

Метод наименьших расстояний для конфлюентной модели с гомоскедастичными измерениями столбцов матрицы и правой части.

Автором в работах [1,2,3] в самых общих предположениях проведено доказательство метода наименьших расстояний оценивания параметров конфлюентных моделей пассивного эксперимента. В данной работе подробно исследуется, возможно, наиболее распространенный частный случай такой модели с различной по векторам измерений, но гомоскедастичной внутри каждого вектора, дисперсией. Результат иллюстрируется примером из эконометрии.

1. Основная модель.

Рассмотрим основное предположение [2,3] для наиболее типичного случая, когда все ошибки в столбцах конфлюентной матрицы \mathbf{X} и в векторе отклика у гомоскедастичны.

Предположение 1. Будем исходить из следующей линейной стохастической модели пассивного эксперимента:

$$\begin{cases} \mathbf{y} = \mathbf{\Xi}\beta + \mathbf{H}\delta + \mathbf{e}, \mathbf{y} \in \mathbb{R}^n, \beta \in \mathbb{R}^m, \mathbf{H} \in \mathbb{R}^{nk}, \delta \in \mathbb{R}^k, \mathbf{E}\mathbf{e} = \mathbf{0}, \mathbf{E}\mathbf{e}\mathbf{e}^T = \sigma^2 \mathbf{I}, \\ \mathbf{X} = \mathbf{\Xi} + \mathbf{C}, \mathbf{X} \in \mathbb{R}^{nm}, \mathbf{E}\mathbf{C} = \mathbf{0}, \mathbf{E}\mathbf{e}\mathbf{C}^T = \mathbf{0}, \mathbf{E}\mathbf{c}_i\mathbf{c}_j^T = \delta_{ij} \mu_i^2 \mathbf{I}, i, j = \overline{1, m}. \end{cases} \quad (1)$$

с матрицей $[\mathbf{\Xi}, \mathbf{H}]$ линейного функционального уравнения

$$\begin{aligned} \mathbf{g} &= \mathbf{\Xi}\beta + \mathbf{H}\delta, \mathbf{g} \in \mathbb{R}^n, \mathbf{\Xi} \in \mathbb{R}^{nm}, \mathbf{H} \in \mathbb{R}^{nk}, \beta \in \mathbb{R}^m, \delta \in \mathbb{R}^k, \\ &\text{полного ранга} (\delta_{ij} - \text{символ Кронекера}). \end{aligned} \quad (2)$$

То есть в модели (1) пассивные наблюдения, которые будем считать нормально распределенными, имеют одинаковую дисперсию σ^2 в \mathbf{y} и одинаковые дисперсии μ_i^2 в каждом i -том столбце матрицы \mathbf{X} . Тогда задача оценивания параметров будет иметь вид:

Задача 1. Зная одну реализацию $\tilde{\mathbf{y}}$ и $\tilde{\mathbf{X}}$ ($\text{rank } \tilde{\mathbf{X}} = m$):

$$\begin{cases} \tilde{\mathbf{y}} = \mathbf{\Xi}\beta + \mathbf{H}\delta + \tilde{\mathbf{e}}, \\ \tilde{\mathbf{X}} = \mathbf{\Xi} + \tilde{\mathbf{C}}, \end{cases}$$

случайных величин \mathbf{y} и \mathbf{X} , точно теоретическую матрицу \mathbf{H} , дисперсии $\sigma^2, \mu_i^2, i = \overline{1, m}$; оценить неизвестные элементы $\mathbf{g}, \mathbf{\Xi}$ и неизвестные параметры β, δ линейной стохастической модели (1) методом максимального правдоподобия.

Т.е., учитывая в данном случае тот факт, что ошибки измерений не зависят от параметров [3] получим, что параметры надо оценить таким образом, чтобы квадрат расстояния измерений $\tilde{\mathbf{y}}, \tilde{\mathbf{x}}_i, i = \overline{1, m}$, от искомых значений $\mathbf{g}, \xi_i, i = \overline{1, m}$,

$$S^2 = \sigma^{-2} (\tilde{\mathbf{y}} - \mathbf{g})^T (\tilde{\mathbf{y}} - \mathbf{g}) + \sum_{i=1}^m \mu_i^{-2} (\tilde{\mathbf{x}}_i - \xi_i)^T (\tilde{\mathbf{x}}_i - \xi_i) \quad (3)$$

в линейных ограничениях $\mathbf{g} = \mathbf{\Xi}\beta + \mathbf{H}\delta$ (2) был бы минимален (иначе говоря, методом наименьших расстояний -м.н.р.).

Теорема 1. Оценки $\hat{\beta}, \hat{\delta}$ параметров β, δ линейной модели (1) из Задачи 1 доставляют минимум квадратичной форме

$$S^2 = \frac{\|\tilde{\mathbf{X}}\hat{\beta} + \mathbf{H}\hat{\delta} - \tilde{\mathbf{y}}\|^2}{\sigma^2 + \sum_{i=1}^m \mu_i^2 \beta_i^2}, \quad (4)$$

или (как можно показать с помощью дифференцирования) вычисляются из следующей нормальной системы линейных алгебраических уравнений (с.л.а.у.):

$$\begin{cases} (\tilde{\mathbf{X}}^T \tilde{\mathbf{X}} - \text{diag}(\mu_1^2, \dots, \mu_m^2) \hat{\mathbf{S}}^2) \hat{\mathbf{b}} + \tilde{\mathbf{X}}^T \mathbf{H} \hat{\mathbf{d}} = \tilde{\mathbf{X}}^T \tilde{\mathbf{y}}, \\ \mathbf{H}^T \tilde{\mathbf{X}} \hat{\mathbf{b}} + \mathbf{H}^T \hat{\mathbf{d}} = \mathbf{H}^T \tilde{\mathbf{y}}, \end{cases} \quad (5)$$

где \hat{S}^2 - минимальное значение остаточной суммы квадратов S^2 (4).

Теорема является частным случаем доказанного в [2,3] утверждения с более общим видом ковариационной матрицы.

2. Частный случай.

В качестве следствия рассмотрим построение оценки для линейной двупараметрической стохастической конфлюентной модели с различной для каждой переменной, но гомоскедастичной внутри измерений дисперсией:

$$\begin{cases} \mathbf{y} = \beta_1 \xi_1 + \beta_2 \xi_2 + \delta + \mathbf{e}, \mathbf{y} \in \mathbb{R}^n, \beta \in \mathbb{R}^2, \delta \in \mathbb{R}^1, E\mathbf{e} = 0, E\mathbf{e}\mathbf{e}^T = \sigma^2 \mathbf{I}, \\ \mathbf{x}_1 = \xi_1 + \mathbf{c}_1, \mathbf{x}_1 \in \mathbb{R}^n, Ec_1 = 0, Ec_1^T = 0, Ec_1 c_1^T = \mu_1^2 \mathbf{I}, \\ \mathbf{x}_2 = \xi_2 + \mathbf{c}_2, \mathbf{x}_2 \in \mathbb{R}^n, Ec_2 = 0, Ec_2^T = 0, Ec_2 c_2^T = \mu_2^2 \mathbf{I}, \end{cases} \quad (6)$$

и одним свободным (регрессионным) параметром δ .

Как следует из теоремы 1, оценки $\hat{\beta}_1, \hat{\beta}_2, \hat{\delta}$ параметров β_1, β_2, δ линейной модели (6) из Задачи 1 доставляют минимум квадратичной форме

$$S^2 = \frac{\|\beta_1 \tilde{\mathbf{x}}_1 + \beta_2 \tilde{\mathbf{x}}_2 + \delta - \tilde{\mathbf{y}}\|^2}{\sigma^2 + \mu_1^2 \beta_1^2 + \mu_2^2 \beta_2^2}, \quad (7)$$

или является решением следующей с.л.а.у.:

$$\begin{bmatrix} \sum_{i=1}^n \tilde{x}_{1i}^2 - \mu_1^2 \hat{S}^2 & \sum_{i=1}^n \tilde{x}_{1i} \tilde{x}_{2i} & \sum_{i=1}^n \tilde{x}_{1i} \\ \sum_{i=1}^n \tilde{x}_{1i} \tilde{x}_{2i} & \sum_{i=1}^n \tilde{x}_{2i}^2 - \mu_2^2 \hat{S}^2 & \sum_{i=1}^n \tilde{x}_{2i} \\ \sum_{i=1}^n \tilde{x}_{1i} & \sum_{i=1}^n \tilde{x}_{2i} & n \end{bmatrix} * \begin{bmatrix} b_1 \\ b_2 \\ d \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^n \tilde{x}_{1i} \tilde{y}_i \\ \sum_{i=1}^n \tilde{x}_{2i} \tilde{y}_i \\ \sum_{i=1}^n \tilde{y}_i \end{bmatrix} \quad (8)$$

где \hat{S}^2 - минимальное по параметрам β_1, β_2, δ значение остаточной суммы квадратов S^2 (7). Очевидно, что для решения с.л.а.у. (8) необходимо использовать итерационный процесс.

3. Пример построения оценки.

Рассмотрим пример из раздела регрессионного анализа книги [4], где цена подержанного автомобиля Ниссан оценивается в функции года производства ("возраста") ξ_1 и пробега ξ_2 .

Рассмотрим сначала чистую регрессию в функции возраста. Для простой линейной модели имеем оценку метода наименьших квадратов [5] (м.н.к.) вида:

$$\mathbf{y} = \delta_1 \eta_1 + \delta + \mathbf{e} \equiv -2,026 \eta_1 + 19,547, \mathbf{y} \in \mathbb{R}^{11}, \hat{s}^2 = 1,58.$$

Далее, для вычисления м.н.к.-оценки, будем считать возраст автомобиля равномерно распределенным в течение года, откуда имеем [6] для его дисперсии величину

$$c_1 \in U_{-0,5;0,5}; Ec_1 = 0; \mu_1^2 = Dc_1 = Ec_1^2 - (Ec_1)^2 = 1/12.$$

и будем полагать, что равномерное распределение для 11 измерений достаточно хорошо аппроксимируется нормальным.

Ниссан	$\tilde{x}_1(\eta_1)$: годы	$\tilde{x}_2(\eta_2)$: мили/1000	y : цены\$/1000
1	5	57	8,5
2	4	40	10,3
3	6	77	7
4	5	60	8,2
5	5	49	8,9
6	5	47	9,8
7	6	58	6,6
8	6	39	9,5
9	2	8	16,9
10	7	69	7
11	7	89	4,8

Таблица 1. Возраст автомобиля, его пробег и объявленная стоимость. В скобках приведены обозначения для регрессионного анализа.

Воспользуемся оценкой дисперсии стоимости из м.н.к. как начальным значением для итерационного процесса вычисления дисперсии цены y . Итерируя до ожидаемой величины степеней свободы $S^2=11-2=9$, достаточно просто подобрать отношение дисперсий исходных данных. Откуда имеем м.н.р.-оценку

$$y = \beta_1 \xi_1 + \delta + e \equiv -2,10 \tilde{x}_1 + 20,0, \hat{S}^2 = 9,0; y \in \mathbb{R}^{11}, \sigma^2 = 1,2; \mu_1^2 = 1/12.$$

Расчет м.н.р. точнее оценивает стоимость двухлетнего автомобиля, чем то недостаточно точное описание (как это отмечено в[4]), что получено для этого автомобиля из м.н.к. В итоге м.н.р.-оценки цен полностью согласуются с исходными данными. Из нее следует, что цена нового автомобиля \$20.000 и срок его службы ~10 лет. На рис. 1 содержатся исходные данные и обе оценки.




Рис. 1. Однопараметрическая модель. Квадратами обозначены исходные данные, точками - м.н.к.-оценка, ромбами - м.н.р.-оценка.

Рассмотрим теперь регрессию в функции пробега. Для простой линейной модели имеем м.н.к.-оценку

$$y = \beta_2 \eta_2 + \delta + e \equiv -0,136 \tilde{x}_2 + 16,204, y \in \mathbb{R}^{11}, \hat{S}^2 = 1,2; \quad (9)$$

и м.н.р.-оценку (считаем ошибку пробега также равномерно распределенной)

$$y = \beta_2 \xi_2 + \delta + e \equiv -0,136 \tilde{x}_2 + 16,205, \hat{S}^2 = 9,0; y \in \mathbb{R}^{11}, \sigma^2 = 1,2; \mu_2^2 = 1/12.$$

Здесь расчет м.н.р. практически совпадает с описанием, полученным из м.н.к.-расчетов, так как теоретическая дисперсия ошибки пробега очень мала, что не совсем согласуется с исходными данными.

Замечание. Действительно, показания спидометра автомобиля напрямую зависят от размера колес, а изменение радиуса колеса на один сантиметр вследствие износа протектора влечет за собой в среднем 4-5% ошибку в измерении пробега, откуда в среднем $\mu_2^2 \approx 2,5$. Поэтому просчитаем результат с такой дисперсией. Здесь также по величине степеней свободы достаточно просто рассчитывается отношение дисперсий исходных данных:

$$y = \beta_2 \xi_2 + \delta + e \equiv -0,137 \tilde{x}_2 + 16,24, \hat{S}^2 = 9,0; y \in \mathbb{R}^{11}, \sigma^2 = 1,1; \mu_2^2 = 2,5.$$

Такая смена дисперсии не сильно влияет на оценку, поскольку на самом деле дисперсия должна быть много больше для большого пробега и такой подход требует расчетов с гетероскедастичной дисперсией [2,3], выходящих за рамки данной работы, однако проведя их, имеем оценку

$$y = \beta_2 \xi_2 + \delta + e \equiv -0,14 \tilde{x}_2 + 16,4, \hat{S}^2 = 9; y \in \mathbb{R}^{11}, \sigma^2 = 1,06; \mu_2^2 = (0,05\bar{y})^2; (10)$$

которая, хотя и лучше согласуется с исходными данными, показывает тем не менее, что только пробег, также как и только возраст, не дает полного описания стоимости автомобиля. На рис. 2 также содержатся исходные данные и оценки (9) и (10).




Рис. 2. Однопараметрическая модель. Квадраты - данные, ромбы - м.н.р.-оценка, точки - м.н.к.-оценка.

Рассмотрим, наконец, регрессию по обеим переменным. Для двупараметрической линейной модели имеем м.н.к.-оценку

$$y = \delta_1 \eta_1 + \delta_2 \eta_2 + \delta + e \equiv -0,95 \eta_1 - 0,082 \eta_2 + 18,3; y \in \mathbb{R}^{11}, \hat{S}^2 = 0,78;$$

и м.н.р.-оценку

$$y = \beta_1 \xi_1 + \beta_2 \xi_2 + \delta + e \equiv -0,99 \tilde{x}_1 - 0,088 \tilde{x}_2 + 18,4; \hat{S}^2 = 8,0; y \in \mathbb{R}^{11}, \sigma^2 = 1; \mu_1^2 = 0,034; \mu_2^2 = 2,5$$

И м.н.к. и м.н.р.-оценки согласуются с исходными данными. На рис. 3 также содержатся данные и обе оценки и видно, что шесть срединных точек (наиболее правильно представляющих эксперимент) лучше приближаются м.н.р.




Рис. 3. Двупараметрическая линейная модель (на диаграмме в проекции плоскости регрессии на плоскость цены*пробег). Квадраты - данные, ромбы - м.и.р.-оценка, точки - м.и.к.-оценка.

Поскольку возраст и километраж сильно коррелированы (в принципе они не могут эффективно работать вместе в этой модели), то ранг матрицы (8) чувствителен к заданию величины дисперсии и м.и.р.-оценка быстро теряет устойчивость, когда дисперсии независимых переменных выравниваются. По величине степеней свободы достаточно просто рассчитывается отношение дисперсий исходных данных.

Достаточно очевидно, что модель в самом деле нелинейна по этим параметрам (поскольку цена автомобиля не равна нулю через 9-10 лет) и требует более детального рассмотрения в этом плане.

В данной работе автором подробно изучен метод построения оценок параметров для стохастических линейных конфлюентно-регрессионных моделей с различными гомоскедастичными дисперсиями - класса моделей, с одной стороны, достаточно полно описывающих события, встречающиеся в созерцательных исследованиях, с другой стороны, оценки метода нименьших расстояний для которых достаточно легко рассчитать в обычном табличном процессоре типа Excel. На приведенных примерах видно, что использование различной дисперсии может значительно улучшить простейшее описание данных задачи и позволяет полнее провести апостериорное исследование исходных данных и их причинно-следственных связей.

Литература.

- 1.Меченов А.С. О частично приближенных системах линейных алгебраических уравнений // Ж. вычисл. матем. и матем. физ., 1991, т. 31, №6, с. 790-799.
- 2.Меченов А.С. О подходе максимального правдоподобия к оценке параметров линейных функциональных соотношений. //Численные методы в математической физике. М.: Московский университет. 1996. С. 153-159.
- 3.Меченов А.С. О конфлюентном подходе в регрессионном анализе. // Методы математического моделирования. М.: Московский университет. 1998. С. 42-53.
4. Weiss N.A. Introductory statistics, New York. 1995.
5. Gauss K.F. Theoria motus corporum coelestium in sectionibus conicis solem ambientium, 1809, Hamburgi, (Русский перевод Н.Ф.Булаевского: Гаусс К.Ф. Избранные геодезические произведения Т.1-2. М.: Изд-во геодезической литературы. 1957. С. 152).
- 6.Боровков А.А. Теория вероятностей. М.: Наука, 1986, 432 с.