



TEMA 9: Multikolinearitet

- ① Eksakt multikolinearitet
- ② Imperfekt multikolinearitet
- ③ Hvordan håndteres vi (sterk) imperfekt multikolinearitet
- ④ Oppgavesett 9

① Eksakt multikolinearitet

"Kolinearitet" mellom X_1 og X_2 oppstår når

$$X_1 = a + b X_2$$

Dvs.: X_1 kan skrives som en eksakt lineær funksjon av X_2

Når skjer dette?

En vanlig situasjon: X_1 og X_2 er konstante

→ Eksempel: $X_1 = 1$ $X_2 = 2$

Vi forsøker å estimere

$$p_{iis} = \beta_1 X_1 + \beta_2 X_2 + u$$

En annen vanlig situasjon: "Dummyfellen"

→ Eksempel: $X_1 = 1$ eller 2 ("dummy-
 $X_2 = \begin{cases} 1 & \text{hvis } X_1 = 1 \\ 0 & \text{ellers} \end{cases}$ trap")

$$X_3 = \begin{cases} 1 & \text{hvis } X_1 = 2 \\ 0 & \text{ellers} \end{cases}$$

⇒ $X_1 = X_2 + 2 \cdot X_3$: X_1 er en eksakt lineær kombinasjon av X_2 og X_3

→ Eksempel: $X_1 = 1$ eller 2

$$X_2 = \begin{cases} 0,5 & \text{ hvis } X_1 = 1 \\ 0 & \text{ ellers} \end{cases}$$

$$X_3 = \begin{cases} 4 & \text{ hvis } X_1 = 2 \\ 0 & \text{ ellers} \end{cases}$$

$$\Rightarrow X_1 = 2 \cdot X_2 + \frac{1}{2} X_3$$

$$\begin{array}{ccc} \uparrow & & \uparrow \\ 1 & = & \underbrace{0,5}_1 \quad 0 \end{array}$$

$$2 = \quad 0 \quad 2$$

② Imperfekt multikolinearitet

(kort sagt): X_1 og X_2 er korrelerte

Hvis X_1 og X_2 er korrelerte så vil R^2 til

$$X_1 = a_1 + a_2 X_2 + e$$

være større enn 0 (hvisk: $R^2 = (r)^2$)

korrelasjon mellom X_1 og X_2

↳ Jo høyere R^2 , jo mer/stærkere kolinearitet

X_1, X_2, X_3 er imperfekt multikolineare
veis R^2 til

$$X_1 = a_1 + a_2 X_2 + a_3 X_3 + e$$

er større enn 0 og mindre enn 1

↳ Jo høyere R^2 , jo mer/stærkere multikolinearitet

Når er imperfekt multikolinearitet et problem?

↳ Når R^2 er "høy"

Hva er problemet?

↳ $\text{Var}(b)$: Blir veldig høy (dvs.:
 b er et veldig upresist estimat)

Variansinflasjonsfaktoren (VIF,
"Variance Inflation Factor")

Betrakt:

$$Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3 + u$$

Det kan vises at:

$$\text{Var}(b_2) = \frac{\sigma^2}{\sum (x_2 - \bar{x}_2)^2}$$

$$\frac{1}{(1 - R_2^2)}$$

$$\text{Var}(b_3) = \frac{\sigma^2}{\sum (x_3 - \bar{x}_3)^2}$$

$$\frac{1}{(1 - R_3^2)}$$

hvor R_2^2 er R^2 til

$$x_2 = c_1 + c_2 x_3 + v$$

og R_3^2 er R^2 til

$$x_3 = d_1 + d_2 x_2 + w$$

VIF

lowl:

-> $\sigma^2 \uparrow \Rightarrow \text{Var}(b)$ går ned

-> Variasjonen i X går opp, så
går $\text{Var}(b)$ ned

-> Jo høyere R_j^2 (sterkere multi-
kolinearitet), jo større $\text{Var}(b)$

Generelt:

$$Y = \beta_1 + \beta_2 x_2 + \dots + \beta_k x_k + u$$

så er

$$\text{Var}(b_j) = \frac{\sigma^2}{\sum (x_j - \bar{x}_j)^2}$$

VIF

$$\frac{1}{(1 - R_j^2)}$$

hvor R_j^2 er R^2 til en regresjon med X_j som venstresidevariabel og de andre X 'ene som høyresidevariabler (inkludert en konstant)

Teoretiske konsekvenser av sterk
'imperfekt multikolinariitet': Fø
eller ingen

Praktiske konsekvensene:

→ Upresise estimater

→ Estimater og resultater kan endre seg vesentlig ved små endringer i modellen (f. eks. inklusjon/utelatning av bare én variabel, små transformasjoner, osv.)

→ Estimaterne kan ha "uriktige" fortegn

Eksempel: Huspriser 2 i USA

$$(1) \quad \text{pris} = \beta_1 + \beta_2 \text{Vurdering} + \beta_3 \text{BOA} \\ + \beta_4 \text{Tomt} + \beta_5 \text{Badsson} \\ + u$$

↳ β_3 negativ!

Bedste modell? } → (2)
$$\frac{\text{pris}}{\text{BOA}} = B_1 + B_2 \frac{\text{Vurdering}}{\text{BOA}} + B_3 \text{Tomt} + B_5 \text{Badersonn} + u$$

"Moral"/lærdom: Med mindre det er essensielt å studere innvirkninger av BOA på pris, så er det en god idé å studere innvirkningen av vurdering på pris i stedet for (1)
BOA BOA

(3) Hvordan håndterer vi (stunk) i imperfekt multikolinearitet?

→ Kan vi transformere variablene?

→ Kan vi utelate variabler?

↳ Helst ikke! : Kan føre til utelatingsbias

→ Skaffe nye/mer data?

↳ Ofte upraktisk

"Moderne" løsninger: Automatisk modellseleksjonsalgoritmer

→ Forover regresjon (FR)

→ Bakover eliminasjon (BE)

→ Kompliserte varianter av
FR og BE: "General-to-
specific"

④ Oppgave sett 9

→ Eksakt multikolinearitet mellom 2 eller flere forklaringsvariabler: Forklaringsvariablene kan skrives som en eksakt linear kombinasjon av hverandre

↳ Problem: Estimering umulig

→ Imperfekt multikolinearitet mellom forklaringsvariabler: At de er korrelerte

↳ Problem: Høy $\text{Var}(b)$
(Høy $\text{se}(b)$) } "upresise estimater"

1.
 - A) Feil
 - B) Feil
 - C) Riktig
 - D) Feil

2. Tolk "linear avhengighet" som "eksakt"

linear avhengighet "

C) Riktig

D) kan være riktig i visse tilfeller,
men ikke alltid (se eksempel 3
i del 1 i notatene)

3.) A) $\rightarrow t = \frac{b_i}{se(b_i)}$

$\rightarrow se(b_i) = \sqrt{Var(b_i)}$ vif

$\rightarrow Var(b_i) = \frac{\sigma^2}{\sum (X_i - \bar{x})^2} \cdot \frac{1}{1 - R_i^2}$

hvor R_i^2 er R^2 til en regresjon

hvor X_i er uenstreside variabel
og de andre forklaringsvariablene
utgjør høyreside variablene

\Rightarrow A) Feil

B) Riktig

C) Feil

D) Feil: Ekskludering av forklarings-
variabler skal helst unngås

$$4. \quad t = \frac{b}{se(b)} : \text{Høy } Var(b) \Rightarrow \text{lav } t\text{-verdi} \\ \left(se(b) = \sqrt{Var(b)} \right)$$

\Rightarrow Generelt: Høy P-verdi

A) Riktig

B) } GALT
C) }
D) }

6. Husk: $VIF = \frac{1}{1-R_2^2}$ hvor R_2^2 er R^2 for

$$\ln(\text{Vurdering}) = \beta_1 + \beta_2 \ln(\text{Tomt}) \\ + \beta_3 \ln(\text{FF}) + \beta_4 \text{Badsson} \\ + v$$

$$VIF = \frac{1}{1-R_2^2} = 6,247$$



$$1 = 6,247 \cdot (1 - R_2^2)$$



$$R_2^2 = \frac{5,247}{6,247}$$

$$= 0,84 = \underline{\underline{84\%}}$$

c)

$$7. \text{Var}(\hat{\beta}_2): C = \frac{1}{1-R_2^2} \quad \text{hvor } R_2^2 \text{ er } R^2$$

$$\text{til } X_2 = c_1 + c_2 X_3 + v$$

$$\text{Var}(\hat{\beta}_3): C = \frac{1}{1-R_3^2} \quad \text{hvor } R_3^2 \text{ er } R^2$$

$$\text{til } X_3 = d_1 + d_2 X_2 + w$$

$$= \Delta R_2^2 = R_3^2$$

$$A) r_{X_2 X_3} < 0 \Rightarrow R^2 > 0 \Rightarrow \underline{\underline{C > 1}}$$

RIKTIG

$$B) r_{X_2 X_3} > 0 \Rightarrow R^2 > 0 \Rightarrow \underline{\underline{C > 1}}$$

RIKTIG

$$C) r_{X_2 X_3} = 0 \Rightarrow R^2 = 0 \Rightarrow \underline{\underline{C = 1}}$$

GALT

D) RIKTIG

$$8) A) \sqrt{x_2 x_3} = 0 \Rightarrow R^2 = 0 \Rightarrow \underline{\underline{c = 1}}$$

GALT

$$B) \lambda_2 \neq 0 \Rightarrow \sqrt{x_2 x_3} \neq 0 \quad (\text{Husk: ...})$$

$$\Rightarrow R^2 > 0 \Rightarrow \underline{\underline{c > 1}}$$

RIKTIG

C) GALT

$$D) R^2 = 0 \Rightarrow \underline{\underline{c = 1}}. \quad \underline{\underline{GALT}}$$