

SOS3003
**Anvendt statistisk
dataanalyse i
samfunnsvitenskap**
Forelesingsnotat, vår 2003

Erling Berge
Institutt for sosiologi og statsvitenskap
NTNU

Forelesing V

- Kritikk av regresjon I
Hamilton Kap 4 s109-123

Modellanalysar bygg på føresetnader

- OLS er ein enkel analyseteknikk med gode teoretiske eigenskapar, men
- Eigenskapane er basert på visse føresetnader
- Dersom føresetnadane ikkje held vil dei gode eigenskapane forvitre
- Å undersøkje i kva grad føresetnadane held er den viktigaste delen av analysen

OLS-REGRESJON: føresetnader

- I SPESIFIKASJONSKRAVET
 - Føresetnaden er at modellen er rett
- II GAUSS-MARKOV KRAVA
 - Sikrar at estimata er "BLUE"
- III NORMALFORDELTE RESTLEDD
 - Sikrar at testane er valide

FØRESETNADER: I Spesifikasjonskravet

- Modellen er rett spesifisert dersom
 - Forventa verdi av y , gitt verdien av dei uavhengige variablane, er ein lineær funksjon av parametrane til x -variablane
 - Alle inkluderte x -variablar påverkar forventa y -verdi
 - Ingen andre variablar påverkar forventa y -verdi samtidig som dei korrelerer med inkluderte x -variablar

FØRESETNADER: II Gauss-Markov krava (i)

- (1) x er gitt, dvs utan stokastisk variasjon
- (2) Feila har ein forventa verdi på 0 for alle i

$$\bullet E(\varepsilon_i) = 0 \quad \text{for alle } i$$

Gitt (1) og (2) vil ε_i vere uavhengig av x_k for alle k .

Da gir OLS **forventningsrette** estimat av β
(unbiased = forventningsrett)

FØRESETNADER: II Gauss-Markov krava (ii)

(3) Feila har konstant varians for alle i

- $\text{Var}(\varepsilon_i) = \sigma^2$ for alle i

(4) Feila er ukorrelerte med kvarandre

- $\text{Cov}(\varepsilon_i, \varepsilon_j) = 0$ for alle $i \neq j$

FØRESETNADER: II Gauss-Markov krava (iii)

Gitt (3) og (4) i tillegg til (1) og (2) får vi

- a. Estimert av standardfeilen til regresjonskoeffesientane er forventningsrette, og

- b. **Gauss-Markov teoremet:**

OLS estimata har **mindre varians** enn alle andre lineære forventningsrette estimat.

OLS gir “BLUE”

(Best Linear Unbiased Estimate)

FØRESETNADER: II Gauss-Markov krava (iv)

(1) - (4) kallast GAUSS-MARKOV krava

- Gitt (2) - (4) med tillegg av krav om at feila er ukorrelererte med X variablane (jfr. Hardy s5), dvs.:

- $\text{cov}(x_{ik}, \varepsilon_i) = 0$ for alle i, k

er koeffesientar og standardfeil

konsistente

Fotnote 1:

Forventningsrette (unbiased) estimatorar

- Forventningsrett tyder at

$$E[b_k] = \beta_k$$

- I det lange løp vil vi treffe populasjonsverdien - β_k - dersom vi trekkjer mange nok utval, reknar ut b_k og tar gjennomsnittet av desse

Fotnote 2: Konsistente estimatorar

- Estimatoren er konsistent dersom vi har at når utvalgsstorleiken (n) veks mot uendeleg går b mot β og S_b mot σ_β
- $[b_k$ er ein konsistent estimator for β_k dersom vi for vilkårleg liten c har
$$\lim_{n \rightarrow \infty} [\Pr\{|b_k - \beta_k| < c\}] = 1$$

Fotnote 3: Variansminimale estimatorar

- Variansminimale (effisente) estimatorar tyder at
$$\text{var}(b_k) < \text{var}(a_k)$$
 for alle estimatorar a ulik b
- Ekvivalent:
$$E[b_k - \beta_k]^2 < E[a_k - \beta_k]^2$$
 for alle estimatorar a ulik b .

Fotnote 4: Skeive estimatorar

- Sjølv om krava til "BLUE" er oppfylt vil ein stundom kunne finne skeive estimatorar (dvs. dei er ikkje forventningsrette) som har mindre varians, t.d. i
- Ridge Regression

Fotnote 5: Ikkje-lineære estimatorar

- Det kan finnast ikkje-lineære estimatorar som er forventningsrette og har mindre varians enn "BLUE" estimatorane

FØRESETNADER: III Normalfordelte restledd

- (5) Dersom alle feila er normalfordelt med forventning 0 og standardavvik på 1, dvs. dersom

$$\varepsilon_i \sim N(0, \sigma^2) \quad \text{for alle } i$$

- vil ein kunne teste hypoteser om β og σ , og
- OLS estimata vil ha mindre varians enn estimat fra alle andre forventningsrette estimatorar

**OLS gir “BUE”
(Best Unbiased Estimate)**

Problem i regresjonsanalysar som ikkje kan testast

- Om alle relevante variablar er med
- Om det er målefeil i x'ane
- Om forventa verdi til feilleddet er 0
(Dette er der samme som at vi ikkje kan sjekke om korrelasjonen mellom feilledd og x-variabel faktisk er 0. Dette er i prinsippet det samme som første punkt om at modellen er rett spesifisert)

Problem i regresjonsanalysar som kan oppdagast (1)

- Ikkje-lineære samband
- Inkludert irrelevant variabel
- Ikkje-konstant varians hos feilledet
- Autokorrelasjon hos feilledet
- Korrelasjonar mellom feilledd
- Ikkje-normale feilledd
- Multikollinearitet

Konsekvensar av problem (Hamilton, s113)

	Problem	Uønska eigenskapar ved estimata			
		Skeive estimat av b	Skeive estimat av SE_b	Ugyldige t&Ftestar	Høg var[b]
Spesifikasjonskrav	Ikkje-lineært samband	X	X	X	-
	Utelatt relevant variabel	X	X	X	-
	Inkludert irrelevant variabel	0	0	0	X
Gauss-Markov krav	X er målt med feil	X	X	X	-
	Heteroskedastisitet	0	X	X	X
	Autokorrelasjon	0	X	X	X
	X er korrelert med e	X	X	X	-
Normalfordeling	e er ikkje normalfordelt	0	0	X	X
Multikollinearitet		0	0	0	X

Problem i regresjonsanalysar som kan oppdagast (2)

- Utliggjarar (ekstreme y-verdiar)
- Innflytelse (case med stor innverknad: uvanlege kombinasjonar av y og x-verdiar)
- Leverage (potensiale for innflytelse)

Hjelpemiddel

- Studiar av
 - Ein-variabel fordelingar (frekvens fordeling og histogram)
 - To-variabel samvariasjon (korrelasjon og scatterplott)
 - Residualen (fordeling og i samvariasjon med predikert verdi)

Korrelasjon og scatterplott


		ENERGY CONSUMPTION PER PERSON	MEAN ANNUAL POPULATION GROWTH	FERTILIZER USE PER HECTARE	CRUDE BIRTH RATE
ENERGY CONSUMPTION PER PERSON	Pearson Correlation	1	-,505	,533	-,689
	N	125	122	125	122
MEAN ANNUAL POPULATION GROWTH	Pearson Correlation	-,505	1	-,469	,829
	N	122	125	125	125
FERTILIZER USE PER HECTARE	Pearson Correlation	,533	-,469	1	-,589
	N	125	125	128	125
CRUDE BIRTH RATE	Pearson Correlation	-,689	,829	-,589	1
	N	122	125	125	125

Vår 2004

© Erling Berge 2004

21

Korrelasjon og scatterplott



Vår 2004

© Erling Berge 2004

22



Heteroskedastisitet,

(ikkje-konstant varians hos feilledet) kan skuldast


- Målefeil (t.d. y meir nøyaktig ved større x)
- Utliggjarar
- At ε_i inneheld eit viktig ledd som varierer saman med x og y (spesifikasjonsfeil)
- Spesifikasjonsfeil er det samme som feil modell og gir heteroskedastisitet
- Eit viktig diagnoseverktøy er plott av residual mot predikert verdi (\hat{y})

Eksempel: Hamilton tabell 3.2

Dependent Variable: Summer 1981 Water Use	Unstandardized Coefficients			
	B	Std. Error	t	Sig.
(Constant)	242,220	206,864	1,171	,242
Income in Thousands	20,967	3,464	6,053	,000
Summer 1980 Water Use	,492	,026	18,671	,000
Education in Years	-41,866	13,220	-3,167	,002
head of house retired?	189,184	95,021	1,991	,047
# of People Resident, 1981	248,197	28,725	8,641	,000
Increase in # of People	96,454	80,519	1,198	,232



Fordelinga sett frå ein annan vinkel



Vår 2004

© Erling Berge 2004

27


Band-regresjon

- Homoskedastisitet tyder at medianen (og gjennomsnittet) til absoluttverdien av residualen, dvs: $\text{median}\{|e_i|\}$, skal vere om lag den same for alle verdiar av predikert y
- Dersom vi finn at medianen av $|e_i|$ for gitt predikert verdi av y endrar seg systematisk med verdien av predikert y indikerer det heteroskedastisitet
- Slike analysar kan lett gjerast i SPSS

Vår 2004


© Erling Berge 2004

28



Absoluttverdien av ϵ (Basert på regresjonen i tabell 3.2 i Hamilton)

Tilnærma
bandregresjon
(jfr figur 4.4 i
Hamilton)



Autokorrelasjon (1)

- Korrelasjon mellom variabelverdier på same variabel over ulike case (t.d. mellom ε_i og ε_{i-1})
- Autokorrelasjon gir større varians og skeive estimat av standardfeil slik som heteroskedastisitet
- Når vi har enkelt tilfeldig utval frå ein populasjon, er autokorrelasjon usannsynleg

Autokorrelasjon (2)

- Autokorrelasjon kjem frå feilspesifikasjon av modellen
- Ein finn det typisk i tidsseriar og ved geografisk ordna case
- Testar (t.d. Durbin-Watson) er basert på sorteringsrekkefølga av casa. Derfor:
- Ei hypotese om autokorrelasjon må spesifisere korleis casa skal sorterast

Durbin-Watson testen (1)

$$d = \frac{\sum_{i=2}^n (e_i - e_{i-1})^2}{\sum_{i=1}^n e_i^2}$$


Bør ikkje nyttast for autoregressive modellar, dvs. modellar der y-variabelen også finst som forklaringsvariabel (x-variabel) jfr tabell 3.2

Durbin-Watson testen (2)

- Samplingfordelinga til d-observatoren er kjent og tabellert som d_L og d_U (tabell A4.4 i Hamilton), talet av fridomsgrader baserer seg på n og K-1
- Testregel:
 - Forkast dersom $d < d_L$
 - Forkast ikkje dersom $d > d_U$
 - Dersom $d_L < d < d_U$ kan det ikkje konkluderast
- $d=2$ tyder ukorrelerte residualar
- Positiv autokorrelasjon gir $d < 2$
- Negativ autokorrelasjon gir $d > 2$

Dagleg vassforbruk, gjennomsnitt pr måned

Eksempel:



Vår 2004

© Erling Berge 2004

35

Vanleg OLS-regresjon der caset er måned

Dependent Variable: AVERAGE DAILY WATER USE	Unstandardized Coefficients		t	Sig.
	B	Std. Error		
(Constant)	3,828	,101	38,035	,000
AVERAGE MONTHLY TEMPERATURE	,013	,002	7,574	,000
PRECIPITATION IN INCHES	-,047	,021	-2,234	,027
CONSERVATION CAMPAIGN DUMMY	-,247	,113	-2,176	,031

Predictors: (Constant), CONSERVATION CAMPAIGN DUMMY, AVERAGE MONTHLY TEMPERATURE, PRECIPITATION IN INCHES

Vår 2004

© Erling Berge 2004

36

Test for autokorrelasjon

Dependent Variable: AVERAGE DAILY WATER USE	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,572(a)	,327	,312	,36045	,535

Predictors: (Constant), CONSERVATION CAMPAIGN DUMMY, AVERAGE MONTHLY TEMPERATURE, PRECIPITATION IN INCHES

N = 137, K-1 = 3


Finn grensene for å forkaste / akseptere nullhypotesa om ingen autokorrelasjon med nivå 0,05

Auto-korrelasjonskoeffesient

m-te ordens autokorrelasjonskoeffesient

$$r_m = \frac{\sum_{t=1}^{T-m} (e_t - \bar{e})(e_{t+m} - \bar{e})}{\sum_{t=1}^T (e_t - \bar{e})^2}$$

Residual "Dagleg vassforbruk", måned



Vår 2004

© Erling Berge 2004

39

Glatting med 3 punkt

- Glidande gjennomsnitt

$$e_t^* = \frac{e_{t-1} + e_t + e_{t+1}}{3}$$

- "Hanning"

$$e_t^* = \frac{e_{t-1}}{4} + \frac{e_t}{2} + \frac{e_{t+1}}{4}$$

- Glidande median


$$e_t^* = \text{median}\{e_{t-1}, e_t, e_{t+1}\}$$

Vår 2004

© Erling Berge 2004

40

Residual, glatta ein gong




Vår 2004

© Erling Berge 2004

41

Residual, glatta to gonger




Vår 2004

© Erling Berge 2004

42

Residual, glatta fem gonger



Vår 2004

© Erling Berge 2004

43

Konsekvensar av autokorrelasjon

- Hypotesetestar og konfidensintervall er upålitelege. Regresjon kan likevel gi ein god beskrivelse av utvalet. Parametrane er forventningsrette
- Spesialprogram kan estimere standardfeil konsistent
- Ta inn i analysen variablar som påverkar "hosliggjande" case
- Ta i bruk teknikkar frå tidsserieanalyse (t.d.: analyser differansen mellom to tidspunkt) (Δy)

Vår 2004

© Erling Berge 2004

44