

© 2019 г. А.Б. ЮДИЦКИЙ, канд. тех. наук
(anatoli.juditsky@univ-grenoble-alpes.fr)

(LJK, Университет Гренобль-Альпы, Гренобль, Франция),

А.С. НЕМИРОВСКИЙ, д-р физ.-мат. наук (nemirovs@isye.gatech.edu)

(ISyE, Технологический институт Джорджии, Атланта, США)

ВОССТАНОВЛЕНИЕ СИГНАЛОВ С ПОМОЩЬЮ СТОХАСТИЧЕСКОЙ ОПТИМИЗАЦИИ¹

Рассматривается подход к восстановлению сигналов в обобщенных линейных моделях, при котором задача оценивания сигналов сводится к решению стохастических монотонных вариационных неравенств (ВН). Решения таких ВН могут быть получены с помощью эффективно вычислительных процедур, а в случае сильно монотонных ВН допускают верхнюю границу на конечном времени для ожидаемой ошибки $\| \cdot \|_2^2$, сходящуюся к нулю со скоростью $O(1/K)$ с ростом числа K наблюдений. Принятые структурные предположения существенно слабее тех, которые необходимы для обеспечения выпуклости оптимизационной задачи, возникающей при применении метода максимального правдоподобия. Прослеживается связь предлагаемого подхода с идеями, лежащими в основе алгоритма персептрона Розенבלата.

Ключевые слова: обобщенные линейные модели, задача статистического оценивания, стохастическая оптимизация, вариационные неравенства.

DOI: 10.1134/S0005231019100088

1. Введение

Задачи статистического оценивания составляют одну из важнейших прикладных областей стохастической оптимизации. Типичная постановка задачи выглядит следующим образом (например, см. [1] и обширную библиографию, приведенную в этой книге). Допустим, что имеются независимые одинаково распределенные наблюдения $\omega^K = (\omega_1, \dots, \omega_K)$, $\omega_k = (\eta_k, y_k)$, где $\eta_k \in \mathbf{R}^{n \times m}$, $y_k \in \mathbf{R}^m$ — реализации регрессоров (независимые переменные) и отклики (метки) соответственно. Предполагаем, что наблюдения описываются обобщенной линейной моделью (ОЛМ) [2, 3], т.е. условное (по η) математическое ожидание y равно $f(\eta^T x)$, где верхний индекс T — знак транспонирования, $f(\cdot) : \mathbf{R}^m \rightarrow \mathbf{R}^m$ — известная функция связи, а $x \in \mathbf{R}^m$ — неизвестный “сигнал”, т.е. вектор параметров модели. Цель состоит в “подгонке модели”, т.е. в восстановлении вектора x по наблюдениям ω^K . При стандартном подходе к решению задачи оценивания выбирают функцию потерь $\ell(y, \theta) : \mathbf{R}^m \times \mathbf{R}^m \rightarrow \mathbf{R}$ и в качестве оценки x принимают оптимальное решение оптимизацион-

¹ Работа первого автора поддержана грантом 2016-2032Н, РГМО. Работа первого и второго авторов финансировалась грантом CCF-1523768, NSF.

ной задачи

$$(1) \quad \min_{u \in \mathcal{X}} \mathbf{E}_{\omega \sim P_x} \{ \ell(y, f(\eta^T u)) \},$$

где P_x — функция распределения наблюдений $\omega = (\eta, y)$, отвечающая “истинному сигналу x ”, а \mathcal{X} — априори известное множество сигналов. Иными словами, задача статистического оценивания сводится к задаче стохастической оптимизации (1), которая должна решаться приближенно, исходя из имеющихся наблюдений ω^K . Это может быть сделано или напрямую (“пакетно”) путем минимизации по $u \in \mathcal{X}$ аппроксимации выборочного среднего (ВСА)

$$(2) \quad \frac{1}{K} \sum_{k=1}^K \ell(y_k, f(\eta_k^T u))$$

для математического ожидания в (1) (например, см. [4]) или путем применения итеративных алгоритмов стохастической оптимизации типа стохастической аппроксимации (СА) [5, 6].

Пусть функция условного по η распределения $P_{|\eta}^x$ величины y , индуцированная распределением P_x , принадлежит известному параметрическому семейству $\mathcal{P} = \{P^\theta : \theta \in \Theta \subset \mathbf{R}^m\}$, а именно, $P_{|\eta}^x = P^{f(\eta^T x)}$; тогда стандартный выбор функции потерь дается методом максимального правдоподобия (МП). Иными словами, считая, что распределения P^θ имеют плотности p_θ относительно некоторой меры Π , полагают

$$\ell(y, \theta) = -\ln(p_\theta(y)).$$

Например, в классической *логистической регрессии* имеем $m = 1$, $f(s) = (1 + e^{-s})^{-1}$, $\Theta = (0, 1)$, а P^θ , $\theta \in \Theta$, — распределение Бернулли, т.е. y принимает значение единица с вероятностью $q = (1 + \exp\{-\eta^T x\})^{-1}$ и нуль с вероятностью $1 - q$, что приводит к

$$(3) \quad \ell(y, f(\eta^T u)) = \ln(1 + \exp\{\eta^T u\}) - y\eta^T u.$$

В этом случае задача (1) становится оптимизационной задачей вида

$$(4) \quad \min_{u \in \mathcal{X}} \mathbf{E}_{(\eta, y) \sim P_x} \{ \ln(1 + \exp\{\eta^T u\}) - y\eta^T u \},$$

и соответствующая задача ВСА записывается как

$$(5) \quad \min_{u \in \mathcal{X}} \frac{1}{K} \sum_{k=1}^K [\ln(1 + \exp\{\eta_k^T u\}) - y_k \eta_k^T u],$$

а ее оптимальное решение $\hat{x}_{\text{ML}}(\omega^K)$ и есть МП-оценка сигнала x . При предположении о выпуклости множества \mathcal{X} сигналов обе эти задачи выпуклы и, следовательно, глобальный оптимум в задаче ВСА может быть эффективно вычислен, а для алгоритмов СА для (4) могут быть получены гарантированные скорости сходимости.

В более общем случае, когда распределения наблюдений образуют *семейство условных экспоненциальных распределений* [7, 8], функция правдоподобия имеет вид

$$\ell(y, \eta^T u) = F(\eta^T u) - y\eta^T u$$

с выпуклой *кумулянтной функцией* F , а соответствующая задача (1) минимизации риска записывается как

$$(6) \quad \min_{u \in \mathcal{X}} \mathbf{E}_{(\eta, y) \sim P_x} \{F(\eta^T u) - y\eta^T u\}.$$

В этом случае, так же как и при логистической регрессии, для получения МП-оценок параметров модели можно применять ВСА или СА.

Заметим, однако, что предположение о принадлежности распределений экспоненциальному семейству довольно ограничительно. С другой стороны, для распределений, которые не удовлетворяют этому предположению, выпуклость оптимизационной задачи, получающейся при выборе функции потерь $\ell(\cdot)$ по методу максимального правдоподобия, является скорее исключением, чем правилом. Например, рассмотрим нелинейную схему наименьших квадратов, в которой величина y получается из $f(\eta^T x)$ добавлением централизованного гауссовского шума, не зависящего от регрессоров:

$$y = f(\eta^T x) + \xi, \quad \xi \sim \mathcal{N}(0, \sigma^2 I_m).$$

В этом случае задача (1) и ее ВС-аппроксимация при выборе $\ell(\cdot)$ по методу максимального правдоподобия приобретают вид

$$(7) \quad \begin{aligned} & \min_{u \in \mathcal{X}} \mathbf{E}_{\eta \sim Q} \left\{ \|f(\eta^T x) - f(\eta^T u)\|_2^2 \right\}, \\ & \min_{u \in \mathcal{X}} \left\{ \frac{1}{K} \sum_{k=1}^k \|y_k - f(\eta_k^T u)\|_2^2 \right\}, \end{aligned}$$

где Q — распределение регрессоров (они предполагаются независимыми от сигнала). Если функция f нелинейна, то обе эти задачи обычно невыпуклы, и их численное решение затруднено. Аналогично, в задаче “неэкспоненциальной логистической регрессии”, в которой сигмоидная функция $f(s) = (1 + \exp\{-s\})^{-1}$ заменена на общего вида неубывающую функцию связи $f(s) : \mathbf{R} \rightarrow (0, 1)$ (например, так называемая *пробит-функция* или *дополняющая $\log - \log$ функция*), МП-выбор функции потерь, как правило, влечет невыпуклость задачи (1) и ее ВС-аппроксимации.

Цель последующего изложения — предложить альтернативу решению задачи настройки модели, основанному на решении оптимизационной задачи (1) с МП-выбором функции потерь при оценивании сигнала по наблюдениям в ОЛМ. Идеи, лежащие в основе подхода, предлагаемого в настоящей статье, восходят к итеративному алгоритму персептрона Розенבלата [9, 10] и его “пакетной” версии [11]. В этом случае структурные требования, предъявляемые к модели, оказываются существенно слабее тех, которые приводят к вы-

пуклости задач (1) с МП-выбором функции потерь и их ВС-аппроксимаций². При этих предположениях вместо того, чтобы использовать классический подход с формированием задачи стохастической оптимизации (1) и функции потерь [12–16], задача оценивания сводится к другой задаче с выпуклой структурой — *сильно монотонному вариационному неравенству* (ВН), *представимому в виде стохастического оракула*. Полученное вариационное неравенство может быть эквивалентно задаче выпуклой минимизации (например, при $m = 1$ такое ВН эквивалентно задаче выпуклой оптимизации, аналогичной (6)); но даже и в этом случае получающаяся задача, как правило, отличается от МП-версии задачи (1). Решение такого ВН может быть получено в результате эффективной численной процедуры, и оно оказывается “хорошей” оценкой “истинного” сигнала по имеющимся наблюдениям. Для этой оценки здесь доказываются верхние границы на ожидаемую квадратичную ошибку в норме $\|\cdot\|_2^2$, сходящуюся к нулю со скоростью $O(1/K)$ при $K \rightarrow \infty^3$.

2. Постановка задачи

Рассматривается обобщенная линейная модель наблюдений, характеризующаяся следующими предположениями.

Наблюдения зависят от неизвестного сигнала x , принадлежащего заданному выпуклому компактному множеству $\mathcal{X} \subset \mathbf{R}^n$, и представлены в виде

$$(8) \quad \omega^K = \{\omega_k = (\eta_k, y_k), 1 \leq k \leq K\},$$

где ω_k , $1 \leq k \leq K$, — независимые одинаково распределенные реализации случайной пары (η, y) с распределением P_x таким, что

- *регрессор η* является случайной $(n \times m)$ -матрицей с некоторым вероятностным распределением Q , *не зависящим от x* ;
- *отклик (“метка”) y* является m -мерным случайным вектором таким, что его условное по η распределение, индуцированное распределением P_x , имеет математическое ожидание $f(\eta^T x)$:

$$(9) \quad \mathbf{E}_{|\eta}^x \{y\} = f(\eta^T x),$$

где $\mathbf{E}_{|\eta}^x$ — условное по η математическое ожидание метки y , задаваемое распределением P_x величины $\omega = (\eta, y)$, а $f(\cdot) : \mathbf{R}^m \rightarrow \mathbf{R}^m$ — заданное отображение.

Ниже будут сформулированы предположения о параметрах обобщенной линейной модели (а именно, условия на $f(\cdot)$ и на распределение P_x , $x \in \mathcal{X}$ пары (η, y)), необходимые для обоснования предлагаемого подхода.

² Например, в нелинейной схеме наименьших квадратов с $m = 1$ и в неэкспоненциальной логистической регрессии от функции f требовалась лишь непрерывная дифференцируемость и положительность производной, а от множества \mathcal{X} сигналов — выпуклость.

³ Несмотря на простоту приводимых ниже выкладок, авторам не удалось найти упоминание о предлагаемом подходе в статистической литературе.

2.1. Предварительные сведения: монотонные векторные поля

Монотонное векторное поле на \mathbf{R}^m — это однозначное всюду определенное отображение $g(\cdot) : \mathbf{R}^m \rightarrow \mathbf{R}^m$, обладающее свойством монотонности:

$$[g(z) - g(z')]^T [z - z'] \geq 0 \quad \forall z, z' \in \mathbf{R}^m.$$

Скажем, что такое поле монотонно с модулем $\varkappa \geq 0$ на замкнутом выпуклом множестве $Z \subset \mathbf{R}^m$, если

$$[g(z) - g(z')]^T [z - z'] \geq \varkappa \|z - z'\|_2^2 \quad \forall z, z' \in Z;$$

назовем g сильно монотонным на Z , если модуль монотонности \varkappa поля g на Z положителен. Очевидно, что для монотонного векторного поля f , непрерывно дифференцируемого на замкнутом выпуклом множестве Z с непустой внутренностью, условие

$$(10) \quad d^T f'(z) d \geq \varkappa d^T d \quad \forall (d \in \mathbf{R}^n, z \in Z)$$

является необходимым и достаточным условием монотонности с модулем \varkappa . Стандартными примерами монотонных векторных полей являются

- градиентные поля $\nabla \phi(x)$ непрерывно дифференцируемых выпуклых функций m переменных, а также векторные поля $[\nabla_x \phi(x, y); -\nabla_y \phi(x, y)]$, порожденные непрерывно дифференцируемыми функциями $\phi(x, y)$, выпуклыми по x и вогнутыми по y ;
- “диагональные” векторные поля $f(x) = [f_1(x_1); \dots; f_m(x_m)]$ с монотонно неубывающими компонентами $f_i(\cdot)$ — функциями одного аргумента. Если, кроме того, $f_i(\cdot)$ непрерывно дифференцируемы с положительными производными, то соответствующее поле f сильно монотонно на любом компактном выпуклом подмножестве в \mathbf{R}^m с модулем монотонности, зависящим от подмножества.

Монотонные векторные поля на \mathbf{R}^n допускают выполнение простых операций, включающих, например, следующие:

I. [аффинная подстановка аргумента]: Если $f(\cdot)$ — монотонное векторное поле на \mathbf{R}^m и A есть $(n \times m)$ -матрица, то векторное поле

$$g(x) = Af(A^T x + a)$$

также монотонно на \mathbf{R}^n ; если, кроме того, поле f монотонно с модулем $\varkappa \geq 0$ на замкнутом выпуклом множестве $Z \subset \mathbf{R}^m$, а множество $X \subset \mathbf{R}^n$ замкнуто, выпукло и обладает свойством $A^T x + a \in Z$ для всех $x \in X$, то поле g монотонно с модулем $\sigma^2 \varkappa$ на X , где σ — минимальное сингулярное значение матрицы A .

II. [суммирование]: Пусть S — польское пространство, $f(x, s) : \mathbf{R}^m \times S \rightarrow \mathbf{R}^m$ — борелевская векторнозначная функция, монотонная по x при каждом $s \in S$, а $\mu(ds)$ — борелевская вероятностная мера на S такая, что векторное поле

$$F(x) = \int_S f(x, s) \mu(ds)$$

определено для всех x ; тогда $F(\cdot)$ монотонно. Если, кроме того, X — замкнутое выпуклое множество в \mathbf{R}^m , а $f(\cdot, s)$ монотонно на X с борелевским по s модулем $\varkappa(s)$ для всякого $s \in S$, то F монотонно на X с модулем $\int_S \varkappa(s)\mu(ds)$.

2.2. Предположения

В дальнейшем потребуются следующие предположения об основных компонентах задачи оценивания, описанной во введении.

A.1. Векторное поле $f(\cdot)$ непрерывно и монотонно, а векторное поле

$$F(z) = \mathbf{E}_{\eta \sim Q} \{ \eta f(\eta^T z) \}$$

корректно определено (следовательно, монотонно, как и поле f , см. **I**, **II**).

A.2. Множество \mathcal{X} сигналов непусто, выпукло и компактно, а векторное поле F монотонно с положительным модулем \varkappa на \mathcal{X} .

A.3. Для соответствующим образом выбранного $M < \infty$ и всякого $x \in \mathcal{X}$ верно

$$(11) \quad \mathbf{E}_{(\eta, y) \sim P_x} \{ \|\eta y\|_2^2 \} \leq M^2.$$

Простое *достаточное* условие выполнения предположений **A.1–A.3** с соответствующим образом выбранным $M < \infty$ и $\varkappa > 0$ заключается в следующем:

- распределение Q регрессора η имеет конечные моменты всех порядков и $\mathbf{E}_{\eta \sim Q} \{ \eta \eta^T \} \succ 0$;
- функция f непрерывно дифференцируема, и $d^T f'(z) d > 0$ для всех $d \neq 0$ и всех z . Кроме того, f имеет полиномиальный рост, т.е. для некоторых констант $C \geq 0$ и $p \geq 0$ и всех z выполнено $\|f(z)\|_2 \leq C(1 + \|z\|_2^p)$.

Проверка достаточности осуществляется непосредственно.

3. Построения и основной результат

Сформулируем ключевое наблюдение, лежащее в основе представляемых ниже конструкций.

Предложение 1. Пусть выполнены предположения **A.1–A.3**. Сопоставим паре $(\eta, y) \in \mathbf{R}^{n \times m} \times \mathbf{R}^m$ векторное поле

$$(12) \quad G_{(\eta, y)}(z) = \eta f(\eta^T z) - \eta y : \mathbf{R}^n \rightarrow \mathbf{R}^n.$$

Тогда для любого $x \in \mathcal{X}$ имеем

$$(13) \quad \begin{aligned} (a) \quad & \mathbf{E}_{(\eta, y) \sim P_x} \{ G_{(\eta, y)}(z) \} = F(z) - F(x) \quad \forall z \in \mathbf{R}^n \\ (b) \quad & \|F(z)\|_2 \leq M \quad \forall z \in \mathcal{X} \\ (c) \quad & \mathbf{E}_{(\eta, y) \sim P_x} \{ \|G_{(\eta, y)}(z)\|_2^2 \} \leq 4M^2 \quad \forall z \in \mathcal{X}. \end{aligned}$$

Доказательство. Пусть $x \in \mathcal{X}$. Тогда, пользуясь соотношением (9) и определением поля F , имеем

$$\mathbf{E}_{(\eta,y) \sim P_x} \{\eta y\} = \mathbf{E}_{\eta \sim Q} \left\{ \mathbf{E}_{\eta}^x \{\eta y\} \right\} = \mathbf{E}_{\eta} \{ \eta f(\eta^T x) \} = F(x).$$

Отсюда получаем

$$\begin{aligned} \mathbf{E}_{(\eta,y) \sim P_x} \{G_{(\eta,y)}(z)\} &= \mathbf{E}_{(\eta,y) \sim P_x} \{ \eta f(\eta^T z) - \eta y \} = \\ &= \mathbf{E}_{(\eta,y) \sim P_x} \{ \eta f(\eta^T z) \} - F(x) = \\ &= \mathbf{E}_{\eta \sim Q} \{ \eta f(\eta^T z) \} - F(x) = F(z) - F(x); \end{aligned}$$

последнее неравенство следует из (13.a). Кроме того, для $x, z \in \mathcal{X}$ обозначим через P_{η}^z условное по η распределение величины z , индуцированное распределением P_z величины $(\eta, y) = \eta^T y$. С учетом того, что маргинальное распределение величины η , индуцированное распределением P_z , есть не что иное как Q , приходим к

$$\begin{aligned} \mathbf{E}_{(\eta,y) \sim P_x} \{ \|\eta f(\eta^T z)\|_2^2 \} &= \mathbf{E}_{\eta \sim Q} \{ \|\eta f(\eta^T z)\|_2^2 \} = \\ &= \mathbf{E}_{\eta \sim Q} \left\{ \|\mathbf{E}_{y \sim P_{\eta}^z} \{\eta y\}\|_2^2 \right\} \leq \quad \quad \quad [\text{поскольку } \mathbf{E}_{y \sim P_{\eta}^z} \{y\} = f(\eta^T z)] \\ &\leq \mathbf{E}_{\eta \sim Q} \left\{ \mathbf{E}_{y \sim P_{\eta}^z} \{ \|\eta y\|_2^2 \} \right\} = \quad \quad \quad [\text{по неравенству Йенсена}] \\ &= \mathbf{E}_{(\tilde{\eta}, y) \sim P_z} \{ \|\eta y\|_2^2 \} \leq M^2 \quad \quad \quad [\text{по } \mathbf{A.3}, \text{ поскольку } z \in \mathcal{X}]. \end{aligned}$$

В совокупности с соотношением $\mathbf{E}_{(\eta,y) \sim P_x} \{ \|\eta y\|_2^2 \} \leq M^2$, справедливым в соответствии с **A.3** (поскольку $x \in \mathcal{X}$), это влечет выполнение (13.b) и (13.c).

3.1. Основной результат

Напомним, что целью статьи является восстановление сигнала $x \in \mathcal{X}$ по наблюдениям (8). В предположениях **A.1–A.3** точка x есть корень монотонного векторного поля

$$(14) \quad G(z) = F(z) - F(x), \quad F(z) = \mathbf{E}_{\eta \sim Q} \{ \eta f(\eta^T z) \};$$

причем известно, что этот корень принадлежит множеству \mathcal{X} и он единствен, поскольку поле $G(\cdot)$ сильно монотонно на \mathcal{X} , равно как и поле $F(\cdot)$. Известно, что для заданного выпуклого компактного множества \mathcal{X} задача отыскания такого корня эффективно разрешима при наличии “оракула”, который, имея на входе точку $z \in \mathcal{X}$, выдает значение $G(z)$ поля в этой точке. Это не совсем та ситуация, которая здесь описана, поскольку поле G есть математическое ожидание случайного поля:

$$G(z) = \mathbf{E}_{(\eta,y) \sim P_x} \{ \eta f(\eta^T z) - \eta y \}$$

и заранее не известно, каково то распределение, по которому берется ожидание. Однако выборка из этого распределения доступна, причем выборочные

значения в точности и есть наблюдения (8); эти выборочные значения могут использоваться для аппроксимации поля G тем или иным способом с последующим применением этой аппроксимации для восстановления сигнала x . Два стандартных пути реализации этой простой идеи суть ВСА и СА, упоминавшиеся выше. Обсудим эти два метода применительно к ситуации, в которой находимся.

3.1.1. Оценивание: аппроксимация выборочным средним. Идея, лежащая в основе аппроксимации по выборочному среднему (ВСА), совершенно прозрачна: имея наблюдения (8), будем аппроксимировать неизвестное поле G его эмпирическим аналогом

$$G_{\omega K}(z) = \frac{1}{K} \sum_{k=1}^K [\eta_k f(\eta_k^T z) - \eta_k y_k].$$

По закону больших чисел при $K \rightarrow \infty$ эмпирическое поле $G_{\omega K}$ сходится к интересующему нас полю G , поэтому при некоторых необременительных условиях регулярности с большой вероятностью поле $G_{\omega K}$ будет равномерно на \mathcal{X} близко к полю G для достаточно больших значений K . Вследствие сильной монотонности G отсюда следует, что множество “почти нулей” поля $G_{\omega K}$ на \mathcal{X} будет близко к нулю x поля G , т.е. к сигналу, который и подлежит восстановлению. Вопрос теперь заключается в том, как правильно определить понятие “почти нуля” поля $G_{\omega K}$ на \mathcal{X} ⁴. В данной ситуации это удобно сделать исходя из понятия *слабого решения* вариационного неравенства (ВН) с монотонным оператором, определяемого (в данном конкретном случае) следующим образом.

Пусть $\mathcal{X} \subset \mathbf{R}^n$ — непустое выпуклое компактное множество и пусть $H(z): \mathcal{X} \rightarrow \mathbf{R}^n$ — монотонное векторное поле (т.е. $[H(z) - H(z')]^T [z - z'] \geq 0$ для всех $z, z' \in \mathcal{X}$). Вектор $z_* \in \mathcal{X}$ называется *слабым решением* вариационного неравенства, связанного с H, \mathcal{X} , если

$$H(z)^T (z - z_*) \geq 0 \quad \forall z \in \mathcal{X}.$$

Пусть $\mathcal{X} \subset \mathbf{R}^n$ — непустое выпуклое компактное множество и пусть H монотонно на \mathcal{X} . Хорошо известно, что

- ВН, связанное с H, \mathcal{X} (обозначим его через $\text{VI}(H, \mathcal{X})$), всегда имеет слабое решение. Ясно, что если $\bar{z} \in \mathcal{X}$ — корень H , то \bar{z} — слабое решение для $\text{VI}(H, \mathcal{X})$ ⁵.
- Если поле H непрерывно на \mathcal{X} , то любое слабое решение \bar{z} неравенства $\text{VI}(H, \mathcal{X})$ также является и *сильным решением* в том смысле, что

$$(15) \quad H^T(\bar{z})(z - \bar{z}) \geq 0 \quad \forall z \in \mathcal{X}.$$

⁴ Заметим, что “почти нуль” поля $G_{\omega K}$ на \mathcal{X} не может быть определен как корень $G_{\omega K}$ на этом множестве. Если у G действительно имеется корень, принадлежащий множеству \mathcal{X} , то у $G_{\omega K}$ такого корня может и не быть.

⁵ Если $\bar{z} \in \mathcal{X}$ и $H(\bar{z}) = 0$, то монотонность H влечет $H(z)^T [z - \bar{z}] = [H(z) - H(\bar{z})]^T [z - \bar{z}] \geq 0$ для всех $z \in \mathcal{X}$, т.е. \bar{z} — слабое решение для $\text{VI}(H, \mathcal{X})$.

Действительно, соотношение (15) очевидным образом выполнено для $z = \bar{z}$. При $z \neq \bar{z}$, положив $z_t = \bar{z} + t(z - \bar{z})$, $0 < t \leq 1$, имеем $H^T(z_t)(z_t - \bar{z}) \geq 0$ (так как \bar{z} является слабым решением), откуда $H^T(z_t)(z - \bar{z}) \geq 0$ (поскольку $z - \bar{z}$ кратно $z_t - \bar{z}$ с положительным множителем). Переходя к пределу при $t \rightarrow +0$ и вспоминая про непрерывность H , получаем желаемое $H^T(\bar{z})(z - \bar{z}) \geq 0$.

- Если H — градиентное поле непрерывно дифференцируемой выпуклой на \mathcal{X} функции (такое поле монотонно), слабые (или сильные, что в случае непрерывного H одно и то же) решения неравенства $\text{VI}(H, \mathcal{X})$ являются точками минимума функции на \mathcal{X} .

Заметим еще, что сильное решение неравенства $\text{VI}(H, \mathcal{X})$ с монотонным H всегда является и слабым решением: если $\bar{z} \in \mathcal{X}$ удовлетворяет условию $H^T(\bar{z})(z - \bar{z}) \geq 0$ при всех $z \in \mathcal{X}$, то и $H(z)^T(z - \bar{z}) \geq 0$ при всех $z \in \mathcal{X}$, поскольку вследствие монотонности имеем $H(z)^T(z - \bar{z}) \geq H^T(\bar{z})(z - \bar{z})$.

В дальнейшем будем существенно использовать следующий простой и хорошо известный факт.

Лемма 1. Пусть \mathcal{X} — выпуклое компактное множество и пусть H — монотонное векторное поле на \mathcal{X} с модулем монотонности $\varkappa > 0$, т.е.

$$[H(z) - H(z')]^T[z - z'] \geq \varkappa \|z - z'\|_2^2 \quad \forall z, z' \in \mathcal{X}.$$

Пусть также \bar{z} — слабое решение неравенства $\text{VI}(H, \mathcal{X})$. Тогда слабое решение $\text{VI}(H, \mathcal{X})$ единственно. Кроме того,

$$(16) \quad H^T(z)[z - \bar{z}] \geq \varkappa \|z - \bar{z}\|_2^2.$$

Доказательство. В условиях леммы положим $z \in \mathcal{X}$, и пусть \bar{z} есть слабое решение неравенства $\text{VI}(H, \mathcal{X})$ (помним, что оно существует!). Положив $z_t = \bar{z} + t(z - \bar{z})$ при $t \in (0, 1)$, получаем цепочку неравенств

$$H^T(z)[z - z_t] \geq H^T(z_t)[z - z_t] + \varkappa \|z - z_t\|^2 \geq \varkappa \|z - z_t\|^2,$$

первое из которых справедливо в силу сильной монотонности H , а второе следует из того, что величина $H^T(z_t)[z - z_t]$ кратна $H^T(z_t)[z_t - \bar{z}]$ с положительным коэффициентом. Последняя величина неотрицательна, поскольку \bar{z} является слабым решением исследуемого ВН. Таким образом, имеем $H^T(z)[z - z_t] \geq \varkappa \|z - z_t\|_2^2$ и, переходя к пределу при $t \rightarrow +0$, приходим к (16).

Для доказательства единственности слабого решения предположим, что помимо слабого решения \bar{z} имеется отличное от него слабое решение \tilde{z} , и положим $z' = \frac{1}{2}[\bar{z} + \tilde{z}]$. Поскольку \bar{z} и \tilde{z} — слабые решения, то обе величины $H^T(z')[z' - \bar{z}]$ и $H^T(z')[z' - \tilde{z}]$ должны быть неотрицательны, а поскольку в сумме они равны нулю, то каждое из них равно нулю. Поэтому, применяя (16) к $z = z'$, получаем $z' = \bar{z}$, откуда также и $\tilde{z} = \bar{z}$.

Вернемся теперь к исходной задаче оценивания. Пусть предположения **A.1–A.3** выполнены, так что векторные поля $G_{(\eta_k, y_k)}(z)$, определенные в (12),

а следовательно, и векторное поле $G_{\omega^K}(z)$ непрерывны и монотонны. При использовании ВСА было найдено слабое решение $\hat{x}(\omega^K)$ вариационного неравенства $\text{VI}(G_{\omega^K}, \mathcal{X})$ и принято в качестве ВСА-оценки сигнала x по наблюдениям (8). Поскольку векторное поле $G_{\omega^K}(\cdot)$ монотонно и его значения эффективно вычислимы — при условии, что таковым является f , — задача вычисления слабого решения ВН $\text{VI}(G_{\omega^K}, \mathcal{X})$ (точнее, очень хорошего приближения к нему) также является эффективно разрешимой (например, см. [17]). Хотя авторы не ставили перед собой такой задачи в настоящей работе, используя методологию из [16, 18–20] и дополняя предположения **A.1–A.3** необременительными условиями регулярности, можно доказать неасимптотическую верхнюю границу, например, для ожидаемой ошибки $\|\cdot\|_2^2$ ВСА-оценки как функцию размера выборки K и найти скорость, с которой эта верхняя граница сходится к нулю с ростом $K \rightarrow \infty$.

Рассмотрим ВСА-оценки в схеме логистической регрессии. Имеем $f(u) = (1 + e^{-u})^{-1}$ и

$$\begin{aligned} G_{(\eta_k, y_k)}(z) &= \left[\frac{\exp\{\eta_k^T z\}}{1 + \exp\{\eta_k^T z\}} - y_k \right] \eta_k, \\ G_{\omega^K}(z) &= \frac{1}{K} \sum_{k=1}^K \left[\frac{\exp\{\eta_k^T z\}}{1 + \exp\{\eta_k^T z\}} - y_k \right] \eta_k = \\ &= \frac{1}{K} \nabla_z \left[\sum_k (\ln(1 + \exp\{\eta_k^T z\}) - y_k \eta_k^T z) \right]. \end{aligned}$$

Иначе говоря, $G_{\omega^K}(z)$ является градиентным полем отрицательного логарифма эмпирического МП $\ell(z, \omega^K)$, см. (5). В результате слабые решения ВН $\text{VI}(G_{\omega^K}, \mathcal{X})$ дают в точности оптимальные решения задаче (5), т.е. *в схеме логистической регрессии ВСА-оценки есть оценки максимального правдоподобия $\hat{x}_{\text{ML}}(\omega^K)$* ⁶. С другой стороны, в примере для нелинейной схемы наи-

⁶ Заметим, что это явление специфично для модели логистической регрессии. То, что в этом случае ВСА-оценки совпадают с МП-оценками, объясняется тем, что логистическая сигмоида $f(s) = \exp\{s\}/(1 + \exp\{s\})$ удовлетворяет тождеству $f'(s) = f(s)(1 - f(s))$. При ее замене на $f(s) = \phi(s)/(1 + \phi(s))$ с дифференцируемой монотонно неубывающей положительной $\phi(\cdot)$ ВСА-оценка доставляет слабое решение вариационному неравенству $\text{VI}(\Phi, \mathcal{X})$ с

$$\Phi(z) = \sum_k \left[\frac{\phi(\eta_k^T z)}{1 + \phi(\eta_k^T z)} - y_k \right] \eta_k.$$

С другой стороны, градиентное поле *отрицательного* логарифма МП

$$-\frac{1}{K} \sum_k \left[y_k \ln(f(\eta_k^T z)) + (1 - y_k) \ln(1 - f(\eta_k^T z)) \right],$$

которое должно минимизироваться при отыскании МП-оценок, имеет вид

$$\Psi(z) = \sum_k \frac{\phi'(\eta_k^T z)}{\phi(\eta_k^T z)} \left[\frac{\phi(\eta_k^T z)}{1 + \phi(\eta_k^T z)} - y_k \right] \eta_k.$$

При $k > 1$ и неэкспоненциальной ϕ поля Φ и Ψ “существенно различны”; соответственно, ВСА-оценка, как правило, отлична от МП-оценки.

меньших квадратов, приведенном во введении, с монотонной (для простоты скалярной) функцией $f(\cdot)$ векторное поле $G_{\omega K}(\cdot)$ имеет вид

$$G_{\omega K}(z) = \frac{1}{K} \sum_{k=1}^K [f(\eta_k^T z) - y_k] \eta_k,$$

“существенно отличный” (при условии нелинейности f) от градиентного поля

$$\Psi(z) = \frac{2}{K} \sum_{k=1}^K f'(\eta_k^T z) [f(\eta_k^T z) - y_k] \eta_k$$

для МП (7). В результате в этом случае МП-оценка (7), вообще говоря, отличается от ВСА-оценки, но в отличие от МП-оценки ВСА-оценка гораздо проще с вычислительной точки зрения.

3.1.2. Оценивание: стохастическая аппроксимация. Оценки метода *стохастической аппроксимации* (СА) генерируются простым алгоритмом *субградиентного спуска* решения вариационного неравенства $\text{VI}(G, \mathcal{X})$. Если бы значения векторного поля $G(\cdot)$ были доступны, можно было бы аппроксимировать корень $x \in \mathcal{X}$ этого ВН, пользуясь рекурсией

$$z_k = \text{Proj}_{\mathcal{X}}[z_{k-1} - \gamma_k G(z_{k-1})], \quad k = 1, \dots, K,$$

где

- $\text{Proj}_{\mathcal{X}}[z]$ — метрическая проекция \mathbf{R}^n на \mathcal{X} :

$$\text{Proj}_{\mathcal{X}}[z] = \underset{u \in \mathcal{X}}{\text{argmin}} \|z - u\|_2;$$

- $\gamma_k > 0$ — заданная длина шага;
- начальное приближение z_0 — произвольная точка из \mathcal{X} .

Хорошо известно, что в предположениях **A.1–A.3** такая рекуррентная процедура с надлежащим выбором длины шага и начальной точкой из \mathcal{X} позволяет аппроксимировать корень поля G (на самом деле, также и любое слабое решение $\text{VI}(G, \mathcal{X})$) с произвольно высокой точностью, если K достаточно велико. Здесь, однако, имеем ситуацию, когда истинные значения поля G недоступны; стандартный способ преодоления этой трудности заключается в замене “ненаблюдаемых” значений $G(z_{k-1})$ поля G , присутствующих в рекуррентной процедуре, их несмещенными случайными оценками $G_{(\eta_k, y_k)}(z_{k-1})$. Такая модификация приводит к процедуре *стохастической аппроксимации* (восходящей к [21]) — рекурсии вида

$$(17) \quad z_k = \text{Proj}_{\mathcal{X}}[z_{k-1} - \gamma_k G_{(\eta_k, y_k)}(z_{k-1})], \quad 1 \leq k \leq K,$$

где z_0 — раз и навсегда выбранная точка из \mathcal{X} , а $\gamma_k > 0$ — детерминированные скалярные множители.

Анализ сходимости. Приводимый ниже результат очень хорошо известен; для полноты изложения приводим стандартное доказательство этого утверждения в Приложении.

Предложение 2. В предположениях **A.1–A.3** при выборе длины шага

$$(18) \quad \gamma_k = [\varkappa(k+1)]^{-1}, \quad k = 1, 2, \dots$$

для последовательности оценок $\widehat{x}_k(\omega^k) = z_k$ любого сигнала $x \in \mathcal{X}$, даваемой процедурой СА (17) с $\omega^k = (\eta_k, y_k)$, определенными в (8) для любого k , выполняется следующая оценка:

$$(19) \quad \mathbf{E}_{\omega^k \sim P_x^k} \left\{ \|\widehat{x}_k(\omega^k) - x\|_2^2 \right\} \leq \frac{4M^2}{\varkappa^2(k+1)}, \quad k = 0, 1, \dots,$$

где P_x — распределение пары (η, y) , обусловленное сигналом x .

3.2. Численный пример

Для иллюстрации изложенных выше построений приведем результаты некоторых численных экспериментов. Для наглядности рассматриваем простейшие ситуации, а именно:

- $\mathcal{X} = \{x \in \mathbf{R}^n : \|x\|_2 \leq R\}$;
- распределение Q регрессора η есть $\mathcal{N}(0, I_n)$;
- f — монотонное векторное поле на \mathbf{R} , задаваемое одним из следующих четырех способов:
 - A. $f(s) = \exp\{s\}/(1 + \exp\{s\})$;
 - B. $f(s) = s$;
 - C. $f(s) = \max[s, 0]$;
 - D. $f(s) = \min[1, \max[s, 0]]$.
- условное по η распределение y , индуцированное распределением P_x , есть
 - распределение Бернулли с вероятностью $f(\eta^T x)$ исхода единица в случае А (т.е. этот случай соответствует логистической модели),
 - гауссовское распределение $\mathcal{N}(f(\eta^T x), I_n)$ в случаях В–D.

Обратим внимание, что в рассматриваемом примере поле $F(z)$ легко вычисляется. Действительно, для всех $z \in \mathbf{R}^n$ имеем

$$\eta = \frac{zz^T}{\|z\|_2^2} \eta + \underbrace{\left(I_n - \frac{zz^T}{\|z\|_2^2} \right)}_{\eta_\perp} \eta$$

и в силу независимости $\eta^T z$ и η_\perp получаем

$$\begin{aligned} F(z) &= \mathbf{E}_{\eta \sim \mathcal{N}(0, I)} \{ \eta f(\eta^T z) \} = \mathbf{E}_{\eta \sim \mathcal{N}(0, I)} \left\{ \frac{zz^T \eta}{\|z\|_2^2} f(\eta^T z) \right\} = \\ &= \frac{z}{\|z\|_2} \mathbf{E}_{\zeta \sim \mathcal{N}(0, 1)} \{ \zeta f(\|z\|_2 \zeta) \}, \end{aligned}$$

т.е. $F(z)$ пропорционально $z/\|z\|_2$ с коэффициентом

$$h(\|z\|_2) = \mathbf{E}_{\zeta \sim \mathcal{N}(0, 1)} \{ \zeta f(\|z\|_2 \zeta) \}.$$

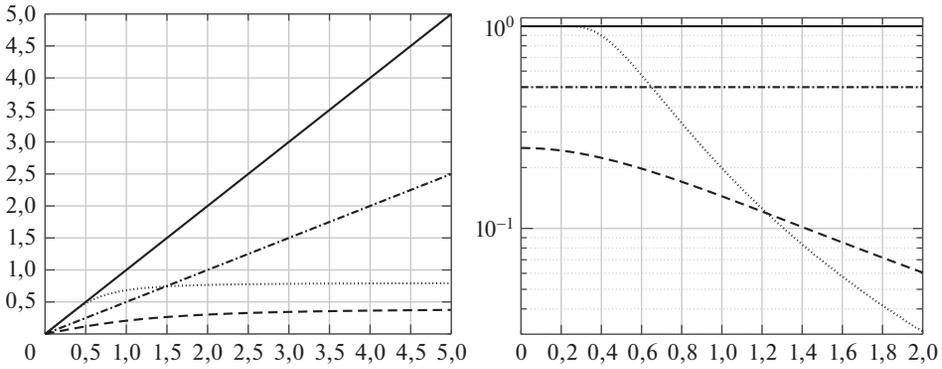


Рис. 1. Слева: функции h ; справа: модули сильной монотонности операторов $F(\cdot)$ на $\mathcal{X} = \{z : \|z\|_2 \leq R\}$ как функции R . Пунктирные линии — случай А, сплошные линии — случай В, штрих-пунктирные линии — случай С, точечные линии — случай D.

На рис. 1 представлены графики функции $h(t)$ для случаев А–D, а также зависимости модулей сильной монотонности соответствующих отображений F на шаре \mathcal{X} от радиуса R шара. Размерность n во всех экспериментах полагалась равной 100, а количество K наблюдений полагалось 400, 10^3 , $4 \cdot 10^3$, 10^4 и $4 \cdot 10^4$. Для каждой комбинации параметров проводилось 10 моделирований сигнала x , порождающего наблюдения (8), генерируемого случайно равномерно на единичной сфере (границе множества \mathcal{X}).

В каждом эксперименте вычислялись ВСА-оценки и СА-оценки (заметим, что в случаях А и В оценки, даваемые ВСА, совпадают с МП-оценками). Длина γ_k шага в СА выбиралась в соответствии с (18) при “эмпирическом” выборе величины \varkappa^7 . Точнее, полученные наблюдения $\omega_k = (\eta_k, y_k)$, $k \leq K$ (8) использовались для построения СА-оценок в два этапа:

— на *этапе настройки* генерировался случайный “обучающий сигнал” $x' \in \mathcal{X}$, после чего генерировались метки y'_k так, как если бы x' являлся истинным сигналом. Например, в случае А метке y'_k придавалось значение единица с вероятностью $q = f(\eta_k^T x')$ и ноль с вероятностью $1 - q$. После того как сгенерированы “обучающий сигнал” и соответствующие метки, к полученным искусственным наблюдениям применялась схема СА с различными значениями \varkappa , вычислялась точность полученных оценок и выбиралось то значение \varkappa , которое приводит к наилучшему восстановлению сигнала;

— на *этапе исполнения* алгоритм СА прогонялся на фактических данных с шагом (18), определяемым тем значением \varkappa , которое было найдено на этапе настройки.

Результаты некоторых численных экспериментов представлены на рис. 2.

Подчеркнем, что время вычислений включает в себя оба этапа. Вывод из результатов экспериментов таков: будучи лишь немногим лучше СА по ка-

⁷ Для величины модуля сильной монотонности векторных полей $F(\cdot)$ могут быть аналитически получены нижние границы, однако это требует немалых усилий, а границы оказываются консервативными.

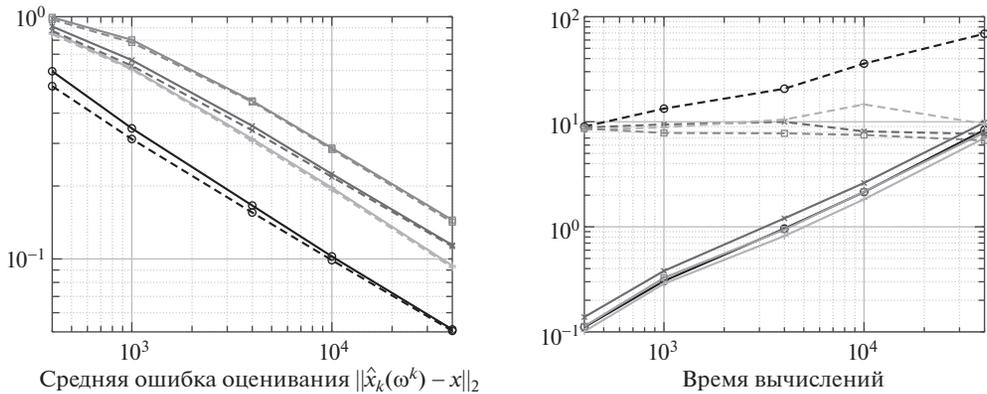


Рис. 2. Численные результаты: средние ошибки и время вычислений для СА-оценок (сплошная линия) и ВСА-оценок (пунктирная линия). о — случай А, × — случай В, + — случай С, □ — случай D.

честву оценивания, ВСА значительно проигрывает ему по времени исполнения. Заметим также, что наблюдаемая в экспериментах зависимость ошибок восстановления от размера K выборки соответствует скорости сходимости $O(1/\sqrt{K})$, установленной в предложении 2.

4. Случай “одного наблюдения”

Исследуем один специальный случай задачи оценивания, в котором последовательность η_1, \dots, η_K регрессоров в (8) детерминированная. На первый взгляд, такая формулировка не укладывается в рамки рассматриваемой здесь общей постановки, в которой регрессоры предполагаются случайными независимыми, одинаково распределенными, выбираемыми из некоторого распределения Q . Однако имеется возможность обойти это “противоречие”, считая, что находимся в ситуации с *одним наблюдением*, где регрессором является матрица $[\eta_1, \dots, \eta_K]$, а Q — вырожденное одноточечное распределение. Конкретно, пусть имеем наблюдение

$$(20) \quad \omega = (\eta, y) \in \mathbf{R}^{n \times mK} \times \mathbf{R}^{mK}$$

(m, n, K — известные натуральные числа), а распределение P_x наблюдений, порожденных сигналом $x \in \mathbf{R}^n$, имеет следующую форму:

- η — заданная детерминированная матрица, не зависящая от x ;
- метка y случайна, и распределение y , индуцированное распределением P_x , имеет среднее $\phi(\eta^T x)$, где $\phi: \mathbf{R}^{mK} \rightarrow \mathbf{R}^{mK}$ — некоторое заданное отображение.

В качестве информативного примера, связывающего рассматриваемую постановку с предыдущей, приведем конструкцию, в которой $\eta = [\eta_1, \dots, \eta_K]$ с $n \times m$ детерминированными “индивидуальными регрессорами” η_k , $y = [y_1; \dots; y_K]$, имеющими “индивидуальные метки” $y_k \in \mathbf{R}^m$, которые условно (при данном x) независимы по k и такими, что математические ожидания y_k ,

индуцированные сигналом x , имеют вид $f(\eta_k^T x)$ для некоторой $f : \mathbf{R}^m \rightarrow \mathbf{R}^m$. Положим $\phi([u_1; \dots; u_K]) = [f(u_1); \dots; f(u_K)]$. Полученная модель “одного наблюдения” представляет собой естественный аналог модели K наблюдений, которая и рассматривалась до сих пор. Единственная разница состоит в том, что индивидуальные регрессоры теперь образуют детерминированную последовательность, не являясь выборкой некоторой случайной матрицы.

Как и повсюду, в настоящей работе цель — использовать наблюдения (20) для восстановления неизвестного сигнала x , порождающего, как объяснено выше, распределение наблюдения. Формально находимся в ситуации $K = 1$ в исходной задаче восстановления, в которой носителем распределения Q является точка $\{\eta\}$, поэтому можем пользоваться всеми предложенными ранее конструкциями. Конкретно:

- векторное поле $F(z)$, соответствующее задаче, имеет вид

$$F(z) = \eta\phi(\eta^T z)$$

(ранее было $\mathbf{E}_{\eta \sim Q}\{\eta f(\eta^T z)\}$), а векторное поле $G(z) = F(z) - F(x)$, где x — сигнал, породивший наблюдение (20), имеет вид

$$G(z) = \mathbf{E}_{(\eta, y) \sim P_x}\{F(z) - \eta y\}$$

(ср. с (14)). Как и ранее, восстанавливаемый сигнал является нулем этого поля $G(\cdot)$. Обратим внимание на то, что теперь векторное поле $F(z)$ наблюдаемо, а векторное поле G по-прежнему является математическим ожиданием (по P_x) наблюдаемого векторного поля:

$$G(z) = \mathbf{E}_{(\eta, y) \sim P_x}\{\underbrace{\eta\phi(\eta^T z) - \eta y}_{G_y(z)}\},$$

ср. с леммой 1.

- предположения **A.1–A.2** теперь принимают следующий вид.

A.1’. Векторное поле $\phi(\cdot) : \mathbf{R}^{mK} \rightarrow \mathbf{R}^{mK}$ непрерывно и монотонно, так что $F(\cdot)$ также непрерывно и монотонно.

A.2’. Множество \mathcal{X} непусто, компактно и выпукло, а поле F сильно монотонно на \mathcal{X} с модулем $\varkappa > 0$.

Простым достаточным условием выполнения приведенных выше условий монотонности является положительная определенность матрицы $\eta\eta^T$ в совокупности с сильной монотонностью ϕ на любом ограниченном множестве.

- Предположение **A.3** удобно переписать в следующей эквивалентной форме:

A.3’. Для надлежащим образом выбранного $\sigma \geq 0$ и всякого $x \in \mathcal{X}$ справедливо

$$\mathbf{E}_{(\eta, y) \sim P_x}\{\|\eta[y - \phi(\eta^T x)]\|_2^2\} \leq \sigma^2.$$

Теперь в новой постановке ВСА-оценка $\hat{x}(y)$ является единственным слабым решением ВН VI(G_y, \mathcal{X}), а качество этой оценки дается следующим утверждением.

Предложение 3. Пусть в рассматриваемой ситуации выполнены предположения **A.1'–A3'**. Тогда для всякого $x \in \mathcal{X}$ и любой реализации соответствующих наблюдений (η, y) (20) справедливо

$$(21) \quad \|\hat{x}(y) - x\|_2 \leq \varkappa^{-1} \underbrace{\|\eta[y - \phi(\eta^T x)]\|_2}_{\Delta(x,y)},$$

откуда также следует

$$(22) \quad \mathbf{E}_{(\eta,y) \sim P_x} \{\|\hat{x}(y) - x\|_2^2\} \leq \sigma^2 / \varkappa^2.$$

Доказательство. Пусть $x \in \mathcal{X}$ — сигнал, породивший наблюдения (20) и пусть $G(z) = F(z) - F(x)$ — соответствующее векторное поле G . Имеем

$$\begin{aligned} G_y(z) &= F(z) - \eta y = F(z) - F(x) + [F(x) - \eta y] = \\ &= G(z) - \eta[y - \phi(\eta^T x)] = G(z) - \Delta(x, y). \end{aligned}$$

При фиксированном y точка $\bar{z} = \hat{x}(y)$ является слабым, а, следовательно, и сильным (так как $G_y(\cdot)$ непрерывно) решением ВН VI(G_y, \mathcal{X}), что в силу $x \in \mathcal{X}$, влечет

$$0 \leq G_y^T(\bar{z})[x - \bar{z}] = G^T(\bar{z})[x - \bar{z}] - \Delta^T(x, y)[x - \bar{z}],$$

откуда

$$-G^T(\bar{z})[x - \bar{z}] \leq -\Delta^T(x, y)[x - \bar{z}].$$

Кроме того, $G(x) = 0$, откуда $G^T(x)[x - \bar{z}] = 0$, так что приходим к

$$[G(x) - G(\bar{z})]^T[x - \bar{z}] \leq -\Delta^T(x, y)[x - \bar{z}],$$

откуда также следует

$$\varkappa \|x - \bar{z}\|_2^2 \leq -\Delta^T(x, y)[x - \bar{z}],$$

поскольку наряду с F поле G сильно монотонно на \mathcal{X} с модулем \varkappa , а $x, \bar{z} \in \mathcal{X}$. Применяя неравенство Коши, приходим к (21).

Пример 1. Пусть $m = 1$, ϕ сильно монотонна на всем \mathbf{R}^K с модулем $\varkappa_\phi > 0$, а η в (20) выбирается случайно из “гауссовского ансамбля”, т.е. столбцы η_k матрицы η размера $n \times K$ — независимые случайные векторы с распределением $\mathcal{N}(0, I_n)$. Пусть шум в наблюдениях также гауссовский:

$$y = \phi(\eta^T x) + \lambda \xi, \quad \xi \sim \mathcal{N}(0, I_K).$$

Хорошо известно, что при $K/n \rightarrow \infty$ минимальное сингулярное значение $(n \times n)$ -матрицы $\eta \eta^T$ с большой вероятностью имеет порядок по крайней

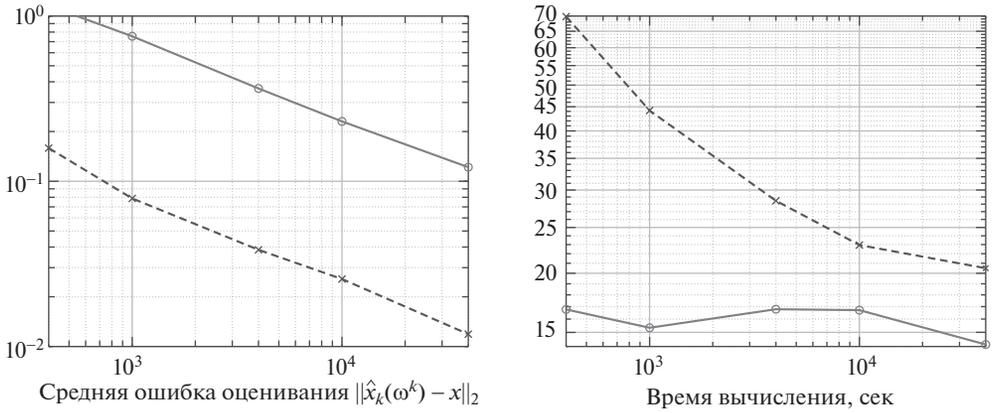


Рис. 3. Средние ошибки и время вычисления для стандартного отклонения $\lambda = 1$ (пунктир) и $\lambda = 0,1$ (сплошная линия).

мере $O(1)K$, откуда следует, что при $K/n \gg 1$ для величины модуля сильной монотонности поля $F(\cdot)$, “как правило”, верно $\varkappa \geq O(1)K\varkappa_\phi$. Более того, в ситуации при $K/n \rightarrow \infty$ фробениусова норма матрицы η с большой вероятностью имеет порядок не более $O(1)\sqrt{nK}$. Иными словами, для больших значений K/n задача восстановления по описанному выше ансамблю, “как правило”, удовлетворяет предположению 3 с $\varkappa = O(1)K\varkappa_\phi$ и $\sigma^2 = O(\lambda^2 nK)$. В результате (22) дает

$$\mathbf{E}_{(\eta,y) \sim P_x} \{ \|\hat{x}(y) - x\|_2^2 \} \leq O(1) \frac{\lambda^2 n}{\varkappa_\phi^2 K}, \quad [K \gg n].$$

Известно, что для стандартного случая линейной регрессии, где $\phi(x) = \varkappa_\phi x$, получающаяся граница почти оптимальна при условии, что \mathcal{X} достаточно велико.

Численная иллюстрация. В условиях рассмотренного выше примера положим $m = 1$, $n = 100$ и примем

$$\phi(u) = \arctan[u] := [\arctan(u_1); \dots; \arctan(u_K)] : \mathbf{R}^K \rightarrow \mathbf{R}^K.$$

Множество \mathcal{X} — единичный шар $\{x \in \mathbf{R}^n : \|x\|_2 \leq 1\}$. В конкретном эксперименте η выбиралась случайно из гауссовского ансамбля, как описано выше, сигнал $x \in \mathcal{X}$, порождающий наблюдения (20), выбирался случайно, помеха $y - \phi(\eta^T x)$ в наблюдении имеет распределение $\mathcal{N}(0, \lambda^2 I_K)$. Результаты 10 экспериментов для каждой комбинации размера выборки и дисперсии λ^2 шума представлены на рис. 3.

5. Заключение

Рассмотрен подход к восстановлению сигналов в обобщенных линейных моделях, основанный на сведении к решению стохастических вариационных

неравенств. Рассмотрены условия, при которых соответствующие ВН сильно монотонны. Показано, что в этом случае полученные оценки допускают верхнюю границу на конечном времени для ожидаемой ошибки в ℓ_2 -норме, сходящуюся к нулю со скоростью $O(1/K)$ с ростом числа K наблюдений.

ПРИЛОЖЕНИЕ

Доказательство предложения 2. Во-первых, заметим, что z_k являются детерминированными функциями $z_k = Z_k(\omega^k)$ “начальных фрагментов” $\omega^k = \{\omega_t, 1 \leq t \leq k\} \sim \underbrace{P_x \times \dots \times P_x}_{P_x^k}$ последовательности наблюдений

$\omega^K = \{\omega_k = (\eta_k, y_k), 1 \leq k \leq K\}$. Введем

$$D_k(\omega^k) = \frac{1}{2} \|Z_k(\omega^k) - x\|_2^2 = \frac{1}{2} \|z_k - x\|_2^2, \quad d_k = \mathbf{E}_{\omega^k \sim P_x^k} \{D_k(\omega^k)\},$$

где $x \in \mathcal{X}$ — сигнал, породивший наблюдения (8). Напомним, что метрическая проекция на замкнутое выпуклое множество \mathcal{X} является сжимающим отображением:

$$\forall (z \in \mathbf{R}^n, u \in \mathcal{X}) : \|\text{Proj}_{\mathcal{X}}[z] - u\|_2 \leq \|z - u\|_2.$$

Соответственно, при $1 \leq k \leq K$ имеем

$$\begin{aligned} D_k(\omega^k) &= \frac{1}{2} \|\text{Proj}_{\mathcal{X}}[z_{k-1} - \gamma_k G_{\omega_k}(z_{k-1}) - x]\|_2^2 \leq \\ &\leq \frac{1}{2} \|z_{k-1} - \gamma_k G_{\omega_k}(z_{k-1}) - x\|_2^2 = \\ &= \frac{1}{2} \|z_{k-1} - x\|_2^2 - \gamma_k G_{\omega_k}^T(z_{k-1})(z_{k-1} - x) + \frac{1}{2} \gamma_k^2 \|G_{\omega_k}(z_{k-1})\|_2^2. \end{aligned}$$

Беря математическое ожидание относительно $\omega^k \sim P_x^k$ от обеих частей полученного неравенства и учитывая соотношения (13) вместе с тем фактом, что $z_{k-1} \in \mathcal{X}$, получаем

$$(II.1) \quad d_k \leq d_{k-1} - \gamma_k \mathbf{E}_{\omega^{k-1} \sim P_x^{k-1}} \{G(z_{k-1})^T(z_{k-1} - x)\} + 2\gamma_k^2 M^2.$$

Поскольку в данном случае поле G сильно монотонно на \mathcal{X} с модулем $\varkappa > 0$, x является слабым решением ВН $\text{VI}(G, \mathcal{X})$, а z_{k-1} принимает значения в \mathcal{X} , то, привлекая (16), получаем, что величина математического ожидания в (II.1) равна по крайней мере $2\varkappa d_k$, и приходим к соотношению

$$(II.2) \quad d_k \leq (1 - 2\varkappa\gamma_k) d_{k-1} + 2\gamma_k^2 M^2.$$

Положим

$$S = \frac{2M^2}{\varkappa^2}, \quad \gamma_k = \frac{\varkappa S}{4M^2(k+1)} = \frac{1}{\varkappa(k+1)};$$

заметим, что γ_k есть в точности длины шагов в (18). Проверим по индукции по k , что соотношение

$$d_k \leq (k+1)^{-1}S \quad (*_k)$$

выполнено для $k = 0, 1, \dots, K$.

Основание индукции $k = 0$. Через D обозначим $\|\cdot\|_2$ -диаметр множества \mathcal{X} , и пусть $z_{\pm} \in \mathcal{Z}$ таково, что $\|z_+ - z_-\|_2 = D$. Согласно (13) имеем $\|F(z)\|_2 \leq M$ для всех $z \in \mathcal{X}$, а сильная монотонность поля $G(\cdot)$ на \mathcal{X} влечет

$$[G(z_+) - G(z_-)]^T [z_+ - z_-] = [F(z_+) - F(z_-)][z_+ - z_-] \geq \varkappa \|z_+ - z_-\|_2^2 = \varkappa D^2.$$

По неравенству Коши левая часть последнего неравенства не превосходит $2MD$, поэтому

$$D \leq \frac{2M}{\varkappa},$$

откуда $S \geq D^2/2$. С другой стороны, по определению d_0 имеем $d_0 \leq D^2/2$. Таким образом, $(*_0)$ выполнено.

Шаг индукции $(*_{k-1}) \Rightarrow (*_k)$. Предположим теперь, что $(*_{k-1})$ выполнено при некотором k , $1 \leq k \leq K$, и докажем, что $(*_k)$ также выполнено. Поскольку $\varkappa\gamma_k = (k+1)^{-1} \leq 1/2$, то

$$\begin{aligned} d_k &\leq d_{k-1}(1 - 2\varkappa\gamma_k) + 2\gamma_k^2 M^2 \leq \quad [\text{по (П.2)}] \\ &\leq \frac{S}{k}(1 - 2\varkappa\gamma_k) + 2\gamma_k^2 M^2 = \quad [\text{по } (*_{k-1}) \text{ и вследствие } \varkappa\gamma_k \leq 1/2] \\ &= \frac{S}{k} \left(1 - \frac{2}{k+1}\right) + \frac{S}{(k+1)^2} = \frac{S}{k+1} \left(\frac{k-1}{k} + \frac{1}{k+1}\right) \leq \frac{S}{k+1}, \end{aligned}$$

поэтому $(*_k)$ справедливо. Индукция закончена. Остается заметить, что по определению величины d_k имеем $d_k = \frac{1}{2}\mathbf{E}\{\|\hat{x}_k - x\|_2^2\}$.

СПИСОК ЛИТЕРАТУРЫ

1. Devroye L., Györfi L., Lugosi G. A Probabilistic Theory of Pattern Recognition (Stochastic Modelling and Applied Probability No. 31). N.Y.: Springer Sci. & Business Media, 2013.
2. Nelder J.A., Wedderburn R.W.M. Generalized Linear Models // J. Royal Statist. Soc., Ser. A (General). 1972. V. 135. No. 3. P. 370–384.
3. McCullagh P., Nelder J.A. Generalized Linear Models. Boca Raton: CRC Press, 1989.
4. Shapiro A., Dentcheva D., Ruszczyński A. Lectures on Stochastic Programming: Modeling and Theory. 2nd ed. Philadelphia: SIAM, 2014.
5. Robbins H., Monro S. A Stochastic Approximation Method // Ann. Math. Statist. 1951. V. 22. No. 3. P. 400–407.
6. Wolfowitz J. On the Stochastic Approximation Method of Robbins and Monro // Ann. Math. Statist. 1952. V. 23. No. 3. P. 457–461.

7. *Barndorff-Nielsen O.* Information and Exponential Families in Statistical Theory. N.Y.: Wiley, 1978.
8. *Feigin P.D.* Conditional Exponential Families and a Representation Theorem for Asymptotic Inference // *Ann. Statist.* 1981. V. 9. No. 3. P. 597–603.
9. *Rosenblatt F.* The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain // *Psychol. Rev.* 1958. V. 65. No. 6. P. 386–408.
10. *Block H.-D.* The perceptron: A model for brain functioning. I // *Rev. Modern Phys.* 1962. V. 134. No. 1. P. 123.
11. *Helmbold D.P., Warmuth M.K.* On Weak Learning // *J. Comput. Syst. Sci.* 1995. V. 50. No. 3. P. 551–573.
12. *Айзерман М.А., Браверман Э.М., Розоноэр Л.И.* Теоретические основы метода потенциальных функций в задаче об обучении автоматов разделению входных ситуаций на классы // *АИТ.* 1964. Т. 25. № 6. С. 917–936.
Aizerman M.A., Braverman E.M., Rozonoer L.I. Theoretical Foundations of the Potential Function Method in Pattern Recognition Learning // *Autom. Remote Control.* 1964. V. 25. No. 6. P. 821–837.
13. *Девятериков И.П., Пропой А.И., Цыпкин Я.З.* О рекуррентных алгоритмах обучения распознаванию образов // *АИТ.* 1967. № 1. С. 122–132.
Devvyaterikov I.P., Propoi A.I., Tsypkin Ya.Z. Iterative Learning Algorithms for Pattern Recognition // *Autom. Remote Control.* 1967. V. 28. No. 1. P. 108–117.
14. *Айзерман М.А., Браверман Э.М., Розоноэр Л.И.* Метод потенциальных функций в теории обучения машин. М.: Наука, 1970.
15. *Bousquet O., Boucheron S., Lugosi G.* Introduction to Statistical Learning Theory / Bousquet O., von Luxburg U., Rätsch G. (eds) *Advanced Lectures on Machine Learning. ML 2003. Lecture Notes in Computer Science*, vol 3176. Springer, Berlin, Heidelberg. P. 169–207.
16. *Sridharan K., Shalev-Shwartz S., Srebro N.* Fast Rates for Regularized Objectives // *Advances in Neural Information Proc. Syst.* No. 21. 2009. P. 1545–1552.
17. *Nemirovski A., Onn S., Rothblum U.* Accuracy Certificates for Computational Problems with Convex Structure // *Math. Oper. Res.* 2010. V. 35. No. 1. P. 52–78.
18. *Bousquet O., Elisseeff A.* Stability and Generalization // *J. Machine Learning Res.* 2002. V. 2. P. 499–526.
19. *Rakhlin A., Mukherjee S., Poggio T.* Stability Results in Learning Theory // *Anal. Appl.* 2005. V. 3. No. 4. P. 397–417.
20. *Shalev-Shwartz S., Shamir O., Srebro N., Sridharan K.* Stochastic Convex Optimization // *Conf. Learning Theory.* 2009.
21. *Kiefer J., Wolfowitz J.* Stochastic Estimation of the Maximum of a Regression Function // *Ann. Mat. Statist.* 1952. V. 23. No. 3. P. 462–466.

Статья представлена к публикации членом редколлегии А.В. Назинным.

Поступила в редакцию 19.07.2018

После доработки 12.09.2018

Принята к публикации 08.11.2019