

Лекция 7. Метод наименьших квадратов

1. Начать с примера из жизни – аппроксимация напорных QH-характеристик насосных агрегатов. В модели движения на работу была детерминированная составляющая – время собственно движения, и случайная составляющая – время ожидания. При этом детерминированная составляющая от эксперимента к эксперименту постоянна.
2. Если посмотреть на реальные точки, то видна их случайная и детерминированная составляющая. Для одного и того же расхода дифнапор от эксперимента к эксперименту скачет. (Буквально таких двух точек с одинаковым расходом нет, но если бы были, то вряд ли дифнапор был бы один и тот же). Несмотря на наличие случайности, дифнапор, однако, имеет тенденцию изменяться при изменении расхода.
3. Поэтому естественно записать следующую вероятностную модель, называемую регрессией.

$$H = \underbrace{\sum_{j=0}^{k-1} \beta_j \cdot Q^j}_{\text{детерминированная составляющая}} + \underbrace{\varepsilon}_{\substack{\text{случайная} \\ \text{составляющая,} \\ \text{шум}}}$$

$$\varepsilon \sim N(0, \underbrace{D_\varepsilon}_{\text{дисперсия шума}})$$

4. Степени расхода Q^0, Q^1, \dots, Q^{k-1} называются факторами. Перейдем к векторной записи. Введем вектор факторов x размерности $k+1$ и вектор коэффициентов.

$$x = \underbrace{\begin{pmatrix} Q^0 \equiv 1 \\ Q^1 \\ \dots \\ Q^{k-1} \end{pmatrix}}_{[k \times 1]} \quad \beta_{\text{ист}} = \underbrace{\begin{pmatrix} \beta_0 \\ \beta_1 \\ \dots \\ \beta_{k-1} \end{pmatrix}}_{[k \times 1]}$$

$$y = x^T \cdot \beta_{\text{ист}} + \varepsilon$$

5. Если $k = 0$, то модель становится похожа на модель разницы показаний датчиков:

$$H = \beta_{\text{ист},0} + \varepsilon$$

дифнапор имеет, вообще говоря, ненулевое постоянное значение $\beta_{\text{ист},0}$, не зависящее от расхода, и зашумленное случайным шумом ε

6. Если $k > 0$, то детерминированная составляющая H полиномиально зависит от Q и также замумлена шумом ε .

7. В учебнике Лурье по Трубопроводному транспорту задана зависимость особого рода

$$H = a - bQ^2$$

8. Какие для нее будут x и β ? Тот же вопрос для зависимостей

$$H = aQ \text{ прямая пропорциональность}$$

$$H = a + bQ \text{ линейная зависимость}$$

9. Поскольку коэффициенты $\beta_{\text{ист}}$ задают детерминированную составляющую отклика y , то они понимаются детерминированные. Однако, на практике они неизвестны, их нужно оценить по реальным данным. Еще раз, вместо истинных β у нас будут только их оценки. Рассмотрим МНК-оценивание коэффициентов $\beta_{\text{ист}}$. Дана выборка объема n , $\{H_i, Q_i\}$, снятая с реального насосного агрегата. Сформируем по ней:

- а. отклики $y_i = H_i$

- б. векторы факторов $x_i^T = (1, Q^1, Q^2, \dots, Q^{k-1})$.

10. Пусть как-то наугад выбрано значение коэффициентов, в общем случае, не равное истинному, $\beta \neq \beta_{\text{ист}}$. Как оценить, насколько, это значение является удачным или неудачным среди всех других возможных значений? Другими словами, как оценить качество модели $x^T \cdot \beta$? Посмотреть, насколько фактическое значение y_i отличается от прогнозного $x_i^T \cdot \beta$ во всех элементах выборки

$$e_i = y_i - x_i^T \cdot \beta$$

11. Величину e_i будем называть остатками. Обратите внимание, что остаток и шум после измерений – вещи разные. Сумма квадратов остатков характеризует качество модели на имеющейся выборке:


$$J(\beta) = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - x_i^T \cdot \beta)^2$$


(функционал является скалярной величиной, хотя и зависит от векторного аргумента β)

12. Если варьировать β , то это будет соответствовать изменению вида графика $x^T \cdot \beta$ в осях Q-N. Рассмотрим пример для линейной модели.
13. В момент поиска β выборка фиксирована (после измерений), поэтому J зависит только компонентов вектора β . В частности для линейной аппроксимации нужны два коэффициента, функционал J будет функцией от двух аргументов. Для хороших значений β функционал $J(\beta)$ будет небольшим, для плохих – большим. Или по-другому, значение β тем лучше, чем меньше функционал $J(\beta)$.
14. Может ли $J(\beta)$ быть ниже нуля? Может ли $J(\beta)$ быть нулем?
15. Пример 1. Зависимость $H = aQ$,

$$J(\beta) = J(a) = \sum_{i=1}^n (H_i - Q_i \cdot a)^2$$

16. Как выбрать β ? Если втупую – то перебрать много значений, построить поверхность в $(k+1)$ -мерном пространстве и найти там минимум. Это очень тупо, зато понятно. Приведенный график имеет характер оврага. Но в середине оврага он еще глубже, там красная точка.





17. Как найти минимум по-умному. Нужно найти экстремум функции, т.е. точку, где все производные равны нулю.

$$\frac{\partial J(\beta_0, \beta_1, \dots, \beta_{k-1})}{\partial \beta_i} = 0, \quad i = 0, \dots, k - 1 \text{ (скалярная запись)}$$

18. Сделаем вывод в векторном виде. Для этого перепишем критерий МНК в векторном виде. Введем вектор фактических значений по всей выборке.

$$Y = \begin{pmatrix} y_1 \\ y_1 \\ \dots \\ y_n \end{pmatrix}_{[n \times 1]} \quad \beta_{\text{ист}} = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \dots \\ \beta_{k-1} \end{pmatrix}_{[k \times 1]}$$

19. Введем матрицу всех факторов по всей выборке, матрицу X , называемую матрицей плана.

$$X = \begin{pmatrix} x_1^T \\ x_2^T \\ \dots \\ x_n^T \end{pmatrix}_{[n \times k]} = \begin{pmatrix} Q_1^0 & Q_1^1 & \dots & Q_1^{k-1} \\ Q_2^0 & Q_2^1 & \dots & Q_2^{k-1} \\ \dots & \dots & \dots & \dots \\ Q_n^0 & Q_n^1 & \dots & Q_n^{k-1} \end{pmatrix}$$

- при произвольной β предсказания по всем элементам выборки будут:

$$X\beta = \begin{pmatrix} x_1^T \beta \\ x_2^T \beta \\ \dots \\ x_n^T \beta \end{pmatrix}$$

20. Вектор всех остатков выборки можно рассчитать так:

$$\vec{e} = Y - X\beta$$

21. Сумма квадратов остатков, т.е. МНК-критерий примет вид:

$$J(\beta) = e^T e = (Y - X\beta)^T (Y - X\beta)$$

22. Требуется найти оптимальное значение функционала качества, доставляющее минимум критерию:

$$\beta$$

23. Условие экстремума состоит в том, что вектор градиент $\text{grad } J(\beta)$ равен нуль-вектору:

$$\text{grad } J(\beta) = \frac{\partial J(\beta)}{\partial \beta^T} = \underbrace{\left(\frac{\partial J}{\partial \beta_0}, \frac{\partial J}{\partial \beta_1}, \dots, \frac{\partial J}{\partial \beta_{k-1}} \right)}_{\text{вектор-градиент}} = 0 \text{ (векторная запись)}$$

24. В чем разница между $\beta_{\text{ист}}$, β и $\hat{\beta}$? Если все понимают, то делаем последний рывок.

25. Рассмотрим правила векторного дифференцирования

а. $\varphi(x) = a^T x$, если есть скаляр $\varphi(x)$, то при дифференцировании получаем

$$\frac{\partial \varphi(x)}{\partial x^T} = a^T$$

б. $\varphi(x) = x^T A x$

$$\frac{\partial \varphi}{\partial x^T} = \frac{\partial (x^T A x)}{\partial x^T} = x^T (A + A^T)$$

если матрица симметрическая $A = A^T$, то

$$\frac{\partial (x^T A x)}{\partial x^T} = 2x^T A$$

26. Раскроем скобки в сумме квадратов и посчитаем

$$J(\beta) = (Y - X\beta)^T (Y - X\beta) = Y^T Y - Y^T X\beta - X^T \beta^T Y + \beta^T X^T X \beta$$

27. Посчитаем производные каждого члена суммы

$$1) \frac{\partial Q(y^T y)}{\partial \beta^T} = \vec{0}$$

$$2) \frac{\partial Q(y^T x \beta)}{\partial \beta^T} = y^T x$$

$$3) \frac{\partial Q(\beta^T x^T x \beta)}{\partial \beta^T} = \beta^T (x^T x + (x^T x)^T) = 2\beta^T x^T x$$

$$(x^T x)^T = x^T (x^T)^T = x^T x \Rightarrow x^T x - \text{симметрическая}$$

28. Итого,

$$\frac{\partial Q(\beta)}{\partial \beta^T} = -2y^T x + 2\beta^T x^T x = \vec{0} \quad (\text{приравниваем производные к 0, чтобы найти min})$$

$$\beta^T x^T x = y^T x$$

$$x^T x \beta = x^T y$$

Размерность системы:

$$\begin{matrix} X^T & X & \beta & = & X^T & Y \\ [k \times n] & [n \times k] & [k \times 1] & = & [k \times n] & [n \times 1] \end{matrix}$$

29. Получили систему линейных уравнений относительно β . Ее решение доставит минимум функционалу качества $J(\beta)$. Эта система уравнений имеет специальное название система нормальных уравнений Умножим обе части слева на $(X^T X)^{-1}$, получим оптимальные оценки коэффициентов:

$$\hat{\beta} = (X^T X)^{-1} X^T Y$$