

Prognozowanie i symulacje

Wykład 5

Cel budowy przyczynowo-skutkowego modelu ekonometrycznego

- Poznanie związków przyczynowo-skutkowych wiążących zmienne (wartość poznawcza – cel analityczny)
- Wyznaczenie przyszłej wartości zmiennej opisującej badane zjawisko (cel prognostyczny)

Etapy budowy modelu ekonometrycznego

określenie celu badania

dobór zmiennych objaśniających

zebranie danych statystycznych

konstrukcja modelu

estymacja parametrów modelu

weryfikacja modelu

zastosowanie modelu

Metody doboru zmiennych objaśniających

- Metoda Hellwiga – metoda integralnej pojemności informacyjnej
- Badanie współliniowości
- Analiza czynnikowa (np. analiza głównych składowych)
- Błąd ex-ante
- Test t-Studenta
- Kryteria informacyjne (Akaike, Hannana-Quinna, bayesowskie Schwarza)

Współliniowość

Zgodnie z założeniami Klasycznego Modelu Regresji Liniowej:

- Zmienne objaśniające powinny być skorelowane ze zmiennymi objaśnianymi
- Zmienne objaśniające nie powinny być skorelowane ze sobą

$$y_t = \beta_0 + \beta_1 x_{t1} + \beta_2 x_{t2} + \varepsilon_t$$

$$\text{cov}(y, x_1) \neq 0 \quad \text{cov}(y, x_2) \neq 0 \quad \text{cov}(x_1, x_2) = 0$$

Skutki występowania (niepełnej) współliniowości

- Niewielkie zmiany w zbiorze danych skutkują dużymi zmianami w otrzymanych wynikach (estymatorach)
- Oceny parametrów β mają duże średnie błędy szacunków \rightarrow małe wartości statystyk t-Studenta \rightarrow częściej wnioskujemy o braku istotności zmiennych objaśniających
- Wysokie wartości współczynnika determinacji
- Oceny parametrów strukturalnych mają znaki niezgodne z oczekiwaniami (niezgodne z teorią ekonomiczną)

Skutki występowania (niepełnej) współliniowości

Wariancja estymatora parametru β

$$\text{var}(\beta_j) = \frac{\sigma^2}{(1 - r_{j.}^2) \sum_{i=1}^n (x_{ij} - \bar{x})^2}$$

- Rośnie wraz ze wzrostem współczynnika korelacji r_j
- maleje wraz ze wzrostem wariancji j-tej zmiennej

Metoda Hellwiga – metoda integralnej pojemności informacyjnej

Współczynnik służy porównaniu wartości informacyjnej konkurencyjnych modeli liniowych opartych o tę samą zmienną objaśnianą Y i różne kombinacje zmiennych objaśniających.

$$H_l = \sum_{j=1}^p \frac{r_j^2}{1 + \sum_{i \neq j} |r_{ij}|},$$

Gdzie: r_j współczynnik korelacji liniowej pomiędzy zmiennymi Y i X_j

r_{ij} współczynnik korelacji liniowej między zmiennymi X_i i X_j

Współczynnik przyjmuje wartości $\langle 0,1 \rangle$.

Wartość 1 oznacza maksymalną ilość informacji dostarczaną przez wyróżnioną kombinację zmiennych

Variance Inflation Factor

VIF mierzy jaka część wariancji estymatora B jest spowodowana przez to, że j-ta zmienna nie jest ortogonalna względem pozostałych zmiennych objaśniających modelu – „czynnik rozdęcia wariancji”

$$VIF = \frac{1}{1 - r_j^2}$$

r_j^2 Współczynnik korelacji wielorakiej pomiędzy j-tą zmienną a pozostałymi zmiennymi niezależnymi modelu

Minimalna wartość VIF=1,

VIF>10 wskazuje na „rozdęcie wariancji” czyli na występowanie współliniowości

Ocena współliniowości VIF(j) - czynnik rozdęcia wariancji
 VIF (Variance Inflation Factors) - minimalna możliwa wartość = 1.0
 Wartości > 10.0 mogą wskazywać na problem współliniowości - rozdęcia wariancji

PKB 2,201
 SRD 2,201

$$AK_t = \beta_0 + \beta_1 PKB_{t1} + \beta_2 SRD_{t2} + \varepsilon_t$$

VIF(j) = 1/(1 - R(j)^2), gdzie R(j) jest współczynnikiem korelacji wielorakiej pomiędzy zmienną 'j' a pozostałymi zmiennymi niezależnymi modelu.

Ocena współliniowości VIF(j) - czynnik rozdęcia wariancji
 VIF (Variance Inflation Factors) - minimalna możliwa wartość = 1.0
 Wartości > 10.0 mogą wskazywać na problem współliniowości - rozdęcia wariancji

SI 133,290
 SO 133,290

$$PKB_t = \beta_0 + \beta_1 SI_{t1} + \beta_2 SO_{t2} + \varepsilon_t$$

VIF(j) = 1/(1 - R(j)^2), gdzie R(j) jest współczynnikiem korelacji wielorakiej pomiędzy zmienną 'j' a pozostałymi zmiennymi niezależnymi modelu.

SI	SO	
1,0000	0,9962	SI
	1,0000	SO

Dobór zmiennych na podstawie błędu ex-ante

- Wyznaczamy błąd ex-ante dla modelu ze wszystkimi potencjalnymi zmiennymi objaśniającymi
- Wyznaczamy błędy ex-ante dla wszystkich możliwych kombinacji zmiennych objaśniających
- Wybieramy tę kombinację, która daje najmniejszy błąd ex-ante
- Metoda bardzo czasochłonna/pracochłonna – przy dużej liczbie zmiennych objaśniających szacowana jest duża liczba modeli, aby wyznaczyć błędy ex-ante, (pośrednio prognozy) należy znać wartości zmiennych objaśniających w okresie prognozowanym

Wartości zmiennych objaśniających w okresie prognozowanym

Ustalenie na poziomie **planowanym**

Wyznaczenie i **ekstrapolacja trendów** wartości zmiennych objaśniających

Zbudowanie **modeli przyczynowo-opisowych** oddzielnie dla każdej zmiennej objaśniającej

Symulacje – zbiór prognoz dla zmiennej objaśnianej odpowiadających różnym możliwym wartościom zmiennych objaśniających

Prognozowanie na podstawie jednorównaniowego modelu przyczynowo-skutkowego

Zależność przyczynowo-skutkowa pomiędzy zmiennymi opisana jest następującym modelem:

$$y_t = \sum_{i=0}^k \beta_i x_{it} + \varepsilon_t, \quad t = 1, \dots, n$$

Aby wyznaczyć prognozy, przyjmujemy że wartości zmiennych objaśniających w okresie prognozowanym ($t > n$) wynoszą odpowiednio:

$$x_{0t}^*, \dots, x_{kt}^*$$

Oraz spełnione są założenia stochastyczne modelu

Prognozowanie na podstawie jednorównaniowego modelu przyczynowo-skutkowego

W takim przypadku prognoza przedstawia się następująco:

$$y_t^P = E\left(y_t \mid x_{0t}^*, \dots, x_{kt}^*\right) = E\left(\sum_{i=0}^k \beta_i x_{it}^* + \varepsilon_t\right)$$


$$= \sum_{i=0}^k E(\beta_i) x_{it}^* + E(\varepsilon_t) = \sum_{i=0}^k E(\beta_i) x_{it}^*$$

Wartości parametrów strukturalnych β nie są znane, znamy tylko oceny parametrów strukturalnych β^\wedge .

Jednak jeżeli spełnione są założenia stochastyczne modelu, KMNK jest najlepszym nieobciążonym estymatorem liniowym nieznanych parametrów β , wówczas:

$$y_t^P = \sum_{i=0}^k \beta_i x_{it}^*$$


$$y_t = \beta_0 + \beta_1 x_{t1} + \varepsilon_t$$



Model trendu z sezonowością

x

Model przyczynowo-
skutkowy →



y


Ordinary Least Squares Estimation

```

*****
Dependent variable is LNX
18 observations used for estimation from 1 to 18
*****
Regressor            Coefficient            Standard Error            T-Ratio[Prob]
A                    12.2142                .0053324                  2290.5[.000]
T                    .018967                .4925E-3                  38.5155[.000]
SR1                  -.048705                .0042719                  -11.4012[.000]
SR2                  -.016201                .0042719                  -3.7924[.002]
SR3                  -.021415                .0045999                  -4.6555[.000]
*****
R-Squared            .99347                R-Bar-Squared            .99146
S.E. of Regression  .010789                F-stat.      F( 4, 13) 494.2496[.000]
Mean of Dependent Variable 12.3907                S.D. of Dependent Variable .11673
Residual Sum of Squares .0015133                Equation Log-likelihood    58.9137
Akaike Info. Criterion 53.9137                Schwarz Bayesian Criterion 51.6877
DW-statistic        1.0479
*****
Diagnostic Tests
*****
*      Test Statistics      *          LM Version          *          F Version          *
*****
*          *          *          *          *
* A:Serial Correlation*CHSQ( 4)= 7.2438[.124]*F( 4, 9)= 1.5153[.277]*
*          *          *          *          *
* B:Functional Form *CHSQ( 1)= .58035[.446]*F( 1, 12)= .39979[.539]*
*          *          *          *          *
* C:Normality *CHSQ( 2)= 1.7389[.419]*          Not applicable          *
*          *          *          *          *
* D:Heteroscedasticity*CHSQ( 1)= .6655E-4[.993]*F( 1, 16)= .5915E-4[.994]*
*****

```

$$\ln x_t = 12.214 + 0.019t - 0.049SR1 - 0.016SR2 - 0.021SR3 + \hat{\varepsilon}_t$$



Single Equation Static Forecasts

Based on OLS regression of LNX on:

A T SR1 SR2 SR3

18 observations used for estimation from 2003Q1 to 2007Q2

Observation	Actual	Prediction	Error	S.D. of Error
19	*NONE*	12.5531	*NONE*	.013029
20	*NONE*	12.6798	*NONE*	.013029

Ordinary Least Squares Estimation

Dependent variable is LNY

17 observations used for estimation from 2003Q2 to 2007Q2

Regressor	Coefficient	Standard Error	T-Ratio[Prob]
A	-1.8029	.73094	-2.4665[.027]
LNY(-1)	.91523	.046870	19.5272[.000]
LNx	.23214	.093172	2.4915[.026]

R-Squared	.99202	R-Bar-Squared	.99088
S.E. of Regression	.020687	F-stat. F(2, 14)	870.0630[.000]
Mean of Dependent Variable	12.2283	S.D. of Dependent Variable	.21661
Residual Sum of Squares	.0059914	Equation Log-likelihood	43.4586
Akaike Info. Criterion	40.4586	Schwarz Bayesian Criterion	39.2088
DW-statistic	1.7874	Durbin's h-statistic	.44679[.655]

Diagnostic Tests

* Test Statistics *	LM Version	* F Version *
* A:Serial Correlation*CHSQ(4)=	.038101[1.00]	*F(4, 10)= .0056157[1.00]*
* B:Functional Form *CHSQ(1)=	1.3526[.245]	*F(1, 13)= 1.1237[.308]*
* C:Normality *CHSQ(2)=	.28478[.867]	* Not applicable *
* D:Heteroscedasticity*CHSQ(1)=	1.1114[.292]	*F(1, 15)= 1.0493[.322]*
* E:Predictive Failure*CHSQ(1)=	.010669[.918]	*F(1, 14)= .010669[.919]*

$$\ln y_t = -1,803 + 0.915 \ln y_{t-1} + 0.232 \ln x_t + \hat{\varepsilon}_t$$

Single Equation Dynamic Forecasts

Based on OLS regression of LNY on:

A LNY(-1) LNX


17 observations used for estimation from 2003Q2 to 2007Q2

Observation	Actual	Prediction	Error	S.D. of Error
19	12.6435	12.6411	.0024469	.023689
20	*NONE*	12.7101	*NONE*	.036310

Summary statistics for single equation dynamic forecasts

Based on 1 observations from 19 to 19

Mean Prediction Errors	.0024469	Mean Sum Abs Pred Errors	.0024469
Sum Squares Pred Errors	.5987E-5	Root Mean Sumsq Pred Errors	.0024469
Predictive failure test	F(1, 14)= .010669[.919]		



Dziękuję za uwagę!
Aleksandra.Kordalska@pg.edu.pl