

Testy diagnostyczne

Natalia Nehrebecka
Stanisław Cichocki

Wykład 10

Plan wykładu

1. Testy diagnostyczne
2. Testowanie prawidłowości formy funkcyjnej modelu
3. Testowanie normalności składników losowych
4. Testowanie stabilności parametrów
5. Testowanie heteroskedastyczności

Plan wykładu

1. Testy diagnostyczne
2. Testowanie prawidłowości formy funkcyjnej modelu
3. Testowanie normalności składników losowych
4. Testowanie stabilności parametrów
5. Testowanie heteroskedastyczności

Testy diagnostyczne

- Służą do weryfikacji założeń KMRL
- Sprawdzenie założeń KMRL jest ważne \longrightarrow na nich opierają się własności estymatorów MNK
- Jeśli któreś z założeń nie jest spełnione \longrightarrow należy zastanowić się nad przeformułowaniem modelu lub zastosować bardziej zaawansowane narzędzia ekonometryczne
- Testy są stosowane po wyestymowaniu modelu

Testy diagnostyczne

- W praktyce do testowania jednego założenia KMRL używa się często kilku testów
- Czasami różne testy zastosowane do testowania tej samej hipotezy zerowej dają sprzeczne wnioski

Plan wykładu

1. Testy diagnostyczne
2. Testowanie prawidłowości formy funkcyjnej modelu
3. Testowanie normalności składników losowych
4. Testowanie stabilności parametrów
5. Testowanie heteroskedastyczności

Testowanie prawidłowości formy funkcyjnej

Test RESET (*Regression Specification Error Test*):

$$H_0 : y_i = x_i\beta + \varepsilon_i \quad - \text{liniowa postać modelu}$$

$$H_1 : y_i = f(x_i\beta) + \varepsilon_i \quad - \text{nieliniowa postać modelu}$$

gdzie $f(\bullet)$ jest nieliniowa

Procedura przeprowadzenia testu RESET

Krok 1: estymujemy współczynniki regresji w modelu:

$$y_i = x_i\beta + \varepsilon_i$$

Krok 2: uzyskujemy wartości dopasowane:

$$\hat{y}_i = x_i b$$

Krok 3: przeprowadzamy regresję pomocniczą:

$$y_i = x_i\beta + \alpha_1 \hat{y}_i^2 + \dots + \alpha_p \hat{y}_i^{p+1} + u_i$$

Testowanie prawidłowości formy funkcyjnej

Krok 4: testujemy łączną nieistotność zmiennych $\hat{y}_i^2, \dots, \hat{y}_i^{p+1}$

- ▶ **Hipoteza zerowa** oznacza łączną nieistotność tych zmiennych, implikuje poprawność formy funkcyjnej przyjętej przez nas w regresji wyjściowej.
- ▶ za pomocą *testu F* testujemy H_0 :

$$H_0 : \alpha_1 = \dots = \alpha_p = 0$$

- ▶ W dużych próbach rozkład statystyki będzie dążył do rozkładu *F-Snedecora* o p i $N-p$ stopniach swobody

Testowanie prawidłowości formy funkcyjnej

▶ Druga forma:

$$e_i = x_i\beta + \alpha_1\hat{y}_i^2 + \dots + \alpha_p\hat{y}_i^{p+1} + \eta_i$$

- Test $LM = NR^2 \xrightarrow{D} \chi^2_p$

Jakie założenie KMRL nie jest spełnione przy odrzuceniu H_0 ?

- ▶ Związek pomiędzy zmienną zależną a zmiennymi niezależnymi opisany jest równaniem:

$$y_i = \beta_1 + \beta_2 x_{2i} + \beta_3 x_{3i} + \dots + \beta_K x_{Ki} + \varepsilon_i \quad i = 1, 2, 3, \dots, N$$

Jakie są skutki niespełnienia założenia KMRL

Odrzucenie hipotezy zerowej o poprawności przyjętej formy funkcyjnej

- podważa interpretacje ekonomiczną modelu (*interpretacja oszacowanych parametrów*)
- niemożliwe udowodnienie własności estymatora MNK (*nieobciążoność czy efektywność estymatora MNK*)

W jaki sposób można rozwiązać problemy zasygnalizowane przez wynik testu?

Możemy próbować poprawić formę funkcyjną modelu wprowadzając do modelu:

- interakcje między zmiennymi,
- dokonać przekształceń zmiennych,
- zastosować model wielomianowy, schodkowy lub krzywej łamanej.

Przykład

$$price = \beta_1 + \beta_2 size + \beta_3 bdrms + \varepsilon$$

$$F = 4.67; p - value = 0.012$$

$$\ln(price) = \beta_1 + \beta_2 \ln(size) + \beta_3 bdrms + \varepsilon$$

$$F = 2.56; p - value = 0.084$$

Przykład

- ▶ Analiza prestiżu wykonywanego zawodu (*siops*)
 - a) wiek (*age*)
 - b) płeć (*sex*, 1 Mężczyzna, 2 kobieta)
 - c) wykształcenie respondenta (*dp* - podstawowe, *ds* – średnie, *dw* –wyższe)
 - d) miejsce zamieszkania respondenta (*size*)
 - e) prestiż wykonywanego przez ojca zawodu (*pasiops* całkowite od 1 do 100.)
 - f) prestiż wykonywanego przez matkę zawodu (*masiops* całkowite od 1 do 100.)
 - g) wykształcenie ojca (*padeq*)
 - h) wykształcenie matki (*madeq*)

Przykład

```
. xi: regress siops age pasiops masiops i.sex ds dw
i.sex          _Isex_1-2          (naturally coded; _Isex_1 omitted)
```

| Source | SS | df | MS | Number of obs = 1232 | | |
|----------|------------|------|------------|----------------------|---|--------|
| Model | 50595.8547 | 6 | 8432.64244 | F(6, 1225) | = | 106.59 |
| Residual | 96913.6778 | 1225 | 79.1132064 | Prob > F | = | 0.0000 |
| Total | 147509.532 | 1231 | 119.829027 | R-squared | = | 0.3430 |
| | | | | Adj R-squared | = | 0.3398 |
| | | | | Root MSE | = | 8.8946 |

| siops | Coef. | Std. Err. | t | P> t | [95% Conf. Interval] | |
|---------|-----------|-----------|-------|-------|----------------------|-----------|
| age | .0627069 | .0192075 | 3.26 | 0.001 | .0250236 | .1003903 |
| pasiops | .08292 | .0304436 | 2.72 | 0.007 | .0231926 | .1426474 |
| masiops | .0960088 | .0317817 | 3.02 | 0.003 | .0336562 | .1583614 |
| _Isex_2 | -1.066076 | .5158061 | -2.07 | 0.039 | -2.078037 | -.0541146 |
| ds | 5.08828 | .6766924 | 7.52 | 0.000 | 3.760676 | 6.415885 |
| dw | 13.55178 | .7347977 | 18.44 | 0.000 | 12.11018 | 14.99338 |
| _cons | 23.4708 | 1.798279 | 13.05 | 0.000 | 19.94275 | 26.99885 |

```
. /*test Ramsey'a RESET na poprawność formy funkcyjnej*/
. ovtest
```

```
Ramsey RESET test using powers of the fitted values of siops
Ho: model has no omitted variables
F(3, 1222) = 1.15
Prob > F = 0.3264
```

OVTEST: w regresji pomocniczej testowana jest łączna nieistotność wartości dopasowanych podniesionych do 2,3 i 4 potęgi

Plan wykładu

1. Testy diagnostyczne
2. Testowanie prawidłowości formy funkcyjnej modelu
3. Testowanie normalności składników losowych
4. Testowanie stabilności parametrów
5. Testowanie heteroskedastyczności

Testowanie normalności składników los.

- Test Jarque – Berra (Test JB):

$H_0 : \varepsilon \sim N(\mathbf{0}, \sigma^2 \mathbf{I})$ - składnik los. ma rozkład normalny

$H_1 : \varepsilon \not\sim N(\mathbf{0}, \sigma^2 \mathbf{I})$ - składnik los. nie ma rozkładu normalnego

Testowanie normalności składników los.

Procedura przeprowadzenia testu JB:

Krok 1: estymujemy współczynniki regresji w modelu:

$$y_i = x_i\beta + \varepsilon_i$$

Krok 2: uzyskujemy reszty: e_i

Krok 3: liczymy *współczynnik skośności i kurtozy* dla rozkładu reszt:

$$\hat{\theta}_1 = \frac{\sum_{i=1}^N e_i^3 / N}{\hat{\sigma}^3} - \text{skośność}$$

$$\hat{\theta}_2 = \frac{\sum_{i=1}^N e_i^4 / N}{\hat{\sigma}^4} - \text{kurtoza}$$

$$\hat{\sigma} = \sqrt{\frac{\sum_{i=1}^N e_i^2}{N}} - \text{odchylenie standardowe}$$

Testowanie normalności składników los.

Krok 4: statystyka testowa:

$$LM = N \left[\frac{\hat{\theta}_1^2}{6} + \frac{(\hat{\theta}_2 - 3)^2}{24} \right] \xrightarrow{D} \chi_2^2$$

Uwaga! Dla rozkładu normalnego:

- Współczynnik skośności $\theta_1=0$
- Kurtoza $\theta_2=3$

Jakie założenie KMRL nie jest spełnione przy odrzuceniu H_0 ?

- ▶ Niespełnione dodatkowe założenie o tym, że składnik losowy ma rozkład normalny

Jakie są skutki niespełnienia założenia KMRL

- ▶ **Próba duża:** rozkłady statystyk są bliskie standardowym rozkładom
- ▶ **Mała próba:** jest problemem, gdyż:
 - To założenie jest niezbędne do wyprowadzenie rozkładów statystyk testowych oraz prawidłowego wnioskowania statystycznego.
 - b_{MNK} jest **najlepszym estymatorem** wśród liniowych i nieobciążonych estymatorów, ale można znaleźć nieobciążony estymator nieliniowy o wariancji mniejszej niż estymator MNK


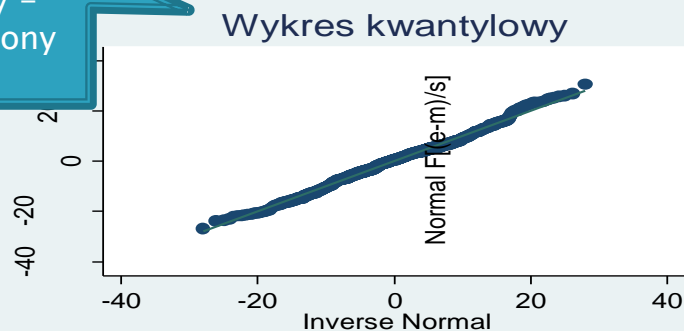

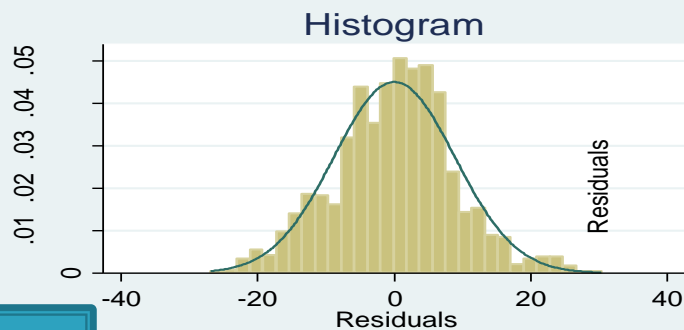
Przykład

. sktest e

Skewness/Kurtosis tests for Normality

| Variable | Obs | Pr(Skewness) | Pr(Kurtosis) | adj chi2(2) | joint Prob>chi2 |
|----------|---------|--------------|--------------|-------------|-----------------|
| e | 1.2e+03 | 0.7140 | 0.0837 | 3.12 | 0.2102 |

Analiza Graficzna Reszt



Wykres kwantylowy - analizuje ogony rozkładu

Wykres prawdopodobieństwa - analizuje środkową część rozkładu

Plan wykładu

1. Testy diagnostyczne
2. Testowanie prawidłowości formy funkcyjnej modelu
3. Testowanie normalności składników losowych
- 4. Testowanie stabilności parametrów**
5. Testowanie heteroskedastyczności

Testowanie stabilności parametrów – Test Chowa

- Służy do weryfikacji czy parametry modelu będą takie same dla kilku różnych próbek
- Załóżmy, że modele dla próbek: $y_s = X_s \beta_s + \varepsilon_s$,
gdzie $s=1, \dots, m$ oznacza numer próbki


$H_0 : \beta_1 = \beta_2 = \dots = \beta_m$ - parametry są takie same w próbkach

$H_1 : \beta_r \neq \beta_s$ - parametry różnią się w próbkach

dla pewnych r, s


Dla szeregu czasowego

1. W momencie t^* parametry modelu ulegają zmianie (zmiany strukturalne w gospodarce)



Dla próby przekrojowej

2. Podgrupa analizowanej populacji opisywana innym modelem niż reszta populacji



Procedura przeprowadzenia testu Chowa

Sprawdzimy, czy parametry regresji są takie same w próbkach wyodrębnionych za pomocą zmiennej np. płeć

KROK 1: przeprowadzamy regresję na całej próbie (nie wprowadzamy do modelu zmiennej płęć!)

- obliczamy: $S = \text{RSS}$ - Suma kwadratów z regresji na całej próbie

KROK 2: przeprowadzamy regresję na próbce kobiet

- obliczamy: $S_1 = \text{RSS}_1$ - Suma kwadratów z regresji na próbce zawierającej kobiety

KROK 3: przeprowadzamy regresję na próbce mężczyzn

- obliczamy: $S_2 = \text{RSS}_2$ - Suma kwadratów z regresji na próbce zawierającej mężczyzn

Testowanie stabilności parametrów – test Chowa

Statystyka opisowa:

$$F = \frac{(S - \sum_{s=1}^m S_s) / (K(m - 1))}{\sum_{s=1}^m S_s / (N - mK)} \sim F(K(m - 1), N - mK)$$

Gdzie:

S – suma kwadratów reszt z regresji na całej próbie,

S_s – suma kwadratów reszt z regresji na j -tej podpróbie,

m – liczba wyodrębnionych próbek,

K – liczba szacowanych parametrów (*taka sama we wszystkich regresjach*),

N – liczba obserwacji.

Przykład – test Chow

```
. xi: regress siops age age3 ds dw pasiops masiops
```

| Source | SS | df | MS |
|----------|------------|------|------------|
| Model | 51114.1379 | 6 | 8519.02298 |
| Residual | 96395.3946 | 1225 | 78.690118 |
| Total | 147509.532 | 1231 | 119.829027 |

```
Number of obs = 1232
F( 6, 1225) = 108.26
Prob > F = 0.0000
R-squared = 0.3465
Adj R-squared = 0.3433
Root MSE = 8.8707
```

| siops | Coef. | Std. Err. | t | P> t | [95% Conf. Interval] | |
|---------|-----------|-----------|-------|-------|----------------------|-----------|
| age | .2190567 | .05151 | 4.25 | 0.000 | .1179991 | .3201142 |
| age3 | -.0000216 | 6.55e-06 | -3.30 | 0.001 | -.0000345 | -8.76e-06 |
| ds | 4.84467 | .6812481 | 7.11 | 0.000 | 3.508127 | 6.181212 |
| dw | 13.31385 | .7250675 | 18.36 | 0.000 | 11.89133 | 14.73636 |
| pasiops | .084663 | .0303691 | 2.79 | 0.005 | .0250818 | .1442441 |
| masiops | .1042921 | .0317458 | 3.29 | 0.001 | .0420101 | .1665742 |
| _cons | 18.39664 | 2.241034 | 8.21 | 0.000 | 13.99995 | 22.79333 |

Przykład – test Chowa

```
. xi: regress siops age age3 ds dw pasiops masiops if sex==2
```

| Source | SS | df | MS |
|----------|------------|-----|------------|
| Model | 31352.4708 | 6 | 5225.41181 |
| Residual | 55567.3783 | 656 | 84.7063694 |
| Total | 86919.8492 | 662 | 131.298866 |

Number of obs = 663
 F(6, 656) = 61.69
 Prob > F = 0.0000
 R-squared = 0.3607
 Adj R-squared = 0.3549
 Root MSE = 9.2036

| siops | Coef. | Std. Err. | t | P> t | [95% Conf. Interval] | |
|---------|-----------|-----------|-------|-------|----------------------|----------|
| age | .1967849 | .0736225 | 2.67 | 0.008 | .0522207 | .3413492 |
| age3 | -.0000169 | 9.01e-06 | -1.88 | 0.061 | -.0000346 | 7.79e-07 |
| ds | 6.909362 | .9927858 | 6.96 | 0.000 | 4.959941 | 8.858783 |
| dw | 12.12589 | .9545302 | 12.70 | 0.000 | 10.25158 | 14.00019 |
| pasiops | .0999609 | .0424373 | 2.36 | 0.019 | .0166316 | .1832903 |
| masiops | .0573792 | .045161 | 1.27 | 0.204 | -.0312982 | .1460567 |
| _cons | 18.25259 | 3.203996 | 5.70 | 0.000 | 11.96127 | 24.54391 |

Przykład – test Chow

```
. xi: regress siops age age3 ds dw pasiops masiops if sex==1
```

| Source | SS | df | MS | | | |
|----------|------------|-----|------------|-----------------|--------|--|
| Model | 21630.7481 | 6 | 3605.12468 | Number of obs = | 569 | |
| Residual | 38951.28 | 562 | 69.3083274 | F(6, 562) = | 52.02 | |
| Total | 60582.0281 | 568 | 106.6585 | Prob > F = | 0.0000 | |
| | | | | R-squared = | 0.3570 | |
| | | | | Adj R-squared = | 0.3502 | |
| | | | | Root MSE = | 8.3252 | |

| siops | Coef. | Std. Err. | t | P> t | [95% Conf. Interval] | |
|---------|-----------|-----------|-------|-------|----------------------|-----------|
| age | .2618198 | .0716213 | 3.66 | 0.000 | .1211416 | .402498 |
| age3 | -.0000284 | 9.46e-06 | -3.00 | 0.003 | -.000047 | -9.81e-06 |
| ds | 2.201164 | .928647 | 2.37 | 0.018 | .3771207 | 4.025207 |
| dw | 15.73118 | 1.160005 | 13.56 | 0.000 | 13.45271 | 18.00966 |
| pasiops | .0491113 | .0431628 | 1.14 | 0.256 | -.0356689 | .1338915 |
| masiops | .1614052 | .0436714 | 3.70 | 0.000 | .0756261 | .2471843 |
| _cons | 18.85553 | 3.117649 | 6.05 | 0.000 | 12.73186 | 24.9792 |

Przykład – test Chowa

$$F = \frac{[S - (S_1 + S_2)] / (K(m - 1))}{(S_1 + S_2) / (N - mK)}$$

$$F = \frac{(96395,3946 - 55567,3783 - 38951,28) / (7 * 1)}{(55567,3783 + 38951,28) / (1232 - 7 * 2)} = 3,4548958$$

$$F^* = F(7, 1218) = 2,0170835$$

Jakie założenie KMRL nie jest spełnione przy odrzuceniu H_0 ?

- ▶ Związek pomiędzy zmienną zależną a zmiennymi niezależnymi opisany jest równaniem:

$$y_i = \beta_1 + \beta_2 x_{2i} + \beta_3 x_{3i} + \dots + \beta_K x_{Ki} + \varepsilon_i \quad i = 1, 2, 3, \dots, N$$

Jakie są skutki niespełnienia założenia KMRL

Odrzucenie hipotezy zerowej o tym, że parametry są stabilne

- podważa interpretacje ekonomiczną modelu (interpretacja oszacowanych parametrów)
- niemożliwe udowodnienie własności estymatora MNK (nieobciążoność czy efektywność estymatora MNK)

W jaki sposób można rozwiązać problemy zasygnalizowane przez wynik testu?

- ▶ Problem niestabilności parametrów można rozwiązać poprzez:
 - wprowadzenie do modelu interakcji pomiędzy zmiennymi 0-1 związanymi z podziałem na grupy a odpowiednimi zmiennymi objaśniającymi (*w przypadku gdy jedynie część parametrów jest różna dla analizowanych podprób*)
 - estymacje osobnych regresji na wyodrębnionych podpróbach

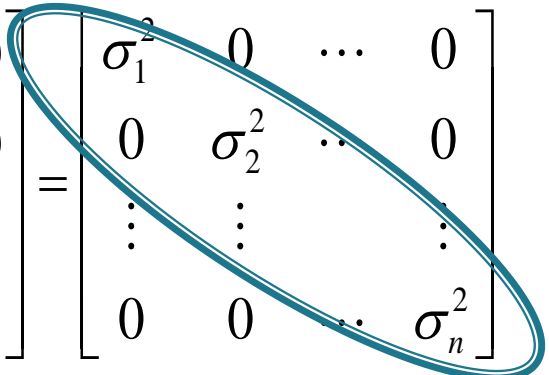
Plan wykładu

1. Testy diagnostyczne
2. Testowanie prawidłowości formy funkcyjnej modelu
3. Testowanie normalności składników losowych
4. Testowanie stabilności parametrów
5. Testowanie heteroskedastyczności

Testowanie heteroskedastyczności

Przypomnienie: Co to znaczy, że w modelu występuje homoskedastyczność/heteroskedastyczność?

- heteroskedastyczność

$$\text{Var}(\varepsilon) = \begin{bmatrix} \text{Var}(\varepsilon_1) & \text{Cov}(\varepsilon_1, \varepsilon_2) & \cdots & \text{Cov}(\varepsilon_1, \varepsilon_n) \\ \text{Cov}(\varepsilon_2, \varepsilon_1) & \text{Var}(\varepsilon_2) & \cdots & \text{Cov}(\varepsilon_2, \varepsilon_n) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(\varepsilon_n, \varepsilon_1) & \text{Cov}(\varepsilon_n, \varepsilon_1) & \cdots & \text{Var}(\varepsilon_n) \end{bmatrix} = \begin{bmatrix} \sigma_1^2 & 0 & \cdots & 0 \\ 0 & \sigma_2^2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \sigma_n^2 \end{bmatrix}$$


Testowanie heteroskedastyczności – Test Goldfelda-Quandta

- ▶ Test Goldfelda-Quandta – **samodzielnie!**
 - z konstrukcji wynika, iż można go stosować do wykrywania zależności między wariancją błędu losowego a wielkością jednej zmiennej
 - jako jedyny z testów na heteroskedastyczność ma rozkład wyprowadzony **dla małych prób**

Testowanie heteroskedastyczności – Test Breusch-Pagana (BP)

- ▶ Test BP stosowany jeśli istnieje podejrzenie, że wariancja błędów losowych w modelu zależy od pewnego wektora zmiennych z_i .

$$H_0 : \text{Var}(\varepsilon_i) = \sigma^2 \quad i = 1, \dots, N$$

$$H_1 : \text{Var}(\varepsilon_i) = \sigma_i^2 = \sigma^2 f(\alpha_0 + z_i \alpha)$$

gdzie: $f(\bullet)$ - funkcja różniczkowalna

z_i - wektor zmiennych, może zawierać zmienne występujące w wektorze zmiennych objaśniających

Testowanie heteroskedastyczności

Test Breuscha-Pagana

▶ **Sposób przeprowadzania:**

▶ **Krok 1:** Estymujemy model $y_i = x_i\beta + \varepsilon_i$ i uzyskujemy reszty e_i .

▶ **Krok 2:** Przeprowadzamy regresję pomocniczą $\frac{e_i^2}{\tilde{\sigma}^2}$ na z_i oraz stałej:

$$\frac{e_i^2}{\tilde{\sigma}^2} = \alpha_0 + \alpha z_i + u_i \quad \tilde{\sigma}^2 = \frac{e'e}{N}$$

▶ **Krok 3:** H_0 weryfikujemy testując w regresji pomocniczej hipotezę:

$$H_0: \alpha = 0$$

▶ Używamy alternatywnie statystyk testowych:

$$\frac{1}{2} ESS \xrightarrow{D} \chi_p^2$$

$$NR^2 \xrightarrow{D} \chi_p^2$$

(jeżeli **nie** jest spełnione założenie o normalności zaburzenia losowego)

gdzie p jest liczbą zmiennych zawartych w z_i

Testowanie heteroskedastyczności

- ▶ Szczególną postacią testu Breuscha-Pagana jest test White'a



Z_i

zawiera
**wszystkie kwadraty
i iloczyny krzyżowe
zmiennych objaśniających**

- ▶ Stosujemy gdy interesuje nas *samo wykrycie heteroskedastyczności* a mniej wykrycie zmiennych, od których zależy wariancja błędu losowego

Testowanie heteroskedastyczności

- ▶ *Test Breuscha-Pagana i White'a* są bardziej uniwersalne niż *test Goldfelda-Quandta* jednak rozkłady statystyk testowych dla tych testów są znane tylko **dla dużych prób**

Przykład – Test Breusch-Pagana

```
xi: regress siops age age3 pasiops masiops i.sex ds dw
```

| Source | SS | df | MS | | | |
|----------|------------|------|------------|-----------------|--------|--|
| Model | 51478.8446 | 7 | 7354.12065 | Number of obs = | 1232 | |
| Residual | 96030.6879 | 1224 | 78.4564444 | F(7, 1224) = | 93.74 | |
| Total | 147509.532 | 1231 | 119.829027 | Prob > F = | 0.0000 | |
| | | | | R-squared = | 0.3490 | |
| | | | | Adj R-squared = | 0.3453 | |
| | | | | Root MSE = | 8.8576 | |

| siops | Coef. | Std. Err. | t | P> t | [95% Conf. Interval] | |
|---------|-----------|-----------|-------|-------|----------------------|-----------|
| age | .2229961 | .0514659 | 4.33 | 0.000 | .122025 | .3239673 |
| age3 | -.000022 | 6.55e-06 | -3.35 | 0.001 | -.0000348 | -9.12e-06 |
| pasiops | .0864447 | .0303352 | 2.85 | 0.004 | .02693 | .1459594 |
| masiops | .1025299 | .0317091 | 3.23 | 0.001 | .0403197 | .1647402 |
| _Isex_2 | -1.107799 | .5138112 | -2.16 | 0.031 | -2.115848 | -.0997512 |
| ds | 4.727672 | .6823969 | 6.93 | 0.000 | 3.388875 | 6.06647 |
| dw | 13.54294 | .7317461 | 18.51 | 0.000 | 12.10733 | 14.97856 |
| _cons | 18.90143 | 2.249919 | 8.40 | 0.000 | 14.48731 | 23.31556 |

Przykład – Test Breusch-Pagana

- W regresji pomocniczej biorą udział wszystkie wyjściowe zmienne

```
hettest, rhs
```

```
Breusch-Pagan / Cook-Weisberg test for heteroskedasticity
```

```
Ho: Constant variance
```

```
Variables: age age3 pasiops masiops _Isex_2 ds dw
```

```
chi2(7) = 30.00
```

```
Prob > chi2 = 0.0001
```

- Poprawka na brak normalności zaburzenia losowego: *iid*

```
hettest, rhs iid
```

```
Breusch-Pagan / Cook-Weisberg test for heteroskedasticity
```

```
Ho: Constant variance
```

```
Variables: age age3 pasiops masiops _Isex_2 ds dw
```

```
chi2(7) = 26.79
```

```
Prob > chi2 = 0.0004
```

Przykład – Test Breuscha-Pagana

- Test Breuscha-Pagana służy do testowania heteroscedastyczności w przypadku, gdy wiemy jakie zmienne ją wywołują.

```
hettest age, iid
```

```
Breusch-Pagan / Cook-Weisberg test for heteroskedasticity
```

```
Ho: Constant variance
```

```
Variables: age
```

```
chi2(1) = 0.61
```

```
Prob > chi2 = 0.4340
```

Przykład – Test White

```
. imtest, white
```

White's test for H_0 : homoskedasticity
against H_a : unrestricted heteroskedasticity

```
chi2(31) = 68.72
```

```
Prob > chi2 = 0.0001
```

Przykład

$$\widehat{price} = - 21.77 + .0021 \textit{lotsize} + .123 \textit{sqrft} + 13.85 \textit{bdrms}$$

(29.48) (.0006) (.013) (9.01)

Heteroskedastyczność

$p - value = .0028$

$$\widehat{\log(price)} = - 1.30 + .168 \log(\textit{lotsize}) + .700 \log(\textit{sqrft}) + .037 \textit{bdrms}$$

(.65) (.038) (.093) (.028)

$p - value = .2390$

homoskedastyczność

Jakie założenie KMRL nie jest spełnione przy odrzuceniu H_0 ?

- ▶ Homoskedastyczność składnika losowego – wariancja błędu losowego jest stała dla wszystkich obserwacji:

$$\text{var}(\varepsilon_i) = \sigma^2 \quad \text{dla } i = 1, 2, \dots, N$$

Pytania teoretyczne

1. Do czego służą testy diagnostyczne?
2. Za pomocą jakiego testu testujemy prawidłowość formy funkcyjnej? Jakiemu założeniu KMRL odpowiada H_0 w tym teście? Jaka jest hipoteza alternatywna w tym teście?
3. (*) Opisz dwa sposoby przeprowadzania testu RESET
4. Za pomocą jakiego testu weryfikowana jest normalność składnika losowego? Jakiemu założeniu KMRL odpowiada H_0 w tym teście? Jaka jest hipoteza alternatywna w tym teście? Jakie są konsekwencje dla własności MNK, jeśli H_0 jest fałszywe?
5. Za pomocą jakich testów testujemy stabilność parametrów? Jakiemu założeniu KMRL odpowiada H_0 w tym testach? Jakie są hipotezy alternatywne w tym testach?
6. (*) W jaki sposób przeprowadzamy test Chowa?

Pytania teoretyczne

1. Za pomocą jakich testów można testować heteroskedastyczność? Jakiemu założeniu KMRL odpowiada H_0 w tych testach? Jakie są hipotezy alternatywne w tym testach?
2. (*) Jak przeprowadza się test Goldfelda-Quandta?
3. (*) Podać postać regresji pomocniczej w przypadku testu Breuscha-Pagana.

Dziękuję za uwagę