

ДК 681.5.015

С.А. Архипова

## ПРИМЕНИМОСТИ МЕТОДОВ РЕГРЕССИОННОГО АНАЛИЗА ЗАДАЧАХ СТРУКТУРНОЙ ИДЕНТИФИКАЦИИ ПРИ НЕПОЛНОЙ ИНФОРМАЦИИ О ПОГРЕШНОСТЯХ ИЗМЕРЕНИЙ

*Рассматривается возможность использования методов регрессионного анализа при решении задач идентификации в условиях отсутствия информации про особенности погрешности измерений. Показана недостаточность этих методов для получения качественных результатов.*

Рассматривается задача построения наилучшей модели  $y = \mu(x_1, x_2, \dots)$  в классе линейных регрессионных моделей по экспериментально полученным данным: матрице плана  $[x_{ij}]$  и вектору  $[z_i] = [y_i] + [e_i]$  результатов измерения значений зависимой переменной  $y$ , наблюдаемой в присутствии аддитивного случайного шума  $E$ . Исследования выполняются на двухфакторном тестовом примере.

Последовательность значений  $x_{i1}, i = \overline{1, n}$  задается программным генератором псевдослучайных чисел. Вектор точных значений переменной рассчитывается соответствии с истинным уравнением регрессии

$$y = x_1 + x_2 + 0,04x_1^2 + 0,05x_2^2 + 0,003x_1x_2^2.$$

Для селекции наилучшей модели применим один из вариантов процедур регрессионного анализа, описанный в работе [1]. Оценивание параметров моделей производится методом наименьших квадратов (МНК). Процедура селекции сводится к следующему (табл. 1):

1. Модели регрессии, в зависимости от количества  $m_j$  входящих в эти модели элементов разбиваются на ряд классов. Класс А представлен моделью  $y = a_0$ .

2. Внутри каждого класса модели упорядочиваются в соответствии с убыванием значений  $S^2 = \frac{1}{n} \sum_{i=1}^n (z_i - \tilde{y}_i)^2$  среднего квадрата ошибки аппроксимации, где  $\tilde{y}_i$  - модельное значение зависимой переменной  $\tilde{y}_i = \tilde{\mu}(x_{1i}, x_{2i}, \dots)$ .

3. В каждом классе отбираются одна или несколько моделей, имеющих минимальные значения  $S^2$ .

4. Производится сопоставление и исследование этих моделей, включающее: проверку адекватности моделей исходным данным, проверку необходимости усложнения этих моделей. Конечная цель этого анализа - выбор структуры аппроксимативной модели.

На рис.1 показана зависимость  $S^2(m_j)$ , при построении которой в качестве ордина использовались минимальные в классах Б - И значения  $S_j^2$  (в табл. 1 выделены рамками).

С введением новых переменных в модель скорость уменьшения показателя замедляется. С этих позиций (согласно [1] - [4]) можно полагать адекватными модели  $\mu_9, \mu_{10}$  либо  $\mu_{11}$  (рис.1).

Таблица 1

j	Класс	Модель $\mu_j$	$m_j$	$S_j^2$	$\tilde{F}_j$
1	А	$y(1)$	1	568,05	
2	Б	$y(x_1)$	1	257,41	2,21
3		$y(x_2)$	1	259,79	2,19
4	В	$y(x_1, x_2)$	2	197,82	2,86
5		$y(x_1, x_1^2)$	2	191,96	2,94
6		$y(x_2, x_2^2)$	2	201,37	2,81
7		$y(x_1, x_2^2)$	2	199,09	2,84
8	Г	$y(x_1, x_2, x_1x_2)$	3	146,08	3,85
9		$y(x_1, x_2, x_1^2)$	3	142,92	3,93
10		$y(x_1, x_2, x_2^2)$	3	142,92	3,93
11	Д	$y(x_1, x_2, x_1^2, x_2^2)$	4	132,79	4,21
12		$y(x_1, x_2, x_1x_2, x_2^2)$	4	138,38	4,04
13		$y(1, x_1, x_2, x_1x_2)$	4	142,20	3,93
14		$y(1, x_1, x_2, x_2^2)$	4	141,51	3,95
15	Е	$y(x_1, x_2, x_1^2, x_2^2, x_1^2x_2)$	5	123,24	4,52
16		$y(x_1, x_2, x_1^2, x_2^2, x_1x_2^2)$	5	121,49	4,57
17		$y(x_1, x_2, x_1^2, x_2^2, x_1^2x_2^2)$	5	127,14	4,38
18		$y(x_1, x_2, x_1x_2, x_2^2, x_1x_2^2)$	5	126,75	4,40
19		$y(x_1, x_2, x_1^2, x_2^2, x_2^3)$	5	124,02	4,49
20		$y(x_1, x_2, x_1^2, x_2^2, x_1^3)$	5	125,29	4,53
21	Ж	$y(x_1, x_2, x_1^2, x_2^2, x_1x_2^2, x_2^3)$	6	121,44	4,56
22		$y(x_1, x_2, x_1^2, x_2^2, x_1x_2^2, x_1^3)$	6	121,25	4,66
23		$y(1, x_1, x_2, x_1^2, x_2^2, x_1x_2^2)$	6	121,15	4,57
24		$y(x_1, x_2, x_1x_2, x_1^2, x_2^2, x_1x_2^2)$	6	121,06	4,57
25	З	$y(x_1, x_2, x_1x_2, x_1^2, x_2^2, x_1^2x_2, x_1x_2^2)$	7	121,01	4,55
26		$y(x_1, x_2, x_1x_2, x_1^2, x_2^2, x_1x_2^2, x_2^3)$	7	121,01	4,55
27		$y(1, x_1, x_2, x_1x_2, x_1^2, x_2^2, x_1x_2^2)$	7	120,24	4,58
28	И	$y(1, x_1, x_2, x_1x_2, x_1^2, x_2^2, x_1^2x_2, x_1x_2^2)$	8	120,19	4,56
29		$y(1, x_1, x_2, x_1x_2, x_1^2, x_2^2, x_1x_2^2, x_2^3)$	8	120,29	4,55

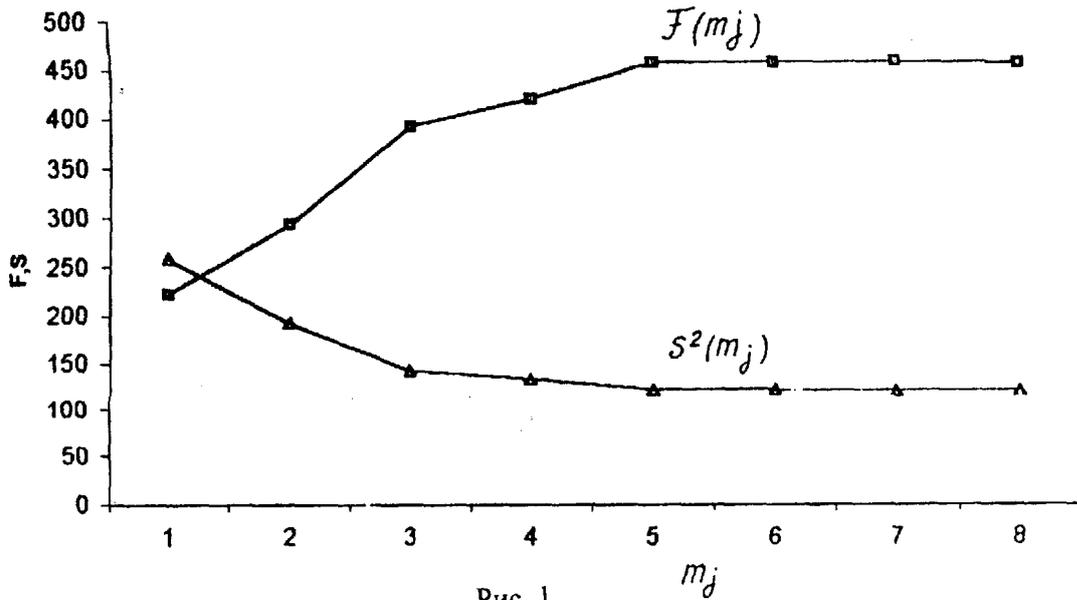


Рис. 1

Эмпиризм подобного подхода обычно побуждает исследователя к поиску других способов селекции модели. При этом прибегают к априорному постулированию нормальности распределения погрешностей измерения значения зависимой переменной, что позволяет сразу решить две проблемы: обоснованность оптимального применения МНК для оценивания параметров модели и использовать имеющиеся в классическом регрессионном анализе наработки по оценке качества линейной регрессии для селекции структуры модели.

Для проверки значимости уравнений регрессии применяют статистику, которая определяет, во сколько раз исследуемая  $j$ -я модель лучше предсказывает результаты эксперимента, чем среднее  $\bar{y}$ , т.е. модель  $y(l) = a_0$  [2], [4]:

$$\tilde{F}_j = \frac{S_1^2 / (n-1)}{S_j^2 / (n-m_j)},$$

Если табличное значение  $F$ -критерия для  $g\%$ -го уровня значимости с  $\nu_1, \nu_2$  степенями свободы оказывается меньше  $\tilde{F}_j$ :  $\tilde{F}_{g, \nu_1, \nu_2} < \tilde{F}_j$ , проверяемая  $j$ -я модель предполагается значимой.

Значения  $\tilde{F}_j$  при  $g=5\%$ ,  $n=200$  приведены в табл. 1 (а также на рис.1) и максимальное значение  $\tilde{F}_{27}=4,58$  соответствует семиэлементной модели  $\mu_{27}$ , что, однако, не означает оптимальности структуры этой модели: высокие значения  $\tilde{F}_j$  следует рассматривать только для статистически подтвержденной значимости соответствующих моделей по отношению к модели среднего  $y = a_0$  (модель  $\mu_1$ ).

Дальнейшая селекция модели с наилучшей структурой основана на применении более сложной системы попарного сопоставительного анализа моделей, в основе которого - проверка значимости изменения показателя  $\tilde{F}$  при поэлементном введении изменений в структуру модели [3] по статистике

$$\tilde{F}_{j \rightarrow r} = \frac{S_j^2 - S_r^2}{S_r^2} \frac{n - m_r}{m_r - m_j},$$

имеющей  $F$  - распределение со степенями свободы  $\nu_1 = m_r - m_j$ ,  $\nu_2 = n - m_r$ . Если теоретическое значение  $F_{g, \nu_1, \nu_2} < \tilde{F}_{j \rightarrow r}$ , следует признать, что усложнение модели приводит к значимому росту ее качества.

По результатам исследований можно предположить, что наиболее адекватны исходным данным модели класса Ж:  $\mu_{21}$ ,  $\mu_{22}$ ,  $\mu_{24}$ .

Если сопоставить итог селекции моделей по показателю  $\tilde{F}_{j \rightarrow r}$  (модели  $\mu_{21}$ ,  $\mu_{22}$ ,  $\mu_{24}$ ) с моделями  $\mu_9$ ,  $\mu_{10}$ ,  $\mu_{11}$ , отобранными по показателю  $S^2$ , очевидно наличие существенных различий в сложности приведенных групп моделей. Даже если предположить, что по каким-либо причинам эти две группы моделей соответствуют противоположным границам области возможных решений задачи структурной идентификации, признать удовлетворительным подобный результат нельзя из-за содержащейся в нем весьма значительной неопределенности: область возможных решений перекрывает четыре класса моделей Г, Д, Е, Ж. Необходимо проведение дополнительных исследований, позволяющих радикально сузить эту область.

Один из возможных способов уточнения вида модели состоит в проверке значимости найденных оценок коэффициентов моделей [2], [4], целиком базирующейся на гипотезе нормальности погрешности.

Поэтому актуальным представляется вопрос о возможности проверки гипотезы нормальности распределения погрешности значений зависимой переменной. Рекомендуется [2] проведение апостериорной проверки гипотезы нормальности распределения погрешности путем проверки нормальности остатков (невязок), определяемых выражением:

$$\varepsilon_i = z_i - \tilde{y}_i. \quad (1)$$

Получение последовательности независимых значений  $e_1, e_2, \dots, e_n$  реализуется программным генератором псевдослучайных чисел (ГПСЧ), закон распределения которых задается в непараметрическом виде. Его графическое представление дано на рис. 2 в виде ступенчатой гистограммы  $f(e)$ . Моментные характеристики этого распределения: математическое ожидание  $M\{e\} \approx 0$ , дисперсия  $D\{e\} = \sigma_e^2 = 121,32$ . На этом же рисунке представлены графики распределения плотности вероятностей для нормального закона  $f^{(N)}(e)$  и закона Лапласа  $f^{(L)}(e)$ , имеющих одинаковые дисперсии  $\sigma_e^2$  и нулевые математические ожидания.

Используя в качестве меры попарной близости распределений  $f(e)$  и  $f^{(N)}(e)$ ,  $f(e)$  и  $f^{(L)}$  статистику

$$\chi\{\}^2 = \sum_{j=1}^{24} \frac{[f_j(e) - f_j\{\}]^2}{f_j\{\}},$$

на достаточно высоком 50%-м уровне значимости можно полагать в равной степени правдоподобной гипотезу принадлежности эмпирического распределения  $f(e)$  как к распределению Гаусса (нормальному), так и к распределению Лапласа.

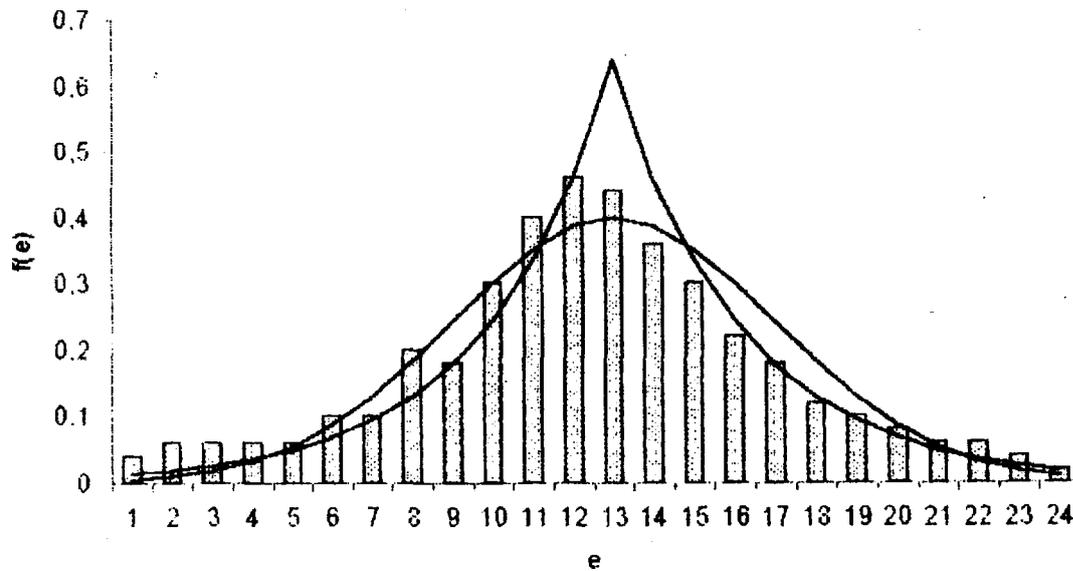


Рис. 2

Оценим возможность и объективность апостериорной проверки гипотезы нормальности через исследование остатков. Сгенерируем  $L$  матриц исходных данных  $\{z_b x_i\}_{1, \dots, \{z_b x_i\}_L}$ . Рассчитаем по формуле (1)  $L$  выборок остатков  $\{\varepsilon_1\}_{1, \dots, \{\varepsilon_i\}_L}$  и проверим близость распределения ее элементов модели Гаусса или Лапласа, осуществим апостериорную проверку гипотезы о законе распределения погрешности  $E$ .

Чтобы исключить возможные искажения оценок погрешностей, будем полагать известной истинную структуру модели

$$y = a_1 x_1 + a_2 x_2 + a_3 x_1^2 + a_4 x_2^2 + a_5 x_1 x_2^2. \quad (2)$$

Результаты представлены в табл. 2:

$r_\Gamma$  - относительное число выборок, для которых из двух конкурирующих гипотез распределения (Гаусса и Лапласа) принята первая;

$r_\Delta$  - относительное число выборок, для которых из двух конкурирующих гипотез принимается гипотеза распределения Лапласа;

$r_-$  - относительное число выборок, для которых отвергаются обе проверяемые гипотезы:  $\chi^2_{(\Gamma)}, \chi^2_{(\Delta)} > \chi^2_{g\%v}$ ;

$r_{\Gamma+}$  - относительное число выборок, для которых гипотеза нормальности является правдоподобной, т.е.  $\chi^2_{(\Gamma)} < \chi^2_{g\%v}$

$\bar{\chi}^2_{(\Gamma)}$  - среднее значение статистики  $\chi^2$ .

Таблица 2

Выборки	$r_\Gamma$	$r_\Delta$	$r_-$	$r_{\Gamma+}$	$\bar{\chi}^2_{(\Gamma)}$
$\{e_i\}$	42%	42%	16%	72%	27.6
$\{\varepsilon_i\}$	55.8%	42%	2.2%	90%	22.3

Первая значащая строка табл. 2 содержит численные значения введенных выше показателей, рассчитанные на множестве сгенерированных выборок  $\{e_i\}_1, \dots, \{e_i\}_L$ , вторая строка – аналогичные показатели, рассчитанные по остаткам, т.е. по апостериорно найденным оценкам погрешностей  $\{\varepsilon_i\}_1, \dots, \{\varepsilon_i\}_L$ . Табличная информация свидетельствует о возрастании доли принимаемых гипотез нормальности при апостериорном анализе данных. Интересно, что помимо роста показателей  $r_\Gamma$  (с 42% до 55,8%) и  $r_{\Gamma+}$  (с 72% до 90%) происходит убывание показателя  $\chi^2_{(\Gamma)}$  с 27,6 до 22,3, характеризующего уровень отличия исследуемых выборочных распределений от нормального, что говорит о нормализации данных, о большей близости функции распределения остатков нормальному распределению по сравнению с исходным распределением.

Высокий уровень значений показателя  $r_{\Gamma+}$ , означает, что при отсутствии рассмотрения конкурирующих либо альтернативных нормальному распределению гипотез нормальность будет признаваться правдоподобной в подавляющем большинстве случаев тогда как наличие только одной альтернативной гипотезы резко снижает (с 90% до 55,8%) число случаев принятия гипотезы нормальности.

Таким образом, если следовать рекомендациям [2] и принять гипотезу нормального распределения погрешностей в значениях зависимой переменной, следует ожидать нормальность распределения оценок параметров исследуемой модели (2).

Проверим это утверждение. Для полученных совокупностей оценок  $\{\tilde{a}_{jl}\}$ ,  $j = \overline{1,5}$ ,  $l = \overline{1,L}$  построим эмпирические функции распределения  $\tilde{F}\{\tilde{a}_j\}$  и исследуем их близость к нормальному распределению и к распределению Лапласа (табл. 3). Гипотеза нормальности распределения оценок подтверждается лишь для коэффициента  $a_2$ . Гипотеза о законе Лапласа оказывается более приемлемой, причем для коэффициентов  $a_4, a_5$  она принимается при высоких уровнях значимости.

Таблица 3

Оцениваемый параметр	Проверка гипотезы распределения оценки по критерию $\chi^2$							
	Нормальное распределение				Распределение Лапласа			
	$\chi^2$	$\chi^2_{g\%,v}$	g%	v	$\chi^2$	$\chi^2_{g\%,v}$	g%	v
$a_1$	34.56	-	-	-	27.97	29.141	1%	16
$a_2$	18.65	21.064	10%	14	38.79	-	-	-
$a_3$	468.8	-	-	-	19.43	21.026	5%	12
$a_4$	290.1	-	-	-	14.78	15.987	15%	10
$a_5$	56.72	-	-	-	13.60	14.631	20%	11

Результаты выполненных исследований позволяют сделать следующие выводы:

– процедура классического регрессионного анализа не содержит способов надежной селекции структуры модели при отсутствии априорных сведений о нормальности погрешности  $E$ ;

– апостериорное утверждение о возможности принятия гипотезы нормальности остатков регрессии не гарантирует нормальности исходной погрешности  $E$  и, следовательно, не может служить обоснованием принятия положений регрессионного анализа, опирающихся на нормальность распределения  $E$ , в частности, гипотезы о нормальности распределения оценок параметров и базирующихся на ней методов проверки значимости оценок и модели регрессии.

#### Список литературы

1. *Себер Дж.* Линейный регрессионный анализ. – М.: Мир, 1980. – 456 с.
2. *Львовский Е.Н.* Статистические методы построения эмпирических формул. – М.: Высш. шк., 1982. – 224 с.
3. *Пугачев В.С.* Теория вероятностей и математическая статистика. – М.: Наука, 1979. – 496 с.
4. *Вучков И., Л.Бояджиева, Е.Солаков* и др. Прикладной линейный регрессионный анализ. – М.: Финансы и статистика, 1987. – 239 с.

Стаття надійшла до редакції 26 березня 1998 року



**Софія Анатоліївна Архіпова** (1961) закінчила Київський політехнічний інститут в 1984 році. Здобувач факультету авіаційного обладнання Київського міжнародного університету цивільної авіації. Автор 15 публікацій в галузі ідентифікації, моделювання та обробки даних.

**Sofiya A. Arkhipova** (b.1961) graduated from Kyiv Polytechnical Institute (1984) post competition graduate of Kyiv International University of Civil Aviation. Author of 15 publication in the field of identification, simulation and data processing.