

Klasyczny Model Regresji Liniowej

Testowanie hipotez

Stanisław Cichocki

Natalia Nehrebecka

Wykład 9

Plan wykładu

- ▶ 1. Kombinacja liniowa parametrów
 - Estymator elementu β_k
- ▶ 2. Prognozowanie
- ▶ 3. Testowanie hipotez
 - Rozkład estymatora \mathbf{b}

Plan wykładu

- ▶ 1. Kombinacja liniowa parametrów
 - Estymator elementu β_k
- ▶ 2. Prognozowanie
- ▶ 3. Testowanie hipotez
 - Rozkład estymatora \mathbf{b}

Kombinacja liniowa parametrów

- ▶ Czasami interesuje nas nie tylko wielkość oszacowanych parametrów ale także oszacowania pewnych funkcji tych parametrów
- ▶ W przypadku MNK łatwo jest przeanalizować własności estymatora kombinacji liniowej parametrów β
- ▶ Kombinacja liniowa:

$$\delta' \beta = \sum_{k=1}^K \delta_k \beta_k$$

gdzie: δ - nielosowy wektor współczynników

Kombinacja liniowa parametrów

- ▶ Nieobciążony estymator tej kombinacji to $\delta' b$
- ▶ Wariancja tej kombinacji:

$$\begin{aligned} \text{Var}(\delta' b) &= E[(\delta' b - \delta' \beta)(\delta' b - \delta' \beta)'] \\ &= E[\delta'(b - \beta)(b - \beta)' \delta] = \delta' E[(b - \beta)(b - \beta)'] \delta \\ &= \delta' \Sigma \delta \end{aligned}$$

- ▶ Estymator wariancji tej kombinacji: $\delta' \hat{\Sigma}_b \delta$

Kombinacja liniowa parametrów

► Przykład

dochod - zmienna zależna,

wiek, wiek_2 oraz interakcje między wykształceniem i płcią - zmienne niezależne

```
xi: regress dochod wiek wiek_2 i.plec*i.wyksztalcenie
```

Source	SS	df	MS	Number of obs =	1083
Model	81648217.6	7	11664031.1	F(7, 1075) =	18.83
Residual	665832918	1075	619379.458	Prob > F =	0.0000
-----				R-squared =	0.1092
Total	747481135	1082	690832.842	Adj R-squared =	0.1034
-----				Root MSE =	787.01

dochod	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
wiek	36.38318	15.39846	2.36	0.018	6.168745	66.59762
wiek_2	-.4049352	.1962222	-2.06	0.039	-.7899572	-.0199131
_Iplec_1	-144.4044	143.4615	-1.01	0.314	-425.9008	137.0919
_Iwyksztal~2	274.2703	105.1538	2.61	0.009	67.94046	480.6002
_Iwyksztal~3	1040.998	137.1701	7.59	0.000	771.8461	1310.149
IpleXwyk~2	-143.4455	153.4394	-0.93	0.350	-444.5201	157.6292
IpleXwyk~3	-682.341	197.7395	-3.45	0.001	-1070.34	-294.3418
cons	-121.1625	300.6773	-0.40	0.687	-711.1435	468.8184

Kombinacja liniowa parametrów

- ▶ Szczególny przypadek tej kombinacji liniowej: kombinacja, która daje k-ty element wektora β

- ▶ Wtedy:

$$\delta' = [0 \dots 0 \quad 1 \quad 0 \dots 0]$$

$$\delta' \beta = \beta_k$$

- ▶ Nieobciążonym estymatorem β_k jest b_k

- ▶ Estymatorem wariancji β_k jest $\delta' \hat{\Sigma}_b \delta = [\hat{\Sigma}_b]_{kk}$

Kombinacja liniowa parametrów

► Przykład

dochod - zmienna zależna,

wiek, wiek_2 oraz interakcje między wykształceniem i płcią - zmienne niezależne

```
xi: regress dochod wiek wiek_2 i.plec*i.wyksztalcenie
```

Source	SS	df	MS	Number of obs =	1083
Model	81648217.6	7	11664031.1	F(7, 1075) =	18.83
Residual	665832918	1075	619379.458	Prob > F =	0.0000
-----				R-squared =	0.1092
Total	747481135	1082	690832.842	Adj R-squared =	0.1034
-----				Root MSE =	787.01

dochod	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
wiek	36.38318	15.39846	2.36	0.018	6.168745	66.59762
wiek_2	-.4049352	.1962222	-2.06	0.039	-.7899572	-.0199131
_Iplec_1	-144.4044	143.4615	-1.01	0.314	-425.9008	137.0919
_Iwyksztal~2	274.2703	105.1538	2.61	0.009	67.94046	480.6002
_Iwyksztal~3	1040.998	137.1701	7.59	0.000	771.8461	1310.149
IpleXwyk~2	-143.4455	153.4394	-0.93	0.350	-444.5201	157.6292
IpleXwyk~3	-682.341	197.7395	-3.45	0.001	-1070.34	-294.3418
cons	-121.1625	300.6773	-0.40	0.687	-711.1435	468.8184

Plan wykładu

- ▶ 1. Kombinacja liniowa parametrów
 - Estymator elementu β_k
- ▶ 2. Prognozowanie
- ▶ 3. Testowanie hipotez
 - Rozkład estymatora \mathbf{b}

Prognoza

- ▶ Prognoza: przewidywana przez model wartość y_f dla danego wektora zmiennych objaśniających x_f
- ▶ Błąd prognozy:

$$e_f = \hat{y}_f - y_f$$

- ▶ Nieobciążona prognoza y_f w KMRL to:

$$\hat{y}_f = x_f b$$

Prognoza

- ▶ Prognoza ta jest nieobciążona bo:

$$\begin{aligned} E(e_f) &= E(\hat{y}_f - y_f) = E(x_f b - x_f \beta) = x_f E(b) - x_f \beta \\ &= x_f \beta - x_f \beta = 0 \end{aligned}$$

Prognoza

▶ Przykład

wydg- zmienna zależna

dochg - zmienna niezależna

```
reg wydg dochg
```

Source	SS	df	MS	Number of obs = 31679		
Model	2.3577e+10	1	2.3577e+10	F(1, 31677)	=	21732.03
Residual	3.4367e+10	31677	1084914.37	Prob > F	=	0.0000
-----+-----				R-squared	=	0.4069
Total	5.7944e+10	31678	1829163.02	Adj R-squared	=	0.4069
-----+-----				Root MSE	=	1041.6

wydg	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
dochg	.5879668	.0039884	147.42	0.000	.5801493	.5957843
_cons	712.8104	10.01991	71.14	0.000	693.171	732.4498

Prognoza

- ▶ Pytanie

Ile wynoszą wydatki jeśli dochód będzie równy 5000 zł?

- ▶ Odpowiedź:

$$wydg_f = 712,81 + 0,58 * 5000 = 3612,81$$

Prognoza

- ▶ Wariancja prognozy:

$$\text{Var}(\hat{y}_f) = \text{Var}(x_f b) = x_f \text{Var}(b) x_f' = x_f \Sigma_b x_f'$$

Prognoza

- ▶ Wariancja błędu prognozy (mierzy precyzję prognozy):

$$\begin{aligned} \text{Var}(e_f) &= E[(\hat{y}_f - y_f)(\hat{y}_f - y_f)'] = E[x_f(b - \beta)(b - \beta)'x_f'] \\ &\quad - 2x_f E[(b - \beta)\varepsilon_f] + E[\varepsilon_f^2] = x_f \Sigma_b x_f' + \sigma^2 = \text{Var}(\hat{y}_f) + \sigma^2 \end{aligned}$$

- ▶ Gdyż: $E[(b - \beta)\varepsilon_f] = (X'X)^{-1} X' E(\varepsilon\varepsilon_f) = 0$

Prognoza

- ▶ Wariancja błędu prognozy:

$$\text{Var}(\hat{e}_f) = \text{Var}(\hat{y}_f) + \sigma^2$$

The diagram illustrates the decomposition of the variance of the forecast error. The equation $\text{Var}(\hat{e}_f) = \text{Var}(\hat{y}_f) + \sigma^2$ is shown. The term $\text{Var}(\hat{y}_f)$ is enclosed in a green circle, and a green arrow points from this circle to the text 'błąd estymacji' (estimation error) below it. The term σ^2 is enclosed in a blue circle, and a blue arrow points from this circle to the text 'błąd losowy' (random error) below it.

błąd estymacji

błąd losowy

Prognoza

- ▶ Estymator wariancji błędu prognozy:

$$x_f \hat{\Sigma} b x_f' + s^2$$


Plan wykładu

- ▶ 1. Kombinacja liniowa parametrów
 - Estymator elementu β_k
- ▶ 2. Prognozowanie
- ▶ 3. Testowanie hipotez
 - Rozkład estymatora \mathbf{b}

Testowanie hipotez

- ▶ Badamy czy hipotezy teoretyczne (wynikające z teorii) znajdują potwierdzenie w danych
- ▶ Hipotezy narzucają pewne ograniczenia na wartości parametrów
- ▶ Oszacowania parametrów powinny spełniać te ograniczenia w przybliżeniu
- ▶ Jeśli oszacowania parametrów odbiegają od postulowanych związków wynikających z teorii to odrzucamy hipotezę jako sprzeczną z danymi
- ▶ Uwzględnienie w modelu wiedzy z hipotezy prawdziwej poprawia precyzję oszacowań
- ▶ Uwzględnienie w modelu wiedzy z hipotezy fałszywej prowadzi do obciążenia estymatora
- ▶ Do testowania hipotez wykorzystujemy testy statystyczne

Dodatkowo założenie klasycznego modelu regresji liniowej



Testowanie hipotez

- ▶ Rozkład estymatora \mathbf{b} :

$$\mathbf{b} \sim N(\boldsymbol{\beta}, \sigma^2 (\mathbf{X}' \mathbf{X})^{-1})$$

Dziękuję za uwagę