

Голубев Г. К., Крымова Е. А.

ОЦЕНИВАНИЕ УРОВНЯ ШУМА В ЛИНЕЙНЫХ МОДЕЛЯХ БОЛЬШОЙ РАЗМЕРНОСТИ ¹

Рассматривается задача оценивания уровня шума σ^2 в гауссовской линейной модели $Y = X\beta + \sigma\xi$, где $\xi \in \mathbb{R}^n$ – стандартный дискретный белый гауссовский шум, а $\beta \in \mathbb{R}^p$ – неизвестный мешающий вектор. Предполагается, что X – известная, плохо обусловленная $n \times p$ -матрица с $n \geq p$. При этом размерность p является большой. В этой ситуации вектор β оценивается с помощью спектральной регуляризации оценки максимального правдоподобия и оценка уровня шума вычисляется с помощью адаптивного, т.е. основанного на наблюдаемых данных, нормирования квадратичной ошибки предсказания. Для этой оценки вычисляется скорость ее концентрации вблизи псевдо-оценки $\|\sigma\xi\|^2/n$.

1 Введение и основной результат

В настоящей работе рассматривается задача оценивания уровня шума $\sigma^2 \in \mathbb{R}^+$ по наблюдениям

$$Y = X\beta + \sigma\xi, \quad (1)$$

где X – известная $n \times p$ -матрица с $n \geq p$, $\beta \in \mathbb{R}^p$ – неизвестный мешающий вектор, а $\xi \in \mathbb{R}^n$ – стандартный дискретный белый гауссовский шум, т.е. вектор, компоненты которого являются независимыми гауссовскими случайными величинами с нулевым средним и единичной дисперсией.

Стандартный подход к оцениванию σ^2 основан на методе максимального правдоподобия, который дает следующую оценку:

$$\hat{\sigma}^2(Y) = \arg \max_{\sigma^2 > 0} \max_{\beta \in \mathbb{R}^p} \left\{ -\frac{\|Y - X\beta\|^2}{2\sigma^2} - \frac{n}{2} \log(\sigma^2) \right\} = \frac{\|Y - X(X^\top X)^{-1}X^\top Y\|^2}{n}.$$

Статистические свойства этой оценки хорошо известны и могут быть легко установлены с помощью метода главных компонент. Пусть $\mathbf{e}_k \in \mathbb{R}^p$, $k = 1, \dots, p$ и $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$ – собственные векторы и собственные числа матрицы $X^\top X$, т.е.

$$X^\top X \mathbf{e}_k = \lambda_k \mathbf{e}_k, \quad k = 1, \dots, p.$$

¹Исследование выполнено при частичной финансовой поддержке РФФИ в рамках проекта 15-07-09121 и Deutsche Forschungsgemeinschaft (проект SFB 823, Statistical modelling of nonlinear dynamic processes).

Определим следующие векторы в $\mathbb{R}^n$:

$$\mathbf{e}_k^* = \frac{X\mathbf{e}_k}{\sqrt{\lambda_k}}.$$

Нетрудно проверить, что $\mathbf{e}_k^*$, $k = 1, \dots, p$, являются ортонормальными векторами в $\mathbb{R}^n$. Дополним эту систему векторов какими-нибудь другими ортонормальными векторами $\mathbf{e}_k^*$, $k = p+1, \dots, n$ до полной ортонормальной системы.

Тогда для линейных статистик $\bar{Y}_k = \langle Y, \mathbf{e}_k^* \rangle$ получим следующее представление:

$$\begin{aligned} \bar{Y}_k &= \sqrt{\lambda_k} \bar{\beta}_k + \sigma \xi'_k, & k = 1, \dots, p, \\ \bar{Y}_k &= \sigma \xi'_k, & k = p+1, \dots, n, \end{aligned} \quad (2)$$

где $\bar{\beta}_k = \langle \beta, \mathbf{e}_k \rangle$, а ξ' — стандартный белый гауссовский шум. Поскольку $\{\mathbf{e}_k^*, k = 1, \dots, n\}$ — полная система векторов в $\mathbb{R}^n$, то очевидно, что статистические модели (1) и (2) являются математически эквивалентными. Заметим однако, что эта эквивалентность уже не бесспорна с вычислительной точки зрения. Дело в том, что для того, чтобы формально перейти от (1) к (2) нужно вычислить спектральное разложение $X^\top X$. Это может быть в принципе достаточно дорогостоящая операция при больших p и плохой обусловленности $X^\top X$. Как мы увидим далее, вычисление спектрального разложения часто не является необходимым. Поэтому в этой статье мы будем использовать представление (2) в основном для доказательств математических результатов, а строить оценки, используя наблюдения (1).

В силу эквивалентности (1) и (2) легко проверить, что

$$\hat{\sigma}^2(Y) = \frac{1}{n} \sum_{k=p+1}^n \bar{Y}_k^2 = \frac{\sigma^2}{n} \sum_{k=p+1}^n \xi_k'^2.$$

и мы видим, что, во-первых, оценка максимального правдоподобия $\hat{\sigma}^2(Y)$ является смещенной. Поэтому, как правило, в статистике используется ее несмещенная модификация

$$\tilde{\sigma}^2(Y) = \frac{\|Y - X(X^\top X)^{-1}X^\top Y\|^2}{n-p} = \frac{1}{n-p} \sum_{k=p+1}^n \bar{Y}_k^2.$$

Во-вторых, ни $\hat{\sigma}^2(Y)$, ни $\tilde{\sigma}^2(Y)$ не используют данные $\bar{Y}_k$, $k = 1, \dots, p$. В задачах классической статистики $p \ll n$ и это не приводит к существенным потерям качества оценивания. В то же время существует достаточно широкий класс статистических задач, в которых $p \approx n$ и при этом собственные числа λ_k достаточно быстро убывают. В этих задачах мы, естественно, уже не сможем хорошо оценивать σ^2 если не будем использовать $\bar{Y}_k$, $k = 1, \dots, p$.

Классическим примером такой задачи является оценивание σ^2 в нелинейной регрессионной модели

$$Y_i = f(X_i) + \sigma \xi_i, \quad i = 1, \dots, n, \quad (3)$$

где ξ – стандартный белый шум, $X_i \in [0, 1]$ – известные регрессоры, а $f(x), x \in [0, 1]$ – неизвестная мешающая гладкая функция, принадлежащая, например, классу Соболева

$$\mathcal{W}_2^m = \left\{ f : \int_0^1 [f^{(m)}(x)]^2 \leq L \right\};$$

здесь $f^{(m)}(x)$ – производная порядка m функции $f(x)$. Более подробно эта модель будет рассмотрена в параграфе 2.

Другим хорошо известным примером являются обратные задачи, возникающие при дискретизации интегральных уравнений Фредгольма первого рода [1].

Когда размерность p велика, а собственные числа λ_k достаточно быстро убывают очевидно, что наблюдения $\tilde{Y}_k, k = 1, \dots, p$, (см. (2)) могут содержать существенную статистическую информацию о σ^2 . Ясно, что эту информацию можно извлечь, но при этом понятно также, что сделать это каким-то простым способом невозможно, поскольку эти наблюдения содержат неизвестные “мешающие” величины $\sqrt{\lambda_k} \beta_k$.

Понятно также, что для того, чтобы построить достаточно хорошие оценки σ^2 , надо вычесть из наблюдений Y некоторую оценку вектора $X\beta$, а для этого нужно, естественно, оценивать β . Как мы видели раньше, стандартную оценку максимального правдоподобия применять не имеет смысла. Поэтому далее в статье мы будем пользоваться спектральными регуляризациями этой оценки, которые вычисляются следующим образом:

$$\hat{\beta}_\alpha(Y) = H_\alpha(X^\top X) [(X^\top X)^{-1} X^\top Y]; \quad (4)$$

здесь

- $(X^\top X)^{-1} X^\top Y$ – классическая оценка максимального правдоподобия неизвестного вектора β ;
- $H_\alpha(\lambda)$ – заданная функция $\mathbb{R}^+ \rightarrow [0, 1]$, индексированная параметром регуляризации $\alpha \in \mathbb{R}^+$.

Матрица $H_\alpha(X^\top X)$, которая сглаживает в спектральной области оценку максимального правдоподобия, формально определяется через спектральное разложение $X^\top X$ следующим образом:

$$H_\alpha(X^\top X) = \sum_{k=1}^p H_\alpha(\lambda_k) \mathbf{e}_k \mathbf{e}_k^\top.$$

Как правило, функции $H_\alpha(\cdot)$, используемые для регуляризации оценки максимального правдоподобия, обладают следующими естественными свойствами:

$$\begin{aligned} 0 &\leq H_\alpha(\lambda) \leq 1, \quad \text{при всех } \lambda \geq 0, \alpha \geq 0; \\ \lim_{\alpha \rightarrow 0} H_\alpha(\lambda) &= 1, \quad \text{при любом } \lambda > 0; \\ \lim_{\lambda \rightarrow 0} H_\alpha(\lambda) &= 0, \quad \text{при любом } \alpha > 0. \end{aligned}$$

Кроме того, семейство функций $\{H_\alpha(\cdot), \alpha \in \mathbb{R}^+\}$ часто является упорядоченным, т.е. таким, что для любых $\alpha, \alpha' \in \mathbb{R}^+$:

либо

$$H_\alpha(\lambda) \leq H_{\alpha'}(\lambda) \quad \text{при всех } \lambda \in \mathbb{R}^+,$$

либо

$$H_{\alpha'}(\lambda) \leq H_\alpha(\lambda) \quad \text{при всех } \lambda \in \mathbb{R}^+.$$

На исключительную полезность этого свойства при адаптивном (основанном на наблюдениях) выборе параметра регуляризации α , по-видимому, впервые обратил внимание А. Кнайп [2].

На первый взгляд может показаться, что для вычисления $\hat{\beta}_\alpha(Y)$ нужно вычислять спектральное разложение $X^\top X$. Однако это не всегда так и на самом деле все зависит от того, каковы функции $H_\alpha(\lambda)$. Рассмотрим, например, метод регуляризации Тихонова

$$\hat{\beta}_\alpha^\top(Y) = \arg \min_{\beta} \left\{ \|Y - X\beta\|^2 + \alpha \|\beta\|^2 \right\} = (\alpha I + X^\top X)^{-1} X^\top Y.$$

Заметим, что

- $\hat{\beta}_\alpha^\top(Y)$ является решением линейного уравнения

$$(\alpha I + X^\top X) \hat{\beta}_\alpha^\top(Y) = X^\top Y;$$

- $\hat{\beta}_\alpha^\top(Y)$ допускает следующее представление:

$$\begin{aligned} \hat{\beta}_\alpha^\top(Y) &= (\alpha I + X^\top X)^{-1} (X^\top X) (X^\top X)^{-1} X^\top Y \\ &= H_\alpha^\top(X^\top X) [(X^\top X)^{-1} X^\top Y], \end{aligned}$$

где

$$H_\alpha^\top(\lambda) = \frac{\lambda}{\alpha + \lambda}.$$

Таким образом, регуляризация Тихонова, с одной стороны, вычисляется как решение системы линейных уравнений, а с другой стороны, представляет собой семейство упорядоченных спектральных регуляризаций. Примеры других спектральных регуляризаций, которые вычисляются рекуррентно, можно найти, например, в [3].

Отметим однако, что если в качестве $H_\alpha(\lambda)$ используется, например, $H_\alpha(\lambda) = \mathbf{1}\{\lambda \geq \alpha\}$, то для того, чтобы построить соответствующие оценки из (4), необходимо уже вычислять спектральное разложение $X^\top X$.

Далее, не оговаривая этого особо, будем предполагать, что для оценивания β используется семейство оценок $\{\hat{\beta}_\alpha(Y), \alpha \in \mathbb{R}^+\}$ из (4) с упорядоченным семейством функций регуляризации $\{H_\alpha(\cdot), \alpha \in \mathbb{R}^+\}$. Соответствующая $\hat{\beta}_\alpha(Y)$ оценка σ^2 вычисляется как

$$\hat{\sigma}_\alpha^2(Y) = \frac{\|Y - X\hat{\beta}_\alpha(Y)\|^2}{n} \left[1 - \frac{2\text{tr}\{H_\alpha(X^\top X)\} - \text{tr}\{[H_\alpha(X^\top X)]^2\}}{n} \right]^{-1}. \quad (5)$$

Таким образом, мы имеем семейство оценок дисперсии $\{\hat{\sigma}_\alpha^2(Y), \alpha \in \mathbb{R}^+\}$ и, в принципе, задача состоит в том, чтобы выбрать в этом семействе наилучшую оценку на основе имеющихся наблюдений Y .

Для этого прежде всего нужно определить, что понимается под наилучшей оценкой. Представим себе идеальную ситуацию, когда $\beta = 0$. В этом случае мы наблюдаем чистый белый шум

$$Y_i = \sigma \xi_i, \quad i = 1, \dots, n$$

и поэтому оценить σ^2 в этом случае можно легко с помощью

$$\hat{\sigma}_\circ^2(\xi) \stackrel{\text{def}}{=} \frac{\|\sigma \xi\|^2}{n} = \sigma^2 + \frac{\sigma^2}{n} \sum_{i=1}^n (\xi_i^2 - 1).$$

Понятно, что ничего принципиально лучшего, чем эта псевдо-оценка не существует. Поэтому мы будем измерять качество оценки $\tilde{\sigma}^2(Y)$ величиной ее отклонения от $\hat{\sigma}_\circ^2(\xi)$, а именно, величиной

$$\Delta(\tilde{\sigma}^2) = n |\tilde{\sigma}^2(Y) - \hat{\sigma}_\circ^2(\xi)|.$$

Очевидно, что чем меньше эта величина, тем лучше мы оцениваем уровень шума с помощью $\tilde{\sigma}^2(Y)$. Поэтому основная задача в этой работе – минимизация $\Delta(\hat{\sigma}_\alpha^2)$ по α на основе имеющихся наблюдений. При этом будем предполагать, что параметр регуляризации α принадлежит отрезку $\mathcal{A} = [\alpha_{\min}, \alpha_{\max}]$, а величина $\alpha_{\min} = \alpha_{\min}(n) > 0$ зависит от n и стремится к 0 при $n \rightarrow \infty$.

Обозначим для краткости

$$G_\alpha(\lambda) = 2H_\alpha(\lambda) - [H_\alpha(\lambda)]^2 \quad \text{и} \quad q_\alpha(n) = \left[1 - \frac{1}{n} \sum_{i=1}^p G_\alpha(\lambda_i)\right]^{-1} - 1.$$

Для простоты предположим, что

$$\frac{1}{n} \sum_{i=1}^p G_\alpha(\lambda_i) \ll 1. \tag{6}$$

Ясно, что без ограничения общности можно считать (см. (2)), что $\lambda_k = 0$ и $\bar{\beta}_k = 0$ при $k = p+1, \dots, n$. Тогда из (2) и (5) находим

$$\begin{aligned} \hat{\sigma}_\alpha^2(Y) &= \frac{1 + q_\alpha(n)}{n} \sum_{i=1}^n [1 - H_\alpha(\lambda_i)]^2 \bar{Y}_i^2 \\ &= \frac{1 + q_\alpha(n)}{n} \sum_{i=1}^n [1 - H_\alpha(\lambda_i)]^2 \lambda_i \bar{\beta}_i^2 + \frac{\sigma^2 [1 + q_\alpha(n)]}{n} \sum_{i=1}^n [1 - G_\alpha(\lambda_i)] \xi_i'^2 \\ &\quad + \frac{2\sigma [1 + q_\alpha(n)]}{n} \sum_{i=1}^n [1 - H_\alpha(\lambda_i)]^2 \xi_i' \sqrt{\lambda_i} \bar{\beta}_i. \end{aligned} \tag{7}$$

Воспользуемся также следующим простым тождеством:

$$\begin{aligned} \sigma^2[1 + q_\alpha(n)] \sum_{i=1}^n [1 - G_\alpha(\lambda_i)] \xi_i'^2 &= \sigma^2 \sum_{k=1}^n \xi_k'^2 \\ &- \sigma^2[1 + q_\alpha(n)] \sum_{k=1}^n G_\alpha(\lambda_k) (\xi_k'^2 - 1) + \sigma^2 q_\alpha(n) \sum_{k=1}^n (\xi_k'^2 - 1). \end{aligned} \quad (8)$$

Тогда с помощью (7) и (8) приходим к

$$\begin{aligned} \Delta(\hat{\sigma}_\alpha^2) &= \left| [1 + q_\alpha(n)] \sum_{i=1}^n [1 - H_\alpha(\lambda_i)]^2 \lambda_i \bar{\beta}_i^2 + \sigma^2 [1 + q_\alpha(n)] \sum_{k=1}^n G_\alpha(\lambda_k) (1 - \xi_k'^2) \right. \\ &\quad \left. + \sigma^2 q_\alpha(n) \sum_{i=1}^n (\xi_i'^2 - 1) + 2\sigma [1 + q_\alpha(n)] \sum_{i=1}^n [1 - H_\alpha(\lambda_i)]^2 \xi_i' \sqrt{\lambda_i \bar{\beta}_i} \right|. \end{aligned} \quad (9)$$

Заметим, что второе слагаемое в правой части этого соотношения имеет порядок $\sqrt{\sum_{i=1}^n G_\alpha^2(\lambda_i)}$, а третье (см. (6)) $n^{-1/2} \sum_{i=1}^n G_\alpha(\lambda_i)$. Поэтому третьим слагаемым можно пренебречь если в наряду с (6) выполняется также

Условие А. При всех $\alpha \in \mathbb{R}^+$

$$\sum_{i=1}^n G_\alpha(\lambda_i) \leq K \sum_{i=1}^n G_\alpha^2(\lambda_i),$$

где K – некоторая постоянная.

Как мы увидим далее последнее слагаемое в правой части (9) мало по сравнению с первым и поэтому из (9) получаем следующую аппроксимацию:

$$\Delta(\hat{\sigma}_\alpha^2) \approx [1 + q_\alpha(n)] \left| \sum_{i=1}^n [1 - H_\alpha(\lambda_i)]^2 \lambda_i \bar{\beta}_i^2 + \sigma^2 \sum_{k=1}^n G_\alpha(\lambda_k) (1 - \xi_k'^2) \right|. \quad (10)$$

Напомним, что наша цель – выбрать параметр регуляризации α так, чтобы величина $\mathbf{E}\Delta(\hat{\sigma}_\alpha^2)$ была бы минимальной. Для этого нужно на основе имеющихся наблюдений каким-то образом контролировать слагаемые в правой части (10).

Рассмотрим сначала второе слагаемое, а именно, случайный процесс

$$\zeta(\alpha) = \sum_{k=1}^n G_\alpha(\lambda_k) (1 - \xi_k'^2), \quad \alpha \in \mathbb{R}^+.$$

Нам этот процесс очевидно не известен поскольку у нас нет доступа к шумам ξ_k' , $k = 1, \dots, n$. Единственное, что можно сделать в этой ситуации – это построить детерминированную верхнюю границу для модуля этого процесса, т.е. найти в некотором смысле минимальную функцию $V(\alpha) : (0, \alpha_{\max}] \rightarrow \mathbb{R}^+$ такую, что

$$\mathbf{E} \sup_{\alpha \leq \alpha_{\max}} [|\zeta(\alpha)| - V(\alpha)]_+ \leq C \sqrt{\mathbf{E}\zeta^2(\alpha_{\max})},$$

где здесь и далее $[x]_+ = \max\{0, x\}$, а C обозначает постоянные величины, значения которых могут меняться, но не зависят от параметров рассматриваемой задачи. Поиск такой функции – нетривиальная задача, приближенное решение которой дает следующая теорема.

Т е о р е м а 1. Пусть

$$D(\alpha) = \sum_{k=1}^n G_\alpha^2(\lambda_k)$$

и

$$V_\epsilon(\alpha) = (1 + \epsilon)\sqrt{2D(\alpha)} \left\{ \log \frac{D(\alpha)}{D(\alpha_{\max})} + 2(1 + \epsilon) \log \left[\frac{Q}{\epsilon^2} \log \frac{D(\alpha)}{D(\alpha_{\max})} \right] \right\}^{1/2}, \quad (11)$$

где

$$Q = \frac{4}{(\sqrt{2} - 1)^2}. \quad (12)$$

Тогда для любого $\epsilon \in (0, 1]$

$$\mathbf{E} \sup_{\alpha \leq \alpha_{\max}} [|\zeta(\alpha)| - V_\epsilon(\alpha)]_+ \leq C\epsilon^{-1}\sqrt{D(\alpha_{\max})}. \quad (13)$$

Доказательство этого результата приведено в приложении. Оно по-сути основано на методе, который хорошо известен и используется при доказательстве закона повторного логарифма [4].

Замечание. Функция $V_\epsilon(\alpha)$ из (11) не является минимальной детерминированной огибающей для $|\zeta(\alpha)|$. По-видимому, таковой является функция

$$\tilde{V}_\epsilon(\alpha) = \sqrt{2D(\alpha)} \left\{ \log \frac{D(\alpha)}{D(\alpha_{\max})} + 2(1 + \epsilon) \left[\log \log \frac{D(\alpha)}{D(\alpha_{\max})} + \log \frac{1}{\epsilon} \right] \right\}^{1/2},$$

которая наряду с $V_\epsilon(\alpha)$ обеспечивает выполнение неравенства

$$\mathbf{E} \sup_{\alpha \leq \alpha_{\max}} [|\zeta(\alpha)| - \tilde{V}_\epsilon(\alpha)]_+ \leq C\epsilon^{-1}\sqrt{D(\alpha_{\max})}$$

для любого $\epsilon \in (0, 1]$. К сожалению, строгого доказательства этой гипотезы у нас нет.

Объединяя (13) и (10), приходим к следующему неравенству:

$$\mathbf{E} \Delta(\hat{\sigma}_{\tilde{\alpha}}^2) \lesssim \mathbf{E}[1 + q_{\tilde{\alpha}}(n)] \left\{ \sum_{i=1}^n [1 - H_{\tilde{\alpha}}(\lambda_i)]^2 \lambda_i \bar{\beta}_i^2 + \sigma^2 V_\epsilon(\tilde{\alpha}) \right\} + C\sigma^2 \frac{\sqrt{D(\alpha_{\max})}}{\epsilon}, \quad (14)$$

которое справедливо для любого, зависящего от наблюдений, параметра регуляризации $\tilde{\alpha} \leq \alpha_{\max}$.

Очевидно, что мы хотели бы выбрать $\tilde{\alpha}$ так, чтобы правая часть в (14) была бы как можно меньше. Это идея приводит к выбору

$$\tilde{\alpha}(\beta) = \arg \min_{\alpha \in \mathcal{A}} [1 + q_\alpha(n)] \left\{ \sum_{i=1}^n [1 - H_\alpha(\lambda_i)]^2 \lambda_i \bar{\beta}_i^2 + \sigma^2 V_\epsilon(\alpha) \right\}. \quad (15)$$

Очевидно, что этот параметр регуляризации нельзя использовать так как он зависит от неизвестного вектора β . Поэтому наш следующий шаг состоит в том, чтобы оценить правую часть в (15) по наблюдениям и тем самым построить оценку для $\alpha(\beta)$. Это можно сделать относительно просто, заменив $\lambda_i \bar{\beta}_i^2$ на $\bar{Y}_i^2 - \sigma^2$ (см. (2)). Таким образом, мы получаем следующую оценку для $\alpha(\beta)$:

$$\begin{aligned} \tilde{\alpha}(Y) = \arg \min_{\alpha \in \mathcal{A}} \left\{ [1 + q_\alpha(n)] \left\{ \sum_{i=1}^n [1 - H_\alpha(\lambda_i)]^2 \bar{Y}_i^2 + \sigma^2 V_\epsilon(\alpha) \right\} \right. \\ \left. + \sigma^2 [1 + q_\alpha(n)] \sum_{i=1}^n G_\alpha(\lambda_i) - \sigma^2 n q_\alpha(n) \right\}. \end{aligned} \quad (16)$$

Эта оценка, как видно, зависит от уровня шума, который мы и хотим оценить. Поэтому вместо σ^2 подставим в правую часть (16) ее простую оценку

$$\frac{\|Y - X\hat{\beta}_\alpha(Y)\|^2}{n} = \frac{1}{n} \sum_{i=1}^n [1 - H_\alpha(\lambda_i)]^2 \bar{Y}_i^2 = \frac{\hat{\sigma}_\alpha^2(Y)}{1 + q_\alpha(n)}.$$

Заметим также, что при выполнении (6)

$$q_\alpha(n) \approx \frac{1}{n} \sum_{i=1}^n G_\alpha(\lambda_i).$$

Таким образом, (16) приводит к следующему методу выбора параметра регуляризации:

$$\hat{\alpha}(Y) = \arg \min_{\alpha \in \mathcal{A}} \left\{ \hat{\sigma}_\alpha^2(Y) \left[1 + \frac{V_\epsilon(\alpha)}{n} \right] \right\}. \quad (17)$$

Чтобы описать статистические свойства оценки $\hat{\sigma}_\alpha^2(Y)$, нам потребуются следующие дополнительные обозначения:

$$\begin{aligned} R_\epsilon(\alpha, \beta) &\stackrel{\text{def}}{=} \left[1 + \frac{V_\epsilon(\alpha)}{n} \right] \left\{ [1 + q_\alpha(n)] \sum_{i=1}^n [1 - H_\alpha(\lambda_i)]^2 \lambda_i \bar{\beta}_i^2 + \sigma^2 V_\epsilon(\alpha) \right\}, \\ r_{\mathcal{A}, \epsilon}(\beta) &\stackrel{\text{def}}{=} \min_{\alpha \in \mathcal{A}} R_\epsilon(\alpha, \beta), \\ \rho_{\mathcal{A}, \epsilon}(\beta) &\stackrel{\text{def}}{=} \frac{\sigma^2 \sqrt{D(\alpha_{\max})}}{r_{\mathcal{A}, \epsilon}(\beta)}. \end{aligned} \quad (18)$$

Т е о р е м а 2. Пусть выполняется условие A и $\alpha_{\min}, \alpha_{\max}$ таковы, что

$$\lim_{n \rightarrow \infty} \frac{D(\alpha_{\min})}{n} = 0, \quad D(\alpha_{\max}) \geq 5. \quad (19)$$

Тогда для любого $\gamma \in (0, \epsilon/(1 + \epsilon))$, при всех $n \geq n_\gamma$

$$\mathbf{E} \Delta(\hat{\sigma}_\alpha^2) \leq \frac{r_{\mathcal{A}, \epsilon}(\beta)}{\gamma} \left\{ 1 + \frac{1}{\sqrt[4]{D(\alpha_{\max})}} \log^{-1/8}[\rho_{\mathcal{A}, \epsilon}(\beta)] + \left[\frac{C}{(\epsilon - \gamma - \gamma\epsilon)\rho_{\mathcal{A}, \epsilon}(\beta)} \right]^{1/2} \right\}^2. \quad (20)$$

Замечания.

1. Хорошо известно и легко проверить, что при $n \rightarrow \infty$

$$\sqrt{n}[\sigma^2 - \hat{\sigma}_\alpha^2(\xi)] \xrightarrow{D} \sqrt{2}\sigma^2\xi,$$

где ξ – стандартная гауссовская случайная величина. Поэтому неравенство (20) фактически описывает члены второго порядка в разложении $\hat{\sigma}_\alpha^2(Y)$ по степеням $n^{-1/2}$. При этом выбор оптимального параметра регуляризации происходит с помощью минимизации этих членов. Отметим, что это типичная ситуация для задач семи-параметрического оценивания, см., например, [5, 6]. Подчеркнем также, что в отличие от этих статей, минимизация членов второго порядка в настоящей работе основана на имеющихся наблюдениях.

Наиболее близкой по математическим методам к настоящей работе является статья [7], хотя в ней рассматривается на первый совершенно другая статистическая задача оценивания квадратичного функционала.

Отметим еще, что в современной статистике теория оптимальности первого порядка семи-параметрических оценок хорошо разработана [8]. В ней оптимальными оценками считаются все такие $\tilde{\sigma}^2(Y)$, что

$$\sqrt{n}[\tilde{\sigma}^2(Y) - \sigma^2] \xrightarrow{D} \sqrt{2}\sigma^2\xi, \quad n \rightarrow \infty.$$

К сожалению, класс подобного рода оценок оказывается очень широким и в нем невозможно определить наилучшую оценку или, что эквивалентно, сказать какой параметр регуляризации α будет наилучшим.

2. На первый взгляд кажется, что оптимальную оценку для σ^2 можно получить если использовать наилучшую оценку для $X\beta$. На самом деле, как показывает теорема 2, это не так. Хорошо известно (см., например, [2]), что наилучший параметр регуляризации α при оценивании $X\beta$ минимизирует

$$\sum_{k=1}^n [1 - H_\alpha(\lambda_k)]^2 \lambda_k \bar{\beta}_k^2 + \sigma^2 \sum_{k=1}^n H_\alpha^2(\lambda_k),$$

в то время как при оценивании σ^2 оптимальное α минимизирует

$$\sum_{k=1}^n [1 - H_\alpha(\lambda_k)]^2 \lambda_k \bar{\beta}_k^2 + \sigma^2 V_\epsilon(\alpha).$$

Подчеркнем, что при малых α (см. (11)) $V_\epsilon(\alpha) \ll \sum_{k=1}^n H_\alpha^2(\lambda_k)$.

3. Условие $\lim_{n \rightarrow \infty} D(\alpha_{\min})/n = 0$ является, по-видимому, техническим. На практике можно использовать $\alpha_{\min} = 0$. К сожалению, математического доказательства этого предположения у нас нет.
4. Величина $\rho_{A,\epsilon}(\beta)$, как правило, мала (см. параграф 2). Поэтому, выражение в круглых скобках в правой части (20) будет в этом случае близко к 1.

2 Оценивание уровня шума в нелинейной регрессии

В этом параграфе мы применим теорему 2 к задаче минимаксного адаптивного оценивания σ^2 в нелинейной модели регрессии (3), предполагая, что число наблюдений n велико. Термин “минимаксный” означает, что нас будет интересовать величина

$$\bar{\Delta}(\tilde{\sigma}^2, \mathcal{W}_2^m) = \max_{f \in \mathcal{W}_2^m} n \mathbf{E} |\tilde{\sigma}^2(Y) - n^{-1} \sigma^2 \|\xi\|^2|,$$

где $\tilde{\sigma}^2(Y)$ – некоторая оценка σ^2 , построенная по наблюдениям (3).

Для того чтобы оценить неизвестную функцию $f(x)$, $x \in [0, 1]$, будем использовать семейство сглаживающих сплайнов

$$\hat{f}_\alpha(\cdot, Y) = \arg \min_f \left\{ \frac{1}{n} \sum_{i=1}^n [Y_i - f(X_i)]^2 + \alpha \int_0^1 [f^{(m)}(x)]^2 dx \right\}. \quad (21)$$

Поскольку этот метод является стандартным в непараметрической статистике, мы опустим его мотивацию и вычислительные аспекты, которые представлены, например, в [9].

Хорошо известно, что получить простую эквивалентную статистическую модель рассматриваемой задачи можно с помощью базиса Деммлера-Райнша [10]. Базисные функции $\phi_k(x)$, $k = 1, \dots, n$, этого базиса обладают очень полезным свойством двойной ортогональности

$$\frac{1}{n} \sum_{i=1}^n \phi_k(X_i) \phi_s(X_i) = \delta_{sk}, \quad \int_0^1 \phi_k^{(m)}(x) \phi_s^{(m)}(x) dx = \nu_k^n \delta_{ks},$$

где $\nu_1^n \leq \nu_2^n \leq \dots \leq \nu_n^n$ – собственные числа базиса, которые зависят, естественно, от регрессоров $X_1, \dots, X_n$. Чтобы упростить изложение, мы ограничимся асимптотическими равномерно распределенными регрессорами, т.е. такими, что

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \mathbf{1}\{X_i \leq x\} = x, \quad x \in [0, 1].$$

Известно (см, например, [11]), что в этом случае и при $n, k \rightarrow \infty$

$$\nu_k^n = (1 + o(1))(\pi k)^{2m}. \quad (22)$$

Легко проверить, что для эмпирических коэффициентов Фурье

$$\bar{Y}_k = \frac{1}{n} \sum_{i=1}^n Y_i \phi_k(X_i)$$

справедливо представление

$$\bar{Y}_k = \bar{f}_k + \frac{\sigma}{\sqrt{n}} \xi'_k, \quad k = 1, \dots, n, \quad (23)$$

где ξ' – стандартный белый гауссовский шум, а

$$\bar{f}_k = \frac{1}{n} \sum_{i=1}^n f(X_i) \phi_k(X_i).$$

Заметим, что из свойства двойной ортогональности вытекает, что сглаживающий сплайн из (21) может быть представлен следующим образом:

$$\hat{f}_\alpha(x, Y) = \sum_{k=1}^n h_\alpha(\nu_k^n) \bar{Y}_k \phi_k(x),$$

где

$$h_\alpha(z) = \frac{1}{1 + \alpha z}, \quad z > 0,$$

и что соболевский эллипсоид $\mathcal{W}_2^m$ в терминах коэффициентов Фурье $\bar{f}_k$, $k = 1, \dots, n$, имеет вид

$$\mathcal{W}_2^m = \left\{ \bar{f}_k : \sum_{k=1}^n \nu_k^n \bar{f}_k^2 \leq L \right\}.$$

Поэтому статистическая модель наблюдений (23) будет эквивалентна модели (2) если в последней положить

$$\sigma = \frac{\sigma}{\sqrt{n}}, \quad \lambda_k = \frac{1}{\nu_k^n}, \quad \beta_k = \sqrt{\nu_k^n} \bar{f}_k.$$

Несложно проверить, воспользовавшись (22), что при $\alpha \rightarrow 0$

$$D(\alpha) = (1 + o(1)) \sum_{k=1}^n \left[\frac{2}{1 + \alpha(\pi k)^{2m}} - \frac{1}{[1 + \alpha(\pi k)^{2m}]^2} \right]^2 = (1 + o(1)) \frac{K(m)\alpha^{-1/(2m)}}{\pi},$$

где

$$K(m) = \int_0^\infty \left[\frac{2}{1 + x^{2m}} - \frac{1}{(1 + x^{2m})^2} \right]^2 dx$$

и поэтому

$$V_\epsilon(\alpha) = (1 + \epsilon + o(1))\alpha^{-1/(4m)} \sqrt{\frac{K(m)}{\pi m} \log \frac{\alpha_{\max}}{\alpha}}.$$

Оценка уровня шума, основанная на сглаживающих сплайнах, вычисляется как

$$\hat{\sigma}_{\hat{\alpha}}^2(Y) = \frac{1}{n} \sum_{i=1}^n [Y_i - \hat{f}_{\hat{\alpha}}(X_i, Y)]^2 \left[1 - \frac{W(\hat{\alpha})}{n} \right]^{-1},$$

где

$$\hat{\alpha} = \arg \min_{\alpha \in \mathcal{A}} \left\{ \sum_{i=1}^n [Y_i - \hat{f}_\alpha(X_i, Y)]^2 \left[1 - \frac{W(\alpha)}{n} \right]^{-1} \left[1 + \frac{V_\epsilon(\alpha)}{n} \right] \right\}, \quad (24)$$

а

$$W(\alpha) = \sum_{k=1}^n [2h_\alpha(\nu_k^2) - h_\alpha^2(\nu_k^2)].$$

Для максимального на классе $\mathcal{W}_2^m$ смещения этой оценки получаем следующую границу сверху:

$$\sup_{f \in \mathcal{W}_2^m} \sum_{k=1}^n [1 - h_\alpha(\nu_k^n)]^2 \bar{f}_k^2 = L \max_k \frac{[1 - h_\alpha(\nu_k^n)]^2}{\nu_k^n} = L\alpha \max_k \frac{\alpha \nu_k^n}{1 + \alpha \nu_k^n} \leq L\alpha.$$

Поэтому для любого $f \in \mathcal{W}_2^m$ при $n \rightarrow \infty$ (см. (18))

$$\begin{aligned} r_{\mathcal{A}, \epsilon}(f) &\leq (1 + \epsilon + o(1)) \min_{\alpha} \left\{ L\alpha + \frac{\sigma^2}{n} \alpha^{-1/(4m)} \sqrt{\frac{K(m)}{\pi m} \log \frac{\alpha_{\max}}{\alpha}} \right\} \\ &= (1 + \epsilon + o(1)) \left(1 + \frac{1}{4m} \right) \frac{\sigma^2}{n} \left(\frac{4mnL}{\sigma^2} \right)^{1/(4m+1)} \\ &\quad \times \left[\frac{4K(m)}{\pi(4m+1)} \log \left(\frac{Ln}{\sigma^2} \right) \right]^{2m/(4m+1)} \asymp \frac{\sigma^2}{n} \left(\frac{nL}{\sigma^2} \right)^{1/(4m+1)} \left[\log \left(\frac{Ln}{\sigma^2} \right) \right]^{2m/(4m+1)}. \end{aligned}$$

Отсюда сразу же вытекает (см. (18)), что при $n \rightarrow \infty$

$$\rho_{\mathcal{A}, \epsilon}(f) \asymp \left(\frac{nL}{\sigma^2} \right)^{-1/(4m+1)} \left[\log \left(\frac{Ln}{\sigma^2} \right) \right]^{-2m/(4m+1)} \rightarrow 0.$$

Поэтому для оценки уровня шума из (24) в силу теоремы 2 справедлива следующая асимптотическая (при $n \rightarrow \infty$) верхняя граница:

$$\Delta(\hat{\sigma}_{\tilde{\alpha}}^2, \mathcal{W}_2^m) \stackrel{\text{asympt}}{\leq} \frac{C(m)}{\gamma} \frac{\sigma^2}{n} \left(\frac{nL}{\sigma^2} \right)^{1/(4m+1)} \left[\log \left(\frac{Ln}{\sigma^2} \right) \right]^{2m/(4m+1)}; \quad (25)$$

здесь $\gamma < \epsilon/(1 + \epsilon)$.

Несмотря на то, что рассматриваемая статистическая модель является стандартной в непараметрической статистике и в ее рамках предложено много подходов к оцениванию σ^2 , ничего не известно об оптимальности верхней границы (25). По-видимому, эту границу нельзя улучшить с точностью до множителя $(1 + \epsilon)/\epsilon$, но доказательства этой гипотезы у нас, к сожалению, нет, хотя в качестве ее подтверждения можно сослаться на [13], где близкий факт доказан для задачи оценивания квадратичного функционала.

3 Приложение

3.1 Вспомогательные результаты

Л е м м а 1. Пусть $\xi_k, k = 1, \dots, n$, – независимые $\mathcal{N}(0, 1)$, а $b_k, k = 1, \dots, n$, – детерминированная последовательность. Тогда для любого $\tilde{\alpha} \in \mathbb{R}^+$, зависящего от $\xi_k, k = 1, \dots, n$, справедливо неравенство

$$\mathbf{E} \left| \sum_{k=1}^n [1 - H_{\tilde{\alpha}}(\lambda_k)]^2 b_k \xi_s \right| \leq \left\{ \mathbf{E} \sum_{k=1}^n [1 - H_{\tilde{\alpha}}(\lambda_k)]^4 b_k^2 \right\}^{1/2}.$$

Л е м м а 2. Пусть

$$\zeta(\alpha_1, \alpha_2) = \sup_{\alpha \in [\alpha_1, \alpha_2]} [\zeta(\alpha) - \zeta(\alpha_2)].$$

Тогда для любого $\lambda > 0$

$$\mathbf{E} \exp[\lambda \zeta(\alpha_1, \alpha_2)] \leq C \exp\{Q \lambda^2 [D(\alpha_1) - D(\alpha_2)]\},$$

где постоянная Q определена в (12).

Доказательство этих результатов вытекает из упорядоченности последовательностей $[1 - H_{\alpha}(\lambda_k)]^2, k = 1, \dots, n$ и $G_{\alpha}(\lambda_k), k = 1, \dots, n$, (см., например, леммы 4 и 6 в [12]).

Нам также потребуется также еще один простой факт.

Л е м м а 3. Пусть η – положительная случайная величина с ограниченным средним $m = \mathbf{E}\eta < \infty$, а θ – случайная величина с ограниченным экспоненциальным моментом $\psi(\lambda) = \mathbf{E} \exp(\lambda \theta) < \infty$ для некоторого $\lambda > 0$. Тогда

$$\mathbf{E} \eta \theta \leq m \frac{H + \log[\psi(\lambda)]}{\lambda}, \quad (26)$$

где

$$H = \mathbf{E} \frac{\eta}{m} \log \frac{\eta}{m}.$$

ДОКАЗАТЕЛЬСТВО. Воспользуемся очевидным неравенством

$$\theta\eta - z \exp(\lambda\theta) \leq \max_x \{ \eta x - z \exp(\lambda x) \} = \frac{\eta}{\lambda} \log \frac{\eta}{z\lambda} - \frac{\eta}{\lambda},$$

которое справедливо для любого $z > 0$. Поэтому

$$\mathbf{E}\theta\eta \leq \min_{z>0} \left\{ z\psi(\lambda) - \frac{m}{\lambda} \log(z) + \mathbf{E} \frac{\eta}{\lambda} \log \frac{\eta}{\lambda} - \frac{m}{\lambda} \right\} = \frac{mH + m \log[\psi(\lambda)]}{\lambda}. \quad \blacksquare$$

Л е м м а 4. Пусть выполнено условие A и (19). Тогда при $n \rightarrow \infty$

$$\mathbf{E} \{ q_\alpha(n) + V_\epsilon(\alpha) [1 + q_\alpha(n)] \} \left| \sum_{s=1}^n (\xi_s'^2 - 1) \right| \leq o(1) \mathbf{E} V_\epsilon(\hat{\alpha}) \log^{-1/4} \frac{\mathbf{E} V_\epsilon(\hat{\alpha})}{\sqrt{D(\alpha_{\max})}}. \quad (27)$$

ДОКАЗАТЕЛЬСТВО. Заметим, что если выполнено условие A и (19), то

$$\{ q_\alpha(n) + V_\epsilon(\alpha) [1 + q_\alpha(n)] \} \leq o(1) \frac{\sqrt{D(\hat{\alpha})}}{\sqrt{n}}. \quad (28)$$

Далее воспользуемся леммой 3, положив

$$\theta = \sqrt{D(\hat{\alpha})} \quad \text{и} \quad \eta = \frac{1}{\sqrt{n}} \sum_{i=1}^n (\xi_i'^2 - 1).$$

Поскольку в этом случае

$$\mathbf{E} \exp(\lambda\eta) = \exp \left[-\lambda\sqrt{n} - \frac{n}{2} \log \left(1 - \frac{2\lambda}{\sqrt{n}} \right) \right],$$

то при всех $\lambda \leq \sqrt{n}/4$

$$\mathbf{E} \exp(\lambda\eta) \leq \exp(8\lambda^2).$$

Поэтому из (26) заключаем, что при любом $\lambda \leq \sqrt{n}/4$ выполнено неравенство

$$\mathbf{E} \sqrt{D(\hat{\alpha})} \frac{1}{\sqrt{n}} \sum_{i=1}^n (\xi_i'^2 - 1) \leq \mathbf{E} \sqrt{D(\hat{\alpha})} \times \left[\frac{1}{\lambda} \mathbf{E} \frac{\sqrt{D(\hat{\alpha})}}{\mathbf{E} \sqrt{D(\hat{\alpha})}} \log \frac{\sqrt{D(\hat{\alpha})}}{\mathbf{E} \sqrt{D(\hat{\alpha})}} + 8\lambda \right].$$

Подставив в правую часть этого неравенства

$$\lambda = \frac{1}{2\sqrt{2}} \left[\mathbf{E} \frac{\sqrt{D(\hat{\alpha})}}{\mathbf{E} \sqrt{D(\hat{\alpha})}} \log \frac{\sqrt{D(\hat{\alpha})}}{\mathbf{E} \sqrt{D(\hat{\alpha})}} \right]^{1/2},$$

приходим к

$$\mathbf{E}\sqrt{D(\hat{\alpha})}\frac{1}{\sqrt{n}}\sum_{i=1}^n(\xi_i^2 - 1) \leq C\sqrt{\mathbf{E}\sqrt{D(\hat{\alpha})}}\left[\mathbf{E}\sqrt{D(\hat{\alpha})}\log\frac{\sqrt{D(\hat{\alpha})}}{\mathbf{E}\sqrt{D(\hat{\alpha})}}\right]^{1/2}.$$

Столь же просто проверяется, что

$$\mathbf{E}\sqrt{D(\hat{\alpha})}\frac{1}{\sqrt{n}}\sum_{i=1}^n(\xi_i^2 - 1) \geq -C\sqrt{\mathbf{E}\sqrt{D(\hat{\alpha})}}\left[\mathbf{E}\sqrt{D(\hat{\alpha})}\log\frac{\sqrt{D(\hat{\alpha})}}{\mathbf{E}\sqrt{D(\hat{\alpha})}}\right]^{1/2}.$$

и, следовательно (см. (28)),

$$\mathbf{E}q_{\hat{\alpha}}(n)\left|\sum_{s=1}^n(\xi_s'^2 - 1)\right| \leq o(1)\sqrt{\mathbf{E}D^{1/2}(\hat{\alpha})\mathbf{E}V_{\epsilon}(\hat{\alpha})}. \quad (29)$$

Нетрудно проверить также, что

$$D^{1/2}(\hat{\alpha}) \leq CV_{\epsilon}(\hat{\alpha})\log^{-1/2}\frac{V_{\epsilon}(\hat{\alpha})}{\sqrt{D(\alpha_{\max})}}$$

и поэтому в силу неравенства Йенсена

$$\mathbf{E}D^{1/2}(\hat{\alpha}) \leq C\mathbf{E}V_{\epsilon}(\hat{\alpha})\log^{-1/2}\frac{\mathbf{E}V_{\epsilon}(\hat{\alpha})}{\sqrt{D(\alpha_{\max})}}.$$

Таким образом

$$\sqrt{\mathbf{E}D^{1/2}(\hat{\alpha})\mathbf{E}V_{\epsilon}(\hat{\alpha})} \leq C\mathbf{E}V_{\epsilon}(\hat{\alpha})\log^{-1/4}\frac{\mathbf{E}V_{\epsilon}(\hat{\alpha})}{\sqrt{D(\alpha_{\max})}}.$$

Это неравенство и (29) завершают доказательство леммы. $\blacksquare$

3.2 Доказательство теоремы 1

Заметим, что (13) эквивалентно следующему неравенству:

$$\mathbf{E}\sup_{\alpha \in \mathcal{A}}[\pm\zeta(\alpha) - V_{\epsilon}(\alpha)]_+ \leq C\frac{\sqrt{D(\alpha_{\max})}}{\epsilon}.$$

Выберем последовательность α_k , $k = 0, 1 \dots$, так, чтобы

$$D(\alpha_k) = (1 + r)^k D(\alpha_{\max}), \quad (30)$$

где величина $r > 0$ будет определена позднее.

Далее воспользуемся следующими очевидными неравенствами:

$$\begin{aligned} \mathbf{E} \sup_{\alpha \in \mathcal{A}} [\zeta(\alpha) - V_\epsilon(\alpha)]_+ &\leq \sum_{k=0}^{\infty} \mathbf{E} \sup_{\alpha \in [\alpha_{k+1}, \alpha_k]} [\zeta(\alpha) - V_\epsilon(\alpha)]_+ \\ &\leq \sum_{k=0}^{\infty} \mathbf{E} [\zeta(\alpha_k) - V_\epsilon(\alpha_k) + \sup_{\alpha \in [\alpha_{k+1}, \alpha_k]} [\zeta(\alpha) - \zeta(\alpha_k)]]_+. \end{aligned} \quad (31)$$

и

$$\begin{aligned} \mathbf{E} \sup_{\alpha \in \mathcal{A}} [-\zeta(\alpha) - V_\epsilon(\alpha)]_+ &\leq \sum_{k=0}^{\infty} \mathbf{E} \sup_{\alpha \in [\alpha_{k+1}, \alpha_k]} [-\zeta(\alpha) - V_\epsilon(\alpha)]_+ \\ &\leq \sum_{k=0}^{\infty} \mathbf{E} [-\zeta(\alpha_{k+1}) - V_\epsilon(\alpha_k) + \sup_{\alpha \in [\alpha_{k+1}, \alpha_k]} [\zeta(\alpha_{k+1}) - \zeta(\alpha)]]_+. \end{aligned} \quad (32)$$

Для того чтобы продолжить эти неравенства, заметим, что в силу неравенства Гельдера, для любых случайных величин ζ_1, ζ_2 и любого $\lambda > 0$ справедливы соотношения

$$\mathbf{E}[\zeta_1 - \zeta_2]_+ \leq \lambda^{-1} \mathbf{E} \exp(-\lambda \zeta_2) \exp(\lambda \zeta_1) \leq \lambda^{-1} [\mathbf{E} \exp(-\lambda p \zeta_2)]^{1/p} [\mathbf{E} \exp(\lambda q \zeta_1)]^{1/q}, \quad (33)$$

где $p, q > 1$ таковы, что

$$\frac{1}{p} + \frac{1}{q} = 1. \quad (34)$$

В случае неравенства (31) положим

$$\zeta_1 = \zeta(\alpha_k), \quad \zeta_2 = -V_\epsilon(\alpha_k) + \sup_{\alpha \in [\alpha_{k+1}, \alpha_k]} [\zeta(\alpha) - \zeta(\alpha_k)].$$

Из леммы 2 (см. также (30)) вытекает, что ζ_2 суб-гауссовская случайная величина, точнее такая, для которой неравенство

$$\mathbf{E} \exp(\lambda \zeta_2) \leq \exp[-\lambda V_\epsilon(\alpha_k) + Qr \lambda^2 D(\alpha_k)] \quad (35)$$

выполняется для любого $\lambda > 0$.

Далее легко проверить, что ζ_1 также суб-гауссовская случайная величина, т.е. для любого $\lambda > 0$

$$\begin{aligned} \mathbf{E} \exp(\lambda \zeta_1) &\leq \exp \left\{ \lambda \sum_{s=1}^n G_{\alpha_k}(\lambda_s) - \frac{1}{2} \sum_{s=1}^n \log[1 + 2\lambda G_{\alpha_k}(\lambda_s)] \right\} \\ &\leq \exp \left\{ \lambda^2 \sum_{s=1}^n [G_{\alpha_k}(\lambda_s)]^2 \right\} = \exp[\lambda^2 D(\alpha_k)]. \end{aligned} \quad (36)$$

Следовательно, объединяя неравенства (33), (35) и (36), находим

$$\mathbf{E}[\zeta_1 - \zeta_2]_+ \leq C\lambda^{-1} \exp[-\lambda V_\epsilon(\alpha_k) + (Qrp + q)\lambda^2 D(\alpha_k)]$$

и подставив в это неравенство

$$\lambda = \frac{V_\epsilon(\alpha_k)}{2(Qrp + q)D(\alpha_k)},$$

приходим к

$$\mathbf{E}[\zeta_1 - \zeta_2]_+ \leq \frac{2(Qrp + q)D(\alpha_k)}{V_\epsilon(\alpha_k)} \exp\left\{-\frac{V_\epsilon^2(\alpha_k)}{4(Qrp + q)D(\alpha_k)}\right\}. \quad (37)$$

Поскольку величина $q > 1$ произвольна, выберем $q = 1 + \sqrt{Qr}$ и тогда из (37) и (34) получим

$$\mathbf{E}[\zeta_1 - \zeta_2]_+ \leq C \frac{C(1 + \sqrt{Qr})^2 D(\alpha_k)}{V_\epsilon(\alpha_k)} \exp\left\{-\frac{V_\epsilon^2(\alpha_k)}{4(1 + \sqrt{Qr})^2 D(\alpha_k)}\right\}. \quad (38)$$

Поэтому, если выбрать $r = \epsilon^2/Q$, то в силу определения $V_\epsilon(\alpha)$ в (11), из (38) находим

$$\mathbf{E}[\zeta_1 - \zeta_2]_+ \leq \frac{C\sqrt{D(\alpha_{\max})}}{k^{1+\epsilon}}$$

и, таким образом, (см. (31))

$$\mathbf{E} \sup_{\alpha \in \mathcal{A}} [\zeta(\alpha) - V_\epsilon(\alpha)]_+ \leq C\epsilon^{-1} \sqrt{D(\alpha_{\max})}.$$

Неравенство (32) продолжается практически аналогично. При этом переопределим величины ζ_1, ζ_2 следующим образом:

$$\zeta_1 = -\zeta(\alpha_{k+1}), \quad \zeta_2 = -V_\epsilon(\alpha_k) + \sup_{\alpha \in [\alpha_{k+1}, \alpha_k]} [\zeta(\alpha_{k+1}) - \zeta(\alpha)].$$

Случайная величина ζ_2 как и ранее будет суб-гауссовской, но это уже не будет справедливо для ζ_1 , т.к.

$$\begin{aligned} \mathbf{E} \exp(\lambda \zeta_1) &= \mathbf{E} \exp\left[\lambda \sum_{s=1}^n G_{\alpha_{k+1}}(\lambda_s)(\xi_s'^2 - 1)\right] \\ &= \exp\left\{-\lambda \sum_{s=1}^n G_{\alpha_{k+1}}(\lambda_s) - \frac{1}{2} \sum_{s=1}^n \log[1 - 2\lambda G_{\alpha_{k+1}}(\lambda_s)]\right\}. \end{aligned} \quad (39)$$

Однако, это тождество будет использоваться при

$$\begin{aligned} \lambda &= \frac{V_\epsilon(\alpha_k)}{2(Qrp + q)D(\alpha_{k+1})} \leq \frac{V_\epsilon(\alpha_k)}{2D(\alpha_{k+1})} \leq \sqrt{\frac{\log[D(\alpha_k)/D(\alpha_{\max})]}{D(\alpha_k)}} \\ &= \frac{1}{\sqrt{D(\alpha_{\max})}} \sqrt{\frac{\log[D(\alpha_k)/D(\alpha_{\max})]}{D(\alpha_k)/D(\alpha_{\max})}} \leq \frac{1}{\sqrt{D(\alpha_{\max})}}. \end{aligned} \quad (40)$$

Поэтому, если $D(\alpha_{\max}) > 5$, то для оценки сверху правой части в (39) можно использовать формулу Тейлора. Таким образом, для λ из (40) получим

$$\begin{aligned} & \exp \left\{ -\lambda \sum_{s=1}^n G_{\alpha_{k+1}}(\lambda_s) - \frac{1}{2} \sum_{s=1}^n \log[1 - 2\lambda G_{\alpha_{k+1}}(\lambda_s)] \right\} \\ & \leq \exp \left[\lambda^2 D(\alpha_{k+1}) + C \frac{V_\epsilon^3(\alpha_k)}{D^2(\alpha_{k+1})} \right] \leq \exp[\lambda^2 D(\alpha_{k+1}) + C]. \end{aligned}$$

Дальнейшее доказательство совершенно аналогично тому, что мы делали раньше и поэтому мы его опустим.

3.3 Доказательство теоремы 2

Обозначим для краткости

$$\begin{aligned} \widehat{\Delta}(\alpha, Y) &= \left[1 + \frac{V_\epsilon(\alpha)}{n} \right] [1 + q_\alpha(n)] \|Y - X\widehat{\beta}_\alpha(Y)\|^2, \\ B(\alpha) &= \sum_{s=1}^n [1 - H_\alpha(\lambda_s)]^2 \lambda_s \bar{\beta}_s^2 \end{aligned}$$

и (см. (18))

$$\alpha_\beta = \arg \min_{\alpha \in \mathcal{A}} R_\epsilon(\alpha, \beta).$$

Доказательство теоремы, по-существу, основано на простом неравенстве

$$\widehat{\Delta}(\widehat{\alpha}, Y) \leq \widehat{\Delta}(\alpha_\beta, Y) \quad (41)$$

и верхней границе, вытекающей из (9) и теоремы 1

$$\begin{aligned} \mathbf{E}\Delta(\widehat{\sigma}_{\widehat{\alpha}}^2) &\leq R_\epsilon(\widehat{\alpha}, \beta) + \frac{C\sigma^2\sqrt{D(\alpha_{\max})}}{\epsilon} \\ &+ \sigma^2 q_{\widehat{\alpha}}(n) \left| \sum_{i=1}^n (\xi_i'^2 - 1) \right| + 2\sigma[1 + q_{\widehat{\alpha}}(n)] \left| \sum_{i=1}^n [1 - H_{\widehat{\alpha}}(\lambda_i)]^2 \xi_i' \sqrt{\lambda_i} \bar{\beta}_i \right|. \end{aligned}$$

С помощью лемм 1 и 4 это неравенство можно продолжить следующим образом:

$$\begin{aligned} \mathbf{E}\Delta(\widehat{\sigma}_{\widehat{\alpha}}^2) &\leq R_\epsilon(\widehat{\alpha}, \beta) + \frac{C\sigma^2\sqrt{D(\alpha_{\max})}}{\epsilon} \\ &+ C\sigma\sqrt{\mathbf{E}B(\widehat{\alpha})} + o(1)\sigma^2\mathbf{E}V_\epsilon(\widehat{\alpha}) \log^{-1/4} \frac{\mathbf{E}V_\epsilon(\widehat{\alpha})}{\sqrt{D(\alpha_{\max})}}. \end{aligned} \quad (42)$$

Чтобы воспользоваться этим неравенством, нужно выяснить как связаны между собой случайный процесс $\widehat{\Delta}(\alpha, Y)$, $\alpha \in \mathcal{A}$, и функция $R_\epsilon(\alpha, \beta)$, $\alpha \in \mathcal{A}$. Эту связь

определяет следующее тождество:

$$\begin{aligned}
\widehat{\Delta}(\alpha, Y) - \sigma^2 \|\xi\|^2 &= \left[1 + \frac{V_\epsilon(\alpha)}{n}\right] [1 + q_\alpha(n)] B(\alpha) \\
&\quad + 2\sigma [1 + q_\alpha(n)] \left[1 + \frac{V_\epsilon(\alpha)}{n}\right] \sum_{s=1}^n [1 - H_\alpha(\lambda_s)]^2 \sqrt{\lambda_s} \bar{\beta}_s \xi'_s \\
&\quad + \sigma^2 \left[1 + \frac{V_\epsilon(\alpha)}{n}\right] \left[V_\epsilon(\alpha) - \sum_{s=1}^n G_\alpha(\lambda_s) (\xi_s'^2 - 1)\right] \\
&\quad + \sigma^2 \{q_\alpha(n) + V_\epsilon(\alpha) [1 + q_\alpha(n)]\} \sum_{s=1}^n (\xi_s'^2 - 1).
\end{aligned} \tag{43}$$

Отсюда и из (41) сразу же получаем

$$\mathbf{E}[\widehat{\Delta}(\hat{\alpha}, Y) - \sigma^2 \|\xi\|^2] \leq \mathbf{E}[\widehat{\Delta}(\alpha_\beta, Y) - \sigma^2 \|\xi\|^2] = R_\epsilon(\alpha_\beta, \beta) = r_{\mathcal{A}, \epsilon}(\beta). \tag{44}$$

Нам потребуется нижняя граница для левой части в этом неравенстве. Ее можно получить подставив в (43)

$$V_\epsilon(\alpha) = (1 - \gamma)V_\epsilon(\alpha) + \gamma V_\epsilon(\alpha);$$

здесь $\gamma \in (0, \epsilon/(1 + \epsilon))$. Заметим (см. (11)), что

$$(1 - \gamma)V_\epsilon(\alpha) \geq V_{\epsilon - \gamma - \gamma\epsilon}(\alpha).$$

При выполнении условия A и (19) очевидно, что $q_\alpha(n) < 1$. Поэтому из (43) с помощью (29), лемм 1, (4) и теоремы 1 приходим к неравенству

$$\begin{aligned}
\mathbf{E}[\widehat{\Delta}(\hat{\alpha}, Y) - \sigma^2 \|\xi\|^2] &\geq \mathbf{E}\left[1 + \frac{V_\epsilon(\hat{\alpha})}{n}\right] \{[1 + q_{\hat{\alpha}}(n)] B(\hat{\alpha}) + \sigma^2 \gamma V_\epsilon(\hat{\alpha})\} \\
&\quad - C\sigma \sqrt{\mathbf{E}B(\hat{\alpha})} - C\sigma^2 \frac{\sqrt{D(\alpha_{\max})}}{(\epsilon - \gamma - \gamma\epsilon)_+} - o(1)\sigma^2 \mathbf{E}V_\epsilon(\hat{\alpha}) \log^{-1/4} \frac{\mathbf{E}V_\epsilon(\hat{\alpha})}{\sqrt{D(\alpha_{\max})}}.
\end{aligned}$$

Воспользовавшись этим неравенством и (44), получим

$$r_{\mathcal{A}, \epsilon}(\beta) \geq \sigma^2 \gamma \mathbf{E}V_\epsilon(\hat{\alpha}) - C\sigma^2 \frac{\sqrt{D(\alpha_{\max})}}{(\epsilon - \gamma - \gamma\epsilon)_+} - o(1)\sigma^2 \mathbf{E}V_\epsilon(\hat{\alpha}) \log^{-1/4} \frac{\mathbf{E}V_\epsilon(\hat{\alpha})}{\sqrt{D(\alpha_{\max})}} \tag{45}$$

и, решая это неравенство относительно $\mathbf{E}V_\epsilon(\hat{\alpha})$, приходим к

$$\mathbf{E} \frac{V_\epsilon(\hat{\alpha})}{\sqrt{D(\alpha_{\max})}} \leq (1 + o(1)) \left[\frac{r_{\mathcal{A}, \epsilon}(\beta)}{\sigma^2 \gamma \sqrt{D(\alpha_{\max})}} + \frac{C}{\gamma(\epsilon - \gamma - \gamma\epsilon)_+} \right].$$

С помощью этого неравенства получим

$$\begin{aligned} \mathbf{E}V_\epsilon(\hat{\alpha}) \log^{-1/4} \frac{\mathbf{E}V_\epsilon(\hat{\alpha})}{\sqrt{D(\alpha_{\max})}} &\leq \frac{Cr_{\mathcal{A},\epsilon}(\beta)}{\gamma\sigma^2\sqrt{D(\alpha_{\max})}} \left[1 + \frac{C\sigma^2\sqrt{D(\alpha_{\max})}}{(\epsilon - \gamma - \epsilon\gamma)_+ r_{\mathcal{A},\epsilon}(\beta)} \right] \\ &\times \log^{-1/4} \left(\frac{r_{\mathcal{A},\epsilon}(\beta)}{\sigma^2\sqrt{D(\alpha_{\max})}} \right). \end{aligned} \quad (46)$$

Подставив в (45) неравенство (46) получаем, что при достаточно больших n

$$\begin{aligned} r_{\mathcal{A},\epsilon}(\beta) &\geq \mathbf{E}[1 + q_{\hat{\alpha}}(n)] [B(\hat{\alpha}) + \gamma\sigma^2V_\epsilon(\hat{\alpha})] \\ &\quad - C\sigma \left\{ \mathbf{E}[1 + q_{\hat{\alpha}}(n)] [B(\hat{\alpha}) + \gamma\epsilon\sigma^2V_\epsilon(\hat{\alpha})] \right\}^{1/2} - \frac{C\sigma^2\sqrt{D(\alpha_{\max})}}{(\epsilon - \gamma - \gamma\epsilon)_+} \\ &\quad - o(1) \frac{r_{\mathcal{A},\epsilon}(\beta)}{\gamma\sqrt{D(\alpha_{\max})}} \log^{-1/4} \left[\frac{r_{\mathcal{A},\epsilon}(\beta)}{\sigma^2\sqrt{D(\alpha_{\max})}} \right]. \end{aligned}$$

Отсюда с помощью простых преобразований приходим к неравенству

$$\begin{aligned} &\mathbf{E}[1 + q_{\hat{\alpha}}(n)] [B(\hat{\alpha}) + \gamma\sigma^2V_\epsilon(\hat{\alpha})] \\ &\leq r_{\mathcal{A},\epsilon}(\beta) \left\{ 1 + \frac{o(1)}{\sqrt[4]{D(\alpha_{\max})}\sqrt{\gamma}} \log^{-1/8} [\rho_{\mathcal{A},\epsilon}(\beta)] + \left[\frac{C}{(\epsilon - \gamma - \gamma\epsilon)_+ \rho_{\mathcal{A},\epsilon}(\beta)} \right]^{1/2} \right\}^2. \end{aligned}$$

и, таким образом,

$$\mathbf{E}R_\epsilon(\hat{\alpha}, \beta) \leq \frac{r_{\mathcal{A},\epsilon}(\beta)}{\gamma} \left\{ 1 + \frac{o(1)}{\sqrt[4]{D(\alpha_{\max})}\sqrt{\gamma}} \log^{-1/8} [\rho_{\mathcal{A},\epsilon}(\beta)] + \left[\frac{C}{(\epsilon - \gamma - \gamma\epsilon)_+ \rho_{\mathcal{A},\epsilon}(\beta)} \right]^{1/2} \right\}^2.$$

Наконец, подставляя это неравенство и (46) в (42), с помощью несложных вычислений приходим к (20).

СПИСОК ЛИТЕРАТУРЫ

1. *Aster, R., Borchers, B., Thurber, C.* Parameter Estimation and Inverse Problems. Elsevier 2013.
2. *Kneip, A.* Ordered linear smoothers // Annals of Statist. 1994. V. 22. № 2. P. 835–866.
3. *Engl, H.W., Hanke, M., and Neubauer, A.* Regularization of Inverse Problems // Mathematics and its Applications. V. 375. Dordrecht: Kluwer Academic Publishers Group 1996.
4. *Kolmogoroff A.* Uber das Gesetz des iterierten Logarithmus // Mathematische Annalen. 1929. V. 101. P. 126–135.

5. *Golubev G., Levit B.* On the second order minimax estimation of distribution function // Math. Methods Statist. 1996. V. 5. P. 1–31.
6. *Dalalyan A, Golubev G. and Tsybakov A.* Bayesian maximum likelihood and semi-parametric second order efficiency // Ann. Statist. 2006. V. 34, № 1. P. 169–201.
7. *Laurent B. and Massart P* Adaptive estimation of a quadratic functional by model selection // The Annals of Statist. 2000. V. 28. № 5. P. 1302–1338.
8. *Van der Vaart A.* Simiparametric statistics // Lectures on Probability Theory and Statistics. Ecole d'été de probabilités de Saint-Flour XXIX-1999 P. 312–425.
9. *Green, P. J. and Silverman, B. W.* Nonparametric Regression and Generalized Linear Models. A roughness penalty approach, Chapman and Hall, 1994.
10. *Demmler A., Reinsch C.* Oscillation matrices with spline smoothing // Numerische Mathematik 1975. V. 24. № 5. P. 375–382.
11. *Speckman P.* Spline smoothing and optimal rates of convergence in nonparametric regression models. // Annals of Statist. 1985. V. 13 № 3. P. 970–983.
12. *Голубев Г. К.* Концентрации рисков выпуклых комбинаций линейных оценок. // Проблемы перед. информ. 2016. Т. 52. № 4. С. 31–48.
13. *Efromovich S. and Low M.* On optimal adaptive estimation of a quadratic functional. // The Annals of Statist. 1996. V. 24. № 3. P. 1106–1125.

Голубев Георгий Ксенофонович

CNRS, Aix-Marseille Université, I2M,

Институт проблем передачи информации им. А.А. Харкевича РАН

`golubev.yuri@gmail.com`

Крымова Екатерина Александровна

Институт проблем передачи информации им. А.А. Харкевича РАН,

Duisburg-Essen University,

`ekkrym@gmail.com`