

# Egzamin z ekonometrii 13.06.2006

## Informatyka i Ekonometria

### I semestr

1. Opisać sposoby przybliżania za pomocą modelu liniowego zależności nieliniowej.

Nieliniową zależność między  $y_i$  a  $x_i$  można przybliżyć za pomocą modelu liniowego stosując model:


(a) Wielomianowy:

$$y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \dots + \beta_k x_i^k + \varepsilon_i$$

Przy większej liczbie zmiennych objaśniających wstawia się do modelu ich kwadraty i iloczyny.

(b) schodkowy


W tym przypadku definiujemy zmienne zerojedynkowe  $D_{s,i} = \mathbb{I}(x_s^* < x_i \leq x_{s+1}^*)$  związane z przedziałami  $x_i$  i przeprowadzamy regresję na tych zmiennych zamiast na  $x_i$ . Wyestymowany model można zilustrować rysunkiem:



(c) krzywej łamanej (odcinkami liniowej) o postaci

$$y = \begin{cases} \alpha + \beta_1 x + \varepsilon & \text{dla } x_i \leq x_1^* \\ \alpha + \beta_1 x_1^* + \beta_2 (x - x_1^*) + \varepsilon & \text{dla } x_1^* < x_i \leq x_2^* \\ \vdots & \vdots \\ \alpha + \beta_1 x_1^* + \sum_{j=2}^{s-1} \beta_j (x_j^* - x_{j-1}^*) + \beta_s x + \varepsilon & \text{dla } x_i > x_s^* \end{cases}$$

Zależność nieliniowa przybliżona jest w tym przypadku krzywą, którą można zilustrować rysunkiem:



2. Udowodnić twierdzenie Gaussa-Markowa.

**Twierdzenie Gaussa-Markowa:** dla spełnionych założeń *KMRL* estymator *MNK* jest najlepszym estymatorem wektora parametrów  $\beta$  w klasie liniowych i nieobciążonych estymatorów tego parametru.

Estymator liniowy wektora parametrów  $\beta$

$$\tilde{\beta} = C y = C (X \beta + \varepsilon)$$

Wartość oczekiwana

$$\begin{aligned} E(\tilde{\beta}) &= E(C X \beta + C \varepsilon) \\ &= C X \beta + C \underbrace{E(\varepsilon)}_0 = C X \beta \end{aligned}$$

Estymator  $\tilde{\beta}$  jest nieobciążony, a więc  $E(\tilde{\beta}) = \beta$ , co implikuje, że  $CX = I$ . Wariancja estymatora liniowego jest równa

$$\begin{aligned}\text{Var}(\tilde{\beta}) &= \text{Var}(Cy) = \text{Var}(CX\beta + C\varepsilon) \\ &= \text{Var}(C\varepsilon) = \underbrace{C\text{Var}(\varepsilon)C'}_{\sigma^2 I} = \sigma^2 CC'\end{aligned}$$

Zdefiniujmy taką macierz  $D$ , że

$$D = C' - X(X'X)^{-1}$$

$C$  można zapisać jako:

$$C = (X'X)^{-1}X' + D'$$

Mnożąc obie strony prawostronnie przez  $X$  uzyskujemy

$$\underbrace{CX}_I = \underbrace{(X'X)^{-1}X'X}_I + D'X$$

a więc

$$D'X = 0$$

Wielkość wariancji  $\tilde{\beta}$  jest równa:

$$\begin{aligned}\text{Var}(\tilde{\beta}) &= \sigma^2 CC' = \sigma^2 [(X'X)^{-1}X' + D'] [(X'X)^{-1}X' + D']' \\ &= \sigma^2 (X'X)^{-1} \underbrace{X'X(X'X)^{-1}}_I + \sigma^2 D'D \\ &\quad + \underbrace{\sigma^2 D'X(X'X)^{-1}}_0 + \sigma^2 (X'X)^{-1} \underbrace{X'D}_0 \\ &= \sigma (X'X)^{-1} + \sigma D'D\end{aligned}$$

Estymator  $MNK$  ma wariancję  $\text{Var}(b) = \sigma (X'X)^{-1}$ . Różnica między macierzą wariancji dowolnego estymatora liniowego i nieobciążonego i macierzą wariancji estymatora  $MNK$  jest równa

$$\text{Var}(\tilde{\beta}) - \text{Var}(b) = \sigma^2 D'D$$

i jest dodatnio określona.

1. Co to jest prognoza? Udowodnić, że prognoza postaci  $x_f b$  jest nieobciążona.

Prognoza jest przewidywaną na podstawie modelu wielkością  $y_f$  dla pewnej znanej wielkości  $x_f$ . Dla modelu spełniającego założenia  $KMRL$  prognoza  $\hat{y}_f = x_f b$  jest nieobciążona, ponieważ oczekiwany błąd prognozy  $e_f = y_f - \hat{y}_f$  jest równy zero:

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

Ponieważ estymator  $MNK$  jest nieobciążony a wartość oczekiwana  $\varepsilon_i$  jest z założeń  $KMRL$  równa zero.

2. Jak testujemy hipotezę postaci,  $H_0 : H\beta = h$  używając do tego sum kwadratów reszt z modelu bez ograniczeń i z ograniczeniami?

Liczymy model bez ograniczeń. Następnie wstawiamy ograniczenia wynikające  $H_0$  do modelu i estymujemy model z ograniczeniami. Do testowania  $H_0$  wykorzystujemy statystykę

$$F = \frac{(S_R - S)/g}{S/(N - K)} \sim F(g, N - K)$$

gdzie  $S_R$  jest sumą kwadratów reszt z modelu z ograniczeniami a  $S$  z modelu bez ograniczeń

**ZADANIE 1** Oszacowano model

$$y_i = \beta_1 + \beta_2 x_i + \varepsilon_i$$

za pomocą *MNK* i uzyskano oszacowania parametrów  $b_0$  i  $b_1$ . Pomiar zmiennej niezależnej  $x_i$  był jednak systematycznie niedokładny. Oznaczmy jako  $x_i^*$  prawdziwą wartość zmiennej niezależnej a jako  $c$  identyczny dla wszystkich obserwacji błąd pomiaru. Załóżmy, że założenia *KMRL* są spełnione dla modelu:

$$y_i = \beta_1 + \beta_2 x_i^* + \varepsilon_i$$

1. Pokazać, że jeśli dla każdej obserwacji  $x_i = cx_i^*$ , to estymator *MNK* parametru  $\beta_2$  będzie obciążony a parametru  $\beta_1$  nieobciążony.

**Podpowiedź:** Skorzystaj z tego, że w modelu z stałą i jedną zmienną objaśniającą  $b_2 = \frac{n \sum x_i y_i - \sum x_i \sum y_i}{n \sum x_i^2 - (\sum x_i)^2}$  a  $b_1 = \bar{y} - b_2 \bar{x}$  i zastanów się czemu jest równa  $E(y_i)$

*Rozwiązanie:*

1. Wartość oczekiwana  $y_i$

$$E(y_i) = E(\beta_1 + x_i^* \beta_2 + \varepsilon_i) = \beta_1 + x_i^* \beta_2 = \beta_1 + c^{-1} x_i \beta_2$$

Wartość oczekiwana  $b_2$

$$\begin{aligned} E(b_2) &= E \left[ \frac{n \sum x_i y_i - \sum x_i \sum y_i}{n \sum x_i^2 - (\sum x_i)^2} \right] \\ &= \frac{1}{n \sum x_i^2 - (\sum x_i)^2} E \left( n \sum x_i y_i - \sum x_i \sum y_i \right) \end{aligned}$$

$$\begin{aligned} E \left( n \sum x_i y_i - \sum x_i \sum y_i \right) &= n \sum x_i E(y_i) - \sum x_i \sum E(y_i) \\ &= c^{-1} n \sum x_i^2 \beta_2 - c^{-1} \left( \sum x_i \right)^2 \beta_2 \\ &= c^{-1} \left\{ n \sum x_i^2 - \left( \sum x_i \right)^2 \right\} \end{aligned}$$

$$E(b_2) = \frac{1}{n \sum x_i^2 - (\sum x_i)^2} c^{-1} \left\{ n \sum x_i^2 - \left( \sum x_i \right)^2 \right\} = c \beta_2$$

Wartość oczekiwana  $b_1$


$$\begin{aligned} E(b_1) &= E(\bar{y} - b_2 \bar{x}) = E \left( \frac{\sum y_i}{n} - b_2 \frac{\sum x_i}{n} \right) \\ &= \frac{\sum E(y_i)}{n} - E(b_2) \frac{\sum x_i}{n} \\ &= \frac{\sum (\beta_1 + c^{-1} x_i \beta_2)}{n} - c^{-1} \beta_2 \frac{\sum x_i}{n} \\ &= \beta_1 + c^{-1} \frac{\sum x_i}{n} \beta_2 - c^{-1} \beta_2 \frac{\sum x_i}{n} = \beta_1 \end{aligned}$$

**ZADANIE 2** Oszacowano regresję stopy bezrobocia (zmienna  $u$ ) na wroście realnego PKB (zmienna  $pkb$ ) i stopie inflacji (zmienna  $cpi$ ) oraz na zmiennych zero-jedynkowych związanych z kwartałami. Regresję przeprowadzono na danych kwartalnych dla Polski z okresu 1995-2003. Wyniki regresji oraz wykresy zmiennych znajdują się poniżej:

| Source   | SS         | df | MS         | Number of obs = | 34     |
|----------|------------|----|------------|-----------------|--------|
| Model    | .020931923 | 5  | .004186385 | F( 5, 28) =     | 6.52   |
| Residual | .01796652  | 28 | .000641661 | Prob > F =      | 0.0004 |
|          |            |    |            | R-squared =     | 0.5381 |
|          |            |    |            | Adj R-squared = | 0.4556 |

| Total |  | .038898443 | 33        | .001178741 | Root MSE | =                    | .02533    |
|-------|--|------------|-----------|------------|----------|----------------------|-----------|
| u     |  | Coef.      | Std. Err. | t          | P> t     | [95% Conf. Interval] |           |
| pkb   |  | -.72455    | .2843119  | -2.55      | 0.017    | -1.306937            | -.1421634 |
| cpi   |  | -.0966945  | .081363   | -1.19      | 0.245    | -.263359             | .06997    |
| _Iq_2 |  | -.0068327  | .0119961  | -0.57      | 0.574    | -.0314056            | .0177403  |
| _Iq_3 |  | -.0117543  | .0124543  | -0.94      | 0.353    | -.0372657            | .0137572  |
| _Iq_4 |  | -.0126153  | .0124595  | -1.01      | 0.320    | -.0381374            | .0129067  |
| _cons |  | .1980322   | .0112852  | 17.55      | 0.000    | .1749155             | .2211489  |

Durbin-Watson (6, 34) = .24  
 Breusch-Godfrey F(2, 26) = 12.62 [0.0001]  
 Breusch-Pagan chi2(2) = 10.41 [0.0054]  
 White chi2(14) = 25.80 [0.0274]  
 RESET F(3, 25) = 2.01 [0.1379]  
 Jarque-Bera chi(2) = 2.18 [.33723]  
 Chow(k=1998.1) F(6, 22) = 3.87 [0.0087]



Przy założonym poziomie istotności  $\alpha = 0.05$  przeprowadzić analizę wyników. Każdą z odpowiedzi należy uzasadnić wielkościami odpowiednich statystyk testowych.

1. Określić, czy model jest dobrze dopasowany, czy zbiór zmiennych niezależnych istotnie objaśnia zmienną zależną.
2. Podać, które zmienne w modelu są istotne.
3. Zbadać, czy w modelu występuje autokorelacja.
4. Zbadać, czy w modelu występuje heteroskedastyczność.
5. Sprawdzić, czy forma funkcyjna modelu jest prawidłowa.
6. Przetestować, czy błąd losowy w modelu ma rozkład normalny.
7. Sprawdzić, czy parametry w modelu są stabilne.
8. Zinterpretować współczynnik przy *pkb*.
9. Wyjaśnić na podstawie wykresów zmiennych dlaczego w modelu zawarto kwartalne zmienne sezonowe.
10. W jaki sposób należałoby weryfikować hipotezę mówiącą o tym, że jedyną zmienną wpływającą na bezrobocie jest *pkb*?
11. Jeśli model nie spełnia założeń KMRL określić:

- (a) które założenie nie jest spełnione?
- (b) jakie ma to konsekwencje dla wnioskowania statystycznego?
- (c) za pomocą jakich metod estymacji można rozwiązać problemy sygnalizowane przez wyniki testów?

*Rozwiązanie:*

1. Oszacowany model objaśnia prawie 54% zmienności zmiennej zależnej (współczynnik  $R^2 = 0.538$ ). Zbiór zmiennych objaśniających (poza stałą) jest łącznie istotny ( $F_{5,28} = 6.52$ ).
2. Tylko zmienna  $pkb$  i stała są istotne na zadanym poziomie istotności ( $p$ -value dla statystyk  $t$  są mniejsze od 0.05).
3. Na podstawie testu Breuscha-Godfrey ( $0.0001 < 0.05$ ) i Durбина-Watsona ( $0.24 < d_L = 1.15$ ) należy odrzucić  $H_0$  o braku autokorelacji.
4. Na podstawie testu Breuscha-Pagana ( $0.8153 > 0.05$ ) i White'a ( $0.8436 > 0.05$ ) nie można odrzucić hipotezy o homoskedastyczności.
5. Na podstawie testu RESET ( $0.1379 > 0.05$ ) nie można odrzucić hipotezy o poprawnej formie funkcyjnej.
6. Na podstawie testu Jarque'a-Bery ( $0.3372 > 0.05$ ) nie można odrzucić hipotezy o normalności rozkładu błędów losowych.
7. Na podstawie testu Chowa ( $0.0087 < 0.05$ ) należy odrzucić hipotezę o stabilności parametrów modelu w okresach  $t < 1998Q1$  i  $t \geq 1998Q1$ .
8. Współczynnik przy zmiennej oznacza, że wzrost PKB o 1% spowoduje spadek stopy bezrobocia o 0.72%.
9. Na wykresie widać, że w pierwszym kwartale następuje sezonowy wzrost bezrobocia. Aby to uwzględnić, zawarto w modelu zmienne sezonowe.
10. Hipotezę o łącznej nieistotności stałej,  $cpi$  i zmiennych kwartalnych należy testować za pomocą testu  $F$ , nakładając łączne ograniczenie na parametry przy tych zmiennych - przyrównując je jednocześnie do zera.
11.
  - (a) Niespełnione jest założenie o braku autokorelacji składnika losowego i o stałości parametrów w całej próbie.
  - (b) W przypadku autokorelacji składnika losowego estymator MNK  $\mathbf{b}$  jest nadal nieobciążony, ale jest nieefektywny. Obciążone oszacowanie macierzy wariancji-kowariancji uniemożliwia prawidłowe przeprowadzenie wnioskowania statystycznego. Z racji na niestabilność parametrów w czasie wynik regresji wydaje się w całości wątpliwy.
  - (c) Model można szacować oddzielnie na podpróbach, co umożliwi obliczenie różnych wielkości współczynników regresji w poszczególnych podpróbach. W celu uzyskania prawidłowego oszacowania macierzy wariancji kowariancji można zastosować odporną macierz Newey'ego-Westa. Można też podjąć próbę usunięcia autokorelacji za pomocą Stosowanej UMNK.

**ZADANIE 3** Uzyskano na podstawie dwóch niezależnych próbek o liczebnościach  $n_1$  i  $n_2$  oszacowania  $\mathbf{b}_1$  i  $\mathbf{b}_2$  parametru  $\beta$  w modelu:

$$y_i = \mathbf{x}_i\beta + \varepsilon_i$$

Oznaczmy jako  $\mathbf{X}_1, \mathbf{y}_1$  macierze obserwacji w pierwszej próbie i odpowiednio jako  $\mathbf{X}_2, \mathbf{y}_2$  macierze obserwacji w drugiej próbie. Załóżmy, że w obu próbkach spełnione są założenia *KMRL*.

Uwaga: przez niezależność próbek rozumiemy, że błędy losowe w obu próbach są od siebie niezależne.

1. Zaproponowano, żeby  $\beta$  wyestymować za średniej ważonej następującej średniej ważonej  $\mathbf{b}_1$  i  $\mathbf{b}_2$ :

$$\bar{\mathbf{b}} = w_1\mathbf{b}_1 + w_2\mathbf{b}_2$$

gdzie nielosowe wagi  $w_1 + w_2 = 1$ . Pokazać, że estymator ten jest nieobciążony i policzyć jego wariancję.

2. Pokazać, że estymator  $MNK$  policzona na połączonych próbkach będzie miał inną postać niż estymator  $\bar{b}$ , że można go przedstawić jako  $\mathbf{b} = \mathbf{W}_1 \mathbf{b}_1 + \mathbf{W}_2 \mathbf{b}_2$  i że  $\mathbf{W}_1 + \mathbf{W}_2 = \mathbf{I}$ .

**Podpowiedź:** Macierze obserwacji dla całej próby można zapisać jako  $\mathbf{y} = \begin{bmatrix} \mathbf{y}_1 \\ \mathbf{y}_2 \end{bmatrix}$  i  $\mathbf{X} = \begin{bmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \end{bmatrix}$ .

3. Dla szczególnego przypadku, kiedy w modelu mamy jedynie stałą znaleźć takie wagi  $w_1$  i  $w_2$ , dla których estymator  $\bar{b}$  będzie równoważny estymatorowi  $\mathbf{b}$ .
4. Przy założeniu, że  $\beta$  i  $\sigma^2$  są w obu podpróbkach takie same, który z estymatorów ( $MNK$  czy  $\bar{b}$ ) będzie lepszy? (odpowiedź uzasadnić)

Rozwiązanie:

1. Wartość oczekiwana estymatora  $\bar{b}$

$$\begin{aligned} E(\bar{\mathbf{b}}) &= E(w_1 \mathbf{b}_1 + w_2 \mathbf{b}_2) = w_1 E(\mathbf{b}_1) + w_2 E(\mathbf{b}_2) \\ &= w_1 \boldsymbol{\beta} + w_2 \boldsymbol{\beta} = \boldsymbol{\beta} \end{aligned}$$

przy czym skorzystaliśmy z nieobciążoności estymatora  $MNK$  w  $KMRL$ . Wariancja  $\bar{b}$

$$\begin{aligned} \text{Var}(w_1 \mathbf{b}_1 + w_2 \mathbf{b}_2) &= w_1^2 \text{Var}(\mathbf{b}_1) + w_2^2 \text{Var}(\mathbf{b}_2) + w_1 w_2 \text{Cov}(\mathbf{b}_1, \mathbf{b}_2) \\ &= w_1^2 \sigma_1^2 (\mathbf{X}'_1 \mathbf{X}_1)^{-1} + w_2^2 \sigma_2^2 (\mathbf{X}'_2 \mathbf{X}_2)^{-1} \end{aligned}$$

Przy czym skorzystaliśmy z tego, że estymatory policzone na podstawie niezależnych próbek są od siebie niezależne a więc  $\text{Cov}(\mathbf{b}_1, \mathbf{b}_2) = 0$

2. Estymator  $MNK$  ma postać

$$\mathbf{X}' \mathbf{X} = \begin{bmatrix} \mathbf{X}'_1 & \mathbf{X}'_2 \end{bmatrix} \begin{bmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \end{bmatrix} = \mathbf{X}'_1 \mathbf{X}_1 + \mathbf{X}'_2 \mathbf{X}_2$$

$$\mathbf{X}' \mathbf{y} = \begin{bmatrix} \mathbf{X}'_1 & \mathbf{X}'_2 \end{bmatrix} \begin{bmatrix} \mathbf{y}_1 \\ \mathbf{y}_2 \end{bmatrix} = \mathbf{X}'_1 \mathbf{y}_1 + \mathbf{X}'_2 \mathbf{y}_2$$

$$\begin{aligned} \mathbf{b} &= (\mathbf{X}' \mathbf{X})^{-1} \mathbf{X}' \mathbf{y} = (\mathbf{X}'_1 \mathbf{X}_1 + \mathbf{X}'_2 \mathbf{X}_2)^{-1} (\mathbf{X}'_1 \mathbf{y}_1 + \mathbf{X}'_2 \mathbf{y}_2) \\ &= (\mathbf{X}'_1 \mathbf{X}_1 + \mathbf{X}'_2 \mathbf{X}_2)^{-1} \mathbf{X}'_1 \mathbf{y}_1 + (\mathbf{X}'_1 \mathbf{X}_1 + \mathbf{X}'_2 \mathbf{X}_2)^{-1} \mathbf{X}'_2 \mathbf{y}_2 \\ &= \underbrace{(\mathbf{X}'_1 \mathbf{X}_1 + \mathbf{X}'_2 \mathbf{X}_2)^{-1} (\mathbf{X}'_1 \mathbf{X}_1)}_{\mathbf{W}_1} \underbrace{(\mathbf{X}'_1 \mathbf{X}_1)^{-1} \mathbf{X}'_1 \mathbf{y}_1}_{\mathbf{b}_1} \\ &\quad + \underbrace{(\mathbf{X}'_1 \mathbf{X}_1 + \mathbf{X}'_2 \mathbf{X}_2)^{-1} (\mathbf{X}'_2 \mathbf{X}_2)}_{\mathbf{W}_2} \underbrace{(\mathbf{X}'_2 \mathbf{X}_2)^{-1} \mathbf{X}'_2 \mathbf{y}_2}_{\mathbf{b}_2} \end{aligned}$$

i rzeczywiście

$$\begin{aligned} \mathbf{W}_1 + \mathbf{W}_2 &= (\mathbf{X}'_1 \mathbf{X}_1 + \mathbf{X}'_2 \mathbf{X}_2)^{-1} (\mathbf{X}'_1 \mathbf{X}_1) + (\mathbf{X}'_1 \mathbf{X}_1 + \mathbf{X}'_2 \mathbf{X}_2)^{-1} (\mathbf{X}'_2 \mathbf{X}_2) \\ &= (\mathbf{X}'_1 \mathbf{X}_1 + \mathbf{X}'_2 \mathbf{X}_2)^{-1} (\mathbf{X}'_1 \mathbf{X}_1 + \mathbf{X}'_2 \mathbf{X}_2) = \mathbf{I} \end{aligned}$$

3. Jeśli  $\mathbf{X}_1 = \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix}$  i  $\mathbf{X}_2 = \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix}$ , to  $\mathbf{X}'_1 \mathbf{X}_1 = n_1$ ,  $\mathbf{X}'_2 \mathbf{X}_2 = n_2$  a  $\mathbf{X}' \mathbf{X} = \mathbf{X}'_1 \mathbf{X}_1 + \mathbf{X}'_2 \mathbf{X}_2 = n_1 + n_2$ .

Macierz  $\mathbf{W}_1 = \frac{n_1}{n_1 + n_2} = w_1$  a  $\mathbf{W}_2 = \frac{n_2}{n_1 + n_2} = w_2$ .

4. Jeśli  $\beta$  i  $\sigma^2$  są takie same w obu podpróbkach, to dla próby złożonej ze wszystkich obserwacji spełnione są założenia  $KMRL$ . Z twierdzenia Gaussa-Markowa wnioskujemy, że najlepszym liniowym i nieobciążonym estymatorem bazującym na wszystkich obserwacjach jest estymator  $MNK$ . Estymator  $\bar{b}$  jest liniowy i nieobciążony ale ma inną postać niż estymator  $MNK$  - musi więc być gorszy niż estymator  $MNK$  (mieć większą wariancję)