

# Testowanie autokorelacji

## Problemy z danymi

**Stanisław Cichocki**

**Natalia Nehrebecka**

Wykład 13

# Plan wykładu

- ▶ 1. Testowanie autokorelacji
- ▶ 2. Heteroskedastyczność i autokorelacja
  - Konsekwencje heteroskedastyczności i autokorelacji
- ▶ 3. Problemy z danymi
  - Zmienne pominięte
  - Zmienne nieistotne
  - Obserwacje nietypowe i błędne
  - Współliniowość

# Plan wykładu

- ▶ 1. Testowanie autokorelacji
- ▶ 2. Heteroskedastyczność i autokorelacja
  - Konsekwencje heteroskedastyczności i autokorelacji
- ▶ 3. Problemy z danymi
  - Zmienne pominięte
  - Zmienne nieistotne
  - Obserwacje nietypowe i błędne
  - Współliniowość

# Testowanie autokorelacji


Przypomnienie: Co to znaczy, że w modelu występuje autokorelacja?

-Brak autokorelacji

$$\text{Var}(\varepsilon) = \begin{bmatrix} \text{Var}(\varepsilon_1) & \text{Cov}(\varepsilon_1, \varepsilon_2) & \cdots & \text{Cov}(\varepsilon_1, \varepsilon_n) \\ \text{Cov}(\varepsilon_2, \varepsilon_1) & \text{Var}(\varepsilon_2) & \cdots & \text{Cov}(\varepsilon_2, \varepsilon_n) \\ \vdots & \vdots & & \vdots \\ \text{Cov}(\varepsilon_n, \varepsilon_1) & \text{Cov}(\varepsilon_n, \varepsilon_1) & \cdots & \text{Var}(\varepsilon_n) \end{bmatrix} = \begin{bmatrix} \sigma^2 & 0 & \cdots & 0 \\ 0 & \sigma^2 & \cdots & 0 \\ \vdots & \vdots & & \vdots \\ 0 & 0 & \cdots & \sigma^2 \end{bmatrix}$$

# Autokorelacja

- ▶ Przypadek zerowych kowariancji dla różnych zaburzeń losowych  $\varepsilon_i$  oraz  $\varepsilon_j$  nazywamy **brakiem autokorelacji zaburzeń**. Oznacza to, że **zaburzenia losowe dla różnych obserwacji są niezależne**, a przez to nieskorelowane, a więc nie mają tendencji do gromadzenia się np. wokół dodatnich lub ujemnych (lub naprzemiennie dodatnich i ujemnych) wartości



Rys. 2. Autokorelacja

# Testowanie autokorelacji

- Test Durbina-Watsona (Test DW):

$$H_0 : Cov(\varepsilon_t, \varepsilon_{t-1}) = 0 \quad \text{- brak autokorelacji}$$

$$H_1 : Cov(\varepsilon_t, \varepsilon_{t-1}) \neq 0 \quad \text{- autokorelacja}$$

gdzie  $t = 1, \dots, T$

# Testowanie autokorelacji

- **Test Durbina-Watsona (Test DW):**

- specjalne tablice z wartościami krytycznymi:  $d_l, d_u$

## 1. Statystyka $DW < 2$

a)  $DW < d_l$  odrzucamy hipotezę zerową o braku autokorelacji i przyjmujemy hipotezę o dodatniej autokorelacji

b)  $d_l < DW < d_u$  - brak konkluzji

c)  $DW > d_u$  - nie ma podstaw do odrzucenia hipotezy zerowej o braku autokorelacji

# Testowanie autokorelacji


- Test Durbina-Watsona (Test DW):

## 2. Statystyka $DW > 2$

- a)  $DW > 4 - d_l$  - odrzucamy hipotezę zerową o braku autokorelacji i przyjmujemy hipotezę o ujemnej autokorelacji
- b)  $4 - d_u < DW < 4 - d_l$  - brak konkluzji
- c)  $DW < 4 - d_u$  - nie ma podstaw do odrzucenia hipotezy zerowej o braku autokorelacji



# Testowanie autokorelacji



# Testowanie autokorelacji

- ▶ Test Durbina-Watsona (Test BW):
  - Do badania autokorelacji I rzędu (między  $\varepsilon_t, \varepsilon_{t-1}$  )
  - Rozkład statystyki testowej wyprowadzony dla małych prób
  - Nie można go stosować w modelach gdzie jedną ze zmiennych objaśniających jest opóźniona zmienna zależna
  - Wada: niestandardowy rozkład i możliwość wystąpienia braku konkluzji

# Testowanie autokorelacji

- ▶ Test Breuscha-Godfrey (Test BG):
  - Do badania autokorelacji wyższego rzędu
  - Można go stosować w modelach gdzie występują opóźnione zmienne zależne

# Testowanie autokorelacji

- Test Breuscha-Godfrey (Test BG):

$$H_0 : Cov(\varepsilon_t, \varepsilon_{t-i}) = 0 \quad \text{gdzie} \quad i = 1, \dots, s$$

$$H_1 : \varepsilon_t = \gamma_1 \varepsilon_{t-1} + \dots + \gamma_s \varepsilon_{t-s} + u_t \quad \text{gdzie} \quad Var(u) = \sigma_u^2 I$$

- Hipoteza zerowa: brak autokorelacji
- Hipoteza alternatywna: autokorelacja

# Testowanie autokorelacji

- ▶ Test Breuscha-Godfrey (Test BG) – sposób przeprowadzenia testu:

1. przeprowadzamy regresję  $y_i$  na  $x_i$  i uzyskujemy reszty

2. przeprowadzamy regresję pomocniczą:

$$e_t = x_t \mu + \gamma_1 e_{t-1} + \dots + \gamma_s e_{t-s} + u_t$$

i testujemy  $H_0: \gamma_1 = \dots = \gamma_s = 0$

# Testowanie autokorelacji

- ▶ Statystyka testowa:

$$LM = TR^2 \xrightarrow{D} \chi_p^2$$

lub statystyka F

# Jakie założenie KMRL nie jest spełnione przy odrzuceniu $H_0$ ?

- ▶ Brak autokorelacji błędu losowego – kowariancja dwóch różnych błędów losowych jest zerowa:

$$\text{cov}(\varepsilon_i, \varepsilon_j) = 0 \quad \text{dla } i \neq j$$

# Plan wykładu

- ▶ 1. Testowanie autokorelacji
- ▶ 2. Heteroskedastyczność i autokorelacja
  - Konsekwencje heteroskedastyczności i autokorelacji
- ▶ 3. Problemy z danymi
  - Zmienne pominięte
  - Zmienne nieistotne
  - Obserwacje nietypowe i błędne
  - Współliniowość



# Autokorelacja

$Cov(\varepsilon_i, \varepsilon_j) = E(\varepsilon_i \varepsilon_j) > 0$  dla  $i \neq j$  - dodatnia autokorelacja

$Cov(\varepsilon_i, \varepsilon_j) = E(\varepsilon_i \varepsilon_j) < 0$  dla  $i \neq j$  - ujemna autokorelacja

# Sferyczność błędów losowych

- ▶ Jeżeli założenie o homoskedastyczności i autokorelacji jest spełnione to błędy losowe są **sferyczne**
- ▶ Jeżeli, któreś z tych założeń nie jest spełnione to błędy losowe są **niesferyczne** a macierz wariancji i kowariancji ma postać dowolnej macierzy symetrycznej i dodatnio półokreślonej:

$$\text{Var}(\varepsilon) = \Omega = \sigma^2 V$$

# Konsekwencje heteroskedastyczności i autokorelacji

- Estymator  $b$  jest nadal **nieobciążony**:

$$\begin{aligned} E(b) &= E\left[(X'X)^{-1}X'y\right] = \\ &E\left[(X'X)^{-1}X'X\beta + (X'X)^{-1}X'\varepsilon\right] = \\ &\beta + (X'X)^{-1}X'E(\varepsilon) = \beta \end{aligned}$$

- Nie będzie on jednak **efektywny**  $\longrightarrow$  można znaleźć estymator o mniejszej wariancji

# Konsekwencje heteroskedastyczności i autokorelacji

- Macierz wariancji i kowariancji b:

$$\begin{aligned} \text{Var}(b) &= E\left((X'X)^{-1}X'\varepsilon\varepsilon'X(X'X)^{-1}\right) = \\ &(X'X)^{-1}X'\Omega X(X'X)^{-1} = \\ &\sigma^2(X'X)^{-1}X'VX(X'X)^{-1} \end{aligned}$$

- Wzór ten różni się znacznie od prawidłowego wzoru na wariancję MNK:

$$\text{Var}(b) = \sigma^2(X'X)^{-1}$$

# Konsekwencje heteroskedastyczności i autokorelacji

- W rezultacie estymator macierzy wariancji i kowariancji  $b$ , którym posługiwaliśmy się do tej pory, nie będzie dobrym oszacowaniem macierzy wariancji i kowariancji  $b$

# Plan wykładu


- ▶ 1. Testowanie autokorelacji
- ▶ 2. Heteroskedastyczność i autokorelacja
  - Konsekwencje heteroskedastyczności i autokorelacji
- ▶ 3. Problemy z danymi
  - Zmienne pominięte
  - Zmienne nieistotne
  - Obserwacje nietypowe i błędne
  - Współliniowość

# Zmienne pominięte

- Mamy 2 modele:

$$y = X_1\beta_1 + u \quad (1)$$

$$y = X_1\beta_1 + X_2\beta_2 + \varepsilon \quad (2)$$

- Potencjalnie każdy z tych modeli może prawidłowo opisywać zmienną  $y$   problemy gdy przy liczeniu estymatorów zastosujemy niewłaściwy model

- Załóżmy, że estymujemy model (1) a prawdziwy jest model (2)

# Zmienne pominięte

- Zakładamy, że  $\beta_2 = 0$  gdy w rzeczywistości  $\beta_2 \neq 0$
- Przypadek ten nazywamy problemem **zmiennych pominiętych** (omitted variables)



# Zmienne pominięte

- $\hat{\beta}_1$  - estymator MNK wektora parametrów w modelu (1)
- Załóżmy, że prawdziwy jest model (2)

$$\begin{aligned}\hat{\beta}_1 &= (X_1'X_1)^{-1}X_1'y = (X_1'X_1)^{-1}X_1'(X_1\beta_1 + X_2\beta_2 + \varepsilon) \\ &= \beta_1 + (X_1'X_1)^{-1}X_1'X_2\beta_2 + (X_1'X_1)^{-1}X_1'\varepsilon\end{aligned}$$

# Zmienne pominięte

$$\begin{aligned} - E(\hat{\beta}_1) &= \beta_1 + (X_1' X_1)^{-1} X_1' X_2 \beta_2 + (X_1' X_1)^{-1} X_1' E(\varepsilon) \\ &= \beta_1 + (X_1' X_1)^{-1} X_1' X_2 \beta_2 \end{aligned}$$

- Jeśli więc pominiemy istotne zmienne estymator nie jest estymatorem nieobciążonym

- Obciążenie: 
$$E(\hat{\beta}_1) - \beta_1 = (X_1' X_1)^{-1} X_1' X_2 \beta_2$$

# Zmienne pominięte

- Dwa przypadki, dla których pominięcie zmiennej nie powoduje obciążenia estymatora

a)  $\beta_2 = 0$

b)  $X_1'X_2 = 0$  - zmienne pominięte nie są skorelowane ze zmiennymi objaśniającymi, które zostały uwzględnione w modelu

# Zmienne pominięte

- Pominięcie istotnych zmiennych jest prawdopodobnie najczęstszym powodem błędów w oszacowaniach
- W praktyce nigdy nie dysponujemy danymi odnośnie wszystkich zmiennych mogących wpływać na zmienną zależną
- W takim przypadku warto umieć określić kierunek ewentualnego obciążenia (trudne w ogólnym przypadku)

# Zmienne pominięte

- Kierunek obciążenia dla najprostszego przypadku (model ze stałą i jedną zmienną objaśniającą, pominięta jedna dodatkowa zmienna objaśniająca):

$$E(\hat{\beta}_1) - \beta_1 = \beta_2 \frac{s_{x_2}}{s_{x_1}} \rho_{x_1 x_2}$$

gdzie:

$s_{x_1}, s_{x_2}$  - wariancja empiryczna  $x_1, x_2$

$\rho_{x_1 x_2}$  - wsp. korelacji między  $x_1$  a  $x_2$

# Zmienne pominięte

- Kierunek obciążenia dla najprostszego przypadku (model ze stałą i jedną zmienną objaśniającą, pominięta jedna dodatkowa zmienna objaśniająca):

Przypadek	Wpływ zmiennej pominiętej na zmienną zależną ( $\beta_2$ )	Korelacja między zmienną pominiętą a zmienną niezależną ( $\rho$ )	Znak obciążenia
I	+	+	<b>+</b> (przeszacowanie)
II	-	-	<b>+</b>
III	+	-	<b>-</b> (niedoszacowanie)
IV	-	+	<b>-</b>

# Zmienne pominięte

- Przykład:

Dla pewnej badanej grupy osób przeprowadzono regresję logarytmu wynagrodzenia na latach nauki (zmienna *latanauki*). Jaki będzie prawdopodobny kierunek obciążenia parametru przy zmiennej *latanauki* wynikający z pominięcia:

- a) wielkości miejscowości, w której zamieszkuje badana osoba;
- b) liczby dzieci badanej osoby?

# Zmienne pominięte

- Obciążenie może prowadzić do:

a) Uznania za zmienną istotną zmiennej, która nie ma żadnego wpływu na zmienna zależną **—————>** najgorszy przypadek

b) Przeszacowania/niedoszacowania wpływu zmiennej objaśniającej na zmienna objaśnianą



# Zmienne pominięte

## ▶ Przykład

reg wydg dochg

Source	SS	df	MS			
Model	2.3577e+10	1	2.3577e+10	Number of obs =	31679	
Residual	3.4367e+10	31677	1084914.37	F( 1, 31677) =	21732.03	
Total	5.7944e+10	31678	1829163.02	Prob > F =	0.0000	
				R-squared =	0.4069	
				Adj R-squared =	0.4069	
				Root MSE =	1041.6	

wydg	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
dochg	.5879668	.0039884	147.42	0.000	.5801493	.5957843
_cons	712.8104	10.01991	71.14	0.000	693.171	732.4498

# Zmienne pominięte

## ▶ Przykład

reg wydg dochg los

Source	SS	df	MS			
Model	2.3886e+10	2	1.1943e+10	Number of obs =	31679	
Residual	3.4059e+10	31676	1075214.71	F( 2, 31676) =	11107.42	
Total	5.7944e+10	31678	1829163.02	Prob > F =	0.0000	
				R-squared =	0.4122	
				Adj R-squared =	0.4122	
				Root MSE =	1036.9	

wydg	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
dochg	.5688205	.0041284	137.78	0.000	.5607287	.5769123
los	65.35337	3.859286	16.93	0.000	57.78902	72.91772
_cons	548.4807	13.91655	39.41	0.000	521.2037	575.7577

# Zmienne nieistotne

- Mamy 2 modele:

$$y = X_1\beta_1 + u \quad (1)$$

$$y = X_1\beta_1 + X_2\beta_2 + \varepsilon \quad (2)$$

- Załóżmy, że estymujemy model (2) a prawdziwy jest model (1)

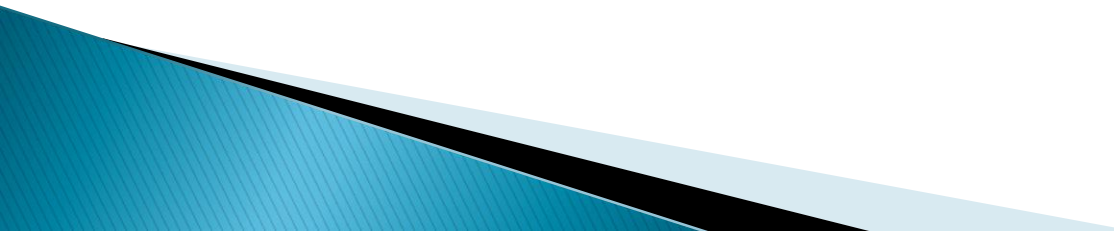
- Zakładamy, że  $\beta_2 \neq 0$  gdy w rzeczywistości  $\beta_2 = 0$

- Przypadek ten nazywamy problemem zmiennych nieistotnych


# Zmienne nieistotne

- Estymator  $\beta_1$  nieobciążony, ale będzie miał większą wariancję niż estymator uzyskany na podstawie modelu (1)
- Inaczej mówiąc, w modelu w którym występują zmienne nieistotne estymator MNK ma wyższą wariancję niż w modelu, z którego usunięto zmienne nieistotne

# Zmienne nieistotne

- Usuwamy z modelu zmienne nieistotne bo:
    - a) Poprawia to precyzję oszacowań parametrów przy zmiennych istotnych (estymator MNK ma mniejszą wariancję)
    - b) Uzyskujemy uproszczenie modelu
- 

# Obserwacje nietypowe i błędne

- ▶ **Obserwacja nietypowa** charakteryzuje się nietypowymi na tle pozostałych obserwacji cechami
  - ▶ Mechanizm, który w przypadku tej zmiennej generuje zmienną zależną jest mechanizmem opisywanym przez model
  - ▶ **Obserwacja błędna** jest obserwacją, której powstania nie da się wytłumaczyć w ramach teoretycznego modelu ekonomicznego stanowiącego podstawę estymowanego modelu
  - ▶ Obserwacje błędne często pojawiają się w wyniku pomyłek przy wpisywaniu obserwacji do bazy danych
- 

# Obserwacje nietypowe i błędne

- ▶ Niekiedy jednak obserwacje błędne są rzeczywistymi obserwacjami, związanymi z pewnymi nietypowymi zdarzeniami, które nie mogą być wyjaśnione za pomocą naszego modelu

- ▶ Przykład:


Estymujemy krzywą popytu na żywność dla różnych państw na świecie. W próbie występują państwa, w których obowiązuje reglamentacja żywności. Obserwacje takie traktujemy jako obserwacje błędne – teoria opisująca krzywą popytu nie znajduje zastosowania w momencie nierynkowego podziału dóbr.

# Obserwacje nietypowe i błędne


- ▶ Wpływ obserwacji nietypowej/błędnej na wynik regresji zależy od tego na ile ta obserwacja pasuje do prostej regresji
- ▶ Najbardziej niepokojąca jest sytuacja gdy obserwacja ma nietypowe wartości dla zmiennych niezależnych i słabo pasuje do prostej regresji



# Obserwacje nietypowe i błędne



# Obserwacje nietypowe i błędne



# Obserwacje nietypowe i błędne

- ▶ Na podstawie samego modelu nie da się ustalić, które obserwacje są błędne  $\longrightarrow$  fakt, że obserwacja nie pasuje do modelu nie może być powodem do jej usunięcia  $\longrightarrow$  tak postępując zawsze udawałoby się nam uzyskać dobrze dopasowany model (usuwając obserwacje, które nie pasują do modelu)
- ▶ Część obserwacji możemy uznać za błędne na podstawie teorii np. zmienna wiek przyjmuje dla pewnych obserwacji wartości ujemne  $\longrightarrow$  wiemy, że wiek musi przyjmować wartości dodatnie więc obserwacja błędna

# Obserwacje nietypowe i błędne

▶ Przykład:

Badamy wynagrodzenia dla próby osób przebadanych w 2007 przez CASE pod kątem wykonywania pracy nierejestrowanej.

```
sum wynagrodzenia
```

Variable	Obs	Mean	Std. Dev.	Min	Max
-----+-----					
zarobki	5773	13392.31	32264.34	0	99997

```
count if wynagrodzenia==99997
```

```
703
```

# Obserwacje nietypowe i błędne

- ▶ Uwzględnienie obserwacji nietypowej pozytywnie wpływa na:
  - a) precyzję oszacowań
  - b) dopasowanie modelu
  
- ▶ Uwzględnienie obserwacji błędnej negatywnie wpływa na:
  - a) precyzję oszacowań
  - b) dopasowanie modelu

# Obserwacje nietypowe i błędne

Przykład:

Porównujemy rentowność dwóch kontraktów: A i B. Dysponujemy 10 obserwacjami dotyczącymi stóp zwrotu (IRR – internal rate of return) dla tych dwóch kontraktów

kontrakt	stopa zwrotu									
A	10	8	8	9	11	10	8	9	11	10
B	16	15	18	17	16	-80	17	16	16	17

# Obserwacje nietypowe i błędne

Regresja z pominięciem jednej obserwacji:

---

IRR	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
+_IB_1	7.155556	.4808912	14.88	0.000	6.140964	8.170147
_cons	9.4	.330972	28.40	0.000	8.70171	10.09829

---

# Obserwacje nietypowe i błędne

Regresja ze wszystkimi obserwacjami:

---

IRR	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
<hr/>						
_IB_1	-3.5	10.66526	-0.33	0.747	-25.90688	18.90688
_cons	9.4	7.541478	1.25	0.229	-6.444057	25.24406

---



# Obserwacje nietypowe i błędne

- ▶ Statystyki służące do wykrycia obserwacji nietypowych, słabo pasujących do prostej regresji, silnie wpływających na wynik regresji:
  - a) dźwignia
  - b) standaryzowane reszty
  - c) odległość Cooka'a

# Obserwacje nietypowe i błędne

- ▶ Dźwignia – używana do stwierdzenia czy wektor zmiennych niezależnych  $x_i$  dla obserwacji  $i$  jest nietypowy na tle pozostałych  $x$ :

$$\begin{aligned} h_i &= \delta_i' X (X' X)^{-1} X' \delta_i = \delta_i' P_X \delta_i = (P_X)_{ii} \\ &= x_i (X' X)^{-1} x_i' \end{aligned}$$

gdzie:

$$\delta_i = [0, \dots, 0, 1, 0, \dots, 0]' \quad P_X = X(X' X)^{-1} X'$$

# Obserwacje nietypowe i błędne

- Dla każdego modelu:

$$0 \leq h_i \leq 1$$

- Dla modelu ze stałą:

$$\frac{1}{N} \leq h_i \leq 1$$

# Obserwacje nietypowe i błędne

- Nieformalna reguła mówi, że obserwacje można traktować jako nietypową gdy:

$$h_i \geq \frac{2K}{N}$$

- To, że obserwacja jest nietypowa nie oznacza, że nie pasuje do modelu
- Aby się o tym przekonać musimy przyjrzeć się **standaryzowanym resztom**

# Obserwacje nietypowe i błędne

- ▶ Standaryzowane reszty:
- ▶ Przypomnienie:  $e = M_x \varepsilon$
- ▶ Wobec tego:

$$\text{Var}(e) = \text{Var}(M_x \varepsilon) = M_x (I \sigma^2) M_x = \sigma^2 M_x$$

# Obserwacje nietypowe i błędne

- ▶ Standaryzowane reszty:

$$\begin{aligned} \text{Var}(e_i) &= \text{Var}(\delta'_i e) = \sigma^2 \delta'_i M_x \delta_i \\ &= \sigma^2 [\delta'_i \delta_i - \delta'_i (X'X)^{-1} X' \delta_i] \\ &= \sigma^2 (1 - \delta'_i P_X \delta_i) = \sigma^2 (1 - h_i) \end{aligned}$$

# Obserwacje nietypowe i błędne

- ▶ Standaryzowane reszty:
- ▶ Jeśli  $\varepsilon \sim N(0, \sigma^2 I)$  to:

$$\tilde{e}_i = \frac{e_i}{\sigma \sqrt{1 - h_i}} \sim N(0, 1)$$

- ▶ Ponieważ  $\sigma$  jest nieznane stosujemy estymator  $s$ :

$$\hat{e}_i = \frac{e_i}{s \sqrt{1 - h_i}} \sim t_{N-K}$$

# Obserwacje nietypowe i błędne

- ▶ Dla nietypowej obserwacji:

$$\left| \hat{e}_i \right| > 2$$

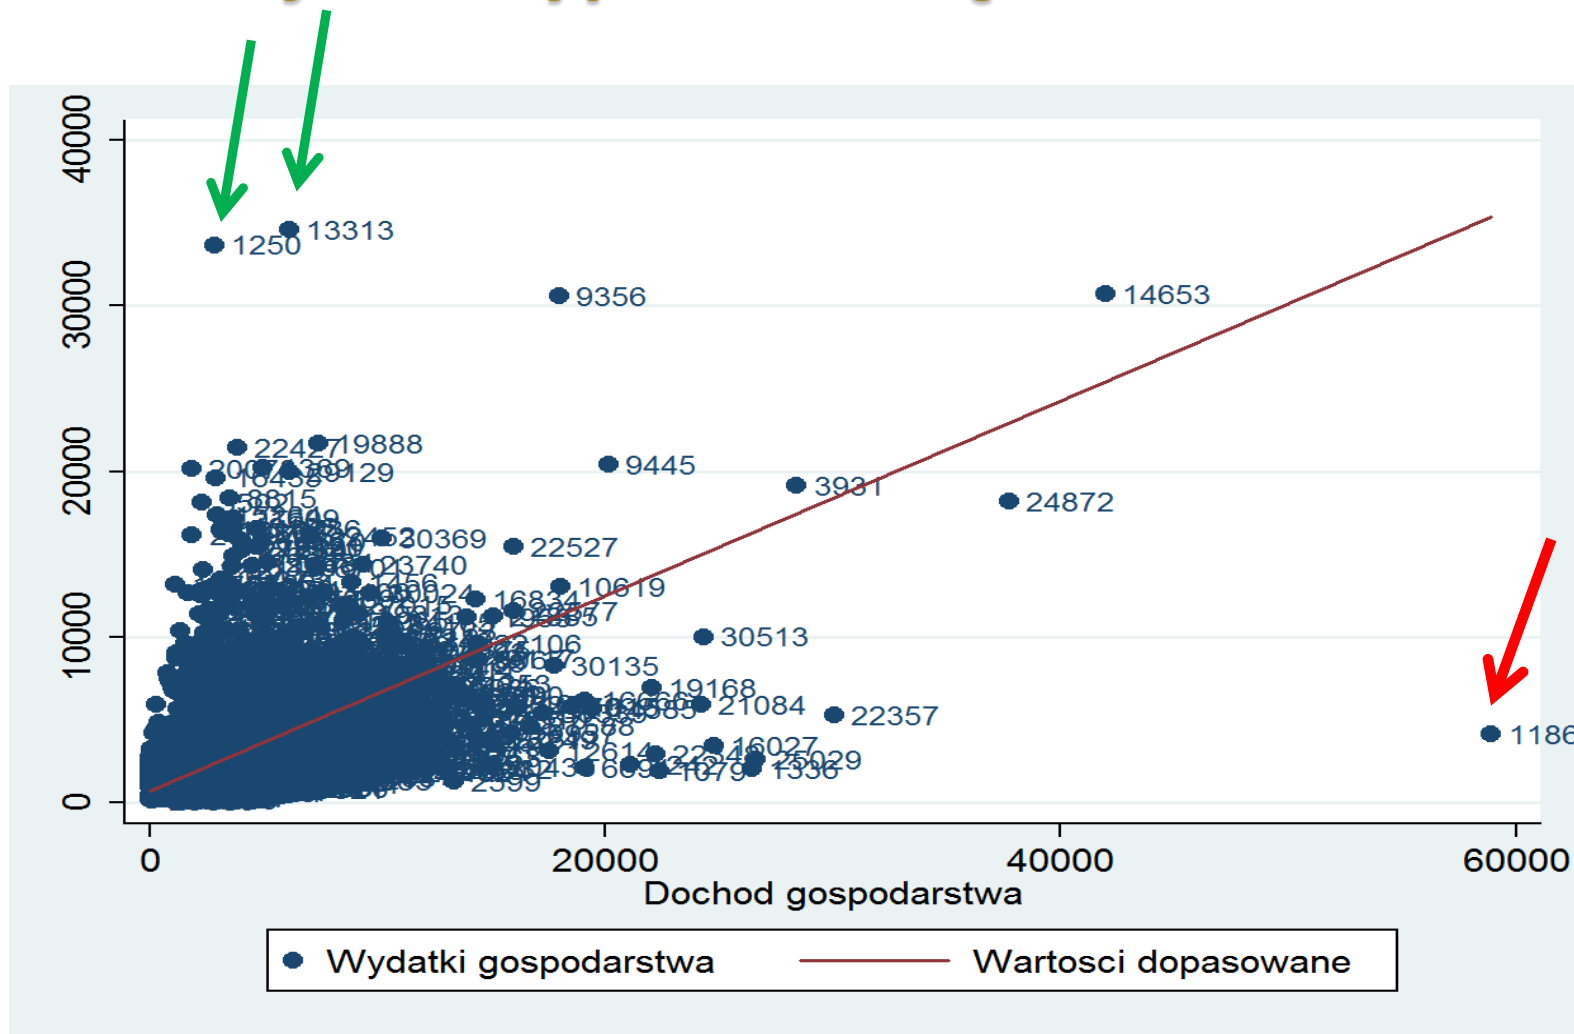
- ▶ Jednak (jeżeli błąd losowy ma rozkład normalny), to statystycznie dla ok. 5% obserwacji:

$$\left| \hat{e}_i \right| > 2$$

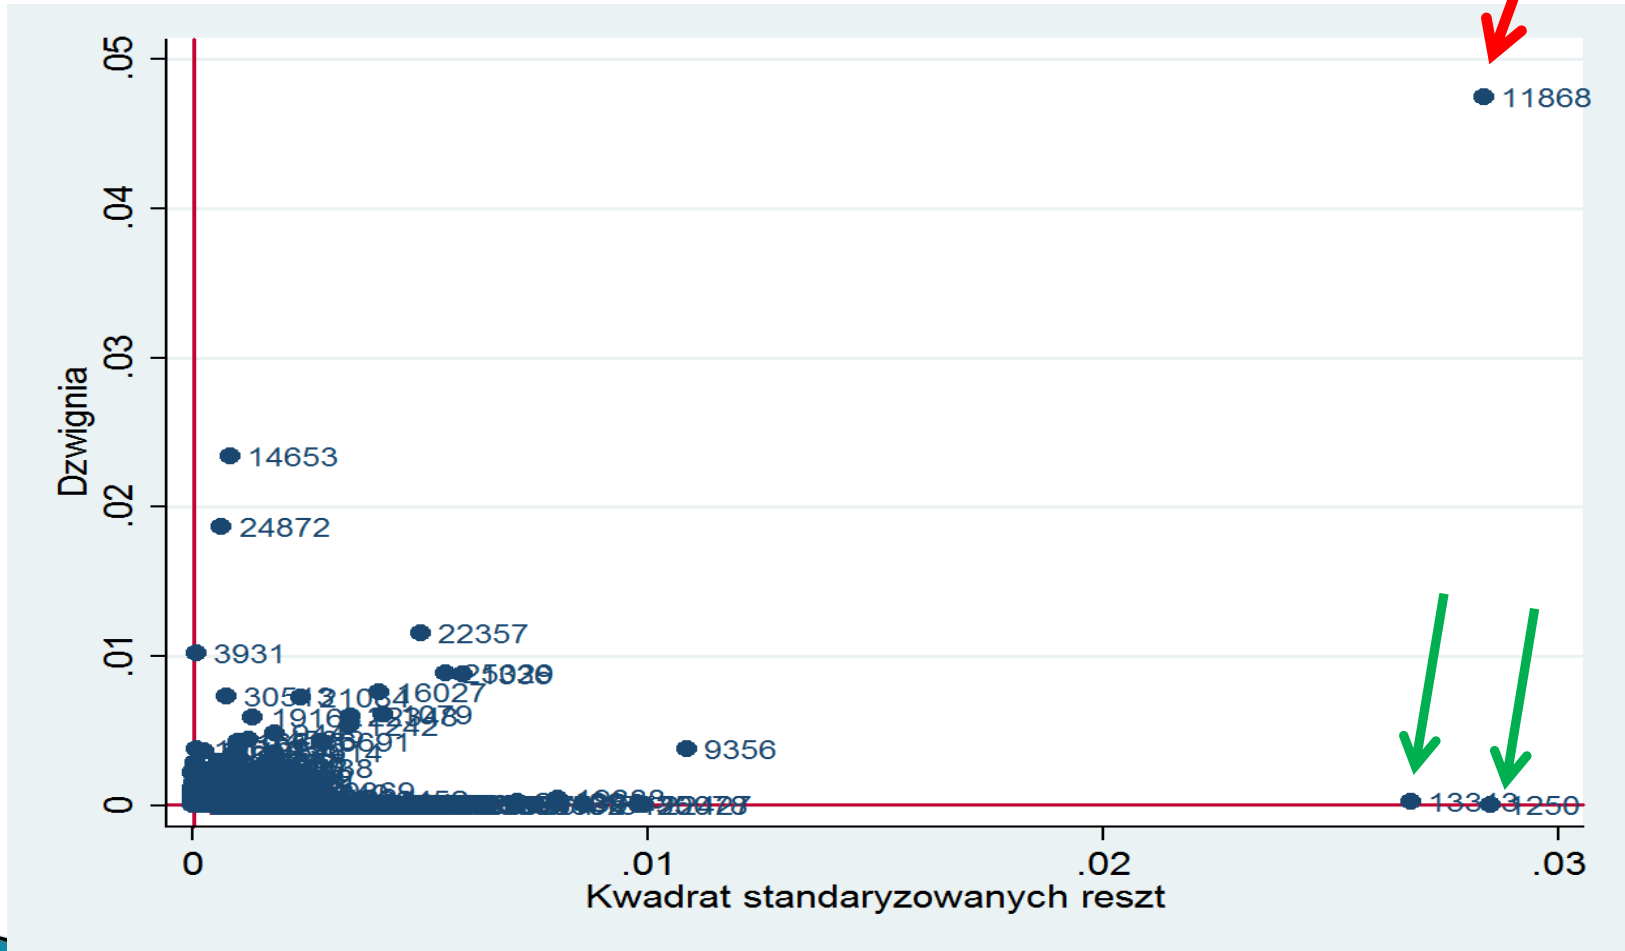
- ▶ Niepokojące jest nie tyle fakt występowania dużych reszt, ile raczej występowanie dużych wartości reszt dla obserwacji nietypowych (o dużych dźwigniach)



# Obserwacje nietypowe i błędne



# Obserwacje nietypowe i błędne



# Obserwacje nietypowe i błędne

- ▶ Odległość Cook'a  $\longrightarrow$  mierzy wpływ pojedynczej obserwacji na wynik regresji:

$$CD_i = \frac{(\hat{y} - \hat{y}_{(i)})'(\hat{y} - \hat{y}_{(i)})}{Ks^2} = \frac{\hat{e}_i^2}{K(1-h_i)}$$

gdzie:

$\hat{y}_{(i)} = X_{(i)}b_{(i)}$  - wartości dopasowane powstałe po usunięciu z próby  $i$  – tej obserwacji

$$\hat{y} = X_{(i)}b$$

# Obserwacje nietypowe i błędne

- ▶ Odległość Cook'a:
- ▶ Najbardziej wpływowe są obserwacje, która mają równocześnie duże  $\hat{e}_i^2$  i  $h_i$
- ▶ Nieformalna zasada mówi, że powinniśmy uważnie przyjrzeć się obserwacjom, dla których:

$$CD_i > \frac{4}{N}$$

# Obserwacje nietypowe i błędne

	numer	dochg	wydg	reszty_st	dzwignia	cook_d~t	
1.	11868	58935	4132	-30.72398	.0474962	23.53513	
2.	1336	26453	2008	-13.74937	.0087709	.8363862	
3.	25029	26645	2563	-13.32397	.0089089	.7979006	
4.	22357	30069	5267	-12.67469	.0115515	.9387016	
5.	1079	22392	1892	-11.54321	.0061053	.4092522	

$$h_i \geq \frac{2K}{N} = \frac{2*2}{31679} \approx 0,00012$$

$$CD_i > \frac{4}{N} = \frac{4}{31679} \approx 0,00012$$

# Obserwacje nietypowe i błędne

	numer	dochg	wydg	cook_d~t	reszty_st	dzwignia	
		-----					
1.	11868	58935	4132	23.53513	-30.72398	.0474962	
2.	1336	26453	2008	.8363862	-13.74937	.0087709	
3.	25029	26645	2563	.7979006	-13.32397	.0089089	
4.	22357	30069	5267	.9387016	-12.67469	.0115515	
5.	1079	22392	1892	.4092522	-11.54321	.0061053	

**Dziękuję za uwagę**