

KOLINEARITAS GANDA (*MULTICOLLINEARITY*)

Oleh Bambang Juanda

$$\text{Model: } Y_i = \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon_i$$

1. Hubungan Linear Sempurna (eksak), Jika

$$\sum_{i=1}^k C_i X_i = 0 \quad C_i \text{ konstanta yg tdk semuanya 0.}$$

- Mudah diketahui krn tdk ada dugaan parameter koef dgn OLS, juga ragamnya.
- Kolinearitas ganda hanya untuk hubungan linear.
bukan, Y_i (biaya)=f(output)
$$= \beta_0 + \beta_1 X + \beta_2 X^2 + \dots + \beta_p X^p$$
- Karena asumsi X nonstokastik (*fixed*),
multikolinearitas hanya fenomena sample saja.

2. Hubungan Linear Tidak Sempurna, jika :

$$\sum_{i=1}^k C_i X_i + v_i = 0, \quad v_i = \text{sisaan}$$

Konsekuensinya (dan Juga mendeteksinya) :

- Masih bersifat Tak Bias, tapi tidak berarti ragamnya harus kecil

$$E(\hat{\beta}) = \beta_i \Rightarrow \text{Tidak Bias, Tapi } \sigma_{\hat{\beta}_i}^2 \Rightarrow \text{Besar}$$

- Tidak bisa (sulit) memisahkan pengaruh masing-masing peubah

bebas, karena $\sim \beta_i$ besar

- Koefisien sulit diinterpretasi (Asumsi Ceteris Paribus?)

- R^2 tinggi, tapi tidak ada (sedikit) koefisien yang nyata, bahkan tandanya bisa terbalik

- Koefisien korelasi sederhana atau R_j^2 utk $X_j = f(X \text{ lainnya})$ tinggi.

Note : $r_{x_i x_j}$ ↑ merupakan syarat cukup bukan syarat perlu
Multikolinearitas

- $Var(\hat{\beta}_j) = \frac{\sigma^2}{\sum x_j^2 (1 - R_j^2)}$

- **VIF : Variance Inflation Factor** = $\frac{1}{1 - R_j^2}$ **Kenaikan $Var(\hat{\beta}_j)$ karena korelasi antara peubah penjelas.**

- $K = \left(\frac{\lambda_{\max}}{\lambda_{\min}} \right)^{1/2}$ **λ = akar ciri matriks (X`X)**

Aturan praktis : kolinearitas jika $K \geq 30$; atau $K \geq (VIF_{j\max})^{1/2}$(Berk 1977)

Mengatasi Kolinearitas Ganda :

1. Manfaatkan Informasi sebelumnya (*a Prior information*)

Mis: tingkat perubahan konsumsi (Y) terhadap perubahan kekayaan (x_3) sepersepuluh dari tingkat perubahannya terhadap perubahan pendapatan (x_2) $\rightarrow \beta_3 = 0,1 \beta_2$

$$Y_i = \beta_1 + \beta_2 X_{2i} + \varepsilon_i \quad ; \quad X_{3i} = X_{2i} + 0.1 X_{3i}$$

2. Mengeluarkan peubah dengan kolinearitas tinggi (**Kesalahan Spesifikasi**)

3. Transformasi data dengan perbedaan pertama (*first difference form*) utk data *time series*.
4. Menggunakan PCA , *Ridge Regression* → berbias tapi $\text{Var}(\beta_i)$ kecil
5. Menggabungkan data '*cross section*' dan '*time series*'

Mis :

$$\ln Q_t = \beta_1 + \beta_2 \ln P_t + \beta_3 \ln Y_t + \varepsilon_t$$

Karena r_{PY} maka

$$\tilde{Q}_t = \beta_1 + \beta_2 \ln P_t$$

, Misal : β_3 dari SUSENAS
dimana harga tidak begitu
bervariasi

6. Penambahan data baru → $\sum_i x_j^2 \uparrow \rightarrow \sigma_{\beta_j}^2 \downarrow$
7. Cek kembali asumsi waktu membuat model (Mis :CRS,IRS,..komponen error)
seringkali jika tidak nyata dianggap masalah kolinearitas ganda ?! Dan
umumnya di pecahkan dengan mencari prosedur pendugaan

HETEROSCEDASTICITY (Heteroskedastisitas)

- Sering terjadi dlm data “cross section”
misal: Hubungan pendapatan & pengeluaran RT, Perusahaan
- Biasanya tdk terjadi dlm data “ Time Series”
- Jika $\text{Var}(\varepsilon_i)$, $E(\varepsilon_i^2)=\sigma_i^2$, penduga koefisien OLS tetap tak bias dan konsisten, tapi tidak efisien, bahkan $\text{Var}(\hat{\beta})_{\text{OLS}}$ berbias

Dlm model linear sederhana:

$$\hat{\beta} = \frac{\sum x_i y_i}{\sum x_i^2} = \frac{\sum x_i (\beta x_i + \varepsilon_i)}{\sum x_i^2}$$

$$E(\hat{\beta}) = \beta + \frac{E(\sum x_i \varepsilon_i)}{\sum x_i^2} ; \quad \text{Var}(\hat{\beta})_{OLS} = \frac{\sigma^2}{\sum x_i^2}$$

$$c_i = \frac{x_i}{\sum x_i^2} \rightarrow \text{Var}(\hat{\beta}) = \sum c_i^2 \sigma_i^2 = \frac{\sum x_i^2 \sigma_i^2}{(\sum x_i^2)^2} = \sum c_i^2 e_i^2 \text{ (White, 1980)}$$

Tetapi tetap inefisien dibandingkan penduga tak bias berikut ini :

Mis. $\sigma_i^2 = \sigma^2 k_i$, k_i : konstanta yg tdk harus sama

$$\text{Var}(\hat{\beta}) = \frac{\sigma^2 \sum x_i^2 k_i}{(\sum x_i^2)^2} = \frac{\sigma^2}{(\sum x_i^2)} \frac{\sum x_i^2 k_i}{(\sum x_i^2)}$$

Jika $\frac{\sum x_i^2 k_i}{(\sum x_i^2)} > 1$ Maka $\text{Var}(\hat{\beta})_{OLS}$ underestimate dan t_{hit} overestimate

Mendeteksi Heteroskedastisitas

- Metode grafik (\hat{Y}, e_i^2) atau (x, e^2) diplotkan.
- Uji Heteroskedastisitas :
Ho : $\sigma_1^2 = \sigma_2^2 = \dots = \sigma_N^2$
H1 : tergantung pendugaan yang dianggap akan menghasilkan koreksi heteroskedastisitas yang paling diinginkan.

1. UJI PARK (Econometrica, vol 34, No. 4, 1966)
menganjurkan fungsi :

$$\sigma_i^2 = \sigma^2 x_i^\beta e^{vi} \rightarrow \beta \text{ signifikan ? masalah pola } vi?$$

Plot σ_i^2 dengan e_i^2

2. UJI GLEJSER (seperti uji Park)

Fungsi Linear $|e_i|$ terhadap : $x_i, \sqrt{x_i}, \frac{1}{x_i}, \frac{1}{\sqrt{x_i}}, \dots$

3. UJI Korelasi Pangkat SPEARMAN (urutan e_i dan X_i)

$$r_s = 1 - 6 \left[\frac{\sum d_i^2}{n(n^2 - 1)} \right] \rightarrow t = \frac{r_s \sqrt{n-2}}{\sqrt{1-r_s^2}} \approx t_{(n-2)}$$

4. UJI GOLDFELD-QUANDT (JASS, Vol 60, 1965) $\rightarrow H_1 : \sigma_i^2 = cx_i^2$

Cara : 1. Urutkan data peubah bebas x.

2. Keluarkan d pengamatan di tengah (jika tidak ada `natural break`) misal : $d = \frac{1}{5}N$

3. Hitung 2 model regresi terpisah tersebut, dengan $dbe = (N - d - 2k) / 2$

4. Hitung JKS_1 dan JKS_2

5. Dengan asumsi masing-masing $\varepsilon_i \sim \text{Normal}$, $\frac{JKS_2}{JKS_1} \approx F_{(dbe_1, db_e)}$

Note : - Jika $k > 2$, urutkan pengamatan berdasarkan salah satu peubah bebasnya

- Supaya kuasa uji tinggi (salah jenis II lebih kecil), harus dengan restriksi dimana kedua model regresi tersebut mempunyai parameter koefisien yang sama

5. UJI BREUSCH-PAGAN (Econometrica, Vol 47, 1979)

Misal Model : $Y_i = \alpha + \beta x_i + \varepsilon_i$

dengan asumsi umum: $\sigma_i^2 = f(\gamma + \delta z_i)$

z dapat merupakan peubah bebas x atau suatu kelompok peubah bebas selain x.

> gunakan $\sum_{i=1}^N \varepsilon_i^2$ untuk menghitung $\sigma^2 = \frac{\sum_{i=1}^N \varepsilon_i^2}{N}$

> Lakukan Regresi: $\frac{\varepsilon_i^2}{\sigma_i^2} = \gamma + \delta z_i + v_i$

> Jika $\varepsilon_i \sim \text{Normal}$, $\frac{JKR}{2} \approx \chi^2_{(p)}$ merupakan statistik uji yang cocok.

Jika nyata (heteroskedastisitas), koreksinya menggunakan peubah z

6. WHITE TEST (Econometrica, Vol. 48, 1980)

- Tidak perlu asumsi kenormalan seperti B-test.
- Dengan asumsi umum : $\hat{\varepsilon}_i^2 = \gamma + \delta z_i + v_i$,

dengan R^2 sebagai ukuran `goodness of fit`.

Jika homoskedastisitas, $NR^2 \approx \chi_{(p)}^2$

CARA MENGATASI (MENGOOREKSI) HETEROSKEDASTISITAS

a) Jika σ^2 diketahui \rightarrow *Weighted Least Squares* (MKT tertimbang);
 kasus khusus dari GLS, yg dpt
 diturunkan dari fungsi kemungkinan
 maximum.

Note : $JKS = \sum \frac{1}{\sigma_i^2} (Y_i - \hat{\alpha} - \hat{\beta} x_i)^2 = \sum \left(\frac{Y_i - \hat{\beta} x_i}{\sigma_i} \right)^2$

simpangan (pengamatan) ekstrim dpt timbangan kecil
 dimana $x_i^* = \frac{x_i}{\sigma_i}$ dan $y_i^* = \frac{y_i}{\sigma_i}$

$$\hat{\beta} = \frac{\sum x_i y_i / \sigma_i^2}{\sum x_i^2 / \sigma_i^2} = \frac{\sum x_i^* y_i^*}{\sum x_i^*}$$

Cara Transformasi Model: $Y_i = \beta_1 + \beta_2 x_{2i} + \dots + \beta_k x_{ki} + \varepsilon_i \quad \left| \times \frac{1}{\sigma_i} \right|$

$$\frac{Y_i}{\sigma_i} = \beta_1 \frac{1}{\sigma_i} + \beta_2 \frac{x_{2i}}{\sigma_i} + \dots + \beta_k \frac{x_{ki}}{\sigma_i} + \frac{\varepsilon_i}{\sigma_i}$$

$$Y_i^* = \beta_1 x_1^* + \beta_2 x_{2i}^* + \dots + \beta_k x_{ki}^* + \varepsilon_i^*$$

$$\rightarrow Var(\varepsilon_i^*) = \frac{1}{\sigma_i^2} Var(\varepsilon_i) = 1$$

b. Jika σ_i^2 tidak diketahui \rightarrow sering menggunakan asumsi tentang σ_i^2

Misal Asumsi : $\mathbf{Var}(\boldsymbol{\varepsilon}_i) = \mathbf{C} \mathbf{X}_{2i}^2$ \rightarrow lakukan seperti di atas dengan transformasi: $\mathbf{x} (\mathbf{X}_{2i})^{-1}$

$$\frac{Y_i}{x_{2i}} = \beta_1 \frac{1}{x_{2i}} + \beta_2 + \beta_3 \frac{x_{3i}}{x_{2i}} + \dots + \beta_k \frac{x_{ki}}{x_{2i}} + \frac{\varepsilon_i}{x_{2i}}$$

$$\rightarrow \mathit{Var}(\varepsilon_i^*) = c$$

c. Dapat dengan Transformasi Log (memperkecil skala) →
kadang-kala dapat masalah baru, seperti *Spurious correlation*, kolinearitas.

Teladan : Dengan OLS : $\hat{Y}_i = 0.89 + 0.237x_i$; $R^2 = 0.93$; $F = 252.7$
(4.4) (15.9) ← statistik t

Dengan WLS : $\frac{Y_i}{x_i} = \beta * + \alpha * \frac{1}{x_i} + \varepsilon_i *$

$\frac{\hat{Y}_i}{x_i} = 0.249 + 0.7529 \frac{1}{x_i}$; $R^2 = 0.76$; $F = 58.7$
(21.3) (7.7)

$R^2_{WLS} < R^2_{OLS}$ → jangan dianggap sebagai indikasi bahwa koreksi heteroskedastisitas kurang baik karena prosedur WLS melibatkan transformasi peubah tak bebas (Y^*)

Dengan indikator :

$$\varepsilon_i = Y_i - (0.7529 + 0.249X_i) \rightarrow R^2 = 1 - \frac{JKS}{JKT} \rightarrow \text{tidak harus } 0-1$$

\hat{Y}_i

R^2

Y_i \hat{Y}_i