

Прикладная статистика 7. Регрессионный анализ.

1 апреля 2013 г.

Постановка задачи линейной регрессии

x_1, \dots, x_n — объекты;

f_1, \dots, f_k, y — признаки, значения которых измеряются на объектах;

f_1, \dots, f_k — объясняющие переменные, предикторы, регрессоры, факторы, признаки;

y — зависимая переменная, отклик.


$y \approx F(f_1, \dots, f_k)$ — модель регрессии;

$y \approx \sum_{j=1}^k \theta_j f_j$ — модель линейной регрессии.

Здесь и далее $n > k$ (или даже $n \gg k$).


Первое появление

Впервые такая постановка появляется в работе Гальтона 1885 г.
 «Регрессия к середине в наследственности роста».



$$y - \bar{y} \approx \frac{2}{3} (x - \bar{x}).$$

Машинка Гальтона



Матричные обозначения:

$$X = \begin{pmatrix} x_{11} & \dots & x_{1k} \\ \vdots & \ddots & \vdots \\ x_{n1} & \dots & x_{nk} \end{pmatrix}; \quad y = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix}; \quad \theta = \begin{pmatrix} \theta_1 \\ \vdots \\ \theta_k \end{pmatrix}.$$

Метод наименьших квадратов:

$$\sum_{i=1}^n \left(y_i - \sum_{j=1}^k \theta_j x_{ij} \right)^2 \rightarrow \min_{\theta_1, \dots, \theta_k};$$

$$\|y - X\theta\| \rightarrow \min_{\theta};$$

$$2X^T(y - X\theta) = 0;$$

$$\hat{\theta} = (X^T X)^{-1} X^T y = X^+ y.$$

Сингулярное разложение

$$X_{n \times k} = V_{n \times k} \cdot D_{k \times k} \cdot U^T_{k \times k}$$

- ❶ $V = (v_1, \dots, v_k)$ — собственные векторы $\frac{XX^T}{n \times n}$; $V^T V = I_k$;
- ❷ $U = (u_1, \dots, u_k)$ — собственные векторы $\frac{X^T X}{k \times k}$; $U^T U = I_k$;
- ❸ $D = \begin{pmatrix} \sqrt{\lambda_1} & & 0 \\ & \ddots & \\ 0 & & \sqrt{\lambda_k} \end{pmatrix}$, $\lambda_1, \dots, \lambda_k$ — собственные значения $X^T X$ и XX^T ;
- ❹ $V = XUD^{-1}$ (достаточно найти только U);

Сингулярное разложение

$$\underset{n \times k}{X} = \underset{n \times k}{V} \cdot \underset{k \times k}{D} \cdot \underset{k \times k}{U}^T$$


$$X^+ = U D^{-1} V = \sum_{j=1}^k \frac{1}{\sqrt{\lambda_j}} u_j v_j^T, \quad (X^T X)^{-1} = U D^{-2} U^T = \sum_{j=1}^k \frac{1}{\lambda_j} u_j u_j^T;$$

$$\hat{\theta} = X^+ y = \sum_{j=1}^k \frac{1}{\sqrt{\lambda_j}} u_j v_j^T y, \quad \hat{y} = X \hat{\theta} V V^T y = \sum_{j=1}^k v_j v_j^T y;$$


$$\|\theta\|^2 = \sum_{j=1}^k \frac{1}{\lambda_j} (v_j^T y)^2; \quad \|y - X \hat{\theta}\|^2 \equiv RSS = y^T y - \sum_{j=1}^k v_j^T y.$$

Вывод: зная SVD, легко выписать МНК-решение задачи регрессии.


Инверсия задачи регрессии




Инверсия задачи регрессии




Инверсия задачи регрессии




Инверсия задачи регрессии



Инверсия задачи регрессии



Инверсия задачи регрессии



Косинус угла между прямыми, осуществляющими линейную МНК-регрессию x на y и y на x , равен значению выборочного коэффициента корреляции между x и y .

Goodness-of-fit

$$TSS = \sum_{i=1}^n (y_i - \bar{y})^2 \text{ (Total Sum of Squares);}$$

$$ESS = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \text{ (Explained Sum of Squares);}$$

$$RSS = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \text{ (Residual Sum of Squares);}$$

$$TSS = ESS + RSS.$$

Коэффициент детерминации:

$$R^2 = \frac{ESS}{TSS} = 1 - \frac{RSS}{TSS}.$$

$$R^2 = \text{corr}(y, \hat{y})^2.$$

Предположения модели

- ❶ Линейность: $y = X\theta + \varepsilon$.
- ❷ Случайность: имеется независимая выборка наблюдений $(x_i, y_i), i = 1, \dots, n$.
- ❸ Полнота ранга: ни в популяции, ни в выборке ни один из признаков не является константой; кроме того, ни один из признаков не является линейной комбинацией других ($\text{rank } X = k$).
- ❹ Случайность ошибок: $\mathbb{E}(\varepsilon | X) = 0$.

В предположениях (1-4) МНК-оценки коэффициентов θ являются несмешёнными:

$$\mathbb{E}\hat{\theta}_j = \theta_j, j = 1, \dots, k$$

и состоятельными:

$$\forall \gamma > 0 \quad \lim_{n \rightarrow \infty} P\left(\left|\theta_j - \hat{\theta}_j\right| < \gamma\right) = 1, j = 1, \dots, k.$$

Предположения модели

- ① Линейность: $y = X\theta + \varepsilon$.
- ② Случайность: имеется независимая выборка наблюдений $(x_i, y_i), i = 1, \dots, n$.
- ③ Полнота ранга: ни в популяции, ни в выборке ни один из признаков не является константой; кроме того, ни один из признаков не является линейной комбинацией других ($\text{rank } X = k$).
- ④ Случайность ошибок: $\mathbb{E}(\varepsilon | X) = 0$.
- ⑤ Гомоскедастичность ошибок: дисперсия ошибки не зависит от значений признаков: $\mathbb{D}(\varepsilon | X) = \sigma^2$.

(предположения Гаусса-Маркова).

Теорема Гаусса-Маркова: в предположениях (1-5) МНК-оценки имеют наименьшую дисперсию в классе оценок θ , линейных по y .

Дисперсия $\hat{\theta}_j$

В предположениях (1-5) дисперсии МНК-оценок коэффициентов θ задаются следующим образом:

$$\mathbb{D}\hat{\theta}_j = \frac{\sigma^2}{TSS_j (1 - R_j^2)},$$

где $TSS_j = \sum_{i=1}^n (x_{ij} - \bar{x}_j)^2$, R_j^2 — коэффициент детерминации при регрессии x_j на все остальные признаки из X .

- чем больше дисперсия ошибки σ^2 , тем больше дисперсия оценки $\hat{\theta}_j$;
- чем больше вариация значений признака x_j в выборке, тем меньше дисперсия оценки $\hat{\theta}_j$;
- чем лучше признак x_j объясняется линейной комбинацией оставшихся признаков, тем больше дисперсия оценки $\hat{\theta}_j$.

$R_j^2 < 1$ по предположению (3); тем не менее, может быть $R_j^2 \approx 1$.

Дисперсия $\hat{\theta}_j$

В матричном виде:

$$\text{cov } \hat{\theta} = \sigma^2 (X^T X)^{-1}.$$

Если столбцы X почти линейно зависимы, то матрица $X^T X$ плохо обусловлена, и дисперсия оценок $\hat{\theta}_j$ растёт.

Близкая к линейной зависимость между двумя или более признаками x_j называется **мультиколлинеарностью**.

Неправильное определение модели

Недоопределение: если зависимая переменная определяется моделью

$$y = \theta_1 x_1 + \dots + \theta_{j-1} x_{j-1} + \theta_j x_j + \theta_{j+1} x_{j+1} + \dots + \theta_k x_k,$$

а мы вместо этого использовали модель

$$y = \theta_1 x_1 + \dots + \theta_{j-1} x_{j-1} + \theta_{j+1} x_{j+1} + \dots + \theta_k x_k,$$

то МНК-оценки $\hat{\theta}_1, \dots, \hat{\theta}_{j-1}, \hat{\theta}_{j+1}, \dots, \hat{\theta}_k$ являются смещёнными и несостоительными оценками $\theta_1, \dots, \theta_{j-1}, \theta_{j+1}, \dots, \theta_k$.

Переопределение: если признак x_j не влияет на y , т.е., $\theta_j = 0$, то МНК-оценка $\hat{\theta}$ остаётся несмешённой состоятельной оценкой θ , но дисперсия её возрастает.

Бинарные признаки

Если x_j принимает только два значения, то они кодируются нулём и единицей. Например, если x_j — пол испытуемого, то можно задать $x_j = [\text{пол} = \text{мужской}]$.

Механизм построения регрессии не меняется.

Категориальные признаки

Как кодировать дискретные признаки x_j , принимающие более двух значений?

Пусть y — средний уровень заработной платы, x — тип должности; рассматриваются три типа: рабочий, инженер и управляющий. Допустим, мы закодировали эти должности следующим образом:

Тип должности	x
рабочий	1
инженер	2
управляющий	3

и построили регрессию $y = \theta_0 + \theta_1 x$. Тогда для рабочего, инженера и управляющего ожидаемые средние уровни заработной платы определяются следующим образом:

$$y_{bc} = \theta_0 + \theta_1;$$

$$y_{pr} = \theta_0 + 2\theta_1;$$

$$y_{wc} = \theta_0 + 3\theta_1.$$

Согласно построенной модели, разница в средних уровнях заработной платы рабочего и инженера в точности равна разнице между зарплатами инженера и управляющего.

Фиктивные переменные

Верный способ использования категориальных признаков в регрессии — введение бинарных фиктивных переменных (dummy variables).

Пусть признак x_j принимает m различных значений, тогда для его кодирования необходима $m - 1$ фиктивная переменная.

Способы кодирования:

	Dummy		Deviation	
Тип должности	x_1	x_2	x_1	x_2
рабочий	0	0	1	0
инженер	1	0	0	1
управляющий	0	1	-1	-1

$$y = \theta_0 + \theta_1 x_1 + \theta_2 x_2$$

- При dummy-кодировании коэффициенты θ_1, θ_2 оценивают среднюю разницу в уровнях зарплат инженера и управляющего с рабочим.
- При deviation-кодировании коэффициенты θ_1, θ_2 оценивают среднюю разницу в уровнях зарплат инженера и управляющего со средним по всем профессиям.

Вопросы

- ❶ Как найти доверительные интервалы для θ_j ?
- ❷ Как проверить гипотезу $H_0: \theta_j = 0$?
- ❸ Как найти доверительный интервал для значения отклика на новом объекте $y(x_0)$?
- ❹ Адекватна ли построенная модель?

Предположение нормальности ошибок

❶ Нормальность ошибок: $\varepsilon \sim N(0, \sigma^2)$.

- В предположениях (1-6) МНК-оценки совпадают с оценками максимального правдоподобия.

ММП:

$$p(\varepsilon_i) = \frac{1}{\sqrt{2\pi}\sigma} e^{\frac{-1}{2\sigma^2}\varepsilon_i^2},$$

$$\ln \prod_{i=1}^n p(\varepsilon_i) \rightarrow \max_{\theta},$$

$$\sum_{i=1}^n \left(-\ln \left(\sigma \sqrt{2\pi} \right) - \frac{1}{2\sigma^2} \varepsilon_i^2 \right) \rightarrow \max_{\theta},$$

$$\sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n \left(y_i - \sum_{j=1}^k \theta_j x_{ij} \right)^2 \rightarrow \min_{\theta}.$$

Предположение нормальности ошибок

❶ Нормальность ошибок: $\varepsilon \sim N(0, \sigma^2)$.

- Эквивалентная запись предположения 6:

$$y | X \sim N(X\theta, \sigma^2).$$

- МНК-оценки $\hat{\theta}$ имеют наименьшую дисперсию среди всех несмешённых оценок θ .
- МНК-оценки $\hat{\theta}$ имеют нормальное распределение $N\left(\theta, \sigma^2 (X^T X)^{-1}\right)$.
- Несмешённой оценкой σ^2 является

$$\hat{\sigma}^2 = \frac{1}{n - k} RSS;$$

кроме того, $\frac{1}{\sigma^2} RSS \sim \chi^2_{n-k}$.

- $\forall c \in \mathbb{R}^k$

$$\frac{c^T (\theta - \hat{\theta})}{\hat{\sigma} \sqrt{c^T (X^T X)^{-1} c}} \sim St(n - k).$$

Доверительные интервалы

100(1 - α)% доверительный интервал для σ :

$$\sqrt{\frac{RSS}{\chi^2_{n-k,1-\alpha/2}}} \leq \sigma \leq \sqrt{\frac{RSS}{\chi^2_{n-k,\alpha/2}}}.$$


Возьмём $c = \left(0 \dots 0 \underset{j}{1} 0 \dots 0\right)$; 100(1 - α)% доверительный интервал для θ_j :

$$\hat{\theta}_j - t_{n-k,1-\alpha/2} \hat{\sigma} \sqrt{(X^T X)_{jj}^{-1}} \leq \theta_j \leq \hat{\theta}_j + t_{n-k,\alpha/2} \hat{\sigma} \sqrt{(X^T X)_{jj}^{-1}}.$$

Для нового объекта x_0 возьмём $c = x_0$; 100(1 - α)% доверительный интервал для $y(x_0)$:

$$x_0^T \hat{\theta} - t_{n-k,1-\alpha/2} \hat{\sigma} \sqrt{x_0^T (X^T X)^{-1} x_0} \leq y(x_0) \leq x_0^T \hat{\theta} + t_{n-k,1-\alpha/2} \hat{\sigma} \sqrt{x_0^T (X^T X)^{-1} x_0}$$

t-критерий Стьюдента

нулевая гипотеза: $H_0: \theta_j = 0;$ альтернатива: $H_1: \theta_j < \neq > 0;$ статистика: $T = \frac{\hat{\theta}_j}{\frac{RSS}{n-k} \sqrt{(X^T X)_{jj}^{-1}}};$ $T \sim St(n - k)$ при $H_0;$ 

достигаемый уровень значимости:

$$p(t) = \begin{cases} 1 - tcdf(t, n - k), & H_1: \theta_j > 0, \\ tcdf(t, n - k), & H_1: \theta_j < 0, \\ 2 \cdot (1 - tcdf(|t|, n - k)), & H_1: \theta_j \neq 0. \end{cases}$$

t-критерий Стьюдента

Пример: имеется 12 испытуемых, x — результат прохождения испытуемым составного теста скорости реакции, y — результат его теста на симулятора транспортного средства. Проведение составного теста значительно проще и требует меньших затрат, поэтому ставится задача предсказания y по x , для чего строится линейная регрессия согласно модели

$$y = \theta_0 + \theta_1 x + \varepsilon.$$


Значима ли переменная x для предсказания y ?

$$H_0: \theta_1 = 0.$$

$$H_1: \theta_1 \neq 0 \Rightarrow p = 2.2021 \times 10^{-5}.$$

t-критерий Стьюдента

нулевая гипотеза: $H_0: \theta_j = a;$
альтернатива: $H_1: \theta_j < \neq > a;$
статистика: $T = \frac{\hat{\theta}_j - a}{\frac{RSS}{n-k} \sqrt{(X^T X)_{jj}^{-1}}};$
 $T \sim St(n - k)$ при H_0 ;



достигаемый уровень значимости:

$$p(t) = \begin{cases} 1 - tcdf(t, n - k), & H_1: \theta_j > a, \\ tcdf(t, n - k), & H_1: \theta_j < a, \\ 2 \cdot (1 - tcdf(|t|, n - k)), & H_1: \theta_j \neq a. \end{cases}$$

t-критерий Стьюдента

Пример: по выборке из 506 жилых районов, расположенных в пригородах Бостона, строится модель средней цены на жильё следующего вида:

$$\ln price = \theta_0 + \theta_1 \ln nox + \theta_2 \ln dist + \theta_3 rooms + \theta_4 stratio + \varepsilon,$$

где nox — содержание в воздухе двуокиси азота, $dist$ — взвешенное среднее расстояние от жилого района до пяти основных мест трудоустройства, $rooms$ — среднее число комнат в доме жилого района, $stratio$ — среднее отношения числа студентов к числу учителей в школах района.

Коэффициент θ_1 имеет смысл эластичности цены по признаку nox . По экономическим соображениям интерес представляет гипотеза о том, что эластичность равна -1.

$$H_0: \theta_1 = -1.$$

$$H_1: \theta_1 \neq -1 \Rightarrow p = 0.6945.$$

Критерий Фишера


$$X_{n \times k} = \begin{pmatrix} X_1 & X_2 \\ n \times k_1 & n \times (k - k_1) \end{pmatrix}, \quad \theta^T = \begin{pmatrix} \theta_1^T & \theta_2^T \\ k_1 \times 1 & (k - k_1) \times 1 \end{pmatrix}^T;$$

нулевая гипотеза: $H_0: \theta_2 = 0$;

альтернатива: $H_1: H_0$ неверна;

статистика: $F = \frac{\frac{1}{k-k_1} \|X\hat{\theta} - X_1\hat{\theta}_1\|^2}{\frac{1}{n-k} \|y - X\hat{\theta}\|^2}$;

$F \sim F(k - k_1, n - k)$ при H_0 ;



достигаемый уровень значимости:

$$p(t) = 1 - fcdf(f, k - k_1, n - k).$$

Критерий Фишера

Пример: для веса ребёнка при рождении имеется следующая модель:

$$weight = \theta_0 + \theta_1 cigs + \theta_2 parity + \theta_3 inc + \theta_4 med + \theta_5 fed + \varepsilon,$$

где $cigs$ — среднее число сигарет, выкуриавшихся матерью за один день беременности, $parity$ — номер ребёнка у матери, inc — среднемесячный доход семьи, med — длительность в годах получения образования матерью, fed — отцом.

Данные имеются для 1191 детей.

Зависит ли вес ребёнка при рождении от уровня образования родителей?

$$H_0: \theta_4 = \theta_5 = 0.$$

$$H_1: H_0 \text{ неверна} \Rightarrow p = 0.2421.$$

Связь между критериями Фишера и Стьюдента

Если $k_1 = 1$, критерий Фишера даёт тот же достигаемый уровень значимости, что и критерий Стьюдента для соответствующей двусторонней альтернативы.

Возможны ситуации, когда критерий Фишера отвергает гипотезу о незначимости признаков X_2 , но ни один из них не признаётся значимым критерием Стьюдента. Возможные объяснения:


- отдельные признаки из X_2 недостаточно хорошо объясняют y , но совокупный эффект значим;
- признаки X_2 мультиколлинеарны.

Возможны ситуации, когда, несмотря на то, что некоторые из признаков в X_2 признаются значимыми критерием Стьюдента, критерий Фишера не отвергает гипотезу о незначимости X_2 . Возможные объяснения:

- незначимые признаки в X_2 маскируют влияние значимых;
- значимость отдельных признаков из X_2 — результат эффекта множественной проверки гипотез.

Критерий Фишера

нулевая гипотеза: $H_0: \theta_1 = \dots = \theta_k = 0;$
альтернатива: $H_1: H_0$ неверна;
статистика: $F = \frac{R^2/(k-1)}{(1-R^2)/(n-k)}$;
 $F \sim F(k-1, n-k)$ при H_0 ;



достигаемый уровень значимости:

$$p(t) = 1 - fcdf(f, k-1, n-k).$$

Критерий Фишера

Пример: имеет ли вообще смысл модель веса ребёнка при рождении, рассмотренная выше?

$$H_0: \theta_1 = \dots = \theta_5 = 0.$$

$$H_1: H_0 \text{ неверна} \Rightarrow p = 6.0331 \times 10^{-9}.$$

Отбор признаков и категориальные переменные

Запрещено включать в модель только часть фиктивных переменных, кодирующих один категориальный признак.

Не имеет смысла отдельно проверять значимость фиктивных переменных, кодирующих один и тот же категориальный признак — представляет интерес только их совместная значимость.

Приведённый коэффициент детерминации

Стандартный коэффициент детерминации всегда увеличивается при добавлении регрессоров в модель, поэтому для отбора признаков его использовать нельзя.

Для сравнения моделей, содержащих разное число признаков, можно использовать приведённый коэффициент детерминации:

$$R_a^2 = \frac{ESS / (n - k)}{TSS / (n - 1)} = 1 - (1 - R^2) \frac{n - 1}{n - k}.$$

Пошаговая регрессия

- **Шаг 0.** Настраивается модель с одной только константой, а также все модели с одной переменной. Рассчитывается F -статистика каждой модели и достигаемый уровень значимости. Выбирается модель с наименьшим достигаемым уровнем значимости. Соответствующая переменная X_{e_1} включается в модель, если этот достигаемый уровень значимости меньше порогового значения $p_E = 0.05$.
- **Шаг 1.** Рассчитывается F -статистика и достигаемый уровень значимости для всех моделей, содержащих две переменные, одна из которых X_{e_1} . Аналогично принимается решение о включении X_{e_2} .
- **Шаг 2.** Если была добавлена переменная X_{e_2} , возможно, X_{e_1} уже не нужна. В общем случае просчитываются все возможные варианты исключения одной переменной, рассматривается вариант с наибольшим достигаемым уровнем значимости, соответствующая переменная исключается, если он превосходит пороговое значение $p_R = 0.1$.
- ...

Эксперимент Фридмана

David A. Freedman, A Note on Screening Regression Equations. The American Statistician, Vol. 37, No. 2 (May, 1983), pp. 152-155.

Как избежать построения переобученных моделей?

- Требовать $n \gg k$.
- Использовать кросс-валидацию.

Прикладная статистика
7. Регрессионный анализ.

Рябенко Евгений
riabenko.e@gmail.com