

Рисунок 9.1.

Сравнение погрешностей метода
Монте-Карло, обычного Квази
Монте-Карло и
модифицированного Квази
Монте-Карло для системы
уравнений на сетке.

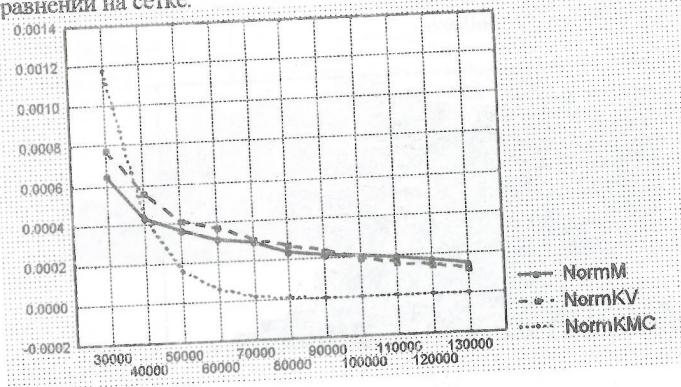
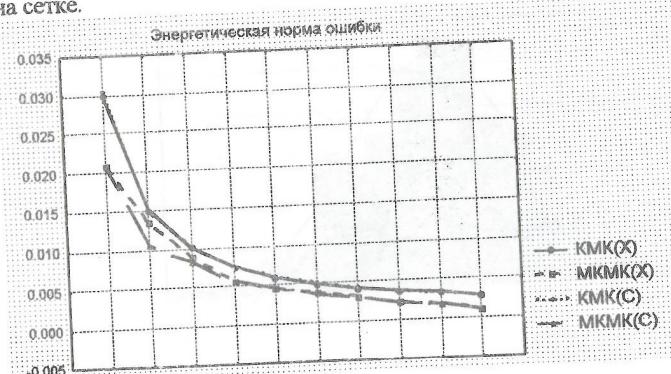


Рисунок 9.2

Сравнение погрешностей метода
КМК (Холтон), КМК (Соболь),
МКМК (Холтон), и МКМК
(Соболь) для системы уравнений
на сетке.



УДК 519.21

С.М. Ермаков, Т.И. Мисов

О МЕТОДАХ ТИПА "РЕСЕМПЛИНГ" В РЕГРЕССИОННОМ АНАЛИЗЕ

В регрессионных задачах важное место занимает проблема оценки систематической погрешности (адекватность модели). Общим методом ее решения является метод повторной выборки (ресемплинг). Мы рассмотрим подход (предложенный Ермаковым и Швабе), основанный на случайной выборке данных с помощью распределения Δ^2 . В работе изучаются различные методы моделирования дискретного распределения Δ^2 и проводится сравнительный анализ их использования в зависимости от параметров модели.

Известно, что в регрессионных задачах важное место занимает проблема оценки систематической погрешности (адекватность модели). Общим методом решения этих проблем является метод повторной выборки ("ресемплинг"). Мы рассмотрим подход, предложенный в работе [4] и основанный на случайной выборке данных с помощью Δ^2 -распределения.

Рассматривается линейная регрессионная модель вида

$$\xi_i = f(x_i) + \varepsilon_i, \quad i = 1, N,$$

где измерения производятся в точках $\{x_i\}_{i=1}^N \in X$, а относительно погрешностей $\{\varepsilon_i\}_{i=1}^N$ вводятся стандартные предположения:

$$E\varepsilon_i = 0; \quad E\varepsilon_i^2 = \sigma^2; \quad \text{cov}(\varepsilon_i, \varepsilon_j) = 0, \quad i \neq j$$

Рассмотрим дискретную меру μ , сосредоточенную с одинаковым весом в точках $\{x_i\}_{i=1}^N$, т.е. $\mu(x_1) = \dots = \mu(x_N) = \frac{1}{N}$.

Аппроксимируем f линейной комбинацией $\sum_{i=1}^m c_i \varphi_i$, где $\{\varphi_i\}_{i=1}^m$ линейно независимы на носителе меры μ . Тогда оценки метода наименьших квадратов \hat{c}_i коэффициентов c_i имеют вид ([4], с.3)

$$\hat{c}_i = \frac{\det \|(\varphi_1, \varphi_j), \dots, (\varphi_{i-1}, \varphi_j), (\xi, \varphi_j), (\varphi_{i+1}, \varphi_j), \dots, (\varphi_m, \varphi_j)\|_{j=1}^m}{\det \|(\varphi_k, \varphi_i)\|_{k,l=1}^m},$$

Работа выполнена при поддержке РФФИ (грант № 05.01.00865-а)
и гранта Президента РФ "Ведущие Научные Школы" НШ 2268.2003.1
© С.М. Ермаков, Т.И. Мисов, 2005

где $(\varphi_k, \varphi_l) = \frac{1}{N} \sum_{r=1}^N \varphi_k(x_r) \varphi_l(x_r)$, а $(\xi, \varphi_k) = \frac{1}{N} \sum_{r=1}^N \xi_r \varphi_k(x_r)$.

Если система функций $\{\varphi_i\}_{i=1}^m$ ортонормирована, то

$$\hat{c}_i = \frac{1}{N} \sum_{r=1}^N \xi_r \varphi_i(x_r)$$

Воспользовавшись теоремой Бине-Коши приходим к соотношению

$$\hat{c}_i = \frac{\sum_{1 \leq i_1 < \dots < i_m \leq N} \Delta_i(\xi, i_1, \dots, i_m) \Delta(i_1, \dots, i_m)}{\sum_{1 \leq i_1 < \dots < i_m \leq N} \Delta^2(i_1, \dots, i_m)},$$

где $\Delta_i(\xi, i_1, \dots, i_m) = \det \|\varphi_1(x_{i_j}), \dots, \varphi_{i-1}(x_{i_j}), \xi_{i_j}, \varphi_{i+1}(x_{i_j}), \dots, \varphi_m(x_{i_j})\|$, $j = \overline{1, m}$, а $\Delta(i_1, \dots, i_m) = \det \|\varphi_j(x_{i_k})\|_{j, k=1}^m$. Введем в точках x_{i_1}, \dots, x_{i_m} вероятностное распределение с плотностью

$$p(i_1, \dots, i_m) = \frac{\Delta^2(i_1, \dots, i_m)}{\sum_{1 \leq i_1 < \dots < i_m \leq N} \Delta^2(i_1, \dots, i_m)} \quad (1)$$

Это распределение называется *дискретным Δ^2 -распределением* (относительно меры $\mu^m = \otimes_{k=1}^m \mu$). Тогда случайная величина, определяемая соотношением

$$\chi_i = \chi_i(i_1, \dots, i_m) = \frac{\Delta_i(\xi, i_1, \dots, i_m)}{\Delta(i_1, \dots, i_m)},$$

является несмещенной оценкой \hat{c}_i , т.е. $E\chi_i = \hat{c}_i$.

В статье [4] доказана некорелированность величин χ_i и сосчитана их дисперсия. К тому же указан способ разделения случайной ошибки от систематической с помощью этих случайных величин.

1 Моделирование дискретного Δ^2 -распределения

Использование дискретного Δ^2 -распределения в задачах регрессионного анализа требует его моделирования. К этому вопросу можно подойти по-разному. С одной стороны применим метод обращения, который часто в случае моделирования дискретных распределений является предпочтительным. Однако из-за специфического вида плотности

$p(i_1, i_2, \dots, i_m)$ – она содержит определители m -ого порядка – применение метода обращения приводит к громоздким выкладкам. Этот вопрос исследован в [4]. Поэтому возникает идея применить метод отбора (в чистом виде) или предложенный в работах [3] и [5] (при исследовании вопроса о моделировании непрерывного распределения Δ^2) "метод условных плотностей", вычислить их трудоемкости и сравнить их с той, которая возникает при использовании метода обращения.

2 Метод обращения

Имеем дискретное распределение

$$\left\{ \begin{array}{l} (i_1, i_2, \dots, i_m) \\ p(i_1, i_2, \dots, i_m) \end{array} \right\}_{1 \leq i_1 < \dots < i_m \leq N},$$

для моделирования которого методом обращения нужно иметь в качестве входных данных, все C_N^m комбинаций (i_1, i_2, \dots, i_m) и соответствующие им вероятности $p(i_1, i_2, \dots, i_m)$, $1 \leq i_1 < \dots < i_m \leq N$. Заметим, что для вычисления всех вероятностей нужно сосчитать C_N^m определителей m -ого порядка, что является весьма трудоемкой процедурой.

Лемма 2.1 Трудоемкость моделирования дискретного Δ^2 -распределения методом обращения не превосходит

$$C_{inv} = \left(m - 1 + mNC_\varphi + C_N^m \frac{2m^3 + m + 6}{3} \right) + \log_2 C_N^m, \quad (2)$$

где C_φ – средняя трудоемкость моделирования любой из функций φ_i в какой бы ни было точке x_j , $i = \overline{1, m}$, $j = \overline{1, N}$.

Замечание 2.1 Если требуется промоделировать R векторов с Δ^2 -распределением, то трудоемкость этой процедуры не будет превышать

$$C_{inv} = \left(m - 1 + mNC_\varphi + C_N^m \frac{2m^3 + m + 6}{3} \right) + R \log_2 C_N^m.$$

Доказательство: Слагаемое $\log_2 C_N^m$ в (2) обусловлено применением метода обратной функции. Известно, что если моделировать дискретное распределение, например, дихотомией, то его трудоемкость есть двоичный логарифм от объема распределения.

Как хорошо известно (см. напр. [3]), трудоемкость вычисления квадрата определителя m -ого порядка не превосходит (а в случае, когда в нем нет ни одного нулевого элемента, и равна) $\frac{2m^3 + m + 3}{3}$.

К тому же, при вычислении вероятностей $p(i_1, i_2, \dots, i_m)$, $1 \leq i_1 < \dots < i_m \leq N$ нужно совершить $m - 1$ сложений в знаменателе и C_N^m делений.

Наконец, на вычисление функций $\varphi_i(x_j)$, $i = \overline{1, m}$, $j = \overline{1, N}$ отводится mNC_φ операций. Лемма доказана.

Как видно из (2), наибольший вклад в общую трудоемкость метода обращения вносит член $C_N^m \frac{2m^3+m+6}{3}$, связанный с вычислением C_N^m определителей m -ого порядка. Во избежание этой неприятной процедуры возникает идея об исследовании моделирования Δ^2 -распределения другими методами.

3 Использование метода отбора

Использование метода отбора при моделировании Δ^2 -распределения помогает избежать процедуру вычисления всех C_N^m определителей m -ого порядка. Недостаток этого метода применительно к дискретным распределениям состоит в том, что его трудоемкость большая: она является оценкой сверху производной Радона-Никодима исходного распределения по отношению к некоторому вспомогательному. Проблема заключается в том, что для дискретных распределений "хорошего", т.е. такого, что производная Радона-Никодима близка к единице, вспомогательного распределения не найти. Поэтому высказывание, что в общем случае метод отбора менее трудоемкий, чем метод обращения применительно к нашей задаче, будет неточным.

Укажем процедуру моделирования Δ^2 -распределения методом отбора и сосчитаем ее трудоемкость.

Алгоритм 3.1 Моделирование дискретного Δ^2 методом отбора

1) Получаем значение α_1 с помощью генератора случайных чисел ($0 \leq \alpha_1 \leq 1$). Присваиваем $i_1 \leftarrow \lceil N * \alpha_1 \rceil$, $i_1 \in \{1, \dots, N\}$.

2) Пусть заданы натуральные числа $k = 2$ и $j = 2$. Пока $j \leq m$, выполняется:

a) Получаем значение α_k с помощью генератора случайных чисел ($0 \leq \alpha_k \leq 1$).

b) Если $\lceil N * \alpha_k \rceil \neq \{i_1, \dots, i_{j-1}\}$, то полагаем $i_j = \lceil N * \alpha_k \rceil$, $j \leftarrow j + 1$, $k \leftarrow k + 1$.

Возвращаемся к 2) (проверяем условие выполнения цикла).

в) В противном случае полагаем $k \leftarrow k + 1$ и возвращаемся к а).

С помощью первых двух шагов алгоритма мы получаем набор (i_1, \dots, i_m) , $i_j \in \{1, \dots, N\}$, $i_j \neq i_l$, $j \neq l$. Сосчитаем трудоемкость получения этого набора (она зависит от количества α_k , которые получаем с помощью генератора случайных чисел). Условимся, что на вычисление $\lceil \cdot \rceil$ отводится 0 операций. Поскольку α_k - реализации равномерного распределения на отрезке $[0, 1]$, то $\lceil N \alpha_k \rceil$ принимает с одинаковой вероятностью $\frac{1}{N}$ каждое из значений $1, \dots, N$. Поэтому, для получения i_j необходимо сгенерировать в среднем $\frac{N}{N-j+1}$ штук α_k -ых, поскольку вероятность того, чтобы i_j не совпало с уже полученными до этого i_1, \dots, i_{j-1} равна $\frac{N-j+1}{N}$. Осталось еще упорядочить набор i_1, \dots, i_m по возрастанию элементов. Для этого, если использовать в качестве сортировки метод пузырька, понадобится совершить $\log_2 m$ операций. Итого, трудоемкость получения набора (i_1, \dots, i_m) равна

$$2 \frac{N^m}{N(N-1)\dots(N-m+1)} + \log_2 m = 2 \frac{N^m(N-m)!}{N!} + \log_2 m$$

Коэффициент 2 появляется за счет того, что при каждом получении α_k мы совершаляем умножение $N \alpha_k$.

3) Вычисляем значения каждой из функций $\varphi_1, \dots, \varphi_m$ в точках (i_1, \dots, i_m) . Для этого нужно совершить $m^2 C_\varphi$ операций, где C_φ определяется так же как и выше. Находим $MAX = \max_{i=1, m, j=1, N} |\varphi_i(x_j)|$. Вычисляем $\Delta^2(i_1, \dots, i_m)$ для полученного нами набора. Согласно неравенству Адамара

$$\Delta^2(i_1, \dots, i_m) \leq m^m (MAX)^{2m} =: M$$

4) Проводим сам отбор. Получаем значение β с помощью генератора случайных чисел ($0 \leq \beta \leq 1$). Если $\Delta^2(i_1, \dots, i_m) > M\beta$, процедура заканчивается, т.е. мы промоделировали вектор с Δ^2 -распределением. В противном случае повторяем 4).

Напомним, что M указывает сколько в среднем определителей m -ого порядка нужно сосчитать для того, чтобы промоделировать один вектор с Δ^2 -распределением. Как уже упоминалось, трудоемкость вычисления одного из них не превосходит $\frac{2m^3+m+3}{3}$. Наконец, напоминая, что на вычисление функций $\varphi_1, \dots, \varphi_m$ в точках x_{i_1}, \dots, x_{i_m} нужно совершить $m^2 C_\varphi$ операций, мы приходим к следующему утверждению:

Лемма 3.1 Трудоемкость моделирования дискретного Δ^2 -распределения методом отбора C_{rej} не превосходит

$$(\sqrt{m} \text{MAX})^{2m} \left(\frac{2m^3 + m + 3}{3} + m^2 C_\varphi + 2 \frac{N^m (N-m)!}{N!} + \log_2 m \right) \quad (3)$$

4 Использование условных плотностей

Для непрерывного Δ^2 -распределения (см. [3]) использование условных плотностей вместо чистого метода отбора заметно уменьшает трудоемкость. Рассмотрим его модификацию в дискретном случае, сосчитаем его трудоемкость и сравним при каких значениях трех параметров N (число точек, в которых сосредоточена дискретная мера μ), m (количество ортонормированных функций) и R (число репликаций, т.е. число векторов с Δ^2 -распределением, которые мы моделируем) стоит им пользоваться, т.е. в каких случаях мы выигрываем в трудоемкости по сравнению с чистым отбором и методом обращения.

Напомним, что "метод условных плотностей" (см. [3]) основан на том, что вместо того, чтобы моделировать само Δ^2 , мы моделируем каждую из условных плотностей в разложении Δ^2 по формуле условной вероятности. Укажем сначала вид безусловных плотностей.

Лемма 4.1 Безусловная плотность s -ого порядка ($s = \overline{1, m}$)

$$p(i_1, \dots, i_s) = \int_X p(i_1, \dots, i_m) \mu(dx_{s+1}) \dots \mu(dx_m) \quad (4)$$

имеет вид

$$p(i_1, \dots, i_s) = \frac{(m-s)!}{m! N^m} \sum_{1 \leq k_1 < \dots < k_s \leq m} \Delta_{k_1 \dots k_s}^2(i_1, \dots, i_s),$$

где $\Delta_{k_1 \dots k_s}(i_1, \dots, i_s) = \det \|\varphi_{k_1}(x_{i_1}), \dots, \varphi_{k_s}(x_{i_s})\|_{l=1}^s$.

Доказательство: Согласно лемме [2], с.194:

$$\sum_{1 \leq i_1 < i_2 < \dots < i_m \leq N} \Delta^2(i_1, i_2, \dots, i_m) = m! N^m \det \left\| \frac{1}{N} \sum_{i=1}^N \varphi_k(x_i) \varphi_l(x_i) \right\|_{k,l=1}^m$$

Поскольку функции $\varphi_1, \dots, \varphi_m$ ортонормированы в $L^2(X, \mu)$, последний определитель равен единице и, следовательно,

$$\sum_{1 \leq i_1 < i_2 < \dots < i_m \leq N} \Delta^2(i_1, i_2, \dots, i_m) = m! N^m.$$

Заметим, что в силу дискретного характера меры μ (4) перепишется в виде

$$\begin{aligned} p(i_1, \dots, i_s) &= \frac{1}{N^{m-s}} \sum_{i_{s+1}=1}^N \dots \sum_{i_m=1}^N p(i_1, \dots, i_m) = \\ &= \frac{1}{N^{m-s}} \sum_{i_{s+1}=1}^N \dots \sum_{i_m=1}^N \frac{\Delta^2(i_1, \dots, i_m)}{m! N^m}. \end{aligned} \quad (5)$$

Рассмотрим

$$\sum_{i_m=1}^N \Delta^2(i_1, \dots, i_m) = \sum_{i_m=1}^N \left((-1)^{m+i_m} \sum_{j_1=1}^m \varphi_{j_1}(x_{i_m}) \Delta_{(j_1)}(i_1, \dots, i_{m-1}) \right)^2,$$

где

$$\Delta_{(j_1)}(i_1, \dots, i_{m-1}) = \det \|\varphi_{j_1}(x_{i_1}), \dots, \varphi_{j_1}(x_{i_{m-1}})\|_{l=1}^{m-1}.$$

В силу ортонормированности системы $\varphi_1, \dots, \varphi_m$ на $L^2(X, \mu)$, т.е.

$$\frac{1}{N} \sum_{i_m=1}^N \varphi_k^2(x_{i_m}) = 1, \quad k = \overline{1, m},$$

получаем

$$\sum_{i_m=1}^N \Delta^2(i_1, \dots, i_m) = N \sum_{j_1=1}^m \Delta_{(j_1)}^2(i_1, \dots, i_{m-1})$$

Далее

$$\begin{aligned} &\sum_{i_{m-1}=1}^m \sum_{i_m=1}^N \Delta^2(i_1, \dots, i_m) = \\ &= N \sum_{j_1=1}^m \sum_{i_{m-1}=1}^N \left((-1)^{m-1+i_{m-1}} \sum_{j_2=1}^{m-1} \varphi_{j_2}(x_{i_{m-1}}) \Delta_{(j_1, j_2)}(i_1, \dots, i_{m-2}) \right)^2, \end{aligned}$$

т.е.

$$\sum_{i_{m-1}=1}^N \sum_{i_m=1}^N \Delta^2(i_1, \dots, i_m) = 2N^2 \sum_{j_1=1}^m \sum_{j_2=1}^{m-1} \Delta_{(j_1, j_2)}^2(i_1, \dots, i_{m-2}),$$

где $\Delta_{(j_1, j_2)}(i_1, \dots, i_{m-2})$ получается из $\Delta(i_1, \dots, i_m)$ вычеркиванием последних двух строк и столбцов с номерами j_1 и j_2 . Множитель 2 возникает в силу того, что в верхней сумме возникает $m(m-1)$ слагаемых, содержащих всевозможные определители $(m-2)$ -ого порядка (всего определителей $(m-2)$ -ого порядка $C_m^{m-2} = \frac{1}{2}m(m-1)$ и каждый из них встречается в сумме 2 раза).

Рассуждая тем же самым образом относительно остальных сумм в (5), получим

$$\sum_{i_{s+1}=1}^N \dots \sum_{i_m=1}^N \Delta^2(i_1, \dots, i_m) = (m-s)! N^{m-s} \sum_{1 \leq j_1 < \dots < j_{m-s} \leq m} \Delta_{(j_1, \dots, j_{m-s})}^2(i_1, \dots, i_s),$$

где $\Delta_{(j_1, \dots, j_{m-s})}^2(i_1, \dots, i_s)$ получается из $\Delta^2(i_1 \dots i_m)$ вычеркиванием последних s строк и столбцов с номерами j_1, \dots, j_{m-s} . Осталось обозначить дополнение индексов (j_1, \dots, j_{m-s}) до $(1, \dots, m)$ через (k_1, \dots, k_s) . Лемма доказана.

Следствие 4.1 Условная плотность s -ого порядка $p(i_s | i_1 \dots i_{s-1})$, $s = \overline{2, m}$, имеет вид

$$p(i_s | i_1 \dots i_{s-1}) = \frac{\sum_{1 \leq k_1 < \dots < k_s \leq m} \Delta_{k_1 \dots k_s}^2(i_1, \dots, i_s)}{(m-s+1) \sum_{1 \leq j_1 < \dots < j_{s-1} \leq m} \Delta_{j_1 \dots j_{s-1}}^2(i_1, \dots, i_{s-1})}$$

Доказательство: Нужно лишь представить условную плотность в виде отношения двух безусловных

$$p(i_s | i_1 \dots i_{s-1}) = \frac{p(i_1, \dots, i_s)}{p(i_1, \dots, i_{s-1})}$$

и сослаться на лемму 4.1. Следствие доказано.

Поскольку условные плотности в дискретном случае имеют абсолютно тот же вид, что и в непрерывном случае (см. [3]), они тем же самым образом представимы в виде смеси распределений с коэффициентами, считающимися итеративным образом. Поэтому и трудоемкость

моделирования в этом случае C_{cond} не будет превосходить сосчитанной в [3] величины

$$\text{MAX}^2 \left(\frac{C_\varphi + 2}{2} m^2 - \frac{C_\varphi + 8}{2} m - 3 + (m+4)2^{m-1} + \log_2 \prod_{k=2}^{m-1} C_m^k \log_2 C_N^m \right) \quad (6)$$

5 Сравнение трудоемкостей указанных методов

Сравним полученные трудоемкости (2), (3) и (6) методов обращения, отбора и условных плотностей соответственно. Напомним, что это сравнение ведется в зависимости от значений трех параметров модели – N (числа точек, в которых сосредоточена дискретная мера μ), m (количества ортонормированных функций) и R (числа репликаций).

Заметим, что в (2) определяющим является член $C_N^m \frac{2m^3+m+6}{3}$, в (3) – это m^m , а в (6) – $(m+4)2^{m-1}$. Таким образом, с ростом N (при фиксированном m) трудоемкость метода обращения заметно возрастает, в отличии от трудоемкостей методов отбора и условных плотностей, которые слабо зависят от N . Так, например, при $m = 5$, $R = 1$ и $C_\varphi = 10$ методом обращения выгоднее пользоваться (по сравнению с методом отбора) до $N = 19$. Если же $m = 10$, $R = 1$, а $C_\varphi = 10$, то обращением стоит пользоваться до $N = 54$. Эти результаты получены в предположении, что мы не учитываем множитель MAX^{2m} в (3). В обоих случаях, однако, наименьшее количество операций совершается при использовании условных плотностей.

С ростом N использование метода отбора предпочтительнее методу обращения.

Например, при $N = 1000$, $m = 5$, $R = 1$ и $C_\varphi = 10$: $C_{inv} = O(10^{11})$, а $C_{rej} = O(10^6)$. Этого и следовало ожидать, поскольку при "больших" N дискретная модель аппроксимирует непрерывную, в которой и используется отбор (в той или иной форме). Стоит отметить, что в этом же случае $C_{cond} \approx 302$. Это и иллюстрирует огромное преимущество использования условных плотностей при больших N и R .

Список литературы

- [1] Ермаков, С.М., Золотухин, В.Г. Полиномиальные приближения и метод Монте-Карло // Теория вероятностей и ее применения (1960) 5, №4, с.473-475.

- [2] Ермаков, С.М. Метод Монте-Карло и смежные вопросы // "Наука", М., 1971, 327с.
- [3] Ермаков, С.М., Миссов, Т.И. Моделирование Δ^2 -распределения // Вестник СПбГУ, Вып.3, Изд. СПбГУ, 2005
- [4] Ermakov, S.M., Schwabe, R. On Randomizing Estimators in Linear Regression Models // Freie Universitaet Berlin Verlag, Serie A - Mathematik, 1999, 10p.
- [5] Missov, T.I., Ermakov, S.M. Simulation of the Δ^2 -Distribution // Proceedings of the Fifth Workshop on Simulation, NII Chemistry Saint Petersburg University Publishers, 2005, pp.499-502.

УДК 519.24

В. Б. Мелас, А. Н. Пепельшев

ИССЛЕДОВАНИЕ МАКСИМИННО-ЭФФЕКТИВНЫХ ПЛАНОВ НА ОСНОВЕ ФУНКЦИОНАЛЬНОГО ПОДХОДА

В настоящей работе рассматриваются нелинейные регрессионные модели в виде линейных комбинаций экспонент с неизвестными показателями. Предполагается, что для нелинейно входящих параметров заданы априорные интервалы возможных значений. На основе функционального подхода, введенного в работе (Melas, 1978), максиминно эффективные D -оптимальные планы построены и исследованы. Этот подход позволяет представить опорные точки планов, рассматриваемые как функции длины априорных интервалов, с помощью рядов Тейлора.

1 Введение

Целью настоящей работы является применение функционального подхода, развитого в работах (Melas, 1978, 2005; Dette, Melas, Pepelyshev, 2004) и ряде других, к построению и исследованию максиминно эффективных D -оптимальных планов для нелинейных регрессионных моделей. Здесь мы рассматриваем класс моделей, задаваемых в виде линейной комбинации экспонент с неизвестными показателями. Однако, подход применим и к более широкому классу моделей, в частности, к моделям, описанным в работе (Melas, 2005).

Основной чертой нелинейных моделей является зависимость информационной матрицы от неизвестных параметров. Для преодоления этой трудности часто используют локально-оптимальный подход, введенный в работе (Chernoff, 1953). Идея этого подхода состоит в использовании начальных приближений параметров для построения критерия оптимальности. Планы, которые являются локально D -оптимальными в классе планов с минимальной поддержкой для экспоненциальных моделей были подробно изучены в работе (Melas, 1978). Такие планы обычно оказываются локально D -оптимальными в классе всех непрерывных планов. Было доказано, что опорные точки этих планов являются аналитическими функциями нелинейных параметров. В работе (Melas, 2005) для этих функций построены представления в виде степен-

Работа выполнена при частичной поддержке РФФИ (грант N 04-01-00519) и ВНП Минобразования (п.3.1 N 4733).

© В. Б. Мелас, А. Н. Пепельшев, 2005