

SOS3003
**Anvendt statistisk
dataanalyse i
samfunnsvitenskap**

Forelesingsnotat 05

Erling Berge
Institutt for sosiologi og statsvitenskap
NTNU

Fall 2004

© Erling Berge 2004

1

Forelesing V

- Kritikk av regresjon I
Hamilton Kap 4 s109-123

Fall 2004

© Erling Berge 2004

2

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

Fall 2004

© Erling Berge 2004

3

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

Fall 2004

© Erling Berge 2004

4

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 verkar på forventa y -verdi
 - Ingen andre variablar verkar på forventa y -verdi samtidig som dei korrelerer med inkluderte x -variablar

Fall 2004

© Erling Berge 2004

5

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

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

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

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

Fall 2004

© Erling Berge 2004

6

FØRESETNADER: II Gauss-Markov krava (ii)

(3) Feila har konstant varians for alle i

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

Dette vert kalla homoskedastisitet

(4) Feila er ukorrelerte med kvarandre

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

Det er ikke autokorrelasjon

FØRESETNADER: II Gauss-Markov krava (iii)

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

- a. Estimat av standardfeilen til regresjonskoeffisientane 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 ukorrelerte med X variablane (jfr. Hardy s5), dvs.:

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

er koeffisientar 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, når utvalsstorleiken (n) veks mot uendeleig, finn at b nærmar seg β og s_b nærmar seg σ_β
- $[b_k]$ er ein konsistent estimator for β_k dersom vi for vilkårleg liten c har

$$\lim_{n \rightarrow \infty} [\Pr\{ |b_k - \beta_k| < c \}] = 1$$

Fall 2004

© Erling Berge 2004

11

Fotnote 3: I "BLUE tyder "Best" Variansminimal estimator

- Variansminimale (effisiente) 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 .

Fall 2004

© Erling Berge 2004

12

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

Fall 2004

© Erling Berge 2004

13

Fotnote 5: Ikkje-lineære estimatorar

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

Fall 2004

© Erling Berge 2004

14

FØRESETNADER: III Normalfordelte restledd

- (5) Dersom alle feila er normalfordelt med forventning 0 og standardavvik på σ^2 , dvs. dersom

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

- vil det kunne testast hypotesar om β og σ , og
- OLS estimata vil ha mindre varians enn estimat frå 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 feilreddet er 0
(Dette er der same som at vi ikkje kan sjekke om korrelasjonen mellom feilredd og x-variabel faktisk er 0. Dette er i prinsippet det same 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 feilreddet (heteroskedastisitet)
- Autokorrelasjon hos feilreddet
- Korrelasjonar mellom feilredd
- Ikkje-normale feilredd
- Multikollinearitet

Fall 2004

© Erling Berge 2004

17

Konsekvensar av problem (Hamilton, s113)

Krav	Problem	Uønska eigenskapar ved estimata			
		Skeive estimat av b	Skeive estimat av SE_b	Ugyldige t&Ftestar	Høg var[b]
Spesifikasjonskrav	Ikkje-lieært 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 ϵ	X	X	X	-
Normalfordeling	ϵ er ikkje normalfordelt	0	0	X	X
	Multikollinearitet	0	0	0	X

Fall 2004

© Erling Berge 2004

18

Problem i regresjonsanalysar som kan oppdagast (2)

- Utliggarar (ekstreme y-verdiar)
- Innverknad (case med stor innverknad: uvanlege kombinasjonar av y og x-verdiar)
- Leverage (potensiale for innverknad)

Fall 2004

© Erling Berge 2004

19

Hjelpemiddel

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

Fall 2004

© Erling Berge 2004

20

Korrelasjon og scatterplott

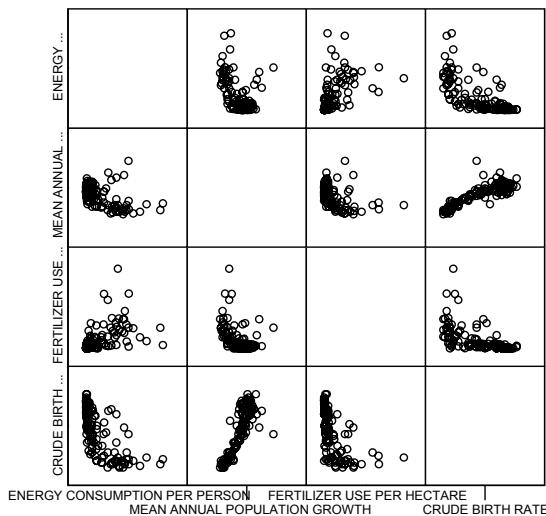
		ENERGY CONSUMPTION PER PERSON	MEAN ANNUAL POPULATION GROWTH	FERTILIZER USE PER HECTARE	CRUDE BIRTH RATE
ENERGY CONSUMPTION PER PERSON	Pearson Correlation	1	-,505	,533	-,689
	N	125	122	125	122
MEAN ANNUAL POPULATION GROWTH	Pearson Correlation	-,505	1	-,469	,829
	N	122	125	125	125
FERTILIZER USE PER HECTARE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

Fall 2004

© Erling Berge 2004

21

Korrelasjon og scatterplott



Fall 2004

© Erling Berge 2004

22

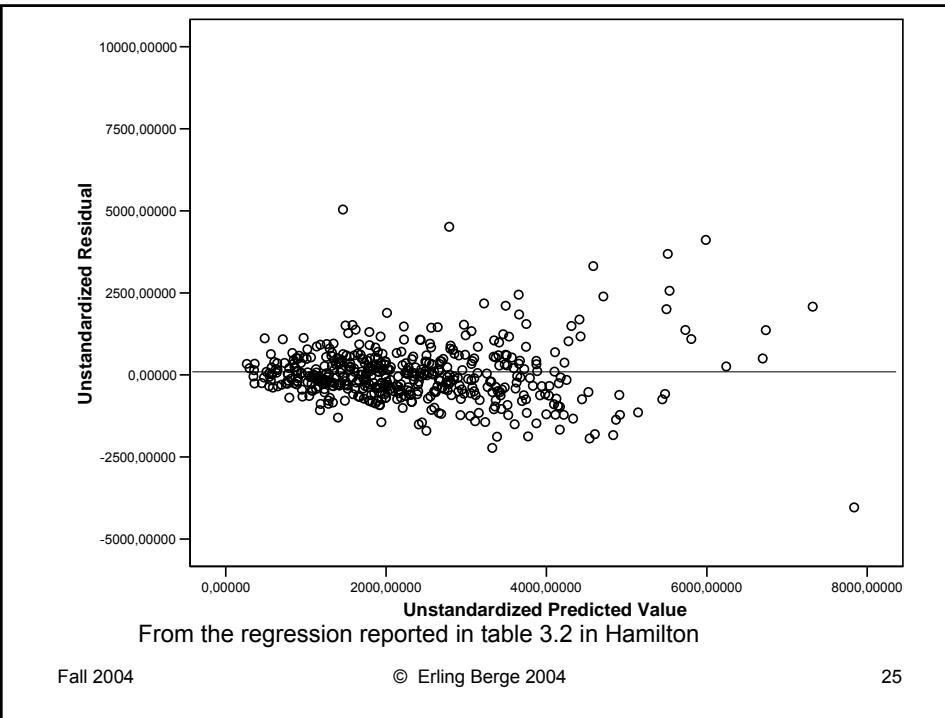
Heteroskedastisitet,

(ikkje-konstant varians hos feilreddet) kan skuldast:

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

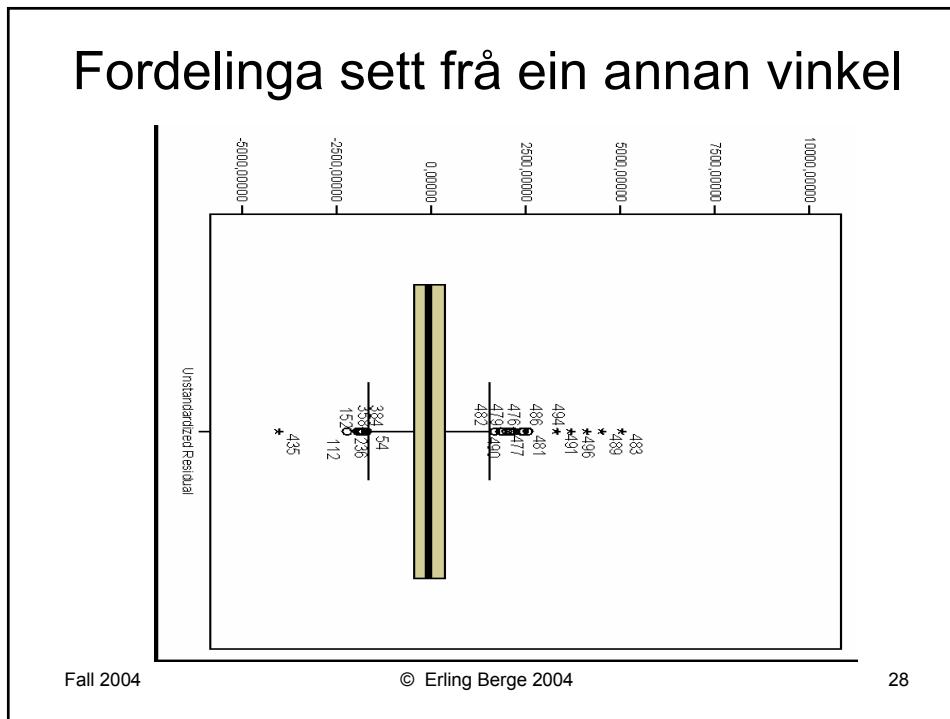
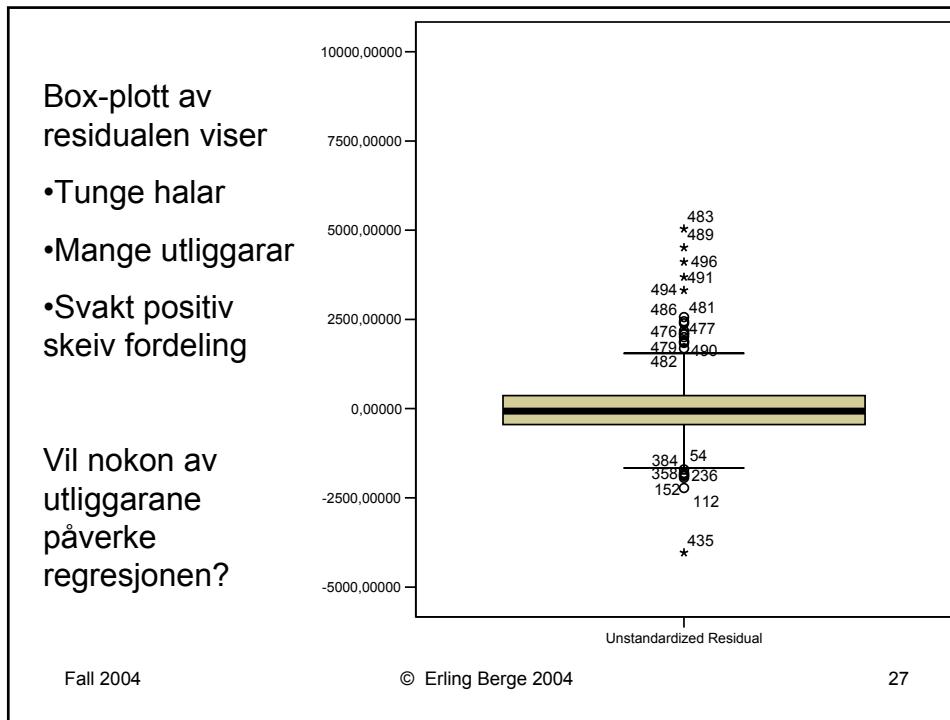
Example: Hamilton table 3.2

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	



Fotnote til føregåande figur

- Dersom spreiinga til residualen (variasjonen rundt ein typisk verdi) varierer systematisk med verdien på ein eller fleire x-variablar har vi heteroskedastisitet
- I figuren her ser vi at spreiinga til residualen aukar med aukande predikert y.
- Predikert Y er her ein indeks som viser til høge gjennomsnittlege x-verdiar.
- Når spreiinga av residualen varierer systematisk med verdiane på x-variablane har vi heteroskedastisitet.



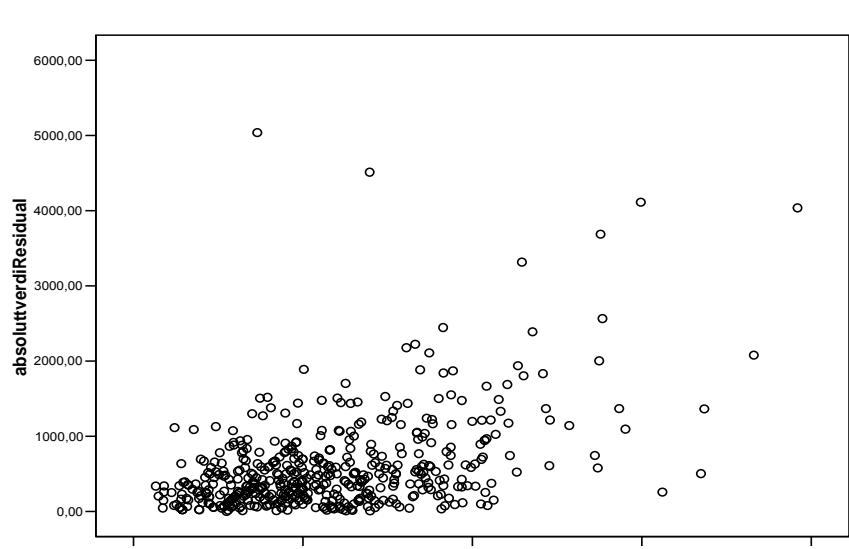
Band-regresjon

- Homoskedastisitet tyder at medianen (og gjennomsnittet) til absoluttverdien av residualen, dvs: $\text{median}\{|e_i|\}$, skal være 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

Fall 2004

© Erling Berge 2004

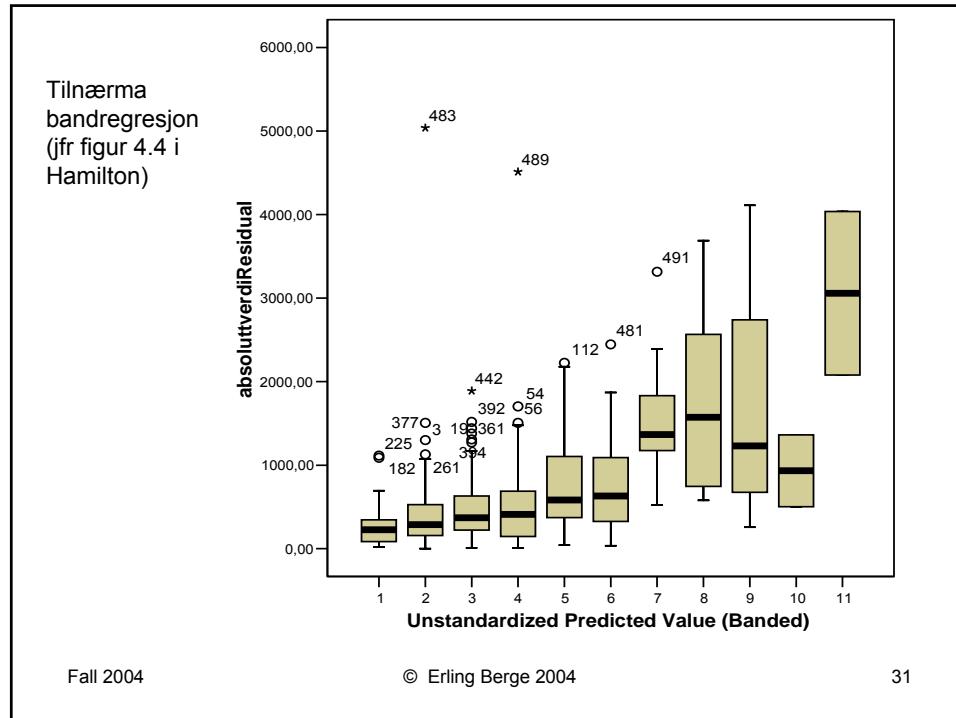
29

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

Fall 2004

© Erling Berge 2004

30



Bandregresjon I SPSS

- Først lagrar vi residualen og predikert y frå regresjonen.
- Så reknar vi om residualen til ein ny variabel med absoluttverdien gjennom "Compute" under "Transform".
- Så deler vi opp predikert y i band gjennom prosedyren "Visual bander" under "Transform".
- Deretter nyttar vi "Boxplot" under "Graphs" der vi spesifiserer absoluttverdi av residual som variabel og bandvariabelen som kategoriakse

Autokorrelasjon (1)

- Korrelasjon mellom variabelverdiar 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 tidssseriar og ved geografisk ordna case
- Testar (t.d. Durbin-Watson) er basert på sorteringsrekkefølgja av casa. Derfor:
- Ei hypotese om autokorrelasjon må spesifisere korleis casa skal sorterast

Durbin-Watson testen (1)

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

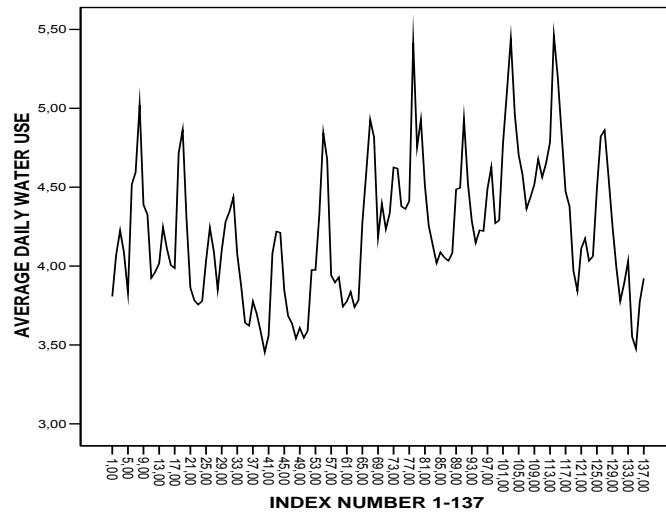
Bør ikke nyttast for autoregressive modellar,
dvs. modellar der y-variabelen også finst som
forklарingsvariabel (x-variabel) jfr tabell 3.2

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 ikke dersom $d > d_U$
 - Dersom $d_L < d < d_U$ kan det ikke konkluderast
- $d=2$ tyder ukorrelerte residualar
- Positiv autokorrelasjon gir $d < 2$
- Negativ autokorrelasjon gir $d > 2$

Dagleg vassforbruk, gjennomsnitt pr måned

Eksempel:



Fall 2004

© Erling Berge 2004

37

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

Fall 2004

© Erling Berge 2004

38

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

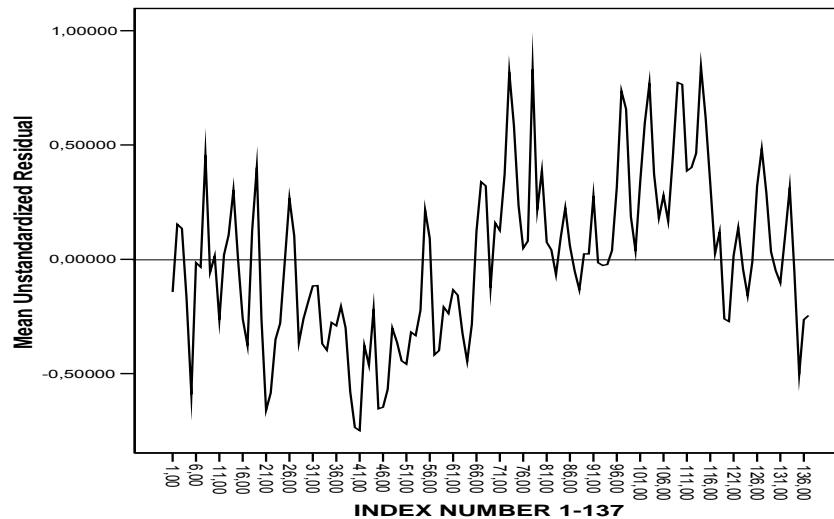
Hjelpe middel: Sjekk opp tabell A4.4 i Hamilton side 355

Autokorrelasjonskoeffisient

m-te ordens autokorrelasjonskoeffisient

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

Residual "Dagleg vassforbruk", månad



Fall 2004

© Erling Berge 2004

41

Glatting med 3 punkt

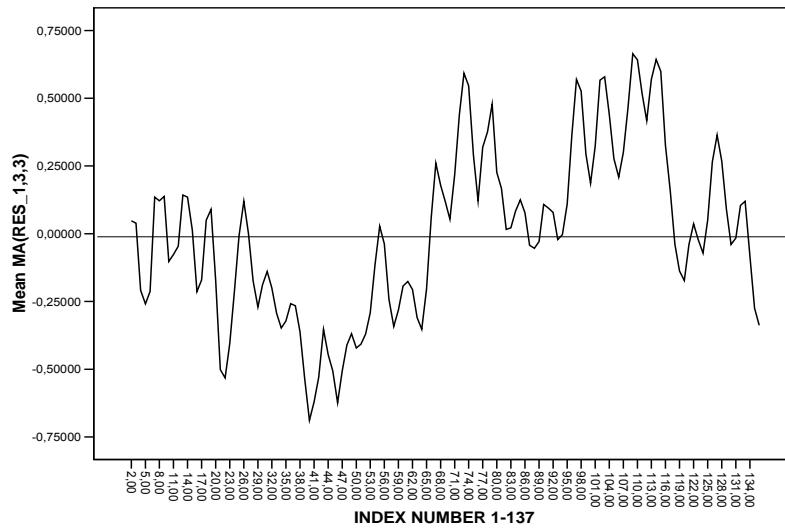
- Glidande gjennomsnitt $e_t^* = \frac{e_{t-1} + e_t + e_{t+1}}{3}$
- "Hanning" $e_t^* = \frac{e_{t-1}}{4} + \frac{e_t}{2} + \frac{e_{t+1}}{4}$
- Glidande median $e_t^* = \text{median}\{e_{t-1}, e_t, e_{t+1}\}$

Fall 2004

© Erling Berge 2004

42

Residual, glatta ein gong

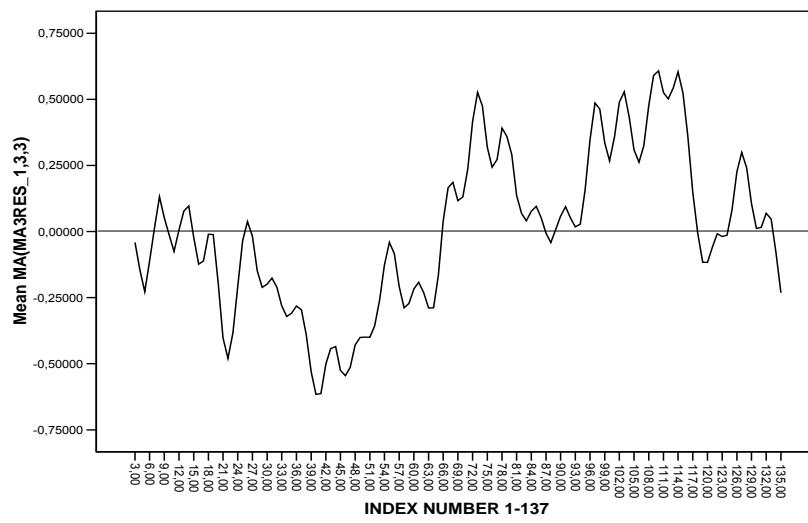


Fall 2004

© Erling Berge 2004

43

Residual, glatta to gonger

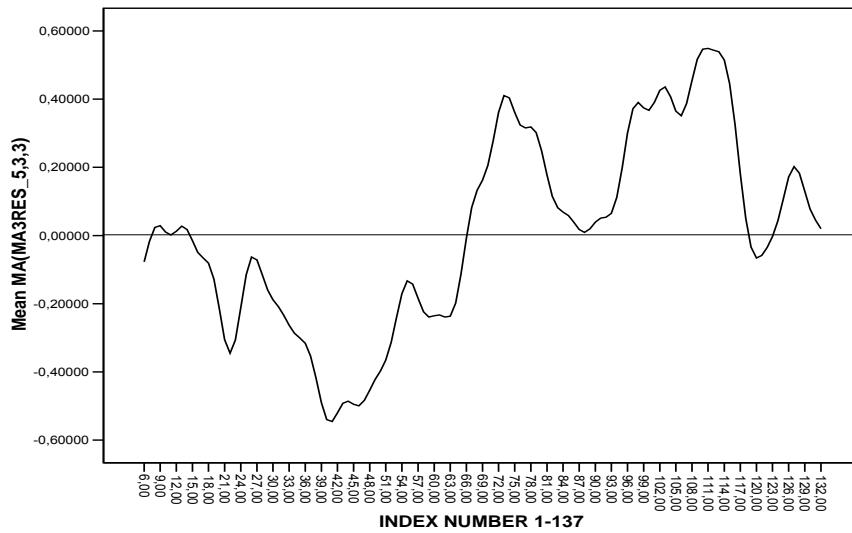


Fall 2004

© Erling Berge 2004

44

Residual, glatta fem gonger



Fall 2004

© Erling Berge 2004

45

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)

Fall 2004

© Erling Berge 2004

46