

Практика 10. Статистические свойства оценок коэффициентов и прогноза регрессионных моделей

Часть 1. Вероятностная модель процесса и код имитации эксперимента

1. Задать вероятностную модель процесса. Для этого
 - a. Взять оценки коэффициентов для модели 2-го порядка из практики, посвященной построению QN-характеристик. **В данной работе считать их истинными** ($\beta_{ист}$).
 - b. Задаться дисперсией шума D_ε .
 - c. Задаться объемом выборки n от 10 до 20.
 - d. Задаться диапазоном значений расхода в планируемом эксперименте $[Q_{min}, Q_{max}]$
2. Реализовать формирователь плана эксперимента по расходу
function Qplan = build_plan(n, Qmin, Qmax).
Qplan – планируемые в эксперименте значения расхода, лежащие в диапазоне $[Q_{min}, Q_{max}]$
В данной работе будет многократно повторяться эксперимент по одному плану, поэтому при формировании матрицы плана не допускается использование случайных генераторов. При повторном вызове функция build_plan должна возвращать такой же план, как изначально.
3. Реализовать формирователь матрицы плана – вспомогательная функция, формирующая матрицу плана для произвольного порядка вектора факторов
function X = build_plan_matrix(Qplan, k)
в дальнейшем в коде матрица плана должна формироваться этой функцией
4. Реализовать генератор экспериментальных данных согласно плана эксперимента
function [Y, X] = generate_process_data(Qplan, $\beta_{ист}$, D_ε)
Y – значение моделируемого параметра процесса
X – матрица плана проведенного эксперимента
5. Сгенерировать выборку объемом n с помощью функции generate_process_data. По полученным данным построить оценку параметров модели $\hat{\beta}$ и вывести их в консоль. В одних осях построить:
 - a. график истинной зависимости $y_{ист} = x^T \beta_{ист}$ в диапазоне $[0.8 Q_{min}, 1.2 Q_{max}]$
 - b. точки экспериментальной выборки
 - c. график восстановленной зависимости $\hat{y} = x^T \hat{\beta}$ в диапазоне $[0.8 Q_{min}, 1.2 Q_{max}]$
6. Несколько раз запустить код, убедиться, что значения $\hat{\beta}$ изменяются и вместе с ним меняется график $\hat{y} = x^T \hat{\beta}$.

Часть 2. Статистические свойства МНК-оценок

1. Построить распределение оценок **каждого** коэффициента регрессии $\hat{\beta}_i$ 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 для x_n , сформированных при $Q = 0.8 Q_{min}$, $Q = 1.2 Q_{max}$.
 - 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 $e_n = \hat{y}(x_n) - y_{ист}(x_n)$ для x_n , сформированных при $Q = 0.8 Q_{min}$, $Q = 1.2 Q_{max}$.
 - 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 $e_n = \hat{y}(x_n) - y_n$ для x_n , сформированных при $Q = 0.8 Q_{\min}$, $Q = 1.2 Q_{\max}$.
 - a. теоретическую плотность распределения
 - b. методом статистического моделирования Монте-Карло
 - c. сопоставить распределения e_{in} , e_n , визуально проверить соответствие дисперсий
 - d. по результатам статистического моделирования определить 95% доверительный интервал коэффициентов, вывести на график
- 5. Количество реализация Монте-Карло выбрать так, чтобы графики hist_density были достаточно гладкими.
- 6. Убедиться, что нет дублирования кода функций первой части задания.

Вопросы к защите

1. Формула МНК-оценок без вывода
2. Объяснение невязок между моделью и данными как реализаций случайного шума.
3. Вероятностная модель выборки до измерений (через матрицу плана, через вектор факторов векторный вид, скалярный вид).
4. 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 $cov(\hat{\beta})$; почему недостаточно посчитать только дисперсии.
 - 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
5. Прогноз регрессионной модели как случайная величина
 - a. Ошибка прогноза истинного значения и ошибка прогноза нового значения. Чем обусловлена погрешность прогноза истинного значения и погрешность прогноза нового значения?
 - b. Доказательство несмещенности прогноза.
 - c. Вывод дисперсии прогноза. Влияние коррелированности компонентов $\hat{\beta}$ при расчете дисперсии прогноза
 - 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?
 - iv. почему важна коррелированность компонентов $\hat{\beta}$? что будет если ее не учесть? в какой момент это учитывается?
 - d. дисперсии ошибок прогноза истинного значения и нового значения
 - e. доверительный интервал прогноза при **известной дисперсии**
 - i. вывод правила трех сигм
 - ii. почему важна несмещенность прогноза?
 - iii. прогноз истинного значения
 - iv. прогноз нового значения