

Тестирование регрессионных моделей

Даниленко Елена Владимировна, гр. 522

Санкт-Петербургский государственный университет
Математико-механический факультет
Кафедра статистического моделирования

Научный руководитель: д.ф.-м.н., проф. Мелас В.Б.
Рецензент: к.ф.-м.н. Шпилев П.В.

Санкт-Петербург
2008г.

Параметрические модели имеют важное практическое значение, поэтому ставится задача проверки адекватности используемой модели.

Рассмотрим следующую модель:

$$Y_i = m(\mathbf{x}_i) + \varepsilon_i, \quad i = 1, \dots, n$$

где $\mathbf{x}_i \in \mathbb{R}^d$ — предиктор, $\varepsilon_i \sim N(0, \sigma^2(\mathbf{x}_i))$ — случайная ошибка,
 $E\varepsilon_i\varepsilon_j = 0, i \neq j$, m — гладкая (неизвестная) регрессионная функция.

Пусть $\mathcal{M} = \{m(\cdot, \theta) | \theta \in \Theta\}$ — некоторое параметрическое функциональное пространство.

Проверяем гипотезу

$$H_0 : \quad m \in \mathcal{M} \quad \quad \quad H_1 : \quad m \notin \mathcal{M}$$

Применяем следующие методы:

- Тест, основанный на разности параметрической и непараметрической оценок дисперсии, Dette (1998)
- Адаптивный тест Неймана, Fan, Huang (2001)
- F-тест

$$\mathcal{M} = \{g^T(x)\theta | \theta \in \Theta\},$$

где $g(x) = (g_1(x), \dots, g_p(x))^T$ — ЛНЗ регрессионные функции.

Введем оценки дисперсии (параметрическую и непараметрическую):

$$\begin{aligned}\hat{\sigma}_{LSE}^2 &= \frac{1}{n-p} \sum_{j=1}^n (y_j - g^T(x_j)\hat{\theta}_n)^2 \\ \hat{\sigma}_{HM}^2 &= \frac{1}{v} \sum_{j=1}^n \left(y_j - \frac{\sum_{i=1}^n y_i K\left(\frac{x_j-x_i}{h}\right)}{\sum_{l=1}^n K\left(\frac{x_j-x_l}{h}\right)} \right)^2\end{aligned}$$

Тестовая статистика:

$$T_n = \hat{\sigma}_{LSE}^2 - \hat{\sigma}_{HM}^2$$

Теорема [Dette, 1998]

$$H_0 : n\sqrt{h}(T_n + C_2 h^{2r}) \xrightarrow{D} N(0, \mu_0^2) \quad (1)$$

$$H_1 : \sqrt{n}(T_n - M^2) \xrightarrow{D} N(0, \mu_1^2) \quad (2)$$

отвергаем гипотезу H_0 , если $n\sqrt{h}T_n > u_{1-\alpha}\hat{\mu}_0$, $h = o(n^{-2/(4r+1)})$

применяем преобразование Фурье к остаткам $\hat{\varepsilon}_i = Y_i - \mathbf{x}_i^T \hat{\theta}_n$
 $\hat{\theta}_n \xrightarrow{P} \theta_0$ – состоятельность оценки МНК
 $\eta_i = m(\mathbf{x}_i) - \mathbf{x}_i^T \theta_0$

$$\begin{aligned}\hat{\sigma}_1^2 &= \frac{1}{n - I_n} \sum_{i=I_n+1}^n \hat{\varepsilon}_i^{*2} - \left(\frac{1}{n - I_n} \sum_{i=I_n+1}^n \hat{\varepsilon}_i^* \right)^2 \\ \hat{\sigma}_2^2 &= \frac{1}{n - I_n} \sum_{i=I_n+1}^n \hat{\varepsilon}_i^{*4} - \left(\frac{1}{n - I_n} \sum_{i=I_n+1}^n \hat{\varepsilon}_i^{*2} \right)^2\end{aligned}$$

$$\begin{aligned}T_{AN,1}^* &= \max_{1 \leq m \leq n} \frac{1}{\sqrt{2m\hat{\sigma}_1^4}} \sum_{i=1}^m (\hat{\varepsilon}_i^{*2} - \hat{\sigma}_1^2) \\ T_{AN,2}^* &= \max_{1 \leq m \leq n} \frac{1}{\sqrt{m\hat{\sigma}_2^2}} \sum_{i=1}^m (\hat{\varepsilon}_i^{*2} - \hat{\sigma}_1^2)\end{aligned}$$

Тестовая статистика:

$$T_{AN,j} = \sqrt{2 \ln \ln n} T_{AN,j}^* - (2 \ln \ln n + 0.5 \ln \ln \ln n - 0.5 \ln(4\pi))$$



Теорема 1 [Fan, 1996]

$$P(T_{AN,j} < x) \xrightarrow{n \rightarrow \infty} \exp(-\exp(-x)), \quad j = 1, 2.$$

Критическая область

$$T_{AN,j} > -\ln(\ln(1 - \alpha)) \quad (j = 1, 2) \quad (3)$$

имеет асимптотический уровень значимости α

Теорема 2 [Fan, 1996]

Если

$$(\ln \ln n)^{-1/2} \max_{1 \leq m \leq n} m^{-1/2} \sum_{i=1}^m \eta_i^* \longrightarrow \infty$$

Тогда критическая область (3) имеет асимптотическую мощность 1.

Сходимость медленная, используем точные квантили распределения
отвергаем гипотезу H_0 , если $T_{AN,j} > T_{\alpha,j}$

На рисунках изображена мощность тестов против данной параметризованной альтернативы в зависимости от значения параметра с уровнем значимости 5%.

Рассмотрены следующие виды альтернатив:

Название	Вид
квадратичная	$m(x) = 5x + \theta x^2$
тригонометрическая	$m(x) = 1 + \cos(\theta x \pi)$
логистическая	$m(x) = \frac{10}{1 + \theta \exp(-2x)}$
F-тест построен в модели	$Y = a_0 + a_1 x + a_2 x^2 + \varepsilon$

Таблица: Виды альтернатив в одномерном случае

Название	Вид
квадратичная	$m(x) = x_1 + \theta x_2^2 + 2x_3$
смешанная	$m(x) = x_1 + \theta x_2 \cdot x_3$
тригонометрическая	$m(x) = x_1 + \cos(\theta x_2 \pi) + 2x_3$
F-тест построен в модели	$Y = a_0 + \sum_i a_i x_i + \sum_{i < j} a_{i,j} x_i x_j + \varepsilon$

Таблица: Виды альтернатив в многомерном случае

Пример 1

$$Y = 5x + \theta x^2 + \varepsilon, \quad \varepsilon \sim N(0, 1)$$





Рис.: Пример 1

- $x \sim p.p.(0, 1)$
- фиксированный равномерный план — лучше всего для теста Dette
- гетероскедастическая модель
 $\sigma^2(x) = 3(1 + x^2)/4$ — наблюдается незначительное снижение мощности
- все тесты ведут себя примерно одинаково, тест Dette несколько лучше

Пример 1

$$Y = 5x + \theta x^2 + \varepsilon, \quad \varepsilon \sim N(0, 1)$$



- $x \sim p.p.(-2, 2)$
- при увеличении длины интервала мощности всех тестов уже при небольшом отклонении от нулевой гипотезы приближаются к единице

Рис.: Пример 1

Пример 2

$$Y = 1 + \cos(\theta x \pi) + \varepsilon, \quad \varepsilon \sim N(0, 1)$$




Рис.: Пример 2

- $x \sim p.p.(-2, 2)$
- F-тест значительно проигрывает
- При большом или очень малом значении параметра мощности тестов низкие, нужно корректировать длину промежутка, на котором берется план

Пример 2

$$Y = 1 + \cos(\theta x \pi) + \varepsilon, \quad \varepsilon \sim N(0, 1)$$




Рис.: Пример 2

- $x \sim N(0, 1)$
- F-тест значительно проигрывает
- при увеличении параметра мощность АН-теста с оцененной дисперсией значительно снижается, нужно скорректировать оценку дисперсии, увеличив порог отсечения I_n

Пример 3

$$Y = \frac{10}{1 + \theta \exp(-2x)} + \varepsilon, \quad \varepsilon \sim N(0, 1)$$





Рис.: Пример 3 ($x \sim p.p.(0, 1)$ слева) ($x \sim p.p.(-2, 2)$ справа)

тест Dette:

- $K(x_1, \dots, x_d) = \prod_{j=1}^d K_j(x_j)$
- нормализующий фактор в условиях H_0 : $n\sqrt{h_1 \cdots h_d}$

АН-тест:

- упорядочивать по первой ГК
- частично-линейная альтернатива $H1 : m(\mathbf{x}) = F(x_1) + \mathbf{x}_2^T \beta_2$
упорядочить по x_1 , оценить β_2
- аддитивная альтернатива $H1 : m(\mathbf{x}) = f_1(x_1) + f_2(x_2) + \dots + f_d(x_d)$
упорядочить по каждому из предикторов

$$\hat{T} = \max_{1 \leq j \leq d} \hat{T}_j$$

Пример 4

$$Y = X_1 + \theta X_2^2 + 2X_3 + \varepsilon, \quad X_1, X_2, X_3 \sim p.p.(-2, 2)$$




Рис.: Пример 4

- АН-тесты для аддитивной и частично линейной альтернативы, а также F-тест лидируют
- АН-тест с упорядочиванием по первой ГК немного проигрывает
- мощность теста Dette растет значительно медленнее

Пример 5

$$Y = X_1 + \theta X_2 \cdot X_3 + \varepsilon, \quad X_1, X_2, X_3 \sim p.p.(-2, 2)$$





Рис.: Пример 5

- F-тест лидирует среди всех модификаций АН-тестов, лидирует АН-тест с упорядочиванием по первой ГК
- в АН-тестах для аддитивной и частично линейной альтернативы применили другую непараметрическую оценку дисперсии
- тест Dette практически не изменился

Пример 6

$$Y = X_1 + \cos(\theta X_2 \pi) + 2X_3 + \varepsilon, \quad X_1, X_2, X_3 \sim p.p.(-2, 2)$$



- АН-тесты уже при небольшом значении параметра имеют высокую мощность
- F-тест провалился

Рис.: Пример 6

- Выполнены реализация и ранее не проводившееся сравнение методов
- Тест Dette обобщен на произвольный отрезок
- В АН-тесте использованы оценки дисперсии, значительно увеличивающие его мощность
- Оба теста, хоть и основаны на различных идеях, показывают примерно одинаковые результаты в одномерном случае. В многомерном тест Fan'a значительно лучше
- В случае, когда находимся в модели F-теста:
 - в одномерном случае тесты имеют незначительно отличающуюся мощность
 - в многомерной регрессии мощность АН-тест путем различных модификаций можно приблизить к мощности F-теста
- В остальных примерах:
мощность обоих тестов значительно превосходит мощность F-теста