

SOS3003
**Anvendt statistisk
dataanalyse i
samfunnsvitenskap**

Forelesingsnotat 09

Erling Berge
Institutt for sosiologi og statsvitenskap
NTNU

Fall 2004

© Erling Berge 2004

1

Forelesing VIII

- Kurvetilpasning
Hamilton kap 5 s145-273

Fall 2004

© Erling Berge 2004

2

Kurvetilpassing

- Ein rett spesifisert modell krev at funksjonen som bind x-variablane og y variabelen saman er i samsvar med røyndomen: er sambandet lineært?
- Data kan granskast gjennom bandregresjon eller glatting
- Teori om kausalsambandet kan spesifisere eit ikkje-lineært samband
- For fenomen som ikkje kan representerast med ei rett linje skal vi sjå på nokre alternativ
 - Kurvelineær regresjon
 - Ikkje-lineær regresjon

Fall 2004

© Erling Berge 2004

3

Bandregresjon

- Kan nyttast til å utforske korleis sambanda mellom variablane ser ut.
- Dersom vi kan sjå at ein underliggjande trend i data er ikkje-lineær, må vi gjennom transformasjonar eller bruk av kurver finne ei form på funksjonen som betre representerer samanhengen


Fall 2004

© Erling Berge 2004

4

Ureining i ulike djup av sediment på sjøbotnen utanfor NH

- Ureining målt ved raten krom/jern i ulike djup av ulike sedimentprøver
- Er sambandet lineært?




Fall 2004

© Erling Berge 2004

5

Medianane i 5 band: raten krom/jern i sediment utanfor kysten i NH



Sambandet er tydeleg ikke-lineært

Fall 2004

© Erling Berge 2004

6

Transformerte variablar

- Brukar vi transformerte variablar vert regresjonen kurvelineær. Transformasjonen gjer den opphavelege kurvesamanhengen til ein lineær samanheng
- Dette er den viktigaste grunnen til å transformere.
- Samtidig kan transformerering ordne opp i ulike typar statistiske problem (utliggjarar, heteroskedastisitet, ikkje-normale feil)
- Framgangsmåte:
 - Vel høveleg transformasjon og lag nye transformerte var.
 - Gjennomfør ein standard analyse med dei transformerte var
 - For tolking bør ein vanlegvis transformere attende til opphaveleg måleskala

Fall 2004

© Erling Berge 2004

7

Den lineære modellen

$$y_i = \beta_0 + \sum_{j=1}^{K-1} \beta_j X_{ji} + \varepsilon_i$$

- I den lineære modellen kan vi transformere x-ane og y-ane utan at det har noko å seie for eigenskapane til OLS-estimata i seg sjølv.
- Så lenge modellen er lineær i parametrane er OLS ein lovleg metode

Fall 2004

© Erling Berge 2004

8

Kurvelineære Modellar


- Dette er i praksis regresjon med transformerte variablar
- Vi skal sjå på korleis ulike transformasjonar gir ulik form på sambanda
 - Semilogaritmiske kurver
 - Log-Log kurver
 - Log-resiproke kurver
 - Polynom (2 og 3 orden)

Fall 2004

© Erling Berge 2004

9

Semilogaritmiske kurver Fig 5.2 i Hamilton




Fall 2004

© Erling Berge 2004

10

Log-log kurver Fig 5.3 i Hamilton




Fall 2004

© Erling Berge 2004

11

Log-resiproke kurver Fig 5.4 Hamilton




Fall 2004

© Erling Berge 2004

12

Andregrads polynom Fig 5.5 Hamilton



$$y = 150 + 8x - 0.2x^2$$


$$y = 150 - 8x + 0.2x^2$$

Fall 2004

© Erling Berge 2004

13

Tredjegrads polynom Fig 5.6 Hamilton



$$y = 400 + 8x - 0.7x^2 + 0.01x^3$$

$$y = 50 - 8x + 0.7x^2 - 0.01x^3$$

Fall 2004

© Erling Berge 2004

14

Val av transformasjon

- Spreiingsplot eller teori kan gi råd
- Elles er transformasjon til symmetri det beste utgangspunktet
- Regresjonen rapportert i tabell 3.2 i Hamilton viste seg problematisk
- Regresjon med transformerte variablar kan redusere problema

Fall 2004

© Erling Berge 2004

15

Val av transformasjon i tab 3.2 Hamilton

$Y = \text{Vassforbruk 1981}$	$Y^* = Y^{0.3}$ gir tilnærma symmetri
$X_1 = \text{Inntekt}$	$X_1^* = X_1^{0.3}$ gir tilnærma symmetri
$X_2 = \text{Vassforbruk 1980}$	$X_2^* = X_2^{0.3}$ gir tilnærma symmetri
$X_3 = \text{Utdanning}$	Transformasjonar kan gjere lite
$X_4 = \text{Pensjonist}$	Transformasjon påverkar ikkje dummyvar
$X_5 = \# \text{ menneske i 1981}$	$X_5^* = \ln(X_5)$ gir tilnærma symmetri
$X_6 = \text{Endring i } \# \text{ menneske}$	$X_6 = X_5 - X_0$ ($= \# \text{ menneske i 1980}$)
$X_7 = \text{Relativ endring i } \# \text{ m}$	$X_7^* = \ln(X_5/X_0)$

Fall 2004

© Erling Berge 2004

16

Regresjon med transformerte variable


Tab 5.2 Hamilton

Dependent Variable: $(\text{Wateruse81})^{0.3}$	B	Std. Err	t	Sig.
(Constant)	1,856	,385	4,822	,000
Income ^{0.3}	,516	,130	3,976	,000
Wateruse80 ^{0.3}	,626	,029	21,508	,000
Education in Years	-,036	,016	-2,257	,024
Retired?	,101	,119	,852	,395
Ln(number of people81)	,715	,110	6,469	,000
Ln(people81/people80)	,916	,263	3,485	,001

Fall 2004

© Erling Berge 2004

17



Fall 2004

© Erling Berge 2004

18

Andre verknader av transformasjonane

- To case med stor innverknad på koeffisienten for inntekt (store DFBTAS) har no ikke slik innverknad (fig 4.11 og 5.9)
- Eit case med stor innverknad på koeffisienten for vassforbruk i 1980 har no ikke så stor innverknad (fig 4.12 og 5.10)
- Transformasjonar som gjer fordelingar symmetriske vil ofte løyse mange problem – men ikke alltid!

Fall 2004

© Erling Berge 2004

19

Tolking

- Estimatet av modellen ser no slik ut

$$y_i^{0.3} = 1.856 + 0.516x_{1i}^{0.3} + 0.626x_{2i}^{0.3} - 0.036x_{3i} \\ + 0.101x_{4i} + 0.715\ln(x_{5i}) + 0.916\ln\left(\frac{x_{5i}}{x_{0i}}\right)$$

- Tolking av koeffisientane er ikke lenger så enkelt (t.d.: måleiningane på parametrane er endra)
- Den enkleste måten å tolke på er å nytte betinga effekt plott

Fall 2004

© Erling Berge 2004

20

Betinga effektplass

- Blir brukt til studere samanhengen mellom den avhengige variabelen y og ein x -variabel gitt faste verdiar på dei andre uavhengige variabla
- Typisk er vi interessert i samanhengen $x-y$ når dei andre variablane får verdiar som
 - Maksimerer y
 - Representerer gjennomsnittverdiar
 - Minimerer y

Fall 2004

© Erling Berge 2004

21

Eksempel basert på regresjonen i tabell 3.2 i Hamilton

Dependent Variable: Summer 1981 Water Use	Unstandardized Coefficients			
	B	Std. Error	t	Sig.
(Constant)	242,220	206,864	1,171	,242
Summer 1980 Water Use	,492	,026	18,671	,000
Income in Thousands	20,967	3,464	6,053	,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

Fall 2004

© Erling Berge 2004


22

For betinga effekt plott er det nyttig med ein tabell over minimum, maximum og gjennomsnitt

	N	Minimum	Maximum	Mean
Summer 1981 water use	496	100	10100	2298,39
Summer 1980 water use	496	200	12700	2732,06
Income in thousands	496	2	100	23,08
Education in years	496	6	20	14,00
Head of househ retired?	496	0	1	,29
# of people resident, 1981	496	1	10	3,07
Relative increase in # of people	496	-3	3	-,04
# People living in 1980	496	1	10	3,11

Likninga

- Estimert $Y = 242,22 + 0,492X_1 + 20,967X_2 - 41,866X_3 + 189,184X_4 + 248,197X_5 + 96,454X_6$
- Makismering av effekten av X_1 på Y krev maksimum av X_2 , X_4 , X_5 , X_6 og minimum av X_3
- Gjennomsnitts verdiar for av effekten av X_1 på Y får vi ved å setje inn gjennomsnittverdiar av X_2 , X_3 , X_4 , X_5 , X_6
- Minimering av effekten av X_1 på Y krev minimum av X_1 , X_2 , X_4 , X_5 , X_6 og maksimum av X_3



$$Y = 242,22 + 0,492X_1 + 20,967 \times 10 - 41,866 \times 7 + 189,184 \times 1 + 248,197 \times 5 + 96,454 \times 1$$

$$Y = 242,22 + 0,492X_1 + 20,967 \times 1 - 41,866 \times 18 + 189,184 \times 0 + 248,197 \times 1 + 96,454 \times 0$$


Fall 2004

© Erling Berge 2004

25

Når x er dummykoda

- Estimert $Y = 242,22 + 0,492X_1 + 20,967X_2 - 41,866X_3 + 189,184X_4 + 248,197X_5 + 96,454X_6$
- Estimert $Y = \text{konstant} + 189,184X_4$
 - X_4 kan ha verdiane 0 eller 1




Fall 2004

© Erling Berge 2004

26

Vassforbruk etter inntekt kontrollert for andre variablar



Fall 2004

© Erling Berge 2004

27

Kva er interessant å plotte?

- Samanhengen inntekt vassforbruk kontrollert for ulike kombinasjonar av andre variabelverdiar
 1. Dei som minimerer vassforbruket
 2. Dei som maksimerer vassforbruket
 3. Gjennomsnittverdiane

$$1 \quad y^{0.3} = (1.856 + 0.626(200)^{0.3} - 0.036(20) + 0.101(0) + 0.715\ln(1) + 0.916(\ln(1) - \ln(10)) + 0.516(x)^{0.3})$$

$$2 \quad y^{0.3} = (1.856 + 0.626(12700)^{0.3} - 0.036(6) + 0.101(1) + 0.715\ln(10) + 0.916(\ln(10) - \ln(1)) + 0.516(x)^{0.3})$$


$$3 \quad y^{0.3} = (1.856 + 0.626(2732)^{0.3} - 0.036(14) + 0.101(0.294) + 0.715\ln(3.07) + 0.916(\ln(3.07) - \ln(3.11)) + 0.516(x)^{0.3})$$

Fall 2004

© Erling Berge 2004

28

Samanlikning av tre typar brukssituasjon



Samanhengen mellom inntekt og vassforbruk Fig 5.12 Hamilton

Fall 2004

© Erling Berge 2004

29

Konstanten si rolle i plottet

- Den einaste skilnaden mellom dei tre kurvene er konstanten
 - I maksimumskurva er (konst) = 14.046
 - I minimumskurva er (konst) = 4.204
 - I gjennomsnittskurva er (konst) = 8.507
$$y_i^{0.3} = (konst) + 0.516x_{1i}^{0.3}$$
- Effekten av inntekt varierer med verdien av (konst)
- Når vi transformerer **avhengig** variabel vert alle samanhengar til interaksjonseffektar

Fall 2004

© Erling Berge 2004

30


Samanlikning av effektar

- I somme samanhengar kan ein nytte den standardiserte regresjonskoeffisienten til å samanlikne effektar, men den er sensitiv for skeive estimat av standardfeilen
- Ein meir generell metode er å samanlikne betinga effekt plott der skaleringa på y-aksen er halden konstant

Fall 2004

© Erling Berge 2004

31



Fall 2004

© Erling Berge 2004

32

Ikkje-lineære modellar


- Dersom vi ikkje har modellar som er lineære i parametrane vil ein trenge andre teknikkar for å estimere parametrane
- Det kan vere to typar argument for slike modellar
 - Teori om den kausale mekanismen kan diktere ein slik modell
 - Inspeksjon av data kan peike på ein bestemt type modell
- Vi skal sjå på
 - Eksponentielle modellar
 - Logistiske modellar
 - Gompertz modellar

Fall 2004

© Erling Berge 2004

33

Eksponentiell vekst og fall Fig 5.14 Hamilton




Fall 2004

© Erling Berge 2004

34

Negative eksponentielle kurver Fig 5.15 Hamilton




Fall 2004

© Erling Berge 2004

35

To-ledds eksponentiellkurver Fig 5.16 Hamilton



Fall 2004

© Erling Berge 2004

36

Logistiske modellar

- Den logistiske funksjonen skriv ein
- Når x veks mot uendeleg vil y nærme seg α
- Når x minkar mot minus uendeleg vil y nærme seg 0

$$y = \frac{\alpha}{1 + \gamma \exp(-\beta x)}$$


- Logistiske modellar passar til mange fenomen
 - Vekst i biologiske populasjoner
 - Spreiing av rykte
 - Spreiing av sjukdom

Fall 2004

© Erling Berge 2004

37

Logistiske kurver Fig 5.17 Hamilton



- γ fastset kvar veksten startar, β kor rask veksten er

Fall 2004

© Erling Berge 2004

38

Logistisk sannsynsmodell

- Dersom ein set $\alpha=\gamma=1$ vil y variere mellom 0 og 1 når x varierer mellom minus uendeleg og pluss uendeleg.
- Logistiske kurver kan da nyttast til å modellere sannsyn

$$y_i = \frac{1}{1 + \exp(-\beta x_i)} + \varepsilon_i$$

Fall 2004

© Erling Berge 2004

39

Gompertzkurver

- Gompertzkurver er sigmoidkurver slik som den logistiske, men tilvekst og vekstredusjon skjer i ulik takt, så dei er ikkje symmetriske

$$y = \alpha e^{-\gamma e^{-\beta x}} + \varepsilon$$


- Parametrane α , γ og β har den same tolkinga som i den logistiske modellen

Fall 2004

© Erling Berge 2004

40

Gompertzkurver Fig 5.18 Hamilton



Fall 2004

© Erling Berge 2004

41

Estimering av ikkje-lineære modellar

- Kriteriet på tilpassing er framleis minimum RSS
- Ein kan sjeldan finne analytiske uttrykk for parametrane. Ein må gjette på ein startverdi og gå igjennom fleire iterasjonar for å finne kva parameterverdi som gir den minste RSS verdien
- Gode startverdiar er som regel nødvendig og alt frå teori til inspeksjon av data vert brukt for å finne dei

Fall 2004

© Erling Berge 2004

42

Prosent kvinner med minst 1 barn etter kvinnas
alder og fødselsår (England og Wales)


	1920	1930	1940	1945	1950	1955	1960	1965
15	0	0	0	0	0	0	0	0
20	7	9	13	17	19	18	13	11
25	39	48	59	60	53	45	39	-
30	67	75	82	82	75	68	-	-
35	76	83	87	88	83	-	-	-
40	78	86	89	90	-	-	-	-
45	-	86	89	-	-	-	-	-

Fall 2004

© Erling Berge 2004

43

Estimering av Gompertz-modellar for kohortar (1)




Fall 2004

© Erling Berge 2004

44

Estimering av Gompertz-modellar for kohortar (2)



Fall 2004

© Erling Berge 2004

45

Modelltilpassing

- For å evaluere ein teoretisk utleda modell
- For prediksjon av y innan eller ut over variasjonsområdet for x
- Substansiell eller komparativ vurdering av parameterverdiar
 - Her kan vi nytte modellen på kohortar som enno ikkje er ferdig med fødslane sine (prediksjon ut over observerte x verdiar)
 - Vi kan nytte modellen til å samanlikne parameterverdiane til ulike kohortar

Fall 2004

© Erling Berge 2004

46

Parametertolking Tab 5.6 Hamilton


Kohort	$\alpha = \text{øvre grense}$	$\gamma = ?$	$\beta = \text{vekstfart}$
1920	79.8	461.2	0.26
1930	86.5	538.0	0.27
1940	89.1	942.0	0.31
1945	90.4	468.1	0.28
1950	87.5	144.9	0.23
1955	88.9	60.3	0.18

Fall 2004

© Erling Berge 2004

47

Fødselsrater i Sunndal, Meråker, Verran og Rana 1968-71



- Modellert med Hadwiger funksjonen
- Ref.: Erling Berge 1981 «The Social Ecology of Human Fertility in Norway 1970», Ph.D dissertation, Boston University

Fall 2004

© Erling Berge 2004

48

Konklusjonar i kapittel 5 (1)

- Dataanalyse startar ofte med lineære modellar.
Dei er enklast.
- Teori eller utforskande dataanalyse
(bandregresjon, glatting) kan seie oss om
kurvelineære eller ikkje-lineære modellar trengst
- Transformasjon av variable gir kurvelineær
regresjon. Dette kan motverke fleire problem
 - Kurvelinearitet i samanhengane
 - Case med stor påverknad
 - Ikkje-normale feil
 - Heteroskedastisitet

Konklusjonar i kapittel 5 (2)

- Ikkje-lineær regresjon nyttar iterative
prosedyrar for å finne parameterestimat.
- Prosedyrane treng initialverdiar og er ofte
sensitive for initialverdiane.
- Tolking av parametrar kan vere vanskeleg.
Grafar som viser sambanda for ulike
parameterverdiar vil hjelpe mye