

Ekonometria- wykład 2, 3

Estymacja i weryfikacja modelu

A decorative graphic element consisting of several horizontal lines of varying lengths and colors (teal, white, and light blue) extending from the right side of the slide.

- **Model regresji liniowej**

- W przypadku, gdy funkcja f z powyższej zależności jest funkcją liniową, model przyjmuje postać:

- $$Y = \alpha_0 + \alpha_1 X_1 + \dots + \alpha_k X_k + \varepsilon$$

- gdzie:

- Y – zmienna objaśniana,
- X_1, X_2, \dots, X_k – zmienne objaśniające,
- ε – składnik losowy,

$$\alpha_0, \alpha_1, \dots, \alpha_k$$

parametry funkcji regresji (parametry modelu), parametry strukturalne

parametry strukturalne przy zmiennych -odzwierciedlają siłę i kierunek wpływu zmiennej objaśniającej na zmienną objaśnianą (endogeniczną), $i=1,2,\dots,k$.

k – liczba zmiennych objaśniających w modelu.

-

ROWNOWAŻNE POJĘCIA EKONOMETRYCZNE

- • Zmienna Y nazywana jest :
 - – Zmienną zależną
 - – Zmienną objaśnianą
 - – Regresantem
 - – Zmienną endogeniczną

- • Zmienna X nazywana jest
 - – Zmienną niezależną
 - – Zmienną objaśniającą
 - – Regresorem
 - – Zmienną egzogeniczną

- **Interpretacja:** Jeżeli zmienna egzogeniczna x_{it} wzrośnie o 1 jednostkę, a pozostałe zmienne objaśniające nie ulegną zmianie, to oczekujemy, że zmienna endogeniczna y_t wzrośnie (spadnie) średnio o α jednostek.
- Parametry strukturalne w modelu linowym są przyrostami krańcowymi.

Model regresji można także zapisać w **postaci macierzowej** jako

$$\mathbf{y} = \mathbf{X}\boldsymbol{\alpha} + \boldsymbol{\varepsilon}$$

$$\begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_n \end{bmatrix} = \begin{bmatrix} 1 & x_{11} & x_{12} & \dots & x_{1k} \\ 1 & x_{21} & x_{22} & \dots & x_{2k} \\ \dots & \dots & \dots & \dots & \dots \\ 1 & x_{n1} & x_{n2} & \dots & x_{nk} \end{bmatrix} \begin{bmatrix} \alpha_0 \\ \alpha_1 \\ \dots \\ \alpha_k \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \dots \\ \varepsilon_n \end{bmatrix}$$

gdzie wektory $\mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_n \end{bmatrix}$, $\boldsymbol{\alpha} = \begin{bmatrix} \alpha_0 \\ \alpha_1 \\ \dots \\ \alpha_k \end{bmatrix}$, $\boldsymbol{\varepsilon} = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \dots \\ \varepsilon_n \end{bmatrix}$, oraz macierz $\mathbf{X} = \begin{bmatrix} 1 & x_{11} & x_{12} & \dots & x_{1k} \\ 1 & x_{21} & x_{22} & \dots & x_{2k} \\ \dots & \dots & \dots & \dots & \dots \\ 1 & x_{n1} & x_{n2} & \dots & x_{nk} \end{bmatrix}$ zawierają wartości:

\mathbf{y} – zmiennej objaśnianej, $\boldsymbol{\alpha}$ – parametrów modelu, $\boldsymbol{\varepsilon}$ – składnika losowego, \mathbf{X} – zmiennych objaśniających.

Estymacja modelu - MNK

Oszacować (estymować) model oznacza znaleźć oceny parametrów strukturalnych na podstawie konkretnej próby


- Jeżeli dysponujemy zbiorem (próbą) n obserwacji $(x_{1i}, x_{2i}, \dots, x_{ki}, y_i)$ – wartości zmiennych objaśniających i objaśnianych, to na jego podstawie możemy próbować znaleźć oszacowania a_0, a_1, \dots, a_k parametrów funkcji regresji.

- Wielkości $\hat{y}_i = a_0 + a_1x_{1i} + \dots + a_kx_{ki}$

- będziemy nazywać *wartościami teoretycznymi* zmiennej y odpowiadającymi i -tej obserwacji, $i=1, 2, \dots, n$.

- Natomiast e_i *resztami modelu*

$$y_i - \hat{y}_i = e_i$$



Metody szacowania parametrów strukturalnych:

- Metoda Najmniejszych Kwadratów (MNK)
- Metoda Momentów (MM),
- Metoda Największej Wiarygodności (MNW),
- i wiele innych.

Twierdzenie Gaussa-Markowa:

W klasycznym modelu regresji liniowej najlepszym nieobciążonym estymatorem liniowym parametrów jest estymator uzyskany MNK

Założenia modelu regresji liniowej (założenia Gaussa-Markowa)

- Postać funkcji regresji jest liniowa i stała, tzn. relacja między zmiennymi jest stabilna,
- Zmienne objaśniające (egzogeniczne) są nielosowe, ich wartości są ustalonymi liczbami rzeczywistymi,
- zmienne objaśniające nie są współliniowe, czyli nie występuje między nimi dokładna zależność liniowa

Przykład współlinowości zmiennych:

X1-liczba pracowników w przedsiębiorstwie,

X2-liczba pracowników na stanowiskach kierowniczych,

X3-liczba pracowników na stanowiskach niekierowniczych.

$$X1=X2+X3,$$

- liczba obserwacji przekracza liczbę szacowanych parametrów modelu ($n > k$)

- Składnik losowy ma rozkład normalny
- o średniej równej 0 i stałym odchyleniu standardowym,
- nie występuje autokorelacja składnika losowego,
- nie występuje korelacja składnika losowego ze zmiennymi objaśniającymi,
- Informacje zawarte w próbie są jedynymi informacjami, na podstawie których dokonuje się szacowania (estymacji) parametrów modelu.
-

Metoda Najmniejszych Kwadratów (MNK)

- Im mniejsza jest odległość wartości rzeczywistych od teoretycznych tym lepszy model
- estymatory parametrów modelu minimalizują sumę odległości y_i od \hat{y}_i

$$\sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n e_i^2$$

- Estymatorem metody najmniejszych kwadratów (MNK-estymatorem) wektora \mathbf{a} jest wektor \mathbf{a} wyznaczony jako

- $$\mathbf{a} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$$

Własności estymatorów MNK

- - Nieobciążoność
- - Efektywność
- - Zgodność

WERYFIKACJA JEDNORÓWNANIOWEGO LINIOWEGO MODELU EKONOMETRYCZNEGO

- ocena merytoryczna (stwierdzenie, czy otrzymane wyniki estymacji zgodne są z pewnymi założeniami i oczekiwaniami, a także z teorią ekonomii),
- weryfikacja statystyczna

Weryfikacja merytoryczna

- 1. określenie poprawności znaków przy parametrach;
- 2. interpretacja wartości oszacowanych parametrów
- (inaczej interpretuje się parametry w równaniu liniowym niż nieliniowym).

Weryfikacja statystyczna

Ocena stopnia dopasowania modelu – (parametry struktury stochastycznej modelu)

- współczynnik determinacji R^2 .
- Jest to syntetyczna miara opisująca dopasowanie wartości teoretycznych do rzeczywistych.

Przyjmuje wartości z przedziału $[0; 1]$.

- Im bliżej 1 (100%) tym lepsze dopasowanie modelu do danych, a więc oszacowania są lepszej jakości.
- $R^2 = 1$ wszystkie punkty empiryczne należą do linii regresji (wszystkie reszty są równe 0).

- **Współczynnik determinacji:** określa, jaka część zmienności cechy zależnej jest wyjaśniona zmiennością cech niezależnych.
- Pewna część zmienności zmiennej objaśnianej pozostaje niewyjaśniona:
 - nieuwzględnienie pewnych zmiennych objaśniających
 - losowy charakter czynników wpływających na zmienną objaśnianą
- Czasami wyznacza się także wartość tzw. **skorygowanego współczynnika determinacji:**
- Wartość jest interpretowana tak, jak zwykłego współczynnika determinacji.
- Współczynnik skorygowany ma zastosowanie do porównywania stopnia dopasowania modeli o różnej liczbie

■ wariancja resztowa

- Miarą przeciętnej wielkości błędu dopasowania jest **wariancja resztowa**, która jest oceną wariancji składnika losowego:

$$S_e^2 = \frac{1}{n - (k + 1)} \sum_{i=1}^n e_i^2$$

- Pierwiastek z wariancji reszt S_e (reprezentujący odchylenie standardowe reszt) jest **przeciętnym (standardowym) błędem szacunku zmiennej objaśnianej**

przeciętny błąd szacunku parametru $S(a_j)$.

- **Przedział ufności dla parametru**

$$P(a_j - t_{\alpha} S(a_j) < \alpha_j < a_j + t_{\alpha} S(a_j)) = 1 - \alpha$$

- gdzie $1 - \alpha$ jest współczynnikiem ufności, a t_{α} jest wartością odczytaną z tablic rozkładu t -Studenta dla $n - (k + 1)$ stopni swobody.

Ocena istotności

$$H_0 : \alpha_j = 0$$

$$H_1 : \alpha_j \neq 0$$

- Sprawdzianem jest statystyka:

$$t(a_j) = \frac{a_j}{S(a_j)}$$

- Statystyka ma rozkład t-Studenta o $n-k-1$ stopniach swobody.

- 1. Jeżeli $|t(a_j)| > t_{kryt}$ wówczas (przy przyjętym z góry poziomie istotności) odrzucamy H_0 na korzyść H_1 .
- Zmienna objaśniająca w istotny sposób wpływa na zmienną objaśnianą.
- 2. Jeżeli $|t(a_j)| < t_{kryt}$ wówczas (przy przyjętym z góry poziomie istotności) nie mamy podstaw do odrzucenia hipotezy zerowej,
- uznajemy dany parametr za nieistotny statystycznie.

Zmienna (czynnik)	Wartość oszacowana	Błąd oszacowania	Statystyka t_{obl}	Rzeczywisty poziom istotności P
Wyraz wolny	a_0	$s(a_0)$	$t(a_0)$	$P(a_0)$
Czynnik X_1	a_1	$s(a_1)$	$t(a_1)$	$P(a_1)$
Czynnik X_2	a_2	$s(a_2)$	$t(a_2)$	$P(a_2)$
Czynnik X_3	a_3	$s(a_3)$	$t(a_3)$	$P(a_3)$

Współczynniki: determinacji R^2 , zbieżności ϕ^2 , błąd resztowy $s(y)$ i inne

Modele nieliniowe

Model potęgowy

Ogólny zapis statycznego modelu potęgowego

$$y_t = \alpha_0 x_{i1}^{a_1} x_{i2}^{a_2} \dots x_{ik}^{a_k} e^{\xi_i}$$

Parametry strukturalne w modelu potęgowym są elastycznościami cząstkowymi. Jest to model o stałych elastycznościach.

Interpretacja: Jeżeli zmienna egzogeniczna x_{it} wzrośnie o 1%, a pozostałe zmienne objaśniające nie ulegną zmianie, to oczekujemy, że zmienna endogeniczna y_t wzrośnie (spadnie) średnio o α %.

- **Linearyzacja modelu potęgowego**

$$\ln y_t = \ln \alpha_0 + \alpha_1 \ln x_{i1} + \alpha_2 \ln x_{i2} + \dots + \alpha_k \ln x_{ik} + \xi_i;$$

$(i = 1, \dots, n)$

$$y = \begin{bmatrix} \ln y_1 \\ \ln y_2 \\ \ln y_3 \\ \vdots \\ \ln y_n \end{bmatrix}_{(n \times 1)}$$

$$X = \begin{bmatrix} 1 & \ln x_{11} & \boxtimes & \ln x_{1k} \\ 1 & \ln x_{21} & \boxtimes & \ln x_{2k} \\ 1 & \ln x_{31} & \boxtimes & \ln x_{3k} \\ \boxtimes & \boxtimes & \boxtimes & \boxtimes \\ 1 & \ln x_{n1} & \boxtimes & \ln x_{nk} \end{bmatrix}_{(n \times (k+1))}$$

- Funkcja potęgowa to często wykorzystywany model:
- -ekonometryczna funkcja produkcji Cobba-Douglasa
- - ekonometryczna funkcja popytu
-

- **Model produkcji**

- Funkcja produkcji wyraża zależność między nakładami czynników produkcji (kapitału i pracy) a wielkością (wartością) wytworzonych produktów.
- Ekonometryczny model produkcji:

$$y = f(K, L, \varepsilon)$$

- gdzie
- K – kapitał (wartość maszyn, surowców, nakładów finansowych),
- L – nakłady pracy.

Wielkości produkcji, kapitału i pracy mogą być wyrażone w jednostkach ilościowych, wartościowych

Funkcja Cobba-Douglasa

- Jest to potęgowa postać funkcji produkcji. Dla dwóch czynników produkcji K i L mamy model:
- $y = \alpha_0 K^{\alpha_1} L^{\alpha_2} \varepsilon \quad \alpha_0, \alpha_1, \alpha_2 > 0$
- Funkcję tę przekształcamy do postaci liniowej przez logarytmowanie:
$$\ln y = \ln \alpha_0 + \alpha_1 \ln K + \alpha_2 \ln L + \ln \varepsilon$$
- Elastyczność funkcji Cobba-Douglasa względem K i L jest stała i równa odpowiednio:

$$E_{y/K} = \frac{\partial \ln y}{\partial \ln K} = \alpha_1 \quad E_{y/L} = \frac{\partial \ln y}{\partial \ln L} = \alpha_2$$

- Parametry funkcji - odpowiednie elastyczności.
- Jeśli wielkość kapitału wzrasta o 1%, to wielkość produkcji wzrasta α_1 o %, zaś przy wzroście nakładów pracy o 1% wielkość produkcji wzrasta o α_2 o %.

Modele popytu

- Funkcja popytu wyraża zależność poziomu popytu od czynników ekonomicznych i pozaekonomicznych.
- Główne czynniki ekonomiczne:
dochody (potencjalnych konsumentów) i ceny (dobra badanego, dóbr substytucyjnych).
- Wśród czynników pozaekonomicznych wymienia się czynniki demograficzne i psychologiczno-socjologiczne.

Elastyczności (E)

- Elastyczność dochodowa popytu jest zwykle dodatnia,
- elastyczność cenowa (względem ceny badanego produktu) jest zazwyczaj ujemna.

- Przyjmuje się, że jeśli $|E| > 1$, to popyt jest doskonale elastyczny (charakterystyczne dla dóbr luksusowych).
- Jeśli $|E| = 1$, to popyt reaguje proporcjonalnie do czynnika
- $0 < |E| < 1$ mówi się o popycie mało elastycznym
- przy $E = 0$ popyt jest sztywny

makro- i mikroekonomiczne funkcje popytu

- **Makroekonomiczne funkcje popytu**
- mierzą popyt dla ludności na większym obszarze (regionu, kraju) w zależności od:
 - dochodu średniego dla grup konsumentów,
 - cen i ich wzajemnych relacji oraz
 - popytu na inne dobra itp.

Są one wyznaczone w przekroju czasowym lub przestrzennym.

Mikroekonomiczne funkcje popytu

- wyrażają zależność popytu na określony produkt dla pojedynczych konsumentów lub gospodarstw w zależności od (zazwyczaj):
- dochodu na osobę
- składu demograficznego oraz
- profilu zawodowego i społecznego.

Mają one często kształt krzywych potrzeb (krzywych Engla), mierzących zależność między popytem i dochodem.

- Do krzywych Engla należą: **funkcja liniowa, potęgowa, hiperboliczna, wykładnicza z odwrotnością, funkcje Törnquista.**

- **Model liniowy**

$$y = \alpha_0 + \alpha_1 x + \varepsilon$$

- y – popyt (konsumpcja), x – dochód

- **Funkcja potęgowa**

$$y = \alpha_0 x^{\alpha_1}$$

- **Model hiperboliczny**

$$y = \alpha_0 + \alpha_1 \frac{1}{x} + \varepsilon$$

- **Funkcja wykładnicza z odwrotnością**

$$y = \alpha_0 e^{\alpha_1 \frac{1}{x}}$$

Weryfikacja stochastyczna- Własności składnika losowego

- brak autokorelacji składników losowych.
- stałość wariancji składników losowych.
- normalność rozkładu składnika losowego.

Jeżeli powyższe hipotezy są prawdziwe wówczas:

estymator MNK parametrów strukturalnych liniowego modelu ekonometrycznego jest estymatorem nieobciążonym, zgodnym i najbardziej efektywnym w klasie estymatorów nieobciążonych – BLUE.

Własności składnika losowego

Złamanie założeń o własnościach składnika losowego może mieć postać:

- autokorelacji, czyli korelacji między składnikami losowymi modelu,
- heteroskedastyczności, czyli zmiennej wariancji składnika losowego
- Rozkład skł. Losowego nie jest normalny

Estymatory MNK pozostają wprawdzie nieobciążone, ale są nieefektywne (nie mają najmniejszej wariancji w klasie liniowych estymatorów nieobciążonych).

Autokorelacja

- autokorelacja składnika losowego to korelacja między składnikami losowymi modelu
- autokorelacja między ε_t a ε_{t-k} określana jest mianem autokorelacji rzędu k i oznaczana przez $\rho(k)$

Autokorelacja: przyczyny

- natura procesów gospodarczych: skutki decyzji i zdarzeń ekonomicznych często rozciągają się na wiele miesięcy lub lat; procesy ekonomiczne, zwłaszcza w skali makro, cechują się pewną inercją
- błędy specyfikacji modelu:
 - niepoprawna postać analityczna
 - niepełny zestaw zmiennych objaśniających
 - niewłaściwa struktura dynamiczna

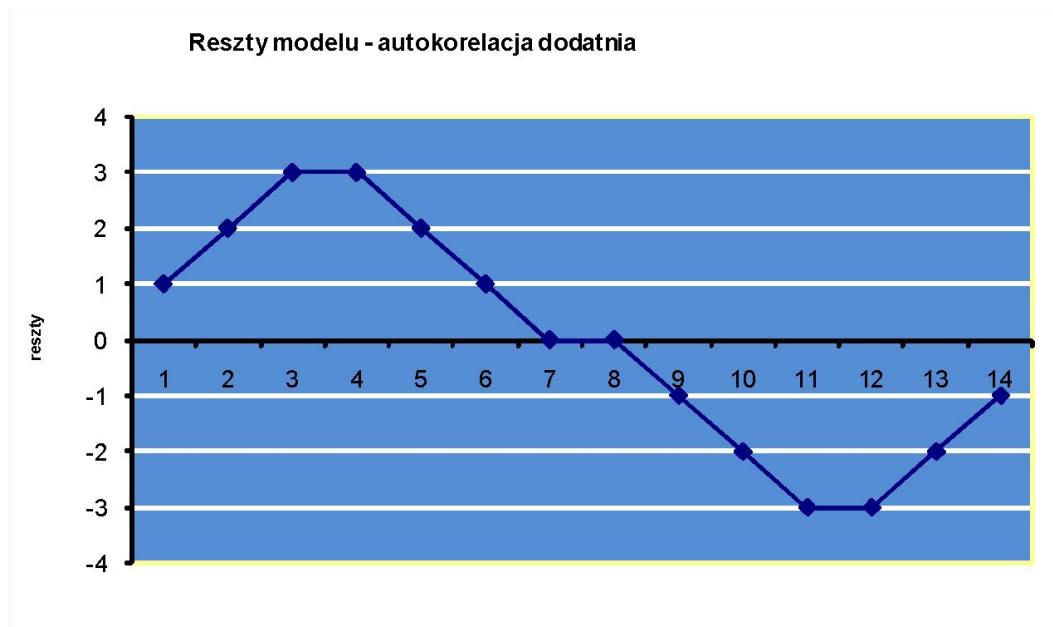
- jeżeli spełnione są założenia KMNK, w szczególności założenie o normalności rozkładu składnika losowego, reszty powinny być niezależne od siebie
- jeżeli reszty są niezależne od siebie, to zachowują się w sposób czysto losowy. Znając wartość reszty z okresu t nie jesteśmy w stanie nic powiedzieć o wartości reszty w okresie $t + 1$. Inaczej zachowują się reszty, które są skorelowane:

A) Autokorelacja składników losowych

Autokorelacja w modelu może być autokorelacją dodatnią:

$$0 < \hat{\rho}_1 < 1$$

Wtedy, gdy obok siebie występować będą seriami składniki losowe takich samych znaków

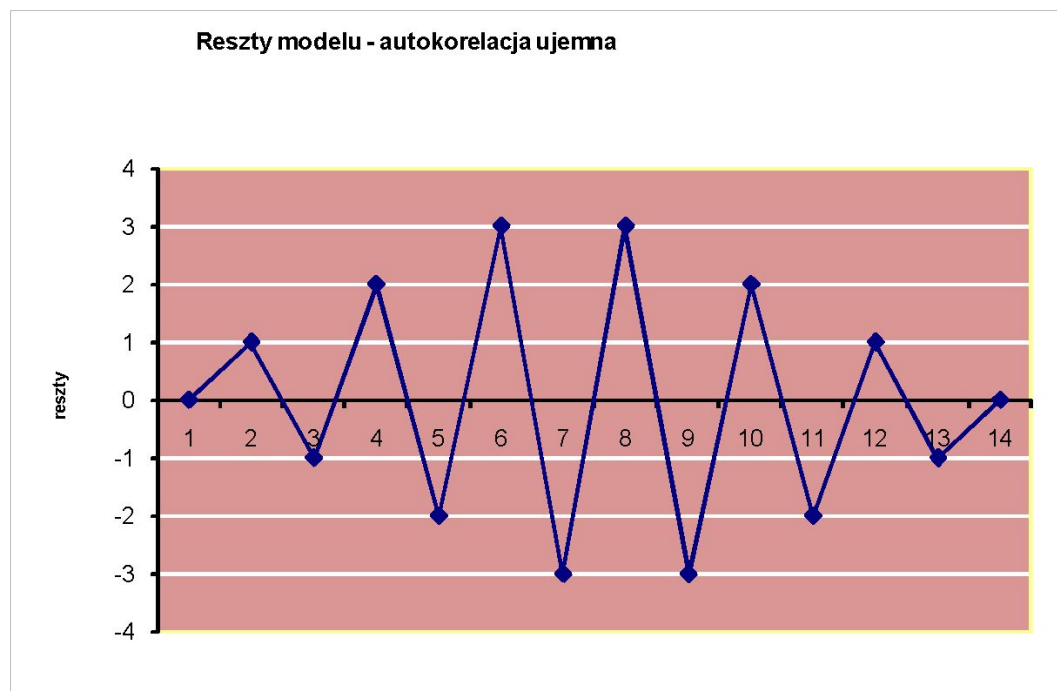


A) Autokorelacja składników losowych

Autokorelacja w modelu może być autokorelacją ujemną:

$$-1 < \hat{\rho}_1 < 0$$

Wtedy, gdy obok siebie występują składniki losowe o różnych znakach.



- dodatnia autokorelacja jest znacznie częściej występującą formą autokorelacji, niż autokorelacja ujemna. Jest ona powszechnym zjawiskiem w przypadku modeli szacowanych na szeregach czasowych
- ujemna autokorelacja składnika losowego powoduje, że większe jest prawdopodobieństwo zmiany znaku przez składnik losowy. Jeżeli w okresie t jest on dodatni, to w okresie $t + 1$ ze znacznie większym prawdopodobieństwem będzie on ujemny niż dodatni.

Autokorelacja: test Durbina-Watsona (DW)

- bardzo prosty test autokorelacji
- obciążony licznymi wadami:
 - można go zastosować wyłącznie do modeli z wyrazem wolnym, bez opóźnionej zmiennej objaśnianej oraz o normalnym rozkładzie składnika losowego
 - nie pozwala wykryć autokorelacji rzędu wyższego niż 1
 - nie zawsze prowadzi do uzyskania jednoznacznego wyniku

Autokorelacja: test DW - cd.

- $H_0: \rho = 0$ $H_1: \rho > 0$, lub $\rho < 0$
- statystyka empiryczna:

$$d = \frac{\sum_{t=2}^T (e_t - e_{t-1})^2}{\sum_{t=1}^T e_t^2}$$

- z tablic testu DW odczytujemy d_L i d_U
- $d > d_U$ - brak autokorelacji; $d < d_L$ - a. występuje; $d \in (d_L, d_U)$ - obszar niekonkluzywności
- $d > 2$ - a. ujemna; jw. dla $4-d$

Autokorelacja: test mnożnika Lagrange'a (LM)

- bardzo ogólny test; nie dotyczą go ograniczenia testu DW
- procedura dwustopniowa; wymaga oszacowania modelu pomocniczego
- ma charakter asymptotyczny, tzn. można go stosować w dużych próbach ($n > 30$)
- statystyka $(T-1)R^2$ ma rozkład χ^2 z jednym stopniem swobody;
 $(T-1)R^2 > \chi_{kryt}^2$ - odrzucamy H_0 o braku autokorelacji

Autokorelacja: co dalej?


- dodanie zmiennych objaśniających
- zmiana postaci analitycznej modelu
- zmiana metody estymacji - Uogólniona Metoda Najmniejszych Kwadratów (UMNK), albo jej równoważniki:
 - metoda Cochrane'a -Orcutta
 - metoda Hildretha -Lu
 - metoda Prais - Winstena

D) Stałość wariancji składników losowych

Homoskedastyczność – składniki losowe w modelu mają stałą wariancję.

Heteroskedastyczność – składniki losowe w modelu nie mają stałej wariancji.

Przykład heteroskedastyczności



Heteroskedastyczność

- skutki heteroskedastyczności składnika losowego dla estymatorów MNK:
 - estymatory są nieefektywne
 - statystyki oparte na wariancjach (a więc i odchyleniach standardowych) estymatorów są niewiarygodne

Heteroskedastyczność: przyczyny

- wśród podmiotów zróżnicowanych między sobą można się spodziewać dużej zmienności zachowań, co może znaleźć odzwierciedlenie w kształtowaniu się składnika losowego
- udoskonalanie technik gromadzenia i przetwarzania informacji może spowodować, że wariancja składnika losowego modelu będzie maleć z upływem czasu
- test heteroskedastyczności może „wyłapać” błędną postać funkcyjną lub pominięte zmienne objaśniające

Heteroskedastyczność: test White'a

- procedura dwustopniowa: wymaga oszacowania modelu pomocniczego
- statystyka testowa (postaci $T \cdot R^2$, gdzie R^2 jest współczynnikiem determinacji równania pomocniczego) ma rozkład χ^2 o liczbie stopni swobody równej liczbie zmiennych objaśniających równania pomocniczego
- hipoteza zerowa: homoskedastyczność;
 $T \cdot R^2 > \chi_{\text{kryt}}^2$ to odrzucamy H_0

Heteroskedastyczność: test Goldfelda-Quandta

- test dla modeli z 1 zmienną objaśniającą x
- wymaga arbitralnego podziału zbioru obserwacji na dwie podpróby: jedną odpowiadającą dużym wartościom zmiennej x , a drugą - małym wartościom, a następnie porównania ich wariancji za pomocą testu F
- w celu łatwiejszego rozróżnienia pomiędzy wariancjami małymi i dużymi pomija się niekiedy „środkowe” wartości zmiennej

Heteroskedastyczność: co dalej?

- zmiana metody estymacji:
 - Uogólniona Metoda Najmniejszych Kwadratów (UMNK), albo jej równoważnik
 - ważona MNK: wartości każdej zmiennej mnoży się przez tzw. wagi (zależne od postaci heteroskedastyczności)

C) Normalność rozkładu składnika losowego

Stosując wszystkie powyższe testy zakładaliśmy, że badana zmienna, a zatem składnik losowy, ma rozkład normalny.


Testowanie normalności rozkładu ξ_t

$$H_0 : \xi_t \sim N$$

$$H_A : \xi_t \text{ nie ma } N$$

Test Jarque'a-Bery, test Doornika-Hansena

Wykres standardowego rozkładu normalnego:



Do wszystkich testów statystycznych

Prawdopodobieństwo empiryczne – *p-value*, *wartość-p*

Jest to prawdopodobieństwo przyjęcia przez statystykę wartości nie mniejszej od uzyskanej wartości statystyki z próby, przy założeniu, że hipoteza zerowa jest prawdziwa.

Reguła decyzyjna:

- brak podstaw do odrzucenia H_0 .
- odrzucamy H_0 .

Inaczej *p value* oznacza poziom istotności powyżej którego należy odrzucić hipotezę zerową.



www.kufel.torun.pl

Model tendencji rozwojowej

- Funkcja tendencji rozwojowej (trendu) należy do szczególnej klasy modeli, w których w roli zmiennej objaśniającej występuje czas.
- Zastosowanie tych modeli do analizy szeregów czasowych pozwala często wykryć pewne prawidłowości, które mogą determinować rozwój badanego zjawiska.

Składowe szeregów czasowych

Wyróżnia się cztery składowe mające wpływ na zmienność zjawiska w ujęciu dynamicznym:

- **trend** (tendencja rozwojowa) – ciągle i regularne zmiany jakim podlega dane zjawisko w długim okresie,
- **wahania okresowe** (często sezonowe) – odchylenia od wartości trendu powtarzające się regularnie co pewien okres, w przybliżeniu stały,
- **wahania koniunkturalne** – zmiany rozwoju gospodarki obserwowane w okresach kilku lub kilkunastoletnich,
- **wahania przypadkowe** – inne uboczne zmiany mające charakter całkowicie nieregularny.

Najczęściej stosowaną metodą wyodrębniania trendów jest metoda analityczna.

funkcja matematyczna, w której zmienną zależną jest poziom obserwowanego w czasie zjawiska a zmienną niezależną – zmienna czasowa.

Model szeregu czasowego ma wówczas postać

$$Y_t = f(t) + u_t \quad t = 1, 2, 3, \dots, n$$

Model trendu liniowego

- Najczęściej spotykaną w praktyce funkcją tendencji rozwojowej jest funkcja liniowa.

Model szeregu czasowego ma wówczas postać:

$$Y_t = \alpha_0 + \alpha_1 \cdot t + u_t$$

- Aby wykonać prognozę na podstawie jednorównaniowego modelu opisowego, musi on charakteryzować
- się dobrymi własnościami. Jego jakość ocenia się przy pomocy miar takich jak współczynnik determinacji czy istotność oszacowań. Równie ważna jest weryfikacja merytoryczna, czyli
- znaki a w przypadku modeli nieliniowych wartości elastyczności. Same prognozy mogą mieć
- charakter punktowy (wynikiem jest konkretna wartość liczbową) lub przedziałowy (otrzymujemy
- przedział, który z określonym prawdopodobieństwem zawiera przyszłą realizację zmiennej
- prognozowanej).
- Dodatkowo zakładamy, że relacje między zmiennymi pozostają stałe w czasie. Oznacza to,
- że postać funkcyjna modelu oraz wzajemne oddziaływanie zmiennych są stałe z okresem prognozy
- łącznie. To założenie (szczególnie w realiach ekonomicznych) jest bardzo silne. Podobne
- założenia czynimy w przypadku omawianych poniżej modeli trendu.
- Składnik losowy również pozostaje stały w czasie co oznacza, że nie powinny pojawić się nowe
- zmienne wpływające na prognozowane zjawisko przy okazji zmieniając już ustalone relacje.
- W okresie prognozowanym musimy znać wartości zmiennych objaśniających. Kiedy nie jest
- możliwe, w sukurs przychodzi metoda prognozowania szeregów czasowych. Można również
- konstruować
- dodatkowe równania, służące otrzymaniu przyszłych wartości pozadanych zmiennych.
- Zazwyczaj takie postępowanie prowadzi do otrzymania układu powiązanych ze sobą równań.
- Niekiedy zaś (w analizach określonych scenariuszy) zakłada się z góry wartości zmiennych
- egzogenicznych
- co upodabnia postępowanie do analizy mnożnikowej.
- Prognozy na podstawie modeli ekonometrycznych, w których uwzględnia się fakt sezonowości
- zmiennych, zakładają istnienie sezonowości również w okresie prognozy. Sezonowość ta ma
- zachowany dotychczasowy okres wahań.

- Same prognozy mogą mieć
- charakter punktowy (wynikiem jest konkretna wartość liczbową) lub przedziałowy (otrzymujemy
- przedział, który z określonym prawdopodobieństwem zawiera przyszłą realizację zmiennej
- prognozowanej).
- Dodatkowo zakładamy, że relacje między zmiennymi pozostaną stałe w czasie. Oznacza to,
- że postać funkcyjna modelu oraz wzajemne oddziaływanie zmiennych są stałe z okresem prognozy
- łącznie. To założenie (szczególnie w realiach ekonomicznych) jest bardzo silne. Podobne
- założenia czynimy w przypadku omawianych poniżej modeli trendu.

- Składnik losowy również pozostaje stały w czasie co oznacza, że nie powinny pojawić się nowe
- zmienne wpływające na prognozowane zjawisko przy okazji zmieniając już ustalone relacje.
- W okresie prognozowanym musimy znać wartości zmiennych objaśniających. Kiedy nie jest
- możliwe, w sukurs przychodzi metoda prognozowania szeregów czasowych. Można również konstruować
- dodatkowe równania, służące otrzymaniu przyszłych wartości pozadanych zmiennych.
- Zazwyczaj takie postępowanie prowadzi do otrzymania układu powiązanych ze sobą równań.
- Niekiedy zaś (w analizach określonych scenariuszy) zakłada się z góry wartości zmiennych egzogenicznych
- co upodabnia postępowanie do analizy mnożnikowej.
- Prognozy na podstawie modeli ekonometrycznych, w których uwzględnia się fakt sezonowości
- zmiennych, zakładają istnienie sezonowości również w okresie prognozy. Sezonowość ta ma
- zachowany dotychczasowy okres wahań.