

Практика 5. Регрессия. МНК и свойства МНК-оценок

Часть 1. Критерий МНК как функция коэффициентов регрессии в трехмерном пространстве

1. Сгенерировать выборку объема n по модели из своего варианта на сайте. Вариант выбирается по списку на сайте. Для модели заданы истинные коэффициенты регрессии и дисперсия шума. Объем выборки n задать от 10 до 20.
2. Рассчитать МНК-оценки коэффициентов регрессии на основе аналитического решения задачи минимизации функционала качества. Расчет сделать функцией regress и по формуле:
$$\hat{\beta} = (X^T X)^{-1} X^T Y$$
3. Построить трехмерный график (surf) и график изолиний (contour) функционала качества МНК $Q(\beta)$. Отобразить точкой аналитическое решение (plot3). Убедиться, что точка лежит точно в минимуме.

Часть 2. Статистические свойства МНК-оценок

1. Построить распределение оценок коэффициентов регрессии как случайных величин:
 - a. теоретическую плотность распределения
 - b. методом статистического моделирования Монте-Карло
 - c. по результатам статистического моделирования определить 95% доверительный интервал коэффициентов, вывести на график
2. Построить распределения прогноза $\hat{y}(x_n)$ как случайной величины при $x=200$ и $x = 240$
 - a. теоретическую плотность распределения
 - b. методом статистического моделирования Монте-Карло
 - c. на графиках отметить истинное значение $y_{ист}(x_n)$
 - d. по результатам статистического моделирования определить 95% доверительный интервал коэффициентов, вывести на график
3. Построить распределение ошибки прогноза истинного значения $e_{и} = \hat{y}(x_n) - y(x_n)$ при $x_n = 200, x_n = 300$.
 - a. теоретическую плотность распределения
 - b. методом статистического моделирования Монте-Карло
 - c. по результатам статистического моделирования определить 95% доверительный интервал коэффициентов, вывести на график
4. Построить распределения ошибки предсказания нового значения $e_n = \hat{y}(x) - y_n$ при $x_n = 200, x_n = 300$.
 - a. теоретическую плотность распределения
 - b. методом статистического моделирования Монте-Карло
 - c. сопоставить распределения $e_{и}, e_n$, визуальнo проверить соответствие дисперсий
 - d. по результатам статистического моделирования определить 95% доверительный интервал коэффициентов, вывести на график
5. Методом статистического моделирования построить полигон относительных частот ошибки предсказания истинного значения $e_{и} = \hat{y}(x) - y(x)$ при $x=200$ и $x = 300$.
6. Методом статистического моделирования построить полигон относительных частот распределения ошибки предсказания нового значения $e_n = \hat{y}(x) - y_n$ при $x=200$ и $x = 300$.
7. Построить теоретические плотности распределения $\hat{y}(x_n), e_{и}, e_n$ при всех x . Отметить 95%-доверительный диапазон. График совместить с графиками из предыдущего пункта.

Вопросы к защите

1. Объяснение невязок между моделью и данными как реализаций случайного шума.
 - помимо примера с QH-характеристикой привести свой пример

- пояснить содержательный смысл дисперсии шума в вашем примере
- 2. Вероятностная модель выборки до измерений (векторный вид, скалярный вид).
- 3. Как сформировать вектор факторов
 - a. для задания линейной зависимости
 - b. для задания полиномиальной зависимости
- 4. Как формируется матрица плана?
- 5. Формальная постановка задачи поиска оценок коэффициентов регрессии как задачи минимизации функционала (в векторном виде).
- 6. Что такое система нормальных уравнений? Как она выводится?
- 7. Оценки коэффициентов регрессии $\hat{\beta}$ как случайные величины.
 - a. как проявляется их случайность?
 - b. модель $\hat{\beta}$ до измерений
 - c. доказательство линейности связи $\hat{\beta}$ и вектора шума
 - d. доказательство несмещенности оценок $\hat{\beta}$
 - e. вывод ковариационной матрицы оценок $cov(\hat{\beta})$
 - f. какое теоретическое распределение имеет коэффициент $\hat{\beta}_i$?
 - g. от чего зависит точность (дисперсия) оценивания $\hat{\beta}$? Внести изменения в коде, чтобы проиллюстрировать влияние этих факторов
- 8. Прогноз регрессионной модели как случайная величина
 - a. ошибка прогноза истинного значения и ошибка прогноза нового значения
 - b. почему важна коррелированность компонентов $\hat{\beta}$?
 - i. вывод формулы дисперсии суммы коррелированных величин $D(X + Y)$
 - ii. обобщение на случай $D(aX + bY)$
 - iii. что играет роль a, b в прогнозе $\hat{y}(x)$? что играет роль X, Y?
 - c. чем обусловлена погрешность прогноза истинного значения и погрешность нового значения?
 - d. доказательство несмещенности прогноза, вывод дисперсии прогноза,
 - e. дисперсии ошибок прогноза истинного значения и нового значения
 - f. доверительный интервал прогноза при **известной дисперсии**
 - i. прогноз истинного значения
 - ii. прогноз нового значения