

Budowa modelu i testowanie hipotez

Problemy metodologiczne

- Dysponujemy oszacowaniami parametrów następującego modelu

$$y_t = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \varepsilon_t$$

- Dysponujemy oszacowaniami parametrów następującego modelu

$$y_t = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \varepsilon_t$$

- Celem jest weryfikacja łącznej istotności parametrów modelu

- Dysponujemy oszacowaniami parametrów następującego modelu

$$y_t = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \varepsilon_t$$

- Celem jest weryfikacja łącznej istotności parametrów modelu
- Czy sposób testowania ma wpływ na uzyskiwany wynik testu?

- Dysponujemy oszacowaniami parametrów następującego modelu

$$y_t = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \varepsilon_t$$

- Celem jest weryfikacja łącznej istotności parametrów modelu
- Czy sposób testowania ma wpływ na uzyskiwany wynik testu?
- $H_0 : \beta_1 = \beta_2 = \dots = \beta_k = 0$

- Dysponujemy oszacowaniami parametrów następującego modelu

$$y_t = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \varepsilon_t$$

- Celem jest weryfikacja łącznej istotności parametrów modelu
- Czy sposób testowania ma wpływ na uzyskiwany wynik testu?
- $H_0 : \beta_1 = \beta_2 = \dots = \beta_k = 0$
- $H_0^1 : \beta_1 = 0, H_0^2 : \beta_2 = 0, \dots, H_0^k : \beta_k = 0$

- Zakładamy, że statystyki są niezależne od siebie

- Zakładamy, że statystyki są niezależne od siebie
- przyjmijmy, że prawdopodobieństwo popełnienia błędu 1 rodzaju wynosi α

- Zakładamy, że statystyki są niezależne od siebie
- przyjmijmy, że prawdopodobieństwo popełnienia błędu 1 rodzaju wynosi α
- poziom istotności w pierwszej procedurze wynosi oczywiście $1 - \alpha$

- Zakładamy, że statystyki są niezależne od siebie
- przyjmijmy, że prawdopodobieństwo popełnienia błędu 1 rodzaju wynosi α
- poziom istotności w pierwszej procedurze wynosi oczywiście $1 - \alpha$
- w drugiej procedurze odrzucamy H_0 gdy zostanie odrzucona choć jedna z k hipotez

- Zakładamy, że statystyki są niezależne od siebie
- przyjmijmy, że prawdopodobieństwo popełnienia błędu 1 rodzaju wynosi α
- poziom istotności w pierwszej procedurze wynosi oczywiście $1 - \alpha$
- w drugiej procedurze odrzucamy H_0 gdy zostanie odrzucona choć jedna z k hipotez
- zatem rzeczywisty poziom istotności testu wynosi $\alpha^* = 1 - (1 - \alpha)^k$

Obciążenie Lovella

Obciążeniem Lovella nazywamy różnicę między nominalnym (założonym) poziomem istotności α a rzeczywistym poziomem istotności przeprowadzanego testu α^*

Obciążenie Lovella

Obciążeniem Lovella nazywamy różnicę między nominalnym (założonym) poziomem istotności α a rzeczywistym poziomem istotności przeprowadzanego testu α^*

- wraz ze wzrostem ilości pojedynczych hipotez składających się na hipotezę łączną obciążenie Lovella rośnie, bowiem

$$\lim_{k \rightarrow \infty} \alpha^* = \lim_{k \rightarrow \infty} 1 - \underbrace{(1 - \alpha)^k}_0 = 1$$

- Czy miesiąc urodzenia wpływa na poziom uzyskiwanego dochodu?
- Dane: Diagnoza Społeczna 2007

dochod	Coef.	Std. Err.	t	P> t
LUT	-23.33821	47.06868	-0.50	0.620
MAR	-41.63749	45.35714	-0.92	0.359
KWI	-42.24827	45.62751	-0.93	0.354
MAJ	-58.53747	46.9147	-1.25	0.212
CZE	-46.12517	46.70989	-0.99	0.323
LIP	-30.14434	47.25495	-0.64	0.524
SIE	-48.19725	46.73686	-1.03	0.302
WRZ	-42.534	47.81215	-0.89	0.374
PAZ	-91.11514	47.37196	-1.98	0.049
LIS	-57.73076	48.37949	-1.19	0.233
GRU	.127865	48.27925	0.00	0.998
stala	1153.077	32.03349	36.00	0.000

- Na poziomie istotności 5% zmienna dla października jest statystycznie istotna

- Na poziomie istotności 5% zmienna dla października jest statystycznie istotna
- ale rzeczywisty poziom istotności dla łącznej hipotezy wynosi $\alpha^* = 0,44$

- Diagnostyka modelu:

```
Number of obs = 10921
F( 11, 10909) = 0.54
Prob > F      = 0.8808
R-squared     = 0.0005
Adj R-squared = -0.0005
Root MSE     = 1030.6
```

- Diagnostyka modelu:

```
Number of obs = 10921  
F( 11, 10909) = 0.54  
Prob > F      = 0.8808  
R-squared     = 0.0005  
Adj R-squared = -0.0005  
Root MSE     = 1030.6
```

- ale nieprawidłowe wyniki testów mogą mieć inną przyczynę

- Diagnostyka modelu:

```
Number of obs = 10921
F( 11, 10909) = 0.54
Prob > F      = 0.8808
R-squared     = 0.0005
Adj R-squared = -0.0005
Root MSE     = 1030.6
```

- ale nieprawidłowe wyniki testów mogą mieć inną przyczynę
- zatem należy zwracać uwagę na ewentualne obciążenie

- Jak ustalić listę zmiennych, które należy uwzględnić w modelu?

- Jak ustalić listę zmiennych, które należy uwzględnić w modelu?
- W jaki sposób wybrać optymalny podzbiór zmiennych?

- Jak ustalić listę zmiennych, które należy uwzględnić w modelu?
- W jaki sposób wybrać optymalny podzbiór zmiennych?
- Niebezpieczeństwa związane ze złą specyfikacją

- Stopniowe upraszczanie modelu ogólnego

- Stopniowe upraszczanie modelu ogólnego
- Narzucanie ograniczeń na parametry modelu

- Stopniowe upraszczanie modelu ogólnego
- Narzucanie ograniczeń na parametry modelu
- Model zagnieżdżony jako szczególny przypadek modelu ogólnego

Przykład 1

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \varepsilon \quad (1)$$

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \varepsilon \quad (2)$$

$$y = \beta_0 + \beta_1 x_1 + \varepsilon \quad (3)$$

$$y = \beta_0 + \beta_1 x_1 + \beta_3 x_3 + \varepsilon \quad (4)$$

Przykład 1

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \varepsilon \quad (1)$$

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \varepsilon \quad (2)$$

$$y = \beta_0 + \beta_1 x_1 + \varepsilon \quad (3)$$

$$y = \beta_0 + \beta_1 x_1 + \beta_3 x_3 + \varepsilon \quad (4)$$

Zapis hipotez

$$H_0^2 \quad \beta_3 = 0$$

$$H_0^3 \quad \beta_2 = \beta_3 = 0$$

$$H_0^4 \quad \beta_1 = \beta_2 = 0$$

- Przykład 2. Dochód gospodarstwa= $f(\text{miasto, płęć, wykształcenie})$

- Przykład 2. Dochód gospodarstwa= $f(\text{miasto, płéć, wykształcenie})$
- H_0^1 płéć głowy nie ma znaczenia

- Przykład 2. Dochód gospodarstwa=f(miasto, płeć, wykształcenie)
- H_0^1 płeć głowy nie ma znaczenia
- H_0^2 płeć głowy, oraz miejsce zamieszkania nie ma znaczenia

- Przykład 2. Dochód gospodarstwa=f(miasto, płeć, wykształcenie)
- H_0^1 płeć głowy nie ma znaczenia
- H_0^2 płeć głowy, oraz miejsce zamieszkania nie ma znaczenia
- H_0^3 płeć głowy, miejsce zamieszkania i wykształcenie głowy nie ma znaczenia

Krzywa Philipsa

- Na podstawie danych miesięcznych dla Polski szacujemy krzywą Philipsa

Source	SS	df	MS	Number of obs = 128	
Model	844.53534	5	168.907069	F(5, 122)	= 20.05
Residual	1027.63908	122	8.42327113	Prob > F	= 0.0000
Total	1872.17442	127	14.7415309	R-squared	= 0.4511
				Adj R-squared	= 0.4286
				Root MSE	= 2.9023

inflacja	Coef.	Std. Err.	t	P> t
stopa				
--.	4.460899	1.194171	3.74	0.000
L1.	-5.479456	2.551726	-2.15	0.034
L2.	.5970146	2.850079	0.21	0.834
L3.	4.454998	2.565207	1.74	0.085
L4.	-4.647815	1.215513	-3.82	0.000
_cons	14.64427	1.332817	10.99	0.000

Krzywa Philipa

Source	SS	df	MS		
Model	844.16574	4	211.041435	Number of obs =	128
Residual	1028.00868	123	8.35779416	F(4, 123) =	25.25
Total	1872.17442	127	14.7415309	Prob > F =	0.0000
				R-squared =	0.4509
				Adj R-squared =	0.4330
				Root MSE =	2.891

inflacja	Coef.	Std. Err.	t	P> t
stopa				
--.	4.348709	1.063177	4.09	0.000
L1.	-5.069354	1.630214	-3.11	0.002
L3.	4.866488	1.643236	2.96	0.004
L4.	-4.760326	1.086158	-4.38	0.000
_cons	14.64621	1.327594	11.03	0.000

Obejmowanie

O modelu A mówimy że obejmuje model B, jeżeli to co można wyjaśnić za pomocą modelu B, może również być wyjaśnione za pomocą modelu A, ale zależność w drugą stronę nie jest prawdziwa

Definiujemy dwa modele

$$y = X_A \beta_A + \varepsilon_A(1)$$

$$y = X_B \beta_B + \varepsilon_B(2)$$

takie że

Definiujemy dwa modele

$$y = X_A \beta_A + \varepsilon_A(1)$$

$$y = X_B \beta_B + \varepsilon_B(2)$$

takie że

- $X_A \cap X_B \neq \emptyset$

Definiujemy dwa modele

$$y = X_A \beta_A + \varepsilon_A(1)$$

$$y = X_B \beta_B + \varepsilon_B(2)$$

takie że

- $X_A \cap X_B \neq \emptyset$
- $X_A \subsetneq X_B$ oraz $X_B \subsetneq X_A$

Można zbudować model ogólny

$$y = \bar{X}_A \beta_A^* + \bar{X}_B \beta_B^* + W\gamma + \varepsilon$$

Można zbudować model ogólny

$$y = \bar{X}_A \beta_A^* + \bar{X}_B \beta_B^* + W\gamma + \varepsilon$$

- model (1) obejmuje model (2) gdy $\beta_B^* = 0$

Można zbudować model ogólny

$$y = \bar{X}_A \beta_A^* + \bar{X}_B \beta_B^* + W\gamma + \varepsilon$$

- model (1) obejmuje model (2) gdy $\beta_B^* = 0$
- model (2) obejmuje model (1) gdy $\beta_A^* = 0$

Można zbudować model ogólny

$$y = \bar{X}_A \beta_A^* + \bar{X}_B \beta_B^* + W\gamma + \varepsilon$$

- model (1) obejmuje model (2) gdy $\beta_B^* = 0$
- model (2) obejmuje model (1) gdy $\beta_A^* = 0$
- należy zweryfikować obie hipotezy. Możliwe wyniki:

Można zbudować model ogólny

$$y = \bar{X}_A \beta_A^* + \bar{X}_B \beta_B^* + W\gamma + \varepsilon$$

- model (1) obejmuje model (2) gdy $\beta_B^* = 0$
- model (2) obejmuje model (1) gdy $\beta_A^* = 0$
- należy zweryfikować obie hipotezy. Możliwe wyniki:
 - (1) prawda (2) prawda \rightarrow nie da się ustalić

Można zbudować model ogólny

$$y = \bar{X}_A \beta_A^* + \bar{X}_B \beta_B^* + W\gamma + \varepsilon$$

- model (1) obejmuje model (2) gdy $\beta_B^* = 0$
- model (2) obejmuje model (1) gdy $\beta_A^* = 0$
- należy zweryfikować obie hipotezy. Możliwe wyniki:
 - (1) prawda (2) prawda \rightarrow nie da się ustalić
 - (1) prawda (2) fałsz \rightarrow model A obejmuje model B

Można zbudować model ogólny

$$y = \bar{X}_A \beta_A^* + \bar{X}_B \beta_B^* + W\gamma + \varepsilon$$

- model (1) obejmuje model (2) gdy $\beta_B^* = 0$
- model (2) obejmuje model (1) gdy $\beta_A^* = 0$
- należy zweryfikować obie hipotezy. Możliwe wyniki:
 - (1) prawda (2) prawda \rightarrow nie da się ustalić
 - (1) prawda (2) fałsz \rightarrow model A obejmuje model B
 - (1) fałsz (2) prawda \rightarrow model B obejmuje model A

Można zbudować model ogólny

$$y = \bar{X}_A \beta_A^* + \bar{X}_B \beta_B^* + W\gamma + \varepsilon$$

- model (1) obejmuje model (2) gdy $\beta_B^* = 0$
- model (2) obejmuje model (1) gdy $\beta_A^* = 0$
- należy zweryfikować obie hipotezy. Możliwe wyniki:
 - (1) prawda (2) prawda \rightarrow nie da się ustalić
 - (1) prawda (2) fałsz \rightarrow model A obejmuje model B
 - (1) fałsz (2) prawda \rightarrow model B obejmuje model A
 - (1) fałsz (2) fałsz \rightarrow brak obejmowania

Test J

Model ogólny może przyjąć postać

$$y = (1 - \lambda)X_A\beta_A + \lambda X_B\beta_B + \varepsilon$$

Test J

Model ogólny może przyjąć postać

$$y = (1 - \lambda)X_A\beta_A + \lambda X_B\beta_B + \varepsilon$$

- gdy $\lambda = 0$ to model A obejmuje model B

Test J

Model ogólny może przyjąć postać

$$y = (1 - \lambda)X_A\beta_A + \lambda X_B\beta_B + \varepsilon$$

- gdy $\lambda = 0$ to model A obejmuje model B
- gdy $\lambda = 1$ to model B obejmuje model A

Test J

- z uwagi na nieliniowość modelu nie można wykorzystać MNK

Test J

- z uwagi na nieliniowość modelu nie można wykorzystać MNK
- rozwiązaniem jest zastosowanie procedury dwustopniowej

Test J

- z uwagi na nieliniowość modelu nie można wykorzystać MNK
- rozwiązaniem jest zastosowanie procedury dwustopniowej
 - 1 regresja y na X_B , uzyskujemy \hat{y}_B

Test J

- z uwagi na nieliniowość modelu nie można wykorzystać MNK
- rozwiązaniem jest zastosowanie procedury dwustopniowej
 - 1 regresja y na X_B , uzyskujemy \hat{y}_B
 - 2 regresja y na X_A oraz \hat{y}_B

Test J

- z uwagi na nieliniowość modelu nie można wykorzystać MNK
- rozwiązaniem jest zastosowanie procedury dwustopniowej
 - 1 regresja y na X_B , uzyskujemy \hat{y}_B
 - 2 regresja y na X_A oraz \hat{y}_B
- test obejmowania sprowadza się do zbadania istotności współczynnika przy zmiennej \hat{y}_B

Test J

- Procedura testowa opiera się na przybliżeniu

Test J

- Procedura testowa opiera się na przybliżeniu

$$y = (1 - \lambda)X_A\beta_A + \lambda X_B\beta_B + \varepsilon$$

Test J

- Procedura testowa opiera się na przybliżeniu

$$y = (1 - \lambda)X_A\beta_A + \lambda X_B\beta_B + \varepsilon$$

$$\approx (1 - \lambda)X_A\beta_A + \lambda X_B b_B + \varepsilon$$

Test J

- Procedura testowa opiera się na przybliżeniu

$$y = (1 - \lambda)X_A\beta_A + \lambda X_B\beta_B + \varepsilon$$

$$\approx (1 - \lambda)X_A\beta_A + \lambda X_B b_B + \varepsilon$$

$$= (1 - \lambda)X_A\beta_A + \lambda \hat{y}_B + \varepsilon$$

- W przypadku modeli szacowanych MNW nie jest możliwe określenie współczynnika R^2

- W przypadku modeli szacowanych MNW nie jest możliwe określenie współczynnika R^2
- Do oceny jakości dopasowania modelu do danych empirycznych stosuje się tzw. kryteria informacyjne

- Kryterium Informacyjne Akaike

$$AIC = -\frac{2\ell(\theta)}{N} + \frac{2k}{N}$$

- Kryterium Informacyjne Akaike

$$AIC = -\frac{2\ell(\theta)}{N} + \frac{2k}{N}$$

- Bayesowskie Kryterium Informacyjne Schwarza

$$BIC = -\frac{2\ell(\theta)}{N} + \frac{k \log(N)}{N}$$

- Kryterium Informacyjne Akaike

$$AIC = \log\left(\frac{e'e}{2}\right) + \frac{2k}{N}$$

- Kryterium Informacyjne Akaike

$$AIC = \log\left(\frac{e'e}{2}\right) + \frac{2k}{N}$$

- Bayesowskie Kryterium Informacyjne Schwarza

$$BIC = \log\left(\frac{e'e}{2}\right) + \frac{k \log(N)}{N}$$

- Model krzywej Philipsa

- Model krzywej Philipa

Tabela: Krzywa Philipa

inflacja	AIC	BIC	ℓ
L(0/4)	641.87	658.98	-314.94
L(0/2)	690.42	701.89	-341.21
L(0134)	639.92	654.18	-314.96