

Czasowy wymiar danych

Problem autokorelacji

Model regresji dla szeregów czasowych

- Model regresji dla szeregów czasowych

$$y_t = X_t\beta + \varepsilon_t$$

- Zasadnicze różnice
 - 1 Budowa prognoz
 - 2 Problem stabilności parametrów
 - 3 Problem autokorelacji

Prognoza

Przez prognozę z modelu rozumiemy przewidywaną przez model wartość \hat{y}_f dla znanego wektora zmiennych objaśniających x_f .

- $\hat{y}_f = x_f b$ jest nieobciążoną prognozą wartości y_f .
- Błąd prognozy wynosi $e_f = \hat{y}_f - y_f$.
- Wartość oczekiwana błędu prognozy wynosi 0, ponieważ

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

Dokładność prognozy

- Wariancja prognozy

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

- Wariancja błędu prognozy

$$\begin{aligned} \text{var}(e_f) &= E[(\hat{y}_f - y_f)(\hat{y}_f - y_f)'] = \\ &= E[x_f(b - \beta)(b - \beta)x_f'] - 2x_f \underbrace{E[(b - \beta)e_f]}_0 + e_f^2 \\ &= x_f \Sigma_b x_f' + \sigma^2 = \text{var}(\hat{y}_f) + \sigma^2 \end{aligned}$$

Przedziały ufności

- Prognoza to szczególny przypadek kombinacji liniowej

$$\frac{\delta' b - \delta' \beta}{\sqrt{\delta' \Sigma_b \delta}} \sim t_{N-k}$$

- Kładąc $\delta' b = x_f b$ uzyskujemy

$$Pr(\hat{y}_f - se(\hat{e}_f)t_{\frac{\alpha}{2}} < y_f < \hat{y}_f + se(\hat{e}_f)t_{\frac{\alpha}{2}})$$

Test prognoz

- Zastosowania testu
 - 1 wykrywanie zmiany strukturalnej
 - 2 sprawdzenie czy podgrupa zachowuje się jak populacja
- Procedura testowa rozpoczyna się od podziału próby

$$\underbrace{1 \dots T}_{\text{okres szacowania parametrów}} \quad \underbrace{T + 1 \dots T + p}_{\text{okres prognozy}}$$

Test prognoz

- Dla okresu szacowania parametrów uzyskujemy wartość parametrów

$$y_E = X_E \beta_E + \varepsilon_E$$

- Dla okresu prognozy

$$y_F = X_F \beta_F + \varepsilon_F$$

- Hipotezą zerową jest $\beta_F = \beta_E$, alternatywną $\beta_F \neq \beta_E$.
- W celu weryfikacji szacowane są parametry modelu na podstawie połączonej próby

$$y_{E+F} = X_{E+F} \beta + X_{E+F} \beta^* + \varepsilon_{E+F}$$

- Weryfikowana jest hipoteza $\beta^* = 0$
- Statystyka testowa ma postać

$$\frac{(S_{E+F} - S_E)/g}{S_F/(N - k)} \sim F(g, N - k)$$

Test Chowa (1960)

- Gregory C. Chow (1960). "Tests of Equality Between Sets of Coefficients in Two Linear Regressions". *Econometrica*. 28 (3): 591–605
- Test służy do weryfikacji hipotezy o stabilności parametrów
- Załóżmy, że istnieje model dla m próbek

$$y_s = X_s \beta_s + \varepsilon_s \quad \varepsilon_s \sim \mathcal{N}(0, \sigma_s^2 \mathbb{I})$$

- Niech Q_{si} będzie zmienną 0-1, wyróżniającą próbkę s

$$y_s = Q_{si} X_s \beta_s + \varepsilon_s$$

- Parametry modeli będą identyczne jeżeli prawdziwa jest

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_m$$

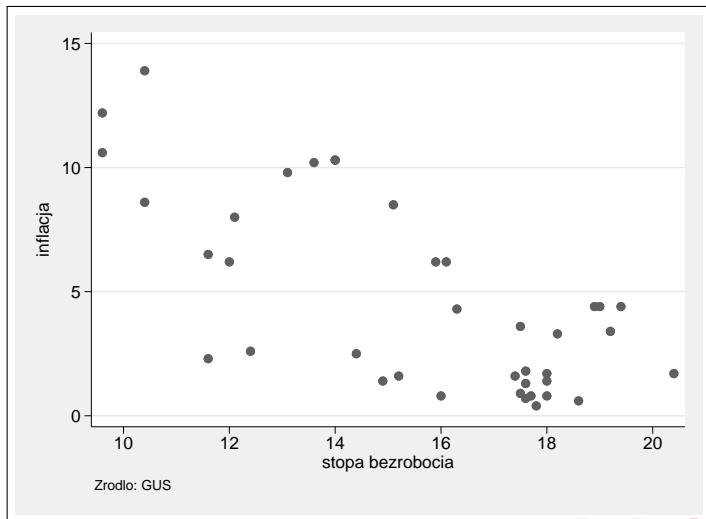
$$H_A : \neg H_0$$

Test Chowa

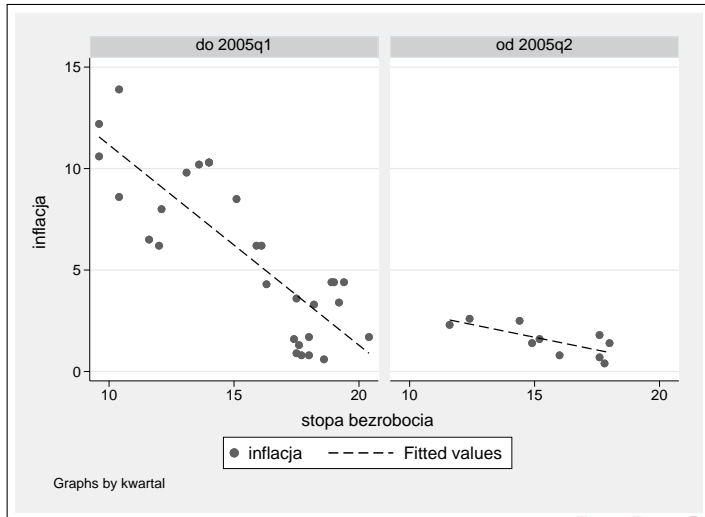
- Statystyka testowa

$$F = \frac{(S_R - \sum_i S_i)/K(m-1)}{\sum_i S_i/(N-mK)} \sim F_{k(m-1), N-mK}$$

Krzywa Philipa



Krzywa Philipa



Krzywa Philipa 1995-2009

Source	SS	df	MS
Model	275.254983	1	275.254983
Residual	280.348607	37	7.57698937
Total	555.60359	38	14.6211471

Number of obs	=	39
F(1, 37)	=	36.33
Prob > F	=	0.0000
R-squared	=	0.4954
Adj R-squared	=	0.4818
Root MSE	=	2.7526

infl	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
bezrob	-.8870748	.1471774	-6.03	0.000	-1.185284 - .5888652
_cons	18.42021	2.331593	7.90	0.000	13.69596 23.14447

- Więc $S_{E+F} = 280.348607$

Krzywa Philipa 1995-2005

Source	SS	df	MS			
Model	294.831523	1	294.831523	Number of obs =	29	
Residual	128.696062	27	4.7665208	F(1, 27) =	61.85	
				Prob > F =	0.0000	
				R-squared =	0.6961	
				Adj R-squared =	0.6849	
				Root MSE =	2.1832	
Total	423.527584	28	15.1259852			


infl	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
bezrob	-.9868678	.1254795	-7.86	0.000	-1.24433	-.7294051
_cons	21.03361	1.993939	10.55	0.000	16.94239	25.12484

- Więc $S_E = 128.696062$

$$\frac{(280 - 128)}{128/27} = 32.0625 > F(1, 25) = 7,77$$

- Zatem nachylenie krzywej Philipa różni się w obu okresach

Krzywa Philipa 1995-2009 - reszty



Estymacja Prais-Winstena

- W modelu

$$y_t = X_t\beta + \varepsilon_t$$

- w którym błąd losowy ma postać

$$\varepsilon_t = \rho\varepsilon_{t-1} + u_t \quad |\rho| < 1$$

- gdzie $\text{var}(u_t) = \sigma^2\mathbb{I}$
- Ten rodzaj autokorelacji jest nazywany autokorelacją pierwszego rzędu

- Można pokazać, że w tym przypadku

$$\text{var}(\varepsilon_t) = \sigma_\varepsilon^2 = \frac{\sigma_u^2}{\sqrt{1 - \rho^2}}$$

$$\text{cov}(\varepsilon_t, \varepsilon_{t+h}) = \sigma_\varepsilon^2 \rho^h$$

- a $\text{var}(\varepsilon) = \sigma_\varepsilon^2 \mathbb{V}$
- Postać macierzy wariancji-kowariancji

$$V(\rho) = \begin{bmatrix} 1 & \rho & \rho^2 & \dots & \dots \\ \rho & 1 & \ddots & & \\ \rho^2 & \rho & 1 & \ddots & \\ \rho^3 & & \ddots & \ddots & \ddots \\ \vdots & & & \ddots & \ddots & \rho \\ \vdots & & & & \rho & 1 \end{bmatrix}$$

- Macierz L ma postać

$$\begin{bmatrix} \sqrt{1-\rho^2} & -\rho & & & 0 \\ -\rho & 1 & \ddots & & \\ & \ddots & \ddots & \ddots & \\ & & \ddots & 1 & -\rho \\ 0 & & & -\rho & 1 \end{bmatrix}$$

- Tym przekształceniom można nadać interpretację

- Przed przekształceniem zmiennych

$$y_t = X_t\beta + \rho\varepsilon_{t-1} + u_t$$

- Dla obserwacji $t - 1$ zmienna y_{t-1} jest dana wzorem

$$y_{t-1} = X_{t-1}\beta + \varepsilon_{t-1}$$

- Mnożąc przez ρ i odejmując stronami uzyskujemy

$$\underbrace{y_t - \rho y_{t-1}}_{y_t^*} = \underbrace{(x_t - \rho x_{t-1})}_{x_t^*} \beta + u_t$$

- Wartość parametru ρ otrzymuje się z regresji pomocniczej

$$e_t = \rho e_{t-1} + \eta_t$$

Procedura iterowana

- 1 Przy użyciu $\hat{\rho}^{(i-1)}$ oblicza się $y_t^{*(i)}$, oraz $x_t^{*(i)}$
 - 2 Z regresji $y_t^{*(i)}$ na $x_t^{*(i)}$ szacowana jest $\beta_{UMNK}^{(i)}$
 - 3 $e_{UMNK}^{(i)} = y - X\beta_{UMNK}^{(i)}$
 - 4 Na podstawie $e_{UMNK}^{(i)}$ oblicza się $\hat{\rho}^{(i)}$
 - 5 Procedurę powtarza się do momentu gdy $|\hat{\rho}^{(i)} - \hat{\rho}^{(i-1)}| < \delta$
- Uzyskane oszacowanie jest asymptotycznie równoważne estymatorowi MNW

Estymator Neweya-Westa

- Newey i West zaproponowali estymator

$$\Sigma_b = T(X'X)^{-1} \hat{S}_x (X'X)^{-1}$$

gdzie

$$\hat{S}_x = \frac{1}{T} \sum_{l=1}^L \sum_{t=1}^T w_l e_t e_{t-l} (x_t x'_{t-l} - x_{t-l} x'_t)$$

a $w_l = 1 - \frac{l}{L+1}$, zazwyczaj $L = T^{\frac{1}{4}}$

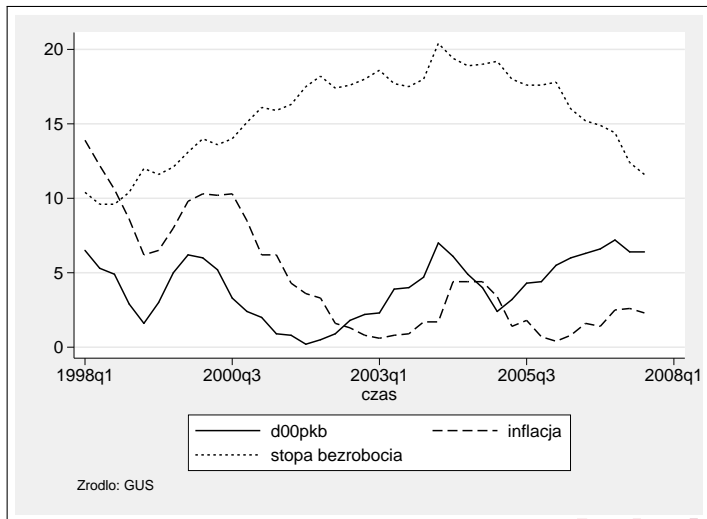
Model kursu walutowego

- Model monetarny kursu walutowego z lepкими cenami


$$s = f(m, d00pkb, infl, stopa)$$

- s - $\ln(kurs_{PL/euro})$
- m - $\ln M1$
- $d00pkb$ - stopa wzrostu gospodarczego (index: baza 100)
- $infl$ - wskaźnik CPI
- $stopa$ - stopa redyskontowa weksli

Model kursu walutowego



Model kursu walutowego




Model kursu walutowego - oszacowania

Source	SS	df	MS	Number of obs = 39		
Model	.128550582	4	.032137645	F(4, 34)	=	14.47
Residual	.075493821	34	.002220406	Prob > F	=	0.0000
Total	.204044403	38	.00536959	R-squared	=	0.6300
				Adj R-squared	=	0.5865
				Root MSE	=	.04712

s	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
m	-.3456742	.0527449	-6.55	0.000	-.4528647	-.2384837
d00pkb	.0211117	.0067436	3.13	0.004	.007407	.0348164
infl	.0094756	.0082777	1.14	0.260	-.0073466	.0262979
stopa	-.02549	.0053733	-4.74	0.000	-.0364099	-.0145702
_cons	7.856898	.2818132	27.88	0.000	7.284184	8.429611

Model kursu walutowego - reszty



Model kursu walutowego

```
. estat dwatson
```

```
Durbin-Watson d-statistic( 5, 39) = 1.329686
```

```
. estat bgodfrey, lags(1/4)
```

```
Breusch-Godfrey LM test for autocorrelation
```

lags(p)	chi2	df	Prob > chi2
1	2.652	1	0.1034
2	2.940	2	0.2299
3	3.252	3	0.3543
4	4.598	4	0.3311

```
H0: no serial correlation
```

Model kursu walutowego

Source	SS	df	MS			
Model	.125641026	3	.041880342	Number of obs =	39	
Residual	.078403558	35	.002240102	F(3, 35) =	18.70	
Total	.204044584	38	.005369594	Prob > F =	0.0000	
				R-squared =	0.6158	
				Adj R-squared =	0.5828	
				Root MSE =	.04733	

s	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
m	-.3474488	.0529554	-6.56	0.000	-.454954	-.2399436
d00pkb	.026742	.004634	5.77	0.000	.0173346	.0361495
stopa	-.0203707	.0029919	-6.81	0.000	-.0264446	-.0142969
_cons	3.223119	.2819451	11.43	0.000	2.65074	3.795498

Model kursu walutowego

```
. estat dwatson
```

```
Durbin-Watson d-statistic( 4, 39) = 1.190611
```

```
. estat bgodfrey, lags(1/4)
```

```
Breusch-Godfrey LM test for autocorrelation
```

lags(p)	chi2	df	Prob > chi2
1	4.489	1	0.0341
2	4.641	2	0.0982
3	4.736	3	0.1922
4	6.251	4	0.1812

```
H0: no serial correlation
```

Model kursu walutowego - odporne oszacowania

```
.newey s m d00pkb stopa, lag(1)
```

```
Regression with Newey-West standard errors
maximum lag: 1
```

```
Number of obs =      39
F( 3, 35) =      11.84
Prob > F      =      0.0000
```

	Coef.	Newey-West Std. Err.	t	P> t	[95% Conf. Interval]	
m	-.3474488	.0585417	-5.94	0.000	-.4662947	-.2286029
d00pkb	.026742	.0059323	4.51	0.000	.0146987	.0387853
stopa	-.0203707	.0037497	-5.43	0.000	-.0279831	-.0127584
_cons	3.223119	.3095652	10.41	0.000	2.594668	3.85157