

Modele dynamiczne

- Modele dynamiczne opisują kształtowanie się zjawiska w czasie

- Modele dynamiczne opisują kształtowanie się zjawiska w czasie
- Najważniejszymi zastosowaniami modeli dynamicznych są

- Modele dynamiczne opisują kształtowanie się zjawiska w czasie
- Najważniejszymi zastosowaniami modeli dynamicznych są
 - badanie procesu dochodzenia do równowagi długookresowej

- Modele dynamiczne opisują kształtowanie się zjawiska w czasie
- Najważniejszymi zastosowaniami modeli dynamicznych są
 - badanie procesu dochodzenia do równowagi długookresowej
 - istnienie takiej równowagi

- Modele dynamiczne opisują kształtowanie się zjawiska w czasie
- Najważniejszymi zastosowaniami modeli dynamicznych są
 - badanie procesu dochodzenia do równowagi długookresowej
 - istnienie takiej równowagi
 - szybkość dostosowań w obliczu szoków egzogenicznych

- Modele dynamiczne opisują kształtowanie się zjawiska w czasie
- Najważniejszymi zastosowaniami modeli dynamicznych są
 - badanie procesu dochodzenia do równowagi długookresowej
 - istnienie takiej równowagi
 - szybkość dostosowań w obliczu szoków egzogenicznych
 - dodatkowo modele dynamiczne można wykorzystać do

- Modele dynamiczne opisują kształtowanie się zjawiska w czasie
- Najważniejszymi zastosowaniami modeli dynamicznych są
 - badanie procesu dochodzenia do równowagi długookresowej
 - istnienie takiej równowagi
 - szybkość dostosowań w obliczu szoków egzogenicznych
 - dodatkowo modele dynamiczne można wykorzystać do
 - budowania prognoz

- Modele dynamiczne opisują kształtowanie się zjawiska w czasie
- Najważniejszymi zastosowaniami modeli dynamicznych są
 - badanie procesu dochodzenia do równowagi długookresowej
 - istnienie takiej równowagi
 - szybkość dostosowań w obliczu szoków egzogenicznych
 - dodatkowo modele dynamiczne można wykorzystać do
 - budowania prognoz
 - objaśniania dynamiki zmiennej zależnej

Szereg czasowy - definicja nieformalna

Proces stochastyczny jest to zbiór ścieżek możliwych realizacji zmiennej losowej. Każdą pojedynczą ścieżkę nazywamy szeregiem czasowym

$$\{y_1, y_2, \dots, y_T\}$$

Model DL

- Wpływ zmiennych niezależnych na zmienną zależną jest rozłożony w czasie

Model DL

- Wpływ zmiennych niezależnych na zmienną zależną jest rozłożony w czasie
- Budując model zjawiska uwzględnia się nie tylko bieżące wartości zmiennej objaśniającej, ale również jej opóźnione wartości

Model DL

- Model DL może spełniać założenia KRML

Model DL

- Model DL może spełniać założenia KRML
- Model DL ma następującą postać

$$y_t = \mu + \beta_0 x_t + \beta_1 x_{t-1} + \dots + \beta_p x_{t-p} + \varepsilon$$

Model DL

- Model DL może spełniać założenia KRML
- Model DL ma następującą postać

$$y_t = \mu + \beta_0 x_t + \beta_1 x_{t-1} + \dots + \beta_p x_{t-p} + \varepsilon$$

- Jeżeli zmienne objaśniające są nielosowe i składnik losowy modelu nie podlega autokorelacji to model DL spełnia założenia KMRL

Szacowana jest zależność między zmianą stopy bezrobocia (U) a zmianą poziomu cen (inflacja) na podstawie danych miesięcznych dla Polski

$$\Delta \text{inflacja}_t = c + \beta_0 \Delta U_t + \beta_1 \Delta U_{t-1} + \beta_2 \Delta U_{t-2} \\ + \beta_3 \Delta U_{t-3} + \beta_4 \Delta U_{t-4} + \varepsilon_t$$

Source	SS	df	MS	Number of obs = 128	
-----+-----				F(5, 122) = 20.05	
Model	844.535344	5	168.907069	Prob > F = 0.0000	
Residual	1027.63908	122	8.42327113	R-squared = 0.4511	
-----+-----				Adj R-squared = 0.4286	
Total	1872.17442	127	14.7415309	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	

- Parametrów modelu DL nie można interpretować tak jak parametrów modelu regresji, bowiem jednostkowa zmiana wartości zmiennej w kolejnym okresie powoduje zmianę wartości opóźnienia zmiennej

- Parametrów modelu DL nie można interpretować tak jak parametrów modelu regresji, bowiem jednostkowa zmiana wartości zmiennej w kolejnym okresie powoduje zmianę wartości opóźnienia zmiennej
- W związku z tym interpretowany jest rozmiar natychmiastowej reakcji na szok, oraz efekt długookresowy.

Mnożnik bezpośredni

- Opisuje natychmiastową reakcję modelu na szok i wynosi

$$E(y_t + \Delta y) = \mu + \beta_0(x_t + \Delta x) + \beta_1 x_{t-1} + \dots + \beta_p x_{t-p}$$

Mnożnik bezpośredni

- Opisuje natychmiastową reakcję modelu na szok i wynosi

$$E(y_t + \Delta y) = \mu + \beta_0(x_t + \Delta x) + \beta_1 x_{t-1} + \dots + \beta_p x_{t-p}$$

$$E(y_t + \Delta y) = \mu + \beta_0 x_t + \beta_1 x_{t-1} + \dots + \beta_p x_{t-p} + \beta_0 \Delta x$$

Mnożnik bezpośredni

- Opisuje natychmiastową reakcję modelu na szok i wynosi

$$E(y_t + \Delta y) = \mu + \beta_0(x_t + \Delta x) + \beta_1 x_{t-1} + \dots + \beta_p x_{t-p}$$

$$E(y_t + \Delta y) = \mu + \beta_0 x_t + \beta_1 x_{t-1} + \dots + \beta_p x_{t-p} + \beta_0 \Delta x$$

$$E(y_t + \Delta y) = E(y_t) + \beta_0 \Delta x$$

Mnożnik bezpośredni

- Opisuje natychmiastową reakcję modelu na szok i wynosi

$$E(y_t + \Delta y) = \mu + \beta_0(x_t + \Delta x) + \beta_1 x_{t-1} + \dots + \beta_p x_{t-p}$$

$$E(y_t + \Delta y) = \mu + \beta_0 x_t + \beta_1 x_{t-1} + \dots + \beta_p x_{t-p} + \beta_0 \Delta x$$

$$E(y_t + \Delta y) = E(y_t) + \beta_0 \Delta x$$

Zatem mnożnik jest równy

$$\frac{E(\Delta y)}{\Delta x} = \beta_0$$

Mnożnik skumulowany

- opisuje reakcję y na zmianę x w τ kolejnych okresach i wynosi

$$E(y_t + \Delta y) = \mu + \beta_0(x_t + \Delta x) + \dots + \beta_\tau(x_{t-\tau} + \Delta x) + \dots + \beta_p x_{t-p}$$

Mnożnik skumulowany

- opisuje reakcję y na zmianę x w τ kolejnych okresach i wynosi

$$E(y_t + \Delta y) = \mu + \beta_0(x_t + \Delta x) + \dots + \beta_\tau(x_{t-\tau} + \Delta x) + \dots + \beta_p x_{t-p}$$

$$E(y_t + \Delta y) = E(y_t) + \sum_{i=0}^{\tau} \beta_i \Delta x$$

Mnożnik skumulowany

- opisuje reakcję y na zmianę x w τ kolejnych okresach i wynosi

$$E(y_t + \Delta y) = \mu + \beta_0(x_t + \Delta x) + \dots + \beta_\tau(x_{t-\tau} + \Delta x) + \dots + \beta_p x_{t-p}$$

$$E(y_t + \Delta y) = E(y_t) + \sum_{i=0}^{\tau} \beta_i \Delta x$$

Zatem mnożnik jest równy

$$\frac{E(\Delta y)}{\Delta x} = \sum_{s=0}^{\tau} \beta_s$$

Mnożnik długookresowy

- Opisuje reakcję y na zmianę jednostkową wszystkich zmiennych niezależnych x

Mnożnik długookresowy

- Opisuje reakcję y na zmianę jednostkową wszystkich zmiennych niezależnych x
- Jest on równy

$$\frac{E(\Delta y)}{\Delta x} = \beta = \sum_{s=0}^{\infty} \beta_s$$

Średnie opóźnienie

- Opisuje czas, w którym realizuje się połowa efektu trwałej zmiany zmiennej niezależnej x

$$\bar{w} = \sum_{s=0}^{\infty} s \frac{\beta_s}{\beta}$$

Przykład

- Mnożnik bezpośredni jest równy 4,46. Zatem 1% wzrost stopy bezrobocia powoduje wzrost inflacji o 4,46 punktu procentowego.

Przykład

- Mnożnik bezpośredni jest równy 4,46. Zatem 1% wzrost stopy bezrobocia powoduje wzrost inflacji o 4,46 punktu procentowego.
- Mnożnik długookresowy jest równy $\sum_{s=0}^{\infty} \beta_s = -0,62$. Efektem długookresowym wzrostu bezrobocia jest spadek inflacji o 0,6 punktu procentowego.

Model ARDL

- Tak jak w przypadku modelu DL, wpływ zmiennych niezależnych na zmienną zależną jest rozłożony w czasie

Model ARDL

- Tak jak w przypadku modelu DL, wpływ zmiennych niezależnych na zmienną zależną jest rozłożony w czasie
- Budując model zjawiska uwzględnia się nie tylko bieżące wartości zmiennej objaśniającej, ale również jej opóźnione wartości oraz opóźnione wartości zmiennej objaśnianej

Model ARDL

- Model ARDL zazwyczaj nie spełnia założeń KRML

Model ARDL

- Model ARDL zazwyczaj nie spełnia założeń KRML
- Model ARDL ma następującą postać

$$y_t = \underbrace{\alpha_1 y_{t-1} + \alpha_2 y_{t-2} + \dots + \alpha_q y_{t-q}}_{AR} + \underbrace{\mu + \beta_0 x_t + \beta_1 x_{t-1} + \dots + \beta_p x_{t-p}}_{DL} + \varepsilon$$

Source	SS	df	MS	Number of obs = 130	
Model	2096.93345	4	524.233362	F(4, 125) = 5629.97	
Residual	11.639349	125	.093114792	Prob > F = 0.0000	
Total	2108.5728	129	16.3455256	R-squared = 0.9945	
				Adj R-squared = 0.9943	
				Root MSE = .30515	

inflacja	Coef.	Std. Err.	t	P> t
inflacja				
L1.	1.197919	.0812572	14.74	0.000
L2.	-.226384	.0788832	-2.87	0.005
stopa				
--.	-.1940366	.0888325	-2.18	0.031
L1.	.1763992	.0909853	1.94	0.055
_cons	.3445489	.1695239	2.03	0.044

Stan równowagi

$$y^* = E(y_t) = E(y_{t-1}) = \dots = E(y_{t-q})$$

Stan równowagi

$$y^* = E(y_t) = E(y_{t-1}) = \dots = E(y_{t-q})$$

$$x^* = x_t = x_{t-1} = \dots = x_{t-p}$$

Stan równowagi

$$y^* = E(y_t) = E(y_{t-1}) = \dots = E(y_{t-q})$$

$$x^* = x_t = x_{t-1} = \dots = x_{t-p}$$

wstawiając y^* oraz x^* do postaci modelu ARDL

$$(1 - \alpha_1 - \dots - \alpha_q)y^* = \mu + \beta_0x^* + \beta_1x^* + \dots + \beta_px^*$$

Stan równowagi

- równowaga zachodzi przy

$$y^* = \mu^* + \beta x^*$$

gdzie

$$\mu^* = \frac{\mu}{1 - \sum \alpha_i}$$

$$\beta = \frac{\sum \beta_i}{1 - \sum \alpha_i}$$

Przykład

Stopa inflacji w długim okresie dąży do poziomu

$$y^* = \mu^* + \beta x^* = \frac{0,345}{1 - 0,960} - \frac{,018}{1 - 0,960} x^*$$

$$y^* = 8.625 - 0.450x^*$$

Przy 10 % bezrobociu stopa inflacji wg modelu powinna wynosić 4,125 %.

Równowaga długookresowa ARDL

Model ARDL posiada równowagę długookresową, gdy jego część autoregresyjna jest opisana procesem stacjonarnym

Mnożnik bezpośredni

- Opisuje natychmiastową reakcję modelu na szok i wynosi

$$E(y_t + \Delta y) = E(y_t) + \beta_0 \Delta x$$

Mnożnik bezpośredni

- Opisuje natychmiastową reakcję modelu na szok i wynosi

$$E(y_t + \Delta y) = E(y_t) + \beta_0 \Delta x$$

- Zatem mnożnik jest równy

$$\frac{E(\Delta y)}{\Delta x} = \beta_0$$

Mnożnik bezpośredni

- Opisuje natychmiastową reakcję modelu na szok i wynosi

$$E(y_t + \Delta y) = E(y_t) + \beta_0 \Delta x$$

- Zatem mnożnik jest równy

$$\frac{E(\Delta y)}{\Delta x} = \beta_0$$

- Postać mnożnika jest identyczna jak w przypadku modelu DL

Mnożnik długookresowy

- Inaczej jest w przypadku mnożnika długookresowego

$$y^* = \mu^* + x^* \beta$$

Mnożnik długookresowy

- Inaczej jest w przypadku mnożnika długookresowego

$$y^* = \mu^* + x^* \beta$$

- po dodaniu Δ uzyskujemy

$$y^* + E(\Delta y) = \mu^* + (x^* + \Delta x) \beta$$

Mnożnik długookresowy

- Inaczej jest w przypadku mnożnika długookresowego

$$y^* = \mu^* + x^*\beta$$

- po dodaniu Δ uzyskujemy

$$y^* + E(\Delta y) = \mu^* + (x^* + \Delta x)\beta$$

- odejmując stronami uzyskujemy

$$E(\Delta y) = \Delta x\beta$$

Mnożnik długookresowy

- Inaczej jest w przypadku mnożnika długookresowego

$$y^* = \mu^* + x^* \beta$$

- po dodaniu Δ uzyskujemy

$$y^* + E(\Delta y) = \mu^* + (x^* + \Delta x) \beta$$

- odejmując stronami uzyskujemy

$$E(\Delta y) = \Delta x \beta$$

- zatem mnożnik długookresowy wynosi

$$\beta = \frac{\sum \beta_i}{1 - \sum \alpha_i}$$

- zmienne objaśniające są **losowe**, ponieważ dla losowego y_t jego opóźnione wartości są losowe

- zmienne objaśniające są **losowe**, ponieważ dla losowego y_t jego opóźnione wartości są losowe
- do wykazania zgodności niezbędne jest założenie $cov(x_t, \varepsilon_t) = 0$

- Niech

$$y_t = \alpha y_{t-1} + \varepsilon_t$$

- Niech

$$y_t = \alpha y_{t-1} + \varepsilon_t$$

- załóżmy, że $\text{cov}(\varepsilon_t, \varepsilon_{t-1}) = \rho$, oraz $\text{cov}(\varepsilon_t, \varepsilon_{t-s}) = 0 \forall s > 1$

- Niech

$$y_t = \alpha y_{t-1} + \varepsilon_t$$

- załóżmy, że $\text{cov}(\varepsilon_t, \varepsilon_{t-1}) = \rho$, oraz $\text{cov}(\varepsilon_t, \varepsilon_{t-s}) = 0 \forall s > 1$
- wobec tego

$$y_{t-1} = \alpha y_{t-2} + \varepsilon_{t-1}$$

- Obliczmy kowariancję y_t oraz ε_{t-1}

$$\text{cov}(y_{t-1}, \varepsilon_t) = \text{cov}(\alpha y_{t-2} + \varepsilon_{t-1}, \varepsilon_t)$$

- Obliczmy kowariancję y_t oraz ε_{t-1}

$$\text{cov}(y_{t-1}, \varepsilon_t) = \text{cov}(\alpha y_{t-2} + \varepsilon_{t-1}, \varepsilon_t)$$

$$\text{cov}(y_{t-1}, \varepsilon_t) = \alpha \underbrace{\text{cov}(y_{t-2}, \varepsilon_t)}_0 + \text{cov}(\varepsilon_{t-1}, \varepsilon_t) = \rho$$

- Obliczmy kowariancję y_t oraz ε_{t-1}

$$\text{cov}(y_{t-1}, \varepsilon_t) = \text{cov}(\alpha y_{t-2} + \varepsilon_{t-1}, \varepsilon_t)$$

$$\text{cov}(y_{t-1}, \varepsilon_t) = \alpha \underbrace{\text{cov}(y_{t-2}, \varepsilon_t)}_0 + \text{cov}(\varepsilon_{t-1}, \varepsilon_t) = \rho$$

- zatem zmienne objaśniające są skorelowane ze składnikiem losowym

Breusch-Godfrey LM test for autocorrelation

lags(p)	chi2	df	Prob > chi2
1	0.995	1	0.3184
2	1.068	2	0.5863
3	1.511	3	0.6798
4	1.522	4	0.8227