

МИНИМАКСНОЕ ОЦЕНИВАНИЕ В НЕОПРЕДЕЛЕННО-СТОХАСТИЧЕСКИХ МОДЕЛЯХ ЛИНЕЙНОЙ РЕГРЕССИИ

Семенихин Константин Владимирович

Кафедра теории вероятностей
Факультет прикладной математики и физики
Московский авиационный институт

Пятая традиционная всероссийская молодежная летняя школа
«Управление, информация и оптимизация»
Солнечногорск, 17 июня 2013 г.

1 Постановка задачи оценивания

- Неопределенно-стохастическая модель линейной регрессии
- Минимаксный подход

2 Проблема оптимальности линейных оценок

- Равномерно оптимальные оценки
- Минимаксные оценки в гауссовском случае
- Минимаксные оценки при неизвестном распределении
- Случай ограниченных параметров

3 Синтез минимаксных линейных оценок

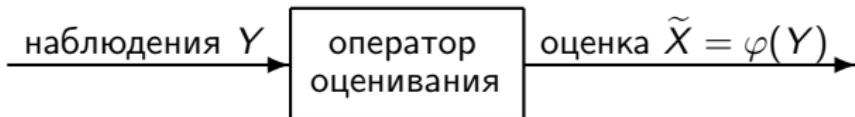
- Метод двойственной оптимизации
- Метод полуопределенного программирования

Постановка задачи оценивания

- Модель наблюдения — уравнения зависимости полезного сигнала X и наблюдений Y от параметров и возмущений + априорная информация: $\theta \in \Theta$, $\mathbf{P}_v \in \mathcal{P}_v$



- Допустимые операторы оценивания φ — доступные средства извлечения информации из данных эксперимента



- Критерий оценивания — правило выбора оператора оценивания на основе имеющейся априорной информации



Неопределенные системы

$$X = a\theta, \quad Y = A\theta + \varepsilon$$

неопределенные параметры $\theta \in \Theta$

неопределенные ошибки $\varepsilon \in E$

Статистические модели

$$X = a\theta, \quad Y = A\theta + \varepsilon$$

неопределенные параметры $\theta \in \Theta$

случайные ошибки $\varepsilon \sim P_\varepsilon$

Неопределенно-стохастические модели

$$X = a\theta + bv, \quad Y = A\theta + Bv$$

θ, v — векторы параметров,
возмущений, ошибок и т.д.

θ — неопределенный вектор: $\theta \in \Theta$

v — случайный вектор: $P_v \in \mathcal{P}_v$

Стохастические модели

$$X = a\xi, \quad Y = A\xi + \varepsilon$$

случайные параметры $\xi \sim P_\xi$

случайные ошибки $\varepsilon \sim P_\varepsilon$

Классы операторов оценивания и функционалы риска

Пусть $X = a\theta + bv \in \mathbb{R}^m$, $Y = A\theta + Bu \in \mathbb{R}^n$.

Классы операторов оценивания:

- \mathcal{B} содержит все борелевские отображения $\varphi: \mathbb{R}^n \rightarrow \mathbb{R}^m$;
- \mathcal{B}_0 состоит из несмешенных операторов, т.е.

$$\mathbf{E}_\theta\{\varphi(Y) - X\} = 0 \quad \forall \theta;$$

- \mathcal{L} содержит все линейные операторы $L: \mathbb{R}^n \rightarrow \mathbb{R}^m$;
- $\mathcal{L}_0 = \mathcal{L} \cap \mathcal{B}_0 = \{L \in \mathcal{L}: LA = a\}$ — класс
линейных несмешенных операторов оценивания,
выполнено условие идентифицируемости

$$\mathcal{L}_0 \neq \emptyset \iff \ker[A] \subseteq \ker[a] \iff aA^+A = a.$$

Функционал риска:

- $\mathfrak{J}_\theta(\varphi, \mathbf{P}_v) = \mathbf{E}_\theta|\varphi(Y) - X|^2$ — с.к. риск
($|\cdot|$ — евклидова норма).

Пусть \mathcal{F} — класс допустимых операторов оценивания.

Определение 1 (Оптимальный подход)

$\hat{X} = \hat{\varphi}(Y)$ — равномерно оптимальная оценка, если $\forall \varphi \in \mathcal{F}$

$$\mathfrak{J}_\theta(\hat{\varphi}, \mathbf{P}_v) \leq \mathfrak{J}_\theta(\varphi, \mathbf{P}_v) \quad \forall \theta \in \Theta \quad \forall \mathbf{P}_v \in \mathcal{P}_v.$$

Определение 2 (Минимаксный подход)

$\hat{X} = \hat{\varphi}(Y)$ — минимаксная оценка, если для любого $\varphi \in \mathcal{F}$

$$\sup_{\mathbf{P}_v \in \mathcal{P}_v} \sup_{\theta \in \Theta} \mathfrak{J}_\theta(\hat{\varphi}, \mathbf{P}_v) \leq \sup_{\mathbf{P}_v \in \mathcal{P}_v} \sup_{\theta \in \Theta} \mathfrak{J}_\theta(\varphi, \mathbf{P}_v).$$

Определение 3 (Минимаксно-асимптотический подход)

$\hat{X}^{(n)} = \hat{\varphi}^{(n)}(Y^{(n)})$ — минимаксно-асимптотическая оценка, если для любого $\varphi = \{\varphi^{(n)}\} \in \mathcal{F}$

$$\sup_{\mathbf{P}_v \in \mathcal{P}_v} \lim_{n \rightarrow \infty} n \mathfrak{J}_\theta(\hat{\varphi}^{(n)}, \mathbf{P}_v) \leq \sup_{\mathbf{P}_v \in \mathcal{P}_v} \lim_{n \rightarrow \infty} n \mathfrak{J}_\theta(\varphi^{(n)}, \mathbf{P}_v) \quad \forall \theta \in \Theta.$$

Пример 1 (Гауссовская регрессия)

Если совместное распределение оцениваемого вектора X и вектора наблюдений Y — гауссовское $\mathcal{N}\left(0, \begin{pmatrix} R_X & R_{XY} \\ R_{YX} & R_Y \end{pmatrix}\right)$, то линейная оценка $\hat{X} = R_{XY}R_Y^+Y$ оптимальна

на классе всех измеримых оценок $\tilde{X} = \varphi(Y)$, $\varphi \in \mathcal{B}$, так как $\hat{X} = \mathbf{E}\{X | Y\}$ по теореме о нормальной корреляции.

Пример 2 (Линейная регрессия при нормальных ошибках)

В модели $X = a\theta$, $Y = A\theta + \varepsilon$, где $\varepsilon \sim \mathcal{N}(0, R_\varepsilon)$, $R_\varepsilon \succ O$,

оценка Гаусса—Маркова $\hat{X} = a(A^*R_\varepsilon^{-1}A)^+A^*R_\varepsilon^{-1}Y$

равномерно оптимальна на классе всех несмешанных оценок $\tilde{X} = \varphi(Y)$, $\varphi \in \mathcal{B}_0$, в силу неравенства Рао—Крамера.

Равномерная оптимальность: вопрос

Вопрос

Как распространить результаты примеров 1 и 2 на случай обобщенной модели

$$\begin{cases} X = a\theta + \xi, \\ Y = A\theta + \eta, \end{cases} \quad \theta \in \mathbb{R}^p, \quad \begin{bmatrix} \xi \\ \eta \end{bmatrix} \sim \mathcal{N}\left(0, \begin{pmatrix} R_X & R_{XY} \\ R_{YX} & R_Y \end{pmatrix}\right) ?$$

Лемма 1 (Н.л.н. оценка в обобщенной модели)

Наилучшая линейная несмешенная (н.л.н.) оценка \hat{X} вектора X по вектору Y существует и имеет вид

- $\hat{X} = a\hat{\theta} + \hat{\xi}$,
- $\hat{\theta} = A^+[I - R_Y(QR_YQ)^+]Y$ — н.л.н. оценка вектора неопределенных параметров θ ,
 $Q = I - AA^+$ — ортопроектор на $\text{im}[A]^\perp$,
- $\hat{\xi} = R_{XY}(QR_YQ)^+Y = \mathbf{E}\{\xi | QY\}$,
где $QY = Y - AA^+Y$ — остаточный вектор.

Теорема 1

В модели наблюдения

$$\begin{cases} X = a\theta + \xi, \\ Y = A\theta + \eta, \end{cases} \quad \theta \in \mathbb{R}^p, \quad \begin{bmatrix} \xi \\ \eta \end{bmatrix} \sim \mathcal{N}\left(0, \begin{pmatrix} R_X & R_{XY} \\ R_{YX} & R_Y \end{pmatrix}\right)$$

наилучшая линейная несмешенная оценка \hat{X} является равномерно оптимальной на классе всех несмешенных оценок.

Лемма 2 (Критерий оптимальности)

Несмешенная оценка \hat{X} равномерно оптимальна тогда и только тогда, когда для всякой несмешенной оценки \tilde{X} выполнено

$$\mathbf{E}_\theta \langle \hat{X} - X, \hat{X} - \tilde{X} \rangle = 0 \quad \forall \theta \in \mathbb{R}^p.$$

Лемма 3 (Основная)

Ошибка наилучшей линейной несмешенной оценки $\Delta = \hat{X} - X$ и вектор наблюдений Y условно независимы относительно н.л.н. оценки $\hat{\theta}$ вектора неопределенных параметров θ .

Доказательство леммы. С помощью теоремы о нормальной корреляции вычисляем условную ковариацию $\text{cov}\{\Delta, Y | \hat{\theta}\} = \text{cov}\{\Delta, Y\} - \text{cov}\{\Delta, \hat{\theta}\}(\text{cov}\{\hat{\theta}, \hat{\theta}\})^+ \text{cov}\{\hat{\theta}, Y\} = O$.

Доказательство.

$$\mathbf{E}_\theta \langle \Delta, \hat{X} - \tilde{X} \rangle = \mathbf{E}_\theta \langle \mathbf{E}_\theta \{\Delta | \hat{\theta}\}, \mathbf{E}_\theta \{\hat{X} - \tilde{X} | \hat{\theta}\} \rangle = \dots$$

- Существует линейный оператор Λ : $\mathbf{E}_\theta \{\Delta | \hat{\theta}\} = \Lambda(\hat{\theta} - \theta)$.
- Найдется несмешенная оценка $\tilde{\theta}$: $\Lambda^* \mathbf{E}_\theta \{\hat{X} - \tilde{X} | \hat{\theta}\} = \hat{\theta} - \tilde{\theta}$.

$$\dots = \mathbf{E}_\theta \langle \hat{\theta} - \theta, \hat{\theta} - \tilde{\theta} \rangle = 0.$$

□

Пример 3 (Теорема Ходжеса—Лемана)

В модели $Y = A\theta + \varepsilon$, где θ — произвольный вектор из \mathbb{R}^p , $\varepsilon \sim \mathcal{N}(0, R_\varepsilon)$, $A^*A \succ O$, $R_\varepsilon \succ O$, оценка Гаусса—Маркова

$$\hat{\theta} = \hat{G}Y, \quad \hat{G} = (A^*R_\varepsilon^{-1}A)^{-1}A^*R_\varepsilon^{-1},$$

минимаксна на классе произвольных оценок:

$$\sup_{\theta \in \mathbb{R}^p} \mathbf{E}_\theta |\hat{\theta} - \theta|^2 \leq \sup_{\theta \in \mathbb{R}^p} \mathbf{E}_\theta |\tilde{\theta} - \theta|^2 \quad \forall \tilde{\theta}.$$

Доказательство. Оцениватель Гаусса—Маркова можно представить в виде предела байесовских оценивателей:

$$\hat{G} = \lim_{d \uparrow \infty} \hat{G}^{(d)}, \quad \hat{G}^{(d)} = (A^*R_\varepsilon^{-1}A + d^{-1}I)^{-1}A^*R_\varepsilon^{-1},$$

где $\hat{G}^{(d)}Y = \mathbf{E}^{(d)}\{\theta | Y\}$ вычисляется в предположении, что $\theta \sim \mathcal{N}(0, dI)$ и не зависит от ε .

Вопрос

Можно ли распространить теорему Ходжеса—Лемана на случай обобщенной модели

$$\begin{cases} X = a\theta + \xi, \\ Y = A\theta + \eta, \end{cases} \quad \theta \in \mathbb{R}^p, \quad v = \begin{bmatrix} \xi \\ \eta \end{bmatrix} \sim \mathcal{N}\left(0, \begin{pmatrix} R_X & R_{XY} \\ R_{YX} & R_Y \end{pmatrix}\right)$$

без требований о невырожденности матриц A^*A , R_Y и т.д.?

Теорема 2

Наилучшая линейная несмешенная оценка $\hat{X} = \hat{L}Y$ является минимаксной на классе произвольных оценок $\tilde{X} = \varphi(Y)$, $\varphi \in \mathcal{B}$:

$$\sup_{\theta \in \mathbb{R}^p} \mathfrak{J}_\theta(\hat{L}, \mathbf{P}_v) \leq \sup_{\theta \in \mathbb{R}^p} \mathfrak{J}_\theta(\varphi, \mathbf{P}_v) \quad \forall \varphi \in \mathcal{B},$$

где $\mathbf{P}_v = \mathcal{N}(0, R)$.

Лемма 4 (Гарантированный риск равен байесовскому риску)

Оценка \hat{X} будет минимаксной, если

$$\sup_{\theta \in \mathbb{R}^p} \mathbf{E}_\theta |\hat{X} - X|^2 = \sup_{\Pi \in \mathcal{P}_\theta} \mathbf{E}^{(\Pi)} |\hat{X}^{(\Pi)} - X|^2,$$

где Π — априорное распределение из некоторого класса \mathcal{P}_θ ,

$$\mathbf{E}^{(\Pi)} \{ \dots \} = \int \mathbf{E}_\theta \{ \dots \} \Pi(d\theta), \quad \hat{X}^{(\Pi)} = \mathbf{E}^{(\Pi)} \{ X | Y \}.$$

Положим $\mathcal{P}_\theta = \{\mathcal{N}(0, T) : T \succeq O\}$. Тогда

$$\sup_{\Pi \in \mathcal{P}_\theta} \mathbf{E}^{(\Pi)} |\hat{X}^{(\Pi)} - X|^2 = \sup_{T \succeq O} \min_{L \in \mathcal{L}} J(L, T),$$

где \mathcal{L} — класс линейных операторов оценивания L ,

$$J(L, T) = \text{tr}[(LA - a)T(LA - a)^* + R_X - 2LR_{YX} + LR_Y L^*].$$

В байесовской модели, где $\theta \sim \mathcal{N}(0, T)$, с.к. риск линейной оценки $\tilde{X} = LY$:

$$J(L, T) = \text{tr}[(LA - a)T(LA - a)^* + R_X - 2LR_{YX} + LR_YL^*].$$

В исходной модели, где θ — вектор неопределенных параметров, с.к. риск линейной оценки $\tilde{X} = LY$ ограничен

$$\sup_{\theta \in \mathbb{R}^p} \mathbf{E}_\theta |\tilde{X} - X|^2 = \sup_{\theta \in \mathbb{R}^p} J(L, \theta\theta^*) = \sup_{T \succeq O} J(L, T) < \infty$$

только если $\tilde{X} = LY$ — несмешенная оценка, т.е. $LA = a$.

Поэтому с.к. риск наилучшей линейной несмешенной оценки $\hat{X} = \hat{L}Y$ равен:

$$\sup_{\theta \in \mathbb{R}^p} \mathbf{E}_\theta |\hat{X} - X|^2 = \min_{L \in \mathcal{L}} \sup_{T \succeq O} J(L, T).$$

Для доказательства теоремы остается проверить:

$$\inf_{L \in \mathcal{L}} \sup_{T \succeq O} J(L, T) = \sup_{T \succeq O} \inf_{L \in \mathcal{L}} J(L, T), \quad (*)$$

- функция $J(L, T)$ — выпуклая по L и вогнутая по T ,
- переменные L, T пробегают выпуклые замкнутые, но неограниченные множества.

Теорема 3 (несимметричная теорема о минимаксе)

Равенство $(*)$ имеет место, если при любом T рецессивный конус функции $J(\cdot, T)$ образует линейное подпространство.

Рецессивный конус выпуклой функции

состоит из тех векторов, вдоль которых функция не возрастает.

$J(\cdot, T)$ — квадратичная \Rightarrow ее рецессивный конус — это ее ядро. \square

Минимаксная версия теоремы о нормальной корреляции

Пример 4 (V.D. Vandelinde (1977) IEEE TAC G. Schwarz (1987) JASA)

Пусть совместное распределение оцениваемого вектора X и вектора наблюдений Y принадлежит классу

$$\mathcal{P}(0, R) = \left\{ \mathbf{P}_v : \mathbf{E}v = 0, \text{cov}\{v, v\} = R = \begin{pmatrix} R_X & R_{XY} \\ R_{YX} & R_Y \end{pmatrix} \right\}.$$

В гауссовском случае линейная оценка $\hat{X} = \hat{\Lambda}Y$, $\hat{\Lambda} = R_{XY}R_Y^+$, будет байесовской \Rightarrow для любого оценивателя $\varphi \in \mathcal{B}$

$$\mathfrak{J}(\hat{\Lambda}, \hat{\mathbf{P}}_v) \leq \mathfrak{J}(\varphi, \hat{\mathbf{P}}_v), \quad \text{где } \hat{\mathbf{P}}_v = \mathcal{N}(0, R).$$

Но $\hat{\Lambda}$ — уравнивающая стратегия, так как для любого допустимого распределения $\mathbf{P}_v \in \mathcal{P}(0, R)$

$$\mathfrak{J}(\hat{\Lambda}, \mathbf{P}_v) = \mathfrak{J}(\hat{\Lambda}, \hat{\mathbf{P}}_v) = \text{tr}[R_X - R_{XY}R_Y^+R_{YX}].$$

Поэтому линейный оцениватель $\hat{\Lambda} = R_{XY}R_Y^+$ и гауссовское распределение $\hat{\mathbf{P}}_v = \mathcal{N}(0, R)$ дают седловую точку с.к. риска:

$$\mathfrak{J}(\hat{\Lambda}, \mathbf{P}_v) \leq \mathfrak{J}(\hat{\Lambda}, \hat{\mathbf{P}}_v) \leq \mathfrak{J}(\varphi, \hat{\mathbf{P}}_v) \quad \forall \varphi \in \mathcal{B} \quad \forall \mathbf{P}_v \in \mathcal{P}(0, R).$$

Вопрос

Пусть в модели $X = a\theta + bv$, $Y = A\theta + Bv$, $\theta \in \mathbb{R}^p$ случайный вектор v имеет любое распределение, такое что

$$\mathbf{E}v = 0, \quad \text{cov}\{v, v\} = R, \quad \text{т.е. } \mathbf{P}_v \in \mathcal{P}(0, R).$$

- Можно ли минимаксную оценку \hat{X} выбрать линейной?
- Что если матрица R априори принадлежит множеству \mathcal{R} ?

С.к. риск линейной несмешенной оценки $\tilde{X} = LY$, $L \in \mathcal{L}_0$:

$$J_\theta(L, \mathbf{P}_v) = J(L, R) = \text{tr}[(LB - b)R(LB - b)^*] \quad \forall \mathbf{P}_v \in \mathcal{P}(0, R) \quad \forall \theta.$$

Лемма 5 (Седловая точка в задаче линейного оценивания)

Если \mathcal{R} выпукло и компактно, то существуют линейный несмешенный оцениватель $\hat{L} \in \mathcal{L}_0$ и допустимая ковариационная матрица $\hat{R} \in \mathcal{R}$, образующие седловую точку

$$J(\hat{L}, R) \leq J(\hat{L}, \hat{R}) \leq J(L, \hat{R}) \quad \forall (L, R) \in \mathcal{L}_0 \times \mathcal{R}.$$



Теорема 4

Линейная минимаксная оценка $\hat{X} = \hat{L}Y$ является одновременно минимаксной на классе произвольных оценок:

$$\sup_{\mathbf{P}_v \in \mathcal{P}_v} \sup_{\theta \in \mathbb{R}^p} \mathfrak{J}_\theta(\hat{L}, \mathbf{P}_v) \leq \sup_{\mathbf{P}_v \in \mathcal{P}_v} \sup_{\theta \in \mathbb{R}^p} \mathfrak{J}_\theta(\varphi, \mathbf{P}_v) \quad \forall \varphi \in \mathcal{B}, \quad (**)$$

где $\mathcal{P}_v = \{\mathbf{P}_v : \mathbf{E} v = 0, \text{cov}\{v, v\} \in \mathcal{R}\}$.

Доказательство.

Если положить $\bar{\mathfrak{J}}(\varphi, \mathbf{P}_v) = \sup_{\theta \in \mathbb{R}^p} \mathfrak{J}_\theta(\varphi, \mathbf{P}_v)$ и $\hat{\mathbf{P}}_v = \mathcal{N}(0, \hat{R})$, то

«левое неравенство» $J(\hat{L}, R) \leq J(\hat{L}, \hat{R})$, $R \in \mathcal{R}$, принимает вид

$$\bar{\mathfrak{J}}(\hat{L}, \mathbf{P}_v) \leq \bar{\mathfrak{J}}(\hat{L}, \hat{\mathbf{P}}_v) \quad \forall \mathbf{P}_v \in \mathcal{P}_v.$$

Из теоремы 2 получаем «правое неравенство»

$$\bar{\mathfrak{J}}(\hat{L}, \hat{\mathbf{P}}_v) \leq \bar{\mathfrak{J}}(\varphi, \hat{\mathbf{P}}_v) \quad \forall \varphi \in \mathcal{B}.$$

Поэтому линейный оцениватель \hat{L} удовлетворяет (**). □



Пример 5 (Оценка Кукса—Ольмана)

Если в модели $Y = A\theta + \varepsilon$, где $\varepsilon \sim \mathcal{N}(0, R_\varepsilon)$, $R_\varepsilon \succ O$,

вектор параметров θ принадлежит эллипсоиду

$\Theta = \{\theta \in \mathbb{R}^p : \langle \Sigma\theta, \theta \rangle \leq 1\}$, то линейная минимаксная оценка \hat{x} скалярной величины $x = \langle c, \theta \rangle$ имеет явный вид

$$\hat{x} = \langle c, (A^* R_\varepsilon^{-1} A + \Sigma)^{-1} A^* R_\varepsilon^{-1} Y \rangle.$$

Вопросы

- ① Будет ли оценка Кукса—Ольмана минимаксной на классе всех возможных оценок?
- ② Будет ли это верно, если вектор ошибок ε имеет произвольное распределение, такое что

$$\mathbf{E}\varepsilon = 0, \quad \text{cov}\{\varepsilon, \varepsilon\} = R_\varepsilon, \quad \text{т.е.} \quad \mathbf{P}_\varepsilon \in \mathcal{P}(0, R_\varepsilon)?$$

Линейность минимаксных оценок: контрпримеры

Пример 6 ( G. Casella, W.E. Strawderman (1981) Ann. Stat., N.4)

Пусть $Y \sim \mathcal{N}(\theta, 1)$ — наблюдение, $\theta \in \Theta = [-r, r]$, $r < 1,05$.

Тогда нелинейная оценка $\hat{\theta} = r\text{th}(rY)$ — минимаксная,

а линейная оценка Кукса—Ольмана $\hat{\theta}^L = \frac{r^2 Y}{1 + r^2}$ — нет:

$$\sup_{\theta \in \Theta} \mathbf{E}_\theta (\hat{\theta} - \theta)^2 \approx 0.45 < 0.5 = \sup_{\theta \in \Theta} \mathbf{E}_\theta (\hat{\theta}^L - \theta)^2 \quad \text{при } r = 1.$$

Пример 7 ( D.L. Donoho (1994) Ann. Stat., N.1)

Пусть в модели $Y = A\theta + \varepsilon$, где $\varepsilon \sim \mathcal{N}(0, \sigma^2 I)$,

вектор параметров θ принадлежит выпуклому

центрально симметричному компакту $\Theta \subset \mathbb{R}^p$.

Если \hat{x} — минимаксная, а \hat{x}^L — минимаксная линейная оценка скалярной величины $x = \langle c, \theta \rangle$, то

$$1 < \sup_{\theta \in \Theta} \mathbf{E}_\theta (\hat{x}^L - x)^2 / \sup_{\theta \in \Theta} \mathbf{E}_\theta (\hat{x} - x)^2 < 1,25.$$

Линейность минимаксных оценок: пример

Пример 8

Пусть параметр $\theta \in \Theta = [-r, r]$ оценивается по $Y = \theta + \varepsilon$ с ошибкой, имеющей произвольный закон распределения, такой что $\mathbf{E}\varepsilon = 0$, $\mathbf{D}\varepsilon = 1$, т.е. $\mathbf{P}_\varepsilon \in \mathcal{P}(0, 1)$.

Тогда линейная оценка $\hat{\theta}^L = \frac{r^2 Y}{1 + r^2}$ будет минимаксной:

$$\sup_{\mathbf{P}_\varepsilon \in \mathcal{P}(0, 1)} \sup_{\theta \in \Theta} \mathbf{E}_\theta (\hat{\theta}^L - \theta)^2 \leq \sup_{\mathbf{P}_\varepsilon \in \mathcal{P}(0, 1)} \sup_{\theta \in \Theta} \mathbf{E}_\theta (\tilde{\theta} - \theta)^2 \quad \forall \tilde{\theta},$$

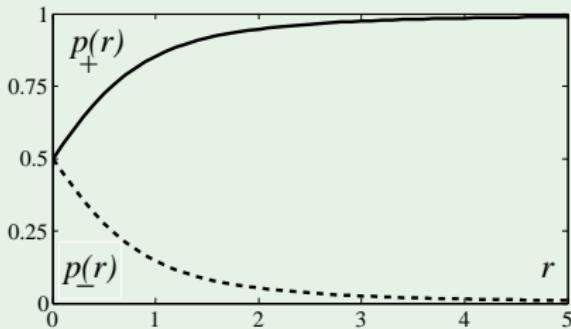
так как $\hat{\theta}^L$ — байесовская оценка, соответствующая наименее благоприятному распределению $\widehat{\mathbf{P}}$:

$$\widehat{\mathbf{P}}(\theta = \pm r) = 1/2,$$

$$\widehat{\mathbf{P}}(Y \in \{\pm\sqrt{1+r^2}\}) = 1,$$

$$\widehat{\mathbf{P}}(Y = \sqrt{1+r^2} \mid \theta = \pm r) =$$

$$= p_\pm(r) = \frac{1}{(\sqrt{1+r^2} \mp r)^2 + 1}.$$



Неопределенно-стохастическая модель наблюдения

$$X = a\theta + bv, \quad Y = A\theta + Bv, \quad \theta \in \mathbb{R}^p,$$

где вектор v имеет произвольное распределение с частично известными моментными характеристиками:

$$u = \mathbf{E}v \in \mathcal{U}, \quad R = \mathbf{cov}\{v, v\} \in \mathcal{R}.$$

Рассматриваются линейные оценки $\tilde{X} = LY$, такие что

$$L \in \mathcal{L}_0, \quad \text{т.е.} \quad LA = a.$$

С.к. риск не зависит от вектора неопределенных параметров θ :

$$J(L, K) = \text{tr}[(LB - b)K(LB - b)^*], \quad K \in \mathcal{K},$$

\mathcal{K} — множество допустимых матриц вторых моментов $\mathbf{E}\{vv^*\}$

$$\mathcal{K} = \{uu^* + R: u \in \mathcal{U}, R \in \mathcal{R}\}.$$

Задача минимаксного линейного оценивания

$$\hat{L} \in \arg \min_{L \in \mathcal{L}_0} \sup_{K \in \mathcal{K}} J(L, K).$$

Метод двойственной оптимизации

- 1 Решить задачу оптимального линейного оценивания:
 - найти оптимальный оператор $L_K \in \arg \min_{L \in \mathcal{L}_0} J(L, K)$
 - и двойственный функционал $\underline{J}(K) = \min_{L \in \mathcal{L}_0} J(L, K).$

Решить двойственную задачу $\hat{K} \in \arg \max_{K \in \mathcal{K}} \underline{J}(K).$

- 3 Построить минимаксный оператор в виде $\hat{L} = L_{\hat{K}}.$

Вопрос

Всегда ли этот метод приводит к искомому решению?



Пример 9

Пусть $Y_i = c_i \theta + \varepsilon_i$, $\theta \in \mathbb{R}$, $\mathbf{E} \varepsilon_i = 0$, $\mathbf{D} \varepsilon_i = 1$, $i = 1, \dots, n$, т.е.

$$\text{cov}\{\varepsilon, \varepsilon\} \in \mathcal{R} = \{R \succeq O : R_{ii} = 1, i = 1, \dots, n\}.$$

Задача минимаксного линейного оценивания:

$$\max_{R \in \mathcal{R}} \mathbf{D} \langle \lambda, Y \rangle = \|\lambda\|_1^2 = \left(\sum_{i=1}^n |\lambda_i| \right)^2 \longrightarrow \min_{\lambda : \langle \lambda, c \rangle = 1}.$$

Пусть i_0 : $|c_{i_0}| > |c_i| \forall i \neq i_0$, тогда получаем:

- минимаксную линейную оценку

$$\hat{\theta} = \langle \hat{\lambda}, Y \rangle = Y_{i_0} / c_{i_0},$$

- минимаксный риск

$$\hat{J} = \max_{R \in \mathcal{R}} \mathbf{D} \hat{\theta} = c_{i_0}^{-2} = \frac{1}{\max(c_1^2, \dots, c_n^2)}.$$

Метод двойственной оптимизации: контрпример

Пример 9 (продолжение)

Двойственная задача: $\underline{J}(R) = \min_{\lambda: \langle \lambda, c \rangle = 1} \mathbf{D} \langle \lambda, Y \rangle \longrightarrow \max_{R \in \mathcal{R}}.$

$$\underline{J}(R) = c^+ (R - R(QRQ)^+ R)(c^+)^* \leq c^+ R(c^+)^* = \dots$$

(здесь $Q = I - cc^+$). Положим $\hat{R} = c_{i_0}^{-2} cc^* \Rightarrow \hat{R} \in \mathcal{R} \Rightarrow$
 $\dots = |c|^{-4} \langle Rc, c \rangle \leq |c|^{-4} \langle \hat{R}c, c \rangle = c_{i_0}^{-2} = \hat{J}.$

$\implies \hat{R}$ — наименее благоприятная, но соответствующая оптимальная линейная оценка $\tilde{\theta}^o$ — неминимаксная:

$$\tilde{\theta}^o = c^+ [I - \hat{R}(Q\hat{R}Q)^+]Y = c^+ Y = \frac{c_1 Y_1 + \dots + c_n Y_n}{c_1^2 + \dots + c_n^2},$$

$$\max_{R \in \mathcal{R}} \mathbf{D} \tilde{\theta}^o = \|c^+\|_1^2 = \left(\frac{|c_1| + \dots + |c_n|}{c_1^2 + \dots + c_n^2} \right)^2 > \frac{1}{\max(c_1^2, \dots, c_n^2)} = \hat{J}.$$

Если $c_k = \frac{1}{k}$, то $\max_{R \in \mathcal{R}} \sqrt{\mathbf{D} \tilde{\theta}^o} \approx \frac{\ln n + \gamma}{\pi^2/6} \gg 1 = \sqrt{\hat{J}}$ при $n \sim \infty$.

Неопределенно-стохастическая модель наблюдения

$$X = a\theta + bv, \quad Y = A\theta + Bv, \quad \theta \in \mathbb{R}^p, \quad K = \mathbf{E}\{vv^*\} \in \mathcal{K}.$$

С.к. риск линейной несмешенной оценки $\tilde{X} = LY$, $L \in \mathcal{L}_0$:

$$\mathbf{E}|\tilde{X} - X|^2 = J(L, K) = \text{tr}[(LB - b)K(LB - b)^*] \quad \text{при} \quad K = \mathbf{E}\{vv^*\}.$$

Теорема 5

Если \mathcal{K} — компакт и в наименее благоприятном случае

$$\hat{K} \in \arg \max_{K \in \text{co}[\mathcal{K}]} \underline{J}(K), \quad \underline{J}(K) = \min_{L \in \mathcal{L}_0} J(L, K),$$

матрица $\mathbf{E}\{YY^*\}$ невырожденная, т.е. $B\hat{K}B^* \succ O$,

то соответствующий оптимальный оператор оценивания $L_{\hat{K}}$ будет минимаксным:

$$L_{\hat{K}} = \arg \min_{L \in \mathcal{L}_0} J(L, \hat{K}) \implies L_{\hat{K}} \in \arg \min_{L \in \mathcal{L}_0} \max_{K \in \mathcal{K}} J(L, K).$$

Кроме того, пара $L_{\hat{K}}, \hat{K}$ — седловая точка $J(\cdot)$ на $\mathcal{L}_0 \times \text{co}[\mathcal{K}]$.

1-й этап: оптимальное линейное оценивание

Пусть модель наблюдения

$$X = a\theta + bv, \quad Y = A\theta + Bu, \quad \theta \in \mathbb{R}^p, \quad K = \mathbf{E}\{uv^*\} \in \mathcal{K}.$$

регулярна, т.е. $K_Y = BKB^* \succ O \quad \forall K \in \mathcal{K}$.

- Оптимальный оператор оценивания:

$$L_K = \Lambda_K + (a - \Lambda_K A)G_K,$$

- $G_K = (A^* K_Y^{-1} A)^+ A^* K_Y^{-1}$ — оцениватель Гаусса—Маркова,
- $\Lambda_K = K_{XY} K_Y^{-1}$ — оцениватель из теоремы о нормальной корреляции.

Двойственный функционал:

$$\underline{J}(K) = \text{tr} [K_X - K_{XY} K_Y^{-1} K_{YX} + (a - \Lambda_K A)(A^* K_Y^{-1} A)^+ (a - \Lambda_K A)^*],$$

где $K_X = bKb^*$, $K_{XY} = bKB^*$, $K_Y = BKB^*$.

2-й этап: двойственная задача

Двойственная задача: $\hat{K} \in \arg \max_{K \in \mathcal{K}} \underline{J}(K), \quad \underline{J}(K) = \min_{L \in \mathcal{L}_0} J(L, K).$

Алгоритм 1 (Метод условного градиента)

- ① Положить $s := 0$ и выбрать $K^0 \in \mathcal{K}$.
- ② Определить оптимальный оператор $L^s = \arg \min_{L \in \mathcal{L}_0} J(L, K^s)$.
- ③ Найти наихудшую матрицу $\tilde{K}^s \in \arg \max_{K \in \mathcal{K}} J(L^s, K)$.
- ④ Вычислить $\delta^s = \underline{J}'(K^s)(\tilde{K}^s - K^s) = J(L^s, \tilde{K}^s - K^s) \geq 0$.
Если $\delta^s = 0$, то $\hat{L} := L^s, \hat{K} := K^s$ — седловая точка.
- ⑤ Найти величину шага $t^s \in \arg \max_{t \in [0,1]} \underline{J}(K^s + t(\tilde{K}^s - K^s))$;
- ⑥ Положить $K^{s+1} := K^s + t^s(\tilde{K}^s - K^s)$, $s := s + 1$ и перейти к шагу 1.

Теорема 6

Пусть множество \mathcal{K} выпукло и компактно и выполнено условие регулярности $K_Y = BKB^* \succ O \quad \forall K \in \mathcal{K}$.

- ❶ $\{L^s\}$ сходится к минимаксному оценивателю \hat{L} , а $\{K^s\}$ — к множеству решений двойственной задачи.
- ❷ Оценка погрешности в прямой и двойственной задачах:

$$\max_{K \in \mathcal{K}} J(L^s, K) - \hat{J} \leq \delta^s, \quad \Delta^s = \hat{J} - \underline{J}(K^s) \leq \delta^s,$$

(\hat{J} — минимаксный риск).

- ❸ Априорная оценка погрешности:

$$\Delta^s \leq \left(\frac{1}{\Delta^0} + \frac{s}{2 \max\{HD^2, \Delta^0\}} \right)^{-1} = O(1/s),$$

$$\|L^s - \hat{L}\|_2 \leq \left(\Delta^s / \min_{K \in \mathcal{K}} \sigma_{\min}[BKB^*] \right)^{1/2} = O(1/\sqrt{s}),$$

(H — константа Липшица $\nabla \underline{J}(\cdot)$ на \mathcal{K} , D — диаметр \mathcal{K}).

Задача полуопределенного программирования (SDP)

$$\langle c, x \rangle \rightarrow \min_{x \in \mathbb{R}^N} \quad \text{при ограничении} \quad \mathcal{A}(x) \succeq O,$$

заданы вектор $c \in \mathbb{R}^N$ и аффинно-линейное отображение \mathcal{A} из \mathbb{R}^N в пространство симметричным $M \times M$ матриц.

Для решения SDP есть пакеты, реализованные в MATLAB:

- SeDuMi:  J.F. Sturm (1999) Optim. Methods Software. N. 12.
- CVX:  M. Grant, S. Boyd (2011) <http://cvxr.com/cvx/download>

Лемма Шура

Для любых $A \succeq O$ и $B \succ O$ справедливо утверждение

$$A - \Gamma^* B^{-1} \Gamma \succeq O \iff \begin{bmatrix} A & \Gamma^* \\ \Gamma & B \end{bmatrix} \succeq O.$$

Пример 10 (Применение SDP к стохастической регрессии)

Пусть ковариационная матрица R оцениваемого вектора X и вектора наблюдений Y

$$R = \text{cov}\{v, v\} = \begin{pmatrix} R_X & R_{XY} \\ R_{YX} & R_Y \end{pmatrix}, \quad \text{где} \quad v = \begin{pmatrix} X \\ Y \end{pmatrix},$$

принадлежит множеству

$$\mathcal{R} = \{R \succeq O: |R_{ij} - R_{ij}^o| \leq \Delta_{ij} \ \forall i, j\}.$$

где R^o — некоторая опорная матрица.

Двойственная задача: $\text{tr}[R_X - R_{XY}R_Y^{-1}R_{YX}] \longrightarrow \max_{R \in \mathcal{R}}$.

Вводим новую переменную T и ограничение на нее:

$$T \preceq R_X - R_{XY}R_Y^{-1}R_{YX}, \quad \text{т.е.} \quad R_X - T - R_{XY}R_Y^{-1}R_{YX} \succeq O.$$

Тогда по лемме Шура двойственная задача — это SDP:

$$\text{tr}[T] \longrightarrow \max_R: \begin{pmatrix} R_X - T & R_{XY} \\ R_{YX} & R_Y \end{pmatrix} \succeq O, \quad |R_{ij} - R_{ij}^o| \leq \Delta_{ij} \ \forall i, j.$$



Вопросы и проблемы

- ① Исследовать проблему линейности минимаксных оценок в моделях, содержащих ограниченные параметры и случайные ошибки с неизвестным распределением.
- ② Как быть, если критерий не среднеквадратичный, а вероятностный, квантильный и т.д.?
- ③ Поиск менее консервативных минимаксных постановок.
- ④ Как применить SDP к решению задачи минимаксного оценивания в неопределенно-стохастических моделях с неограниченными параметрами?
- ⑤ Что даст SDP в моделях наблюдения с ограниченными параметрами?

Спасибо за внимание!