяются формулой

$$\omega_k(r_\varepsilon) = \frac{1}{2\varepsilon^2} \frac{(\theta_k^*(r_\varepsilon))^2}{u_\varepsilon(r_\varepsilon)}, \quad k \in \mathbb{Z},$$

и удовлетворяют условию $\sum_{k \in \mathbb{Z}} \omega_k^2(r_\varepsilon) = 1/2$, а число $r_\varepsilon^*(\beta) > 0$ есть решение уравнения (ср. с (12))

$$u_\varepsilon(r_\varepsilon^*(\beta)) = \sqrt{2}(1 + \sqrt{1 - \beta})\sqrt{\log d}. \quad (14)$$

Хорошо известно, что в случае *известного* параметра β асимптотически минимаксный тест для проверки гипотезы $H_{0j} : \theta_j \equiv 0$ против альтернативы $H_{1j} : \theta_j \in \Theta_\sigma(r_\varepsilon)$ имеет вид $\psi_\varepsilon = \mathbb{I}(t_j > u_\varepsilon(r_\varepsilon)/2)$. Причем, данная задача проверки гипотез имеет смысл, когда $r_\varepsilon/r_\varepsilon^* \rightarrow \infty$, где *критический радиус* $r_\varepsilon^* \rightarrow 0$ определяется из соотношения $u_\varepsilon(r_\varepsilon^*) \asymp 1$ (эти и другие общие факты минимаксной теории проверки гипотез можно найти в монографии [12], работах [4] и [17], а также в цикле обзорных статей [9–11]). Если теперь предположить, что размерность d и радиус $r_\varepsilon > 0$ удовлетворяют соотношениям

$$\log d = o(\varepsilon^{-2/(2\sigma+1)}), \quad \liminf_{\varepsilon \rightarrow 0} \frac{u_\varepsilon(r_\varepsilon)}{\sqrt{\log d}} > \sqrt{2}(1 + \sqrt{1 - \beta}),$$

то можно показать, что для некоторого $\delta > 0$ оценка (ср. с (9))

$$\hat{\eta} = (\hat{\eta}_1, \dots, \hat{\eta}_d), \quad \hat{\eta}_j = \mathbb{I} \left(t_j > \sqrt{(2 + \delta) \log d} \right), \quad j = 1, \dots, d,$$

обеспечивает точную селекцию компонент вектора $\eta \in \mathcal{H}_{d,\beta}$, и как следствие – точное воспроизведение сигнала $f \in \mathcal{F}_{d,\beta,\sigma}$ в модели (1).

Рассмотрим теперь более реалистичную постановку задачи, когда значение индекса разреженности $\beta \in (0, 1)$ неизвестно. В этом случае требуется адаптировать процедуру селекции ко всевозможным значениям β , то есть построить *адаптивную* оценку η^* вектора $\eta \in \mathcal{H}_{d,\beta}$. Для этого рассмотрим “решетку” на интервале $(0, 1)$ вида

$$\beta_m = m\Delta, \quad m = 1, \dots, M = [1/\Delta],$$

с числом узлов $M = M_d$, удовлетворяющим соотношению

$$M \rightarrow \infty, \quad \log M = o(\log d), \quad d \rightarrow \infty.$$

Пусть для каждого $m = 1, \dots, M$ параметр $r_{\varepsilon,m}^* > 0$ определяется уравнением (ср. с (14))

$$u_\varepsilon(r_{\varepsilon,m}^*) = \sqrt{2}(1 + \sqrt{1 - \beta_m})\sqrt{\log d}. \quad (15)$$

Как и в случае известного β , рассмотрим статистики типа взвешенной статистики хи-квадрат (ср. с (13))

$$t_{j,m} = \sum_{k \in \mathbb{Z}} \omega_k(r_{\varepsilon,m}^*) \left[\left(\frac{X_{j,k}}{\varepsilon} \right)^2 - 1 \right], \quad j = 1, \dots, d, \quad m = 1, \dots, M, \quad (16)$$

с весовыми функциями

$$\omega_k(r_{\varepsilon,m}^*) = \frac{1}{2\varepsilon^2} \frac{(\theta_k^*(r_{\varepsilon,m}^*))^2}{u_\varepsilon(r_{\varepsilon,m}^*)}, \quad \sum_{k \in \mathbb{Z}} \omega_k^2(r_{\varepsilon,m}^*) = 1/2. \quad (17)$$

Далее, для каждого $j = 1, \dots, d$ и $m = 1, \dots, M$, положим

$$\eta_{j,m} = \mathbb{I} \left(t_{j,m} > \sqrt{(2 + \delta)(\log d + \log M)} \right),$$

и зададим адаптивную оценку η^* вектора $\eta \in \mathcal{H}_{d,\beta}$ равенством

$$\eta^* = (\eta_1^*, \dots, \eta_d^*), \quad \eta_j^* = \max_{1 \leq m \leq M} \eta_{j,m}, \quad j = 1, \dots, d. \quad (18)$$

Идея построенной нами оценки проста и состоит в следующем. Мы полагаем, что в j -м месте есть сигнал, если он обнаруживается хотя бы при одном β_m . Тогда вероятность пропустить сигнал будет меньше, чем при β_m близком к “правильному” значению β (она приблизительно такая же, как у статистик с неизменным порогом), а вероятность

обнаружения в неправильном месте будет меньше суммы соответствующих вероятностей по всем $m = 1, \dots, M$, и мала за счет выбора порогового значения.

Прежде, чем формулировать основные результаты, введем в рассмотрение множество

$$\Theta_{\sigma,d}(r_\varepsilon) = \left\{ \theta = (\theta_1, \dots, \theta_d) : \theta_j = (\theta_{j,k}) \in l_2(\mathbb{Z}), \right. \\ \left. \sum_{k \in \mathbb{Z}} (2\pi|k|)^{2\sigma} \theta_{j,k}^2 \leq 1, \sum_{k \in \mathbb{Z}} \theta_{j,k}^2 \geq r_\varepsilon^2, 1 \leq j \leq d \right\}.$$

Справедлива следующая теорема.

Теорема 1. *Предположим, что $\log d = o(\varepsilon^{-2/(2\sigma+1)})$, и что величина $r_\varepsilon > 0$ удовлетворяет условию*

$$\liminf_{\varepsilon \rightarrow 0} \frac{u_\varepsilon(r_\varepsilon)}{\sqrt{\log d}} > \sqrt{2}(1 + \sqrt{1 - \beta}).$$

Тогда при $\varepsilon \rightarrow 0$ справедливо соотношение

$$\sup_{\eta \in \mathcal{H}_{d,\beta}} \sup_{\theta \in \Theta_{\sigma,d}(r_\varepsilon)} \mathbf{E}_{\eta,\theta} |\eta - \eta^*| \rightarrow 0,$$

где η^* – оценка вектора η , определяемая формулой (18).

Теорема 1 утверждает, что если одновременно для всех $j = 1, \dots, d$, гипотезы $H_{0j} : \theta_j \equiv 0$ и $H_{1j} : \theta_j \in \Theta_\sigma(r_\varepsilon)$ асимптотически различимы, то процедура селекции, основанная на η^* , выбирает в точности “правильные” компоненты вектора $\eta \in \mathcal{H}_{d,\beta}$ и таким образом обеспечивает точное воспроизведение $(\eta_1 \theta_1, \dots, \eta_d \theta_d)$, равномерно по $\mathcal{H}_{d,\beta}$ и $\Theta_{\sigma,d}(r_\varepsilon)$.

Следующий результат показывает, что при нарушении условия обнаружимости точная селекция невозможна.

Теорема 2. *Предположим, что $\log d = o(\varepsilon^{-2/(2\sigma+1)})$, и что величина $r_\varepsilon > 0$ удовлетворяет условию*

$$\limsup_{\varepsilon \rightarrow 0} \frac{u_\varepsilon(r_\varepsilon)}{\sqrt{\log d}} < \sqrt{2}(1 + \sqrt{1 - \beta}).$$

Тогда при $\varepsilon \rightarrow 0$ справедливо неравенство

$$\liminf_{\varepsilon \rightarrow 0} \inf_{\tilde{\eta}} \sup_{\eta \in \mathcal{H}_{d,\beta}} \sup_{\theta \in \Theta_{\sigma,d}(r_\varepsilon)} \mathbf{E}_{\eta,\theta} |\eta - \tilde{\eta}| > 0,$$

где нижняя грань берется по всевозможным оценкам $\tilde{\eta}$ вектора η в (7).

Замечание 1. Как следует из теорем 1 и 2, точный критический радиус $r_\varepsilon^* = r_\varepsilon^*(\beta)$, наличие которого делает задачу селекции содержательной, определяется из уравнения (14), в котором функция $u_\varepsilon(r_\varepsilon)$ удовлетворяет соотношению (11).

Замечание 2. Сравнение теорем 1 и 2 с результатами работы [6], полученными для векторного случая и кратко изложенными в п. 2.3, показывает, что в функциональной задаче селекции роль параметра a принимает на себя величина $u_\varepsilon(r_\varepsilon)$, где $u_\varepsilon^2(r_\varepsilon)$ – значение экстремальной задачи (10).

§4. ДОКАЗАТЕЛЬСТВО ТЕОРЕМ

4.1. Доказательство теоремы 1. Прежде чем переходить к доказательству теоремы 1, мы установим ряд свойств статистик $t_{j,m}$ (см. определение (16)) и поясним необходимость условия

$$\log d = o\left(\varepsilon^{-2/(2\sigma+1)}\right) \quad (19)$$

в утверждении теоремы 1.

Из леммы 6.1 в [5] следует, что при нулевой гипотезе $H_{0j} : \theta_j = 0$

$$\mathbf{E}_0(t_{j,m}) = 0, \quad \mathbf{Var}_0(t_{j,m}) = 1,$$

в то время как при альтернативе $H_{1j} : \theta_j \in \Theta_\sigma(r_\varepsilon)$, где при достаточно малых ε малый параметр $r_\varepsilon > 0$ удовлетворяет условию $r_\varepsilon/r_{\varepsilon,m}^* > 1$, мы имеем

$$\begin{aligned} \mathbf{E}_{\theta_j}(t_{j,m}) &= \varepsilon^{-2} \sum_{k \in \mathbb{Z}} \omega_k(r_{\varepsilon,m}^*) \theta_{j,k}^2 \geq u_\varepsilon(r_{\varepsilon,m}^*), \\ \mathbf{Var}_{\theta_j}(t_{j,m}) &= 1 + O(\mathbf{E}_{\theta_j}(t_{j,m}) \max_{k \in \mathbb{Z}} \omega_k(r_{\varepsilon,m}^*)). \end{aligned} \quad (20)$$

Более того, при указанных ограничениях на r_ε and $r_{\varepsilon,m}^*$ справедлив следующий результат.

Лемма 3. Пусть величина $T = T_\varepsilon \rightarrow -\infty$ и весовые функции $\omega_k(r_{\varepsilon,m}^*)$, определяемые равенством (17), таковы, что при $\varepsilon \rightarrow 0$

$$T \max_{k \in \mathbb{Z}} \omega_k(r_{\varepsilon,m}^*) \rightarrow 0 \quad \text{и} \quad \mathbf{E}_{\theta_j}(t_{j,m}) \max_{k \in \mathbb{Z}} \omega_k(r_{\varepsilon,m}^*) \rightarrow 0. \quad (21)$$

Тогда при $\varepsilon \rightarrow 0$

$$\mathbf{P}_0(t_{j,m} \leq T) \leq \exp\left(-\frac{T^2}{2}(1+o(1))\right),$$

и для любого $j = 1, \dots, d$, равномерно по $\theta_j \in \Theta_\sigma(r_\varepsilon)$,

$$\mathbf{P}_{\theta_j}(t_{j,m} - \mathbf{E}_{\theta_j}(t_{j,m}) \leq T) \leq \exp\left(-\frac{T^2}{2}(1+o(1))\right).$$

Доказательство этой важной леммы повторяет доказательство предложения 6.1 в работе [5] и потому опускается. При использовании леммы 1 в доказательстве теоремы 1 величина T оказывается порядка $O(\sqrt{\log d})$. Поэтому и в силу (20), оба условия в (21) выполняются, когда

$$\sqrt{\log d} \max_{k \in \mathbb{Z}} \omega_k(r_{\varepsilon,m}^*) \rightarrow 0, \quad \varepsilon \rightarrow 0. \quad (22)$$

При нашем определении $\omega_k(r_{\varepsilon,m}^*)$, которое зависит от рассматриваемого в данной работе класса гладких функций \mathcal{F}_σ , условие (22) выполняется, когда размерность $d = d_\varepsilon$ растет согласно (19).

Действительно, нам нужно удовлетворить требованию (22), в котором

$$\omega_k(r_{\varepsilon,m}^*) = \frac{1}{2\varepsilon^2} \frac{(\theta_{j,k}^*(r_{\varepsilon,m}^*))^2}{u_\varepsilon(r_{\varepsilon,m}^*)} =: \frac{(v_{j,k}^*(r_{\varepsilon,m}^*))^2}{2u_\varepsilon(r_{\varepsilon,m}^*)},$$

где $(\theta_{j,k}^*(r_\varepsilon))_{k \in \mathbb{Z}}$ – экстремальная последовательность в задаче (одной и той же для всех $j = 1, \dots, d$)

$$\frac{1}{2\varepsilon^4} \sum_{k \in \mathbb{Z}} \theta_{j,k}^4 \rightarrow \inf_{\theta_j \in \Theta_\sigma(r_\varepsilon)},$$

а $u_\varepsilon^2(r_\varepsilon)$ – значение этой задачи. Чтобы иметь возможность осуществить точную селекцию, необходимо, чтобы гипотезы $H_{0j} : \theta_j \equiv 0$ и $H_{1j} : \theta_j \in \Theta_\sigma(r_\varepsilon)$ были асимптотически различимы одновременно для всех $j = 1, \dots, d$. Из общей минимаксной теории проверки гипотез известно, что $u_\varepsilon^2(r_\varepsilon)$ определяет пороговое значение оптимального теста в данной задаче. Известно также (см., например, [13, п. 2]), что

$$(v_{j,k}^*(r_\varepsilon))^2 \asymp r_\varepsilon^{2+1/\sigma} \varepsilon^{-2}, \quad u_\varepsilon(r_\varepsilon) \asymp r_\varepsilon^{2+1/(2\sigma)} \varepsilon^{-2}, \quad (23)$$

и потому для всех $k \in \mathbb{Z}$

$$\omega_k(r_\varepsilon) = \frac{(v_{j,k}^*(r_\varepsilon))^2}{2u_\varepsilon(r_\varepsilon)} \asymp \frac{r_\varepsilon^{2+1/\sigma} \varepsilon^{-2}}{r_\varepsilon^{2+1/(2\sigma)} \varepsilon^{-2}} = r_\varepsilon^{1/(2\sigma)}. \quad (24)$$

Далее, гипотезы H_{0j} и H_{1j} асимптотически различимы, когда $r_\varepsilon/r_\varepsilon^* \rightarrow \infty$ (или, при наличии точного критического радиуса r_ε^* , когда $\liminf r_\varepsilon/r_\varepsilon^* > 1$), где критический радиус r_ε^* удовлетворяет соотношению $u_\varepsilon(r_\varepsilon^*) \asymp (r_\varepsilon^*)^{2+1/(2\sigma)}\varepsilon^{-2}$ с одной стороны (см. (23)) и соотношению $u_\varepsilon(r_\varepsilon^*) \asymp u_\varepsilon(r_{\varepsilon,m}^*) \asymp \log^{1/2} d$ с другой стороны (см. (15) и замечание 1). Поэтому, используя упомянутое выше свойство непрерывности функции $u_\varepsilon(r_\varepsilon)$, находим

$$r_\varepsilon^* \asymp r_{\varepsilon,m}^* \asymp (\varepsilon^4 \log d)^{\sigma/(4\sigma+1)}. \quad (25)$$

Осталось заметить, что (22) и (24) позволяют получить соотношение $(r_{\varepsilon,m}^*)^{1/(2\sigma)} \log^{1/2} d = o(1)$, которое, ввиду (25), эквивалентно $\varepsilon^{2/(4\sigma+1)} (\log d)^{(2\sigma+1)/(4\sigma+1)} = o(1)$, что и приводит к (19).

Доказательство теоремы 1. По определению селектора η^* имеем

$$\begin{aligned} & \sup_{\eta \in \mathcal{H}_{d,\beta}} \sup_{\eta \in \Theta_{\sigma,d}(r_\varepsilon)} \mathbf{E}_{\eta,\theta} |\eta - \eta^*| = \sup_{\eta \in \mathcal{H}_{d,\beta}} \sup_{\eta \in \Theta_{\sigma,d}(r_\varepsilon)} \mathbf{E}_{\eta,\theta} \sum_{j=1}^d |\eta_j - \eta_j^*| \\ &= \sup_{\eta \in \mathcal{H}_{d,\beta}} \sup_{\eta \in \Theta_{\sigma,d}(r_\varepsilon)} \mathbf{E}_{\eta,\theta} \left(\sum_{j:\eta_j=0} \eta_j^* + \sum_{j:\eta_j=1} (1 - \eta_j^*) \right) \\ &= \sup_{\eta \in \mathcal{H}_{d,\beta}} \left(\sum_{j:\eta_j=0} \mathbf{E}_0(\eta_j^*) + \sum_{j:\eta_j=1} \sup_{\theta_j \in \Theta_\sigma(r_\varepsilon)} \mathbf{E}_{\theta_j}(1 - \eta_j^*) \right) \\ &= \sup_{\eta \in \mathcal{H}_{d,\beta}} \left(\sum_{j:\eta_j=0} \mathbf{E}_0 \left[\max_{1 \leq m \leq M} \mathbb{I} \left(t_{j,m} > \sqrt{(2+\delta)(\log d + \log M)} \right) \right] \right. \\ & \quad \left. + \sum_{j:\eta_j=1} \sup_{\theta_j \in \Theta_\sigma(r_\varepsilon)} \mathbf{E}_{\theta_j} \left[1 - \max_{1 \leq m \leq M} \mathbb{I} \left(t_{j,m} > \sqrt{(2+\delta)(\log d + \log M)} \right) \right] \right) \\ &= (d - d^{1-\beta}) \mathbf{E}_0 \left[\max_{1 \leq m \leq M} \mathbb{I} \left(t_{1,m} > \sqrt{(2+\delta)(\log d + \log M)} \right) \right] \\ & \quad + d^{1-\beta} \sup_{\theta_1 \in \Theta_\sigma(r_\varepsilon)} \mathbf{E}_{\theta_1} \left[1 - \max_{1 \leq m \leq M} \mathbb{I} \left(t_{1,m} > \sqrt{(2+\delta)(\log d + \log M)} \right) \right] \\ &=: I_1 + I_2. \end{aligned} \quad (26)$$

Для первого слагаемого, используя вариант леммы 1 с $T = T_\varepsilon \rightarrow \infty$, при $d \rightarrow \infty$ получаем следующую оценку сверху:

$$\begin{aligned}
I_1 &\leq d \sum_{m=1}^M \mathbf{E}_0 \left[\mathbb{I} \left(t_{1,m} > \sqrt{(2+\delta)(\log d + \log M)} \right) \right] \\
&\leq Md \max_{1 \leq m \leq M} \mathbf{P}_0 \left(t_{1,m} > \sqrt{(2+\delta)(\log d + \log M)} \right) \\
&= O(Md) \exp \left(-\frac{2+\delta}{2} (\log d + \log M) \right) = O((Md)^{-\delta/2}) = o(1).
\end{aligned} \tag{27}$$

Рассмотрим второе слагаемое и заметим, что

$$1 - \max_{1 \leq m \leq M} \mathbb{I} \left(t_{1,m} > \sqrt{(2+\delta)(\log d + \log M)} \right)$$

равняется единице, когда $t_{1,m} \leq \sqrt{(2+\delta)(\log d + \log M)}$ для всех $m = 1, \dots, M$, и нулю в противном случае. Поэтому

$$\begin{aligned}
I_2 &= d^{1-\beta} \sup_{\theta_1 \in \Theta_\sigma(r_\varepsilon)} \mathbf{P}_{\theta_1} \left(\bigcap_{m=1}^M \left\{ t_{1,m} \leq \sqrt{(2+\delta)(\log d + \log M)} \right\} \right) \\
&\leq d^{1-\beta} \sup_{\theta_1 \in \Theta_\sigma(r_\varepsilon)} \min_{1 \leq m \leq M} \mathbf{P}_{\theta_1} \left(t_{1,m} \leq \sqrt{(2+\delta)(\log d + \log M)} \right) \\
&= d^{1-\beta} \sup_{\theta_1 \in \Theta_\sigma(r_\varepsilon)} \min_{1 \leq m \leq M} \mathbf{P}_{\theta_1} \left(t_{1,m} - \mathbf{E}_{\theta_1}(t_{1,m}) \right. \\
&\quad \left. \leq \sqrt{(2+\delta)(\log d + \log M)} - \mathbf{E}_{\theta_1}(t_{1,m}) \right). \tag{28}
\end{aligned}$$

Далее, чтобы применить лемму 1 к правой части (28), нужно показать, что для некоторого индекса m , такого что при всех достаточно малых ε , выполняется неравенство $r_\varepsilon/r_{\varepsilon,m}^* > 1$, справедливо соотношение

$$\sqrt{(2+\delta)(\log d + \log M)} - \inf_{\theta_1 \in \Theta_\sigma(r_\varepsilon)} \mathbf{E}_{\theta_1}(t_{1,m}) \rightarrow -\infty, \quad \varepsilon \rightarrow 0. \tag{29}$$

По условию, для некоторого $\delta > 0$ (можно считать, что $\delta = o(1)$)

$$u_\varepsilon(r_\varepsilon) \geq \sqrt{2}(1 + \sqrt{1-\beta})\sqrt{\log d}(1 + \delta).$$

Следовательно, в силу “непрерывности” $u_\varepsilon(r_\varepsilon)$, найдется близкое к β значение β_m , определяющее $r_{\varepsilon,m}^*$, такое что (см. (15))

$$\begin{aligned}
u_\varepsilon(r_{\varepsilon,m}^*) &= \sqrt{2}(1 + \sqrt{1-\beta})\sqrt{\log d}(1 + o(1)) \\
&\geq \sqrt{2}(1 + \sqrt{1-\beta})\sqrt{\log d}(1 + \delta + o(1)).
\end{aligned}$$

Таким образом, для некоторого числа $\delta_1 > 0$,

$$r_\varepsilon \geq (1 + \delta_1)r_{\varepsilon,m}^* =: Br_{\varepsilon,m}^*, \quad B > 1.$$

Далее, в силу предложения 3.1 из [5], при некотором $\delta_2 > 0$, таком что $B^2(1 + o(1)) > 1 + \delta_2$, получаем, используя (20),

$$\begin{aligned} \inf_{\theta_1 \in \Theta_\sigma(r_\varepsilon)} \mathbf{E}_{\theta_1}(t_{1,m}) &\geq \inf_{\theta_1 \in \Theta_\sigma(Br_{\varepsilon,m}^*)} \varepsilon^{-2} \sum_{k \in \mathbb{Z}} \omega_k(r_{\varepsilon,m}^*) \theta_{1,k}^2 \\ &\geq B^2 \inf_{\theta_1 \in \Theta_\sigma(r_{\varepsilon,m}^*)} \varepsilon^{-2} \sum_{k \in \mathbb{Z}} \omega_k(r_{\varepsilon,m}^*) \theta_{1,k}^2 = B^2 \inf_{\theta_1 \in \Theta_\sigma(r_{\varepsilon,m}^*)} \mathbf{E}_{\theta_1}(t_{1,m}) = B^2 u_\varepsilon(r_{\varepsilon,m}^*) \\ &= B^2 \sqrt{2}(1 + \sqrt{1 - \beta}) \sqrt{\log d} (1 + o(1)) > \sqrt{2}(1 + \sqrt{1 - \beta}) \sqrt{\log d} (1 + \delta_2). \end{aligned}$$

Отсюда, для некоторого малого числа $\delta > 0$ при достаточно малых ε (и следовательно при достаточно больших d),

$$\begin{aligned} \inf_{\theta_1 \in \Theta_\sigma(r_\varepsilon)} \mathbf{E}_{\theta_1}(t_{1,m}) &> \sqrt{2}(1 + \sqrt{1 - \beta}) \sqrt{\log d} (1 + \delta_2) \\ &> \sqrt{(2 + \delta)(\log d + \log M)}, \end{aligned}$$

что и доказывает (29).

Поэтому, применяя лемму 1 в правой части неравенства (28), мы получаем при $d \rightarrow \infty$ (и малом $\delta > 0$)

$$\begin{aligned} I_2 &\leq d^{1-\beta} \exp \left(- \frac{\left(\sqrt{(2 + \delta)} - \sqrt{2}(1 + \sqrt{1 - \beta})(1 + \delta_2) \right)^2}{2} \log d (1 + o(1)) \right) \\ &= O \left(d^{-\beta - \delta/2 - (1 + \sqrt{1 - \beta})^2(1 + \delta_2)^2 + \sqrt{2(2 + \delta)}(1 + \sqrt{1 - \beta})(1 + \delta_2)} \right) = o(1). \quad (30) \end{aligned}$$

Подставляя (27) и (30) в (26), выводим требуемый результат:

$$\sup_{\eta \in \mathcal{H}_{d,\beta}} \sup_{\theta \in \Theta_{\sigma,d}(r_\varepsilon)} \mathbf{E}_{\eta,\theta} |\eta - \eta^*| \leq I_1 + I_2 = o(1), \quad \varepsilon \rightarrow 0.$$

Теорема 1 доказана. \square

4.2. Доказательство теоремы 2. При доказательстве теоремы 2 будем предполагать, что η_j и θ_j , $j = 1, \dots, d$, есть реализации независимых случайных величин и последовательностей, соответственно. При таком байесовском подходе и подходящем выборе априорных распределений, минимаксный риск

$$R_\varepsilon = \inf_{\tilde{\eta}} \sup_{\eta \in \mathcal{H}_{d,\beta}} \sup_{\theta \in \Theta_{\sigma,d}(r_\varepsilon)} \mathbf{E}_{\eta,\theta} |\eta - \tilde{\eta}|$$

будет не меньше байесовского риска, для которого, в свою очередь, существует положительная нижняя грань. Как и в теореме 1, ограничение на рост размерности d играет здесь ключевую роль. Оно гарантирует, что нормированная экстремальная последовательность $(v_{j,k}^*)_{k \in \mathbb{Z}}$, определяемая формулой (32), удовлетворяет важному для нашего доказательства условию $v_{j,k}^* = o(1)$ при $\varepsilon \rightarrow 0$.

Доказательство теоремы 2. Как и прежде, обозначим через $\theta_j^* = (\theta_{j,k}^*)_{k \in \mathbb{Z}}$ экстремальную последовательность в задаче (одной и той же для всех $j = 1, \dots, d$)

$$\frac{1}{2\varepsilon^4} \sum_{k \in \mathbb{Z}} \theta_{j,k}^4 \rightarrow \inf_{\theta_j \in \Theta_{\sigma}(r_\varepsilon)}.$$

Пусть априорное распределение “вектора” $\theta = (\theta_1, \dots, \theta_d) \in \Theta_{\sigma,d}(r_\varepsilon)$ имеет вид

$$\pi_\theta(d\theta) = \prod_{j=1}^d \pi_{\theta_j}(d\theta_j), \quad \pi_{\theta_j}(d\theta_j) = \prod_{k \in \mathbb{Z}} \left(\frac{\delta_{-\theta_{j,k}^*} + \delta_{\theta_{j,k}^*}}{2} \right) (d\theta_{j,k}),$$

где δ_x есть δ -мера с единичной массой в точке x . Обозначим теперь через

$$p = d^{1-\beta} / d = d^{-\beta}$$

долю ненулевых компонент вектора $\eta = (\eta_1, \dots, \eta_d) \in \mathcal{H}_{d,\beta}$. Априорное распределение η естественно положить равным

$$\pi_\eta(d\eta) = \prod_{j=1}^d \pi_{\eta_j}(d\eta_j), \quad \pi_{\eta_j}(d\eta_j) = ((1-p)\delta_0 + p\delta_1)(d\eta_j).$$

Тогда, в предположении независимости $\theta = (\theta_j)$ и $\eta = (\eta_j)$, справедливо неравенство

$$\begin{aligned} R_\varepsilon &= \inf_{\tilde{\eta}} \sup_{\eta \in \mathcal{H}_{d,\beta}} \sup_{\theta \in \Theta_{\sigma,d}(r_\varepsilon)} \mathbf{E}_{\eta,\theta} |\eta - \tilde{\eta}| \geq \inf_{\tilde{\eta}} \mathbf{E}_{\pi_\eta} \mathbf{E}_{\pi_\theta} \mathbf{E}_{\eta,\theta} |\eta - \tilde{\eta}| \\ &= \inf_{\tilde{\eta}} \mathbf{E}_{\pi_\eta} \mathbf{E}_{\pi_\theta} \mathbf{E}_{\eta,\theta} \sum_{j=1}^d |\eta_j - \tilde{\eta}_j| \\ &= \inf_{\tilde{\eta}} \sum_{j=1}^d \mathbf{E}_{\pi_{\eta_j}} \mathbf{E}_{\pi_{\theta_j}} \mathbf{E}_{\eta_j, \theta_j} |\eta_j - \tilde{\eta}_j| =: R_{B,\varepsilon}, \end{aligned}$$

где $\mathbf{E}_{\eta_j \theta_j}$ – математическое ожидание по мере $\mathbf{P}_{\eta_j \theta_j}$, индуцированной наблюдением $X_j = (X_{j,k})_{k \in \mathbb{Z}}$, состоящим из независимых случайных величин $X_{j,k}$, $k \in \mathbb{Z}$, распределенных по нормальному закону $N(\eta_j \theta_{j,k}, \varepsilon^2)$, а $R_{B,\varepsilon}$ – байесовский риск по отношению к введенным априорным распределениям.

Рассмотрим смесь по распределению $\mathbf{P}_{\eta_j \theta_j}$, определяемую формулой

$$\begin{aligned} \mathbf{P}_{\pi, \eta_j}(dX_j) &= \mathbf{E}_{\pi \theta_j} \mathbf{P}_{\eta_j \theta_j}(dX_{j,k}) \\ &= \prod_{k \in \mathbb{Z}} \left(\frac{N(-\eta_j \theta_{j,k}^*, \varepsilon^2) + N(\eta_j \theta_{j,k}^*, \varepsilon^2)}{2} \right) (dX_{j,k}). \end{aligned} \quad (31)$$

В частности, при $\eta_j = 0$, $\mathbf{P}_{\pi, 0}(dX_j) = \prod_{k \in \mathbb{Z}} N(0, \varepsilon^2)(dX_{j,k})$. Используя обозначение

$$v_{j,k}^* = \frac{\theta_{j,k}^*}{\varepsilon}, \quad (32)$$

мы получаем относительно вероятностной меры \mathbf{P}_{π, η_j}

$$Y_{j,k} := \frac{X_{j,k}}{\varepsilon} = \eta_j v_{j,k}^* + \xi_{j,k} \stackrel{\text{ind.}}{\sim} \mathcal{N}(\eta_j v_{j,k}^*, 1), \quad 1 \leq j \leq d, \quad k \in \mathbb{Z}.$$

Далее, обозначая $Y_j = (Y_{j,k})_{k \in \mathbb{Z}}$, переписываем отношение правдоподобия в виде

$$\frac{d\mathbf{P}_{\pi, \eta_j}}{d\mathbf{P}_{\pi, 0}}(Y_j) = \prod_{k \in \mathbb{Z}} \exp\left(-\frac{\eta_j (v_{j,k}^*)^2}{2}\right) \cosh(\eta_j v_{j,k}^* Y_{j,k}). \quad (33)$$

Отсюда, принимая во внимание тот факт, что η_j принимает лишь два значения, ноль и 1 с вероятностями $(1 - p)$ и p , соответственно, продолжим нашу оценку снизу:

$$\begin{aligned} R_\varepsilon \geq R_\varepsilon^* &= \sum_{j=1}^d \inf_{\tilde{\eta}_j} \mathbf{E}_{\pi \eta_j} \mathbf{E}_{\pi, \eta_j} |\eta_j - \tilde{\eta}_j| \\ &= \sum_{j=1}^d \inf_{\tilde{\eta}_j} [(1 - p) \mathbf{E}_{\pi, 0}(\tilde{\eta}_j) + p \mathbf{E}_{\pi, 1}(1 - \tilde{\eta}_j)], \end{aligned}$$

где $\inf_{\tilde{\eta}_j} [(1 - p) \mathbf{E}_{\pi, 0}(\tilde{\eta}_j) + p \mathbf{E}_{\pi, 1}(1 - \tilde{\eta}_j)]$ – байесовский риск в задаче проверки двух простых гипотез

$$H_0 : \mathbf{P} = \mathbf{P}_{\pi, 0}, \quad H_1 : \mathbf{P} = \mathbf{P}_{\pi, 1},$$

с вероятностными мерами $\mathbf{P}_{\pi,0}$ and $\mathbf{P}_{\pi,1}$, определенными в (31). В частности, при нулевой гипотезе, вектор $Y_j = (Y_{j,k})_{k \in \mathbb{Z}}$ имеет нормальное распределение с плотностью $p_{\pi,0}(t) = \prod_{k \in \mathbb{Z}} (2\pi)^{-1/2} \exp(-t_k^2/2\varepsilon^2)$, $t = (t_k)_{k \in \mathbb{Z}}$. Согласно формуле (33), отношением правдоподобия в данной задаче является статистика

$$\Lambda_\pi = \Lambda_\pi(Y_j) = \frac{d\mathbf{P}_{\pi,1}}{d\mathbf{P}_{\pi,0}}(Y_j) = \prod_{k \in \mathbb{Z}} \exp\left(-\frac{(v_{j,k}^*)^2}{2}\right) \cosh(v_{j,k}^* Y_{j,k}),$$

и оптимальный (байесовский) тест η_B имеет вид (см., например, [3, § 8.11])

$$\eta_B(Y_j) = \mathbb{I}\left(\Lambda_\pi(Y_j) \geq \frac{1-p}{p}\right).$$

Используя полученный результат, мы выводим

$$R_\varepsilon \geq R_{B,\varepsilon} = d \left[(1-p) \mathbf{P}_{\pi,0} \left(\Lambda_\pi(Y_j) \geq \frac{1-p}{p} \right) + p \mathbf{P}_{\pi,1} \left(\Lambda_\pi(Y_j) < \frac{1-p}{p} \right) \right].$$

Таким образом, для доказательства теоремы 2 нужно показать, что для некоторого числа $c > 0$ при достаточно малых ε байесовский риск $R_{B,\varepsilon}$ удовлетворяет условию $R_{B,\varepsilon} \geq c$. Последнее неравенство заведомо выполняется, когда для некоторой константы $C > 0$ при достаточно больших d справедливо неравенство

$$d(1-p) \mathbf{P}_{\pi,0} \left(\Lambda_\pi(Y_j) \geq \frac{1-p}{p} \right) \geq C, \quad (34)$$

к проверке которого мы и переходим.

Введем случайные величины

$$\lambda_\pi = \lambda_\pi(Y_j) = \log \Lambda_\pi(Y_j) = \sum_{k \in \mathbb{Z}} \lambda_{\pi,k}(Y_{j,k}), \quad (35)$$

$$\lambda_{\pi,k} = \lambda_{\pi,k}(Y_{j,k}) = -\frac{(v_{j,k}^*)^2}{2} + \log \cosh(v_{j,k}^* Y_{j,k}), \quad (36)$$

и, обозначая

$$H := \log \frac{1-p}{p} \sim \beta \log d,$$

перепишем интересующую нас вероятность в виде

$$\begin{aligned} \mathbf{P}_{\pi,0} \left(\Lambda_\pi > \frac{1-p}{p} \right) &= \mathbf{P}_{\pi,0}(\lambda_\pi > H) = \mathbf{E}_{\pi,0} \mathbb{I}(\lambda_\pi > H) \\ &= \mathbf{E}_{\pi,0} (e^{h\lambda_\pi} e^{-h\lambda_\pi} \mathbb{I}(\lambda_\pi - H > 0)). \end{aligned}$$

Далее, используя для краткости вместо $\mathbf{P}_{\pi,0}$ обозначение \mathbf{P}_0 , введем вероятностную меру \mathbf{P}_h , зависящую от параметра $h > 0$, следующим образом:

$$\frac{d\mathbf{P}_h}{d\mathbf{P}_0}(Y_j) := \frac{e^{h\lambda_\pi(Y_j)}}{\Psi(h)}, \quad \Psi(h) = \mathbf{E}_{\mathbf{P}_0} e^{h\lambda_\pi(Y_j)}.$$

Мы имеем

$$\begin{aligned} \mathbf{P}_0 \left(\Lambda_\pi > \frac{1-p}{p} \right) &= \mathbf{E}_{\mathbf{P}_h} \left(\frac{d\mathbf{P}_0}{d\mathbf{P}_h}(Y_j) e^{h\lambda_\pi} e^{-h\lambda_\pi} \mathbb{I}(\lambda_\pi - H > 0) \right) \\ &= \Psi(h) \mathbf{E}_{\mathbf{P}_h} [e^{-h\lambda_\pi} \mathbb{I}(\lambda_\pi - H > 0)] \\ &= \Psi(h) e^{-hH} \mathbf{E}_{\mathbf{P}_h} [e^{-h(\lambda_\pi - H)} \mathbb{I}(\lambda_\pi - H > 0)] \\ &=: \Psi(h) e^{-hH} J(h). \end{aligned}$$

Отсюда получаем, что

$$\log \mathbf{P}_0 \left(\Lambda_\pi \geq \frac{1-p}{p} \right) = \log \Psi(h) - hH + \log J(h). \quad (37)$$

Мы покажем, что при надлежащем выборе параметра $h = h_\varepsilon > 0$ и при достаточно малых ε слагаемое $\log J(h)$ мало по сравнению с $\log \Psi(h)$ и hH .

Именно, предположим, что h удовлетворяет равенству

$$\mathbf{E}_{\mathbf{P}_h} \lambda_\pi = H. \quad (38)$$

Тогда для случайной величины

$$Z_h := \frac{\lambda_\pi - H}{\sigma_h}, \quad \sigma_h^2 = \mathbf{Var}_{\mathbf{P}_h}(\lambda_\pi), \quad (39)$$

справедливо

$$\mathbf{E}_{\mathbf{P}_h}(Z_h) = 0, \quad \mathbf{Var}_{\mathbf{P}_h}(Z_h) = 1.$$

Далее рассмотрим вероятностные меры $\mathbf{P}_{h,k}$, $k \in \mathbb{Z}$, определяемые соотношением

$$\frac{d\mathbf{P}_h}{d\mathbf{P}_0}(Y_j) = \frac{e^{h \sum_k \lambda_{\pi,k}(Y_{j,k})}}{\mathbf{E}_{\mathbf{P}_0} e^{h \sum_k \lambda_{\pi,k}(Y_{j,k})}} = \prod_{k \in \mathbb{Z}} \frac{e^{h \lambda_{\pi,k}(Y_{j,k})}}{\mathbf{E}_{\mathbf{P}_0} e^{h \lambda_{\pi,k}(Y_{j,k})}} =: \prod_{k \in \mathbb{Z}} \frac{d\mathbf{P}_{h,k}}{d\mathbf{P}_0}(Y_{j,k}),$$

где $\lambda_{\pi,k} = \lambda_{\pi,k}(Y_{j,k}) = -(v_{j,k}^*)^2/2 + \log \cosh(v_{j,k}^* Y_{j,k})$, а величины $v_{j,k}^*$ заданы в (32). Имеет место следующий результат, справедливый при достаточно малых ε .

Лемма 4. Для $\mathbf{P}_{h,k}$ -среднего и дисперсии статистик $\lambda_{\pi,k}$ имеем

$$\begin{aligned}\mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}) &= \frac{(v_{j,k}^*)^4}{2} (h - 1/2) + o((v_{j,k}^*)^4), \\ \mathbf{Var}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}) &= \frac{(v_{j,k}^*)^4}{2} + o((v_{j,k}^*)^4),\end{aligned}$$

и, следовательно,

$$\begin{aligned}\mathbf{E}_{\mathbf{P}_h}(\lambda_\pi) &= u_\varepsilon^2(r_\varepsilon)(h - 1/2)(1 + o(1)), \\ \sigma_h^2 = \mathbf{Var}_{\mathbf{P}_h}(\lambda_\pi) &= u_\varepsilon^2(r_\varepsilon)(1 + o(1)).\end{aligned}$$

Используя методы доказательства леммы 2, можно показать, что случайная величина Z_h в определении (39) асимптотически нормальна (см. лемму 3). Доказательство обеих лемм дано в Приложении.

Лемма 5. При $\varepsilon \rightarrow 0$ выполняется условие Ляпунова, т.е.

$$L_h^{(4)} = \frac{\sum_k \mathbf{E}_{\mathbf{P}_{h,k}} (\lambda_{\pi,k} - \mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}))^4}{(\sum_k \mathbf{Var}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}))^2} \rightarrow 0,$$

и, следовательно, в пределе Z_h имеет стандартное нормальное распределение.

Так как параметр h выбран таким образом, что справедливо (см. (38) и лемму 2)

$$\mathbf{E}_{\mathbf{P}_h}(\lambda_\pi) = (h - 1/2) u_\varepsilon^2(r_\varepsilon)(1 + o(1)) = H \sim \beta \log d,$$

то при $\varepsilon \rightarrow 0$

$$h \sim \frac{1}{2} + \frac{\beta \log d}{u_\varepsilon^2(r_\varepsilon)}. \quad (40)$$

А поскольку по условию теоремы справедливо соотношение $u_\varepsilon^2(r_\varepsilon) \asymp \log d$, то из (40) находим, что

$$h = O(1). \quad (41)$$

Вернемся к (37) и рассмотрим функцию

$$J(h) = \mathbf{E}_{\mathbf{P}_h} [e^{-h\sigma_h Z_h} \mathbb{I}(Z_h > 0)].$$

Очевидно, что

$$\mathbf{P}_h(Z_h \in [0, \delta]) e^{-h\sigma_h \delta} \leq J(h) \leq 1,$$

где по лемме 3 при достаточно малых δ

$$\mathbf{P}_h(Z_h \in [0, \delta]) \sim \delta/\sqrt{2\pi} \geq C > 0.$$

Отсюда получаем

$$-h\sigma_h\delta + \log \delta - \frac{1}{2} \log(2\pi) \leq \log J(h) \leq 0, \quad (42)$$

где в силу (41) и леммы 2,

$$h\sigma_h \asymp u_\varepsilon(r_\varepsilon) \asymp \sqrt{H} \asymp \sqrt{\log d}, \quad (43)$$

и потому $h\sigma_h \rightarrow \infty$ при $\varepsilon \rightarrow 0$. Следовательно, при подходящем выборе малого δ в левой части (42), мы приходим к соотношению $\log J(h) = o(h\sigma_h) = o(\sqrt{H})$. Откуда, учитывая (37), получаем

$$\log \mathbf{P}_0 \left(\Lambda_\pi \geq \frac{1-p}{p} \right) = \log \Psi(h) - hH + o(\sqrt{H}). \quad (44)$$

Обратимся теперь к функции

$$\Psi(h) = \mathbf{E}_{\mathbf{P}_0} e^{h\lambda_\pi} = \prod_{k \in \mathbb{Z}} \mathbf{E}_{\mathbf{P}_0} e^{h\lambda_{\pi,k}} =: \prod_{k \in \mathbb{Z}} \Psi_k(h),$$

где λ_π и $\lambda_{\pi,k}$ определяются соответственно выражениями (35) и (36). Заметим, что при $\varepsilon \rightarrow 0$ имеет место $h = O(1)$ (см. (41)) и, кроме того,

$$v_{j,k}^* = o(1).$$

Действительно, мы знаем, что гипотезы H_{0j} и H_{1j} асимптотически неразличимы, когда $r_\varepsilon/r_\varepsilon^* \rightarrow 0$ (или, при наличии точного критического радиуса r_ε^* , когда $\limsup r_\varepsilon/r_\varepsilon^* < 1$). Поэтому равенство $v_{j,k}^* = o(1)$ при $\varepsilon \rightarrow 0$ есть прямое следствие условий теоремы 2, “непрерывности” функции $u_\varepsilon(r_\varepsilon)$ и соотношений (23) и (25).

Покажем, что при $h = O(1)$ и $v_{j,k}^* = o(1)$,

$$\begin{aligned} \Psi(h) &= \prod_{k \in \mathbb{Z}} \left[\frac{h^2 - h}{4} (v_{j,k}^*)^4 + o((v_{j,k}^*)^4) \right] \\ &= \exp \left(\frac{h^2 - h}{2} u_\varepsilon^2(r_\varepsilon) (1 + o(1)) \right). \end{aligned} \quad (45)$$

Для этого рассмотрим функцию

$$\tilde{p}(v, y) = p(v, y) + \frac{v^4}{4}, \quad p(v, y) = -\frac{v^2}{2} + \log \cosh(vy),$$

относительно которой известно (см. формулу (6.6) в [1]), что если $h = O(1)$ и $v \rightarrow 0$, то

$$\mathbf{E}_{\mathbf{P}_0} e^{h\tilde{p}(v, Y_{j,k})} = \exp\left(\frac{h^2 v^4}{2} + o(v^4)\right).$$

Поэтому мы имеем

$$\begin{aligned} \Psi_k(h) &= \mathbf{E}_{\mathbf{P}_0} \left(e^{h\tilde{p}(v_{j,k}^*, Y_{j,k})} e^{-h(v_{j,k}^*)^4/4} \right) \\ &= \exp\left(\frac{h^2 - h}{4} (v_{j,k}^*)^4 + o((v_{j,k}^*)^4)\right), \end{aligned} \quad (46)$$

и, как следствие, равенство (45).

Завершая доказательство, отметим (см. (43)), что $u_\varepsilon^2 = u_\varepsilon^2(r_\varepsilon) \asymp H \asymp \log d$. Поэтому, подставляя (40) и (45) в (44), находим, что при всех достаточно малых ε

$$\begin{aligned} \log \mathbf{P}_0 \left(\Lambda_\pi \geq \frac{1-p}{p} \right) &= \frac{h^2 - h}{2} u_\varepsilon^2 + o(H) - hH + o(\sqrt{H}) \\ &= \left(-\frac{1}{8} + \frac{H^2}{2u_\varepsilon^4} \right) u_\varepsilon^2 - \frac{H}{2} - \frac{H^2}{u_\varepsilon^2} + o(H), \end{aligned}$$

откуда

$$\log \mathbf{P}_0 \left(\Lambda_\pi \geq \frac{1-p}{p} \right) = -\frac{u_\varepsilon^2}{8} - \frac{H^2}{2u_\varepsilon^2} - \frac{H}{2} + o(H),$$

и, следовательно, при достаточно малых ε

$$\mathbf{P}_0 \left(\Lambda_\pi \geq \frac{1-p}{p} \right) \sim \exp\left(-\frac{u_\varepsilon^2}{8} - \frac{H^2}{2u_\varepsilon^2} - \frac{H}{2}\right) = \exp\left(-\frac{(H + u_\varepsilon^2/2)^2}{2u_\varepsilon^2}\right).$$

А так как условие $\limsup_{\varepsilon \rightarrow 0} \frac{u_\varepsilon(r_\varepsilon)}{\sqrt{\log d}} < \sqrt{2}(1 + \sqrt{1-\beta})$, влечет при достаточно малых ε неравенство

$$d \exp\left(-\frac{(H + u_\varepsilon^2/2)^2}{2u_\varepsilon^2}\right) \geq C > 0,$$

то справедливость (34) установлена, и теорема 2 доказана. \square

ПРИЛОЖЕНИЕ

Доказательство леммы 2. Рассмотрим математическое ожидание

$$\begin{aligned} \mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}) &= \frac{1}{\Psi_k(h)} \mathbf{E}_{\mathbf{P}_0}(\lambda_{\pi,k}) \\ &= \frac{1}{\Psi_k(h)} \mathbf{E}_{\mathbf{P}_0} \left(\exp \left\{ -\frac{h(v_{j,k}^*)^2}{2} + h \log \cosh(v_{j,k}^* Y_{j,k}) \right\} \right. \\ &\quad \left. \times \left[-\frac{(v_{j,k}^*)^2}{2} + \log \cosh(v_{j,k}^* Y_{j,k}) \right] \right) \end{aligned}$$

и напомним, что \mathbf{P}_{π, η_j} -распределение компонент вектора $Y_j = (Y_{j,k})_{k \in \mathbb{Z}}$ есть нормальное распределение со средним $\eta_j v_{j,k}^*$, где $\eta_j = 0$ или 1 , и единичной дисперсией. (Распределение \mathbf{P}_{π, η_j} определяется формулой (31), и мы используем более короткое обозначение \mathbf{P}_0 для $\mathbf{P}_{\pi, 0}$.) Для краткости положим

$$v = v_{j,k}^*, \quad Y = Y_{j,k}$$

и напомним, что $v = o(1)$. Тогда, используя равенство (46), мы можем продолжить:

$$\begin{aligned} \mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}) &= \left[\exp \left(\frac{h^2 - h}{4} v^4 + o(v^4) \right) \right]^{-1} \\ &\quad \times \left[-\frac{v^2}{2} \exp \left(-\frac{h v^2}{2} \right) \mathbf{E}_{\mathbf{P}_0} \{ \exp(h \log \cosh(vY)) \} \right. \\ &\quad \left. + \exp \left(-\frac{h v^2}{2} \right) \mathbf{E}_{\mathbf{P}_0} \{ \log \cosh(vY) \exp(h \log \cosh(vY)) \} \right]. \end{aligned} \quad (47)$$

Первое математическое ожидание в правой части (47) можно представить в виде

$$\begin{aligned} \mathbf{E}_{\mathbf{P}_0} \{ \exp(h \log \cosh(vY)) \} &= \mathbf{E}_{\mathbf{P}_0} \{ \exp(h \log \cosh(vY)) \mathbb{I}(|Y| \leq 1/\sqrt{v}) \} \\ &\quad + \mathbf{E}_{\mathbf{P}_0} \{ \exp(h \log \cosh(vY)) \mathbb{I}(|Y| > 1/\sqrt{v}) \} =: L_1 + L_2. \end{aligned}$$

Заметим, что если $|Y| < 1/\sqrt{v}$, то $|vY| < \sqrt{v} \rightarrow 0$. Поэтому, с использованием неравенства $\cosh(x) \leq \exp(x^2/2)$, $x \in \mathbb{R}$, остаточный член L_2

оценивается следующим образом:

$$L_2 = \int_{|y|>1/\sqrt{v}} \frac{e^{-y^2/2}}{\sqrt{2\pi}} \exp(h \log \cosh(vy)) dy$$

$$\leq \int_{|y|>1/\sqrt{v}} \frac{e^{-(y^2/2)(1-hv^2)}}{\sqrt{2\pi}} dy = O\left(v^{1/2}e^{-1/(2v)}\right).$$

Далее, принимая во внимание разложения

$$\log \cosh x = \frac{x^2}{2} - \frac{x^4}{12} + o(x^4), \quad e^x = 1 + x + \frac{x^2}{2} + o(x^2), \quad x \rightarrow 0, \quad (48)$$

мы находим, что

$$L_1 = \mathbf{E}_{\mathbf{P}_0} \left[1 + \frac{hv^2Y^2}{2} + \left(\frac{h^2v^4}{8} - \frac{hv^4}{12} \right) Y^4 (1 + o(1)) \right]$$

$$- \mathbf{E}_{\mathbf{P}_0} \left[\left(1 + \frac{hv^2Y^2}{2} + \left(\frac{h^2v^4}{8} - \frac{hv^4}{12} \right) Y^4 (1 + o(1)) \right) \mathbb{I}(|Y| > 1/\sqrt{v}) \right]$$

$$= 1 + \frac{hv^2}{2} + \left(\frac{3h^2v^4}{8} - \frac{hv^4}{4} \right) (1 + o(1)) + O(v^{1/2}e^{-1/(2v)}) = 1 + \frac{hv^2}{2} + O(v^4),$$

и потому

$$\mathbf{E}_{\mathbf{P}_0} \{ \exp(h \log \cosh(vY)) \} = L_1 + L_2 = 1 + \frac{hv^2}{2} + O(v^4). \quad (49)$$

Аналогичные рассуждения, основанные на (48) и том факте, что если $|y| < 1/\sqrt{v}$ и $v = o(1)$, то

$$\exp(h \log \cosh(vy)) = 1 + \frac{hv^2y^2}{2} + O(v^4y^4), \quad (50)$$

ведут к представлению второго математического ожидания в правой части (47) в виде

$$\mathbf{E}_{\mathbf{P}_0} \{ \log \cosh(vY) \exp(\log \cosh(vY)) \}$$

$$= \mathbf{E}_{\mathbf{P}_0} \left(\frac{v^2Y^2}{2} + \frac{hv^4Y^4}{4} - \frac{v^4Y^4}{12} \right) + o(v^4)$$

$$= \frac{v^2}{2} + \frac{3hv^4}{4} - \frac{v^4}{4} + o(v^4). \quad (51)$$

Подставляя (49) и (51) в (47), выводим

$$\begin{aligned} \mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}) &= \left[\exp\left(\frac{h^2 - h}{4}v^4 + o(v^4)\right) \right]^{-1} \exp\left(-\frac{hv^2}{2}\right) \\ &\times \left[-\frac{v^2}{2} \left(1 + \frac{hv^2}{2} + O(v^4)\right) + \left(\frac{v^2}{2} + \frac{3hv^4}{4} - \frac{v^4}{4} + o(v^4)\right) \right] \\ &= (1 + O(v^2)) \left[\frac{v^4}{2} \left(h - \frac{1}{2}\right) + o(v^4) \right] = \frac{v^4}{2} \left(h - \frac{1}{2}\right) + o(v^4). \end{aligned}$$

Это дает искомое выражение для $\mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k})$.

Далее, рассмотрим дисперсию

$$\mathbf{Var}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}) = \mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}^2) - (\mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}))^2.$$

Требуется вычислить

$$\begin{aligned} \mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}^2) &= \Psi_k^{-1}(h) \mathbf{E}_{\mathbf{P}_0} \left(\lambda_{\pi,k}^2 \frac{d\mathbf{P}_{h,k}}{d\mathbf{P}_0}(Y) \right) = \Psi_k^{-1}(h) \mathbf{E}_{\mathbf{P}_0} (e^{h\lambda_{\pi,k}} \lambda_{\pi,k}^2) \\ &= \Psi_k^{-1}(h) \mathbf{E}_{\mathbf{P}_0} (e^{h\lambda_{\pi,k}} \lambda_{\pi,k}^2 \mathbb{I}(|Y| \leq 1/\sqrt{v})) \\ &\quad + \Psi_k^{-1}(h) \mathbf{E}_{\mathbf{P}_0} (e^{h\lambda_{\pi,k}} \lambda_{\pi,k}^2 \mathbb{I}(|Y| > 1/\sqrt{v})) =: M_1 + M_2, \end{aligned}$$

где $\lambda_{\pi,k} = -\frac{v^2}{2} + \log \cosh(vY)$, $h = O(1)$, $v = o(1)$ и, согласно (46),

$$\Psi_k(h) = 1 + O(v^4). \quad (52)$$

Для первого слагаемого M_1 , используя (48) и (50), мы получаем выражение

$$\begin{aligned} M_1 &= \Psi_k^{-1}(h) \mathbf{E}_{\mathbf{P}_0} \left[e^{-\frac{hv^2}{2} + h \log \cosh(vY)} \left(-\frac{v^2}{2} + \log \cosh(vY) \right)^2 \mathbb{I}(|Y| \leq 1/\sqrt{v}) \right] \\ &= \mathbf{E}_0 \left[e^{-\frac{hv^2}{2}} \left(1 + \frac{hv^2 Y^2}{2} + O(v^4 Y^4) \right) \right. \\ &\quad \left. \times \left(-\frac{v^2}{2} + \frac{v^2 Y^2}{2} - \frac{v^4 Y^4}{12} (1 + o(1)) \right)^2 \mathbb{I}(|Y| \leq 1/\sqrt{v}) \right] \times (1 + O(v^4)), \end{aligned}$$

откуда после простых вычислений с использованием формулы

$$e^{-\frac{hv^2}{2}} = 1 - \frac{hv^2}{2} + \frac{h^2 v^4}{8} + o(v^4)$$

ВЫВОДИМ

$$M_1 = \mathbf{E}_{\mathbf{P}_0} \left(\frac{v^4}{4} - \frac{v^4 Y^2}{2} + \frac{v^4 Y^4}{4} \right) + o(v^4) = \frac{v^4}{2} + o(v^4).$$

Далее, замечая, что $M_2 = o(v^4)$, получаем

$$\mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}^2) = M_1 + M_2 = \frac{v^4}{2} + o(v^4).$$

Возвращаясь к полным обозначениям и используя тот факт, что

$$\mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}) = \frac{(v_{j,k}^*)^4}{2} (h - 1/2) + o((v_{j,k}^*)^4),$$

находим

$$\begin{aligned} \mathbf{Var}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}) &= \mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}^2) - (\mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}))^2 = \frac{(v_{j,k}^*)^4}{2} + o((v_{j,k}^*)^4), \\ \mathbf{Var}_{\mathbf{P}_h}(\lambda_{\pi}) &= \sum_{k \in \mathbb{Z}} \mathbf{Var}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}) = u_{\varepsilon}^2(r_{\varepsilon})(1 + o(1)). \end{aligned}$$

Лемма 2 доказана. \square

Доказательство леммы 3. Среднее значение в числителе дроби Ляпунова равняется

$$\begin{aligned} \mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k} - \mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}))^4 &= \mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}^4) - 4\mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k})\mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}^3) \\ &\quad + 6\mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}^2)(\mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}))^2 - 3(\mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}))^4, \end{aligned} \quad (53)$$

и потому, согласно лемме 2,

$$\begin{aligned} \mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k} - \mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}))^4 &= \mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}^4) + O((v_{j,k}^*)^4) \mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}^3) + O((v_{j,k}^*)^{12}). \end{aligned}$$

Вычисление моментов $\mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}^3)$ и $\mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}^4)$ проводится по той же схеме, что и вычисление среднего и дисперсии в лемме 2. Именно, использование соотношений (48) и (52) приводит к выражениям

$$\begin{aligned} \mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}^3) &= \Psi_k^{-1}(h) \mathbf{E}_{\mathbf{P}_0}(e^{h\lambda_{\pi,k}} \lambda_{\pi,k}^3) = O((v_{j,k}^*)^6), \\ \mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}^4) &= \Psi_k^{-1}(h) \mathbf{E}_{\mathbf{P}_0}(e^{h\lambda_{\pi,k}} \lambda_{\pi,k}^4) = O((v_{j,k}^*)^8). \end{aligned}$$

Поэтому, принимая во внимание (53), мы находим, что

$$\mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k} - \mathbf{E}_{\mathbf{P}_{h,k}}(\lambda_{\pi,k}))^4 \asymp (v_{j,k}^*)^8 \leq \max_{k \in \mathbb{Z}} (v_{j,k}^*)^4 \sum_{k \in \mathbb{Z}} (v_{j,k}^*)^4.$$

Отсюда, из леммы 2 и формулы (43) получаем требуемый результат:

$$\begin{aligned}
 L_h^{(4)} &= \frac{\sum_{k \in \mathbb{Z}} \mathbf{E}_{\mathbf{P}_{h,k}} (\lambda_{\pi,k} - \mathbf{E}_{\mathbf{P}_{h,k}} (\lambda_{\pi,k}))^4}{\left(\sum_{k \in \mathbb{Z}} \mathbf{Var}_{\mathbf{P}_{h,k}} (\lambda_{\pi,k})\right)^2} \asymp \frac{\sum_{k \in \mathbb{Z}} (v_{j,k}^*)^8}{\left(\sum_{k \in \mathbb{Z}} (v_{j,k}^*)^4\right)^2} \\
 &\leq \frac{\max_{k \in \mathbb{Z}} (v_{j,k}^*)^4}{\sum_{k \in \mathbb{Z}} (v_{j,k}^*)^4} = \frac{o(1)}{u_\varepsilon^2(r_\varepsilon)} = \frac{o(1)}{O(\log d)} = o(\log^{-1} d).
 \end{aligned}$$

Лемма 3 доказана. □

ЛИТЕРАТУРА

1. C. Butucea, Yu. I. Ingster, *Detection of a sparse submatrix of a high-dimensional noisy matrix*. — <http://arxiv.org/abs/1109.0898> (2012).
2. L. Comminges, A. S. Dalalyan, *Tight conditions for consistency of variable selection in the context of high dimensionality*. — <http://arxiv.org/abs/1106.4293> (2012).
3. M. De Groot, *Optimal Statistical Decisions*. McGraw-Hill Book Company, New York, 1970.
4. М. С. Ермаков, *Минимаксное обнаружение сигнала в гауссовском белом шуме*. — Теория вероятн. и ее примен. **35**, No. 4 (1991), 667–679.
5. G. Gayraud, Yu. I. Ingster, *Detection of sparse variable functions*. — <http://arxiv.org/abs/1011.6369> (2012).
6. C. R. Genovese, J. Jin, L. Wasserman, *Revisiting marginal regression*. — <http://arxiv.org/abs/0911.4080> (2009).
7. J. Huang, J. L. Howoritz, F. Wei, *Variable selection in nonparametric additive models*. — Ann. Statist. **38** (2010), 2282–2313.
8. I. A. Ibragimov, R. Z. Khasminskii, *Some estimation problems on infinite dimensional Gaussian white noise*. — In: Festschrift for Lucien Le Cam. Research Papers in Probability and Statistics. Springer-Verlag, New York (1997), pp. 275–296.
9. Yu. I. Ingster, *Asymptotically minimax hypothesis testing for nonparametric alternatives. I*. — Math. Methods Statist. **2**, No. 2 (1993), 85–114.
10. Yu. I. Ingster, *Asymptotically minimax hypothesis testing for nonparametric alternatives. II*. — Math. Methods Statist. **2**, No. 3 (1993), 171–189.
11. Yu. I. Ingster, *Asymptotically minimax hypothesis testing for nonparametric alternatives. III*. — Math. Methods Statist. **2**, No. 4 (1993), 249–268.
12. Yu. I. Ingster, I. A. Suslina, *Nonparametric Goodness-of-Fit Testing Under Gaussian Models*. Lect. Notes Statist., **169**, Springer-Verlag, New York, 2003.
13. Yu. I. Ingster, I. A. Suslina, *On estimation and detection of smooth function of many variables*. — Math. Methods Statist. **14** (2005), 299–331.
14. Y. LIN, *Tensor product space ANOVA models*. — Ann. Statist. **28** (2000), 734–755.
15. G. Raskutti, M. J. Wainwright, B. Yu, *Minimax-optimal rates for sparse additive models over kernel classes via convex programming*. — <http://arxiv.org/abs/1008.3654> (2011).
16. A. V. Skorohod, *Integration in Hilbert Spaces*, Springer-Verlag, Berlin–New York, 1974.

17. V. G. Spokoiny, *Adaptive hypothesis testing using wavelets*. — Ann. Statist. **24**, No. 6 (1996), 2477–2498.
18. C. J. Stone, *Additive regression and other nonparametric models*. — Ann. Statist. **13**, No. 2 (1985), 689–705.

IngsterYu.I., Stepanova N. A. Adaptive variable selection in nonparametric sparse regression.

We study the problem of exact recovery of an unknown multivariate function f observed in the continuous regression model. It is assumed that, in addition to some smoothness constraints, f possesses an additive sparse structure determined by the sparsity index $\beta \in (0, 1)$. As a consequence of the additive sparsity assumption, the recovery problem transforms to a variable selection problem. Conditions for exact variable selection are provided, and a family of asymptotically minimax variable selection procedures is constructed. The procedures are adaptive in the sparsity index β .

С.-Петербургский Государственный
Электротехнический Университет,
ул. Профессора Попова 5,
Санкт-Петербург 197376, Россия

Поступило 15 октября 2012 г.

Карлтон Университет,
Колонел Бай Драйв 1125,
Оттава, Онтарио K1S 5B6, Канада
E-mail: `nstep@math.carleton.ca`