

SOS3003

# Anvendt statistisk dataanalyse i samfunnsvitenskap

Forelesingsnotat, vår 2003

Erling Berge  
Institutt for sosiologi og statsvitenskap  
NTNU

## Forelesing II

- Bivariat regresjon II
  - Hamilton Kap 2 s51-59
- Multivariat regresjon I
  - Hamilton Kap 3 s65-72


## Repetisjon: Bivariat Regresjon: Modell for utval

- $Y_i = b_0 + b_1 X_{1i} + e_i$
- $i=1, \dots, n$        $n = \# \text{ case i utvalet}$

Eksempel frå første forelesning med

- $Y = \text{IMPORTANCE OF PUBLIC CONTROL OF SALES OF AGRIC. ESTATES}$
  - $X = \text{NUMBER OF DEKAR LAND OWNED}$
- Kva var galt i eksempelet?

Kva er galt? Spredningsdiagram med regresjonslinje



# Generelt: Kva kan skape problem?

- Utelatte variablar
- Ikkje-lineære samanhengar
- Ikkje-konstant varians på feilen (heteroskedastisitet)
- Korrelasjon mellom feila (autokorrelasjon)
- Ikkje normale feil
- Innflytelsesrike case

## Ikkje-normale feil: Meir om variabelfordelingar

- Regresjon har **IKKJE føresetnader om fordelinga** til variablane
- MEN for å teste hypoteser må vi ha eit **normalfordelt feilledd**
- DERSOM modellen er korrekt og n er stor sikrar sentralgrenseteoremet at feilleddet er tilnærma normalfordelt
- MEN som regel er modellen feil eller ufullstendig. Derfor må vi **teste om residualen faktisk er normalfordelt.**


# Residualanalyse:

## Viktigaste innfallsporten til problema i regresjonsanalysen


Hjelpe middel:

- Scatterplott
- Plott av residual mot predikert verdi
- Histogram
- Boksplott
- Symmetriplott
- Kvantil-normalplott

### Kva er galt? (1) residual-predikert verdi plott



## Kva er galt? (2) residual normal-kvantilplott



## Potenstransformasjonar

kan løyse problem i samband med

- kurve-linearitet i modellen
- utliggarar
- case med stor innverknad
- ikkje-konstant varians hos feilreddet
- ikkje-normale feilredd

**Transformasjon er mao eit generelt verkemiddel**

## Potenstransformasjonar (jfr H:17-22)



|   |  |
|---|--|
| $Y^*$ : les "transformert Y"<br>(transformasjon fra Y til $Y^*$ ) | Invers trasformasjon<br>(transformasjon fra $Y^*$ til Y) |
| • $Y^* = Y^q$ $q > 0$   | • $Y = [Y^*]^{1/q}$ $q > 0$                              |
| • $Y^* = \ln[Y]$ $q = 0$  | • $Y = \exp[Y^*]$ $q = 0$                                |
| • $Y^* = -[Y^q]$ $q < 0$  | • $Y = [-Y^*]^{1/q}$ $q < 0$                             |

## Potenstransformasjonar: konsekvensar

- $X^* = X^q$ 
  - $q > 1$  **aukar tyngda** til øvre hale relativt til nedre
  - $q = 1$  gir identitet
  - $q < 1$  **reduserer tyngda** til øvre hale relativt til nedre
- Dersom  $Y^* = \ln(Y)$  vil regresjonskoeffisienten for ein intervallskala X variabel kunne tolkast som % endring i Y for ei einings endring i X

# Potenstransformert


## $X = \text{NUMBER OF DEKAR LAND OWNED}$



SQRT=kvadratrotta av areaowned – LN=naturleg logaritme av (areaowned+1)



# Potenstransformert

## $X = \text{NUMBER OF DEKAR LAND OWNED}$




Point3power = 0,3 potensen av areaowned

# Hjelper det med potenstransformasjon?




0.3potens-transformasjon gir lette halar og ingen utliggarar

Boksplott av residualen viser tilnærma symmetri utan utliggarar



# SPSSutskrift vs boka (jfr. s16)



# Lesing av utskrifter fra SPSS (1)

| Descriptive Statistics                 |         | Mean                         | Std. Deviation <sup>1</sup>           | N <sup>2</sup>                                |                       |             |     |     |                  |
|--|---------|------------------------------|---------------------------------------|---|-----------------------|-------------|-----|-----|------------------|
| I. OF P. CNTR. OF SALES OF AGRIC. EST. |         | 4.61                         | 2.185                                 | 307   |                       |             |     |     |                  |
| Point3powerAreaowned                   |         | 8.5032                       | 5.31834                               | 307   |                       |             |     |     |                  |
| Change Statistics                      |         |                              |                                       |   |                       |             |     |     |                  |
| M<br>o<br>d<br>el                      | R       | R<br>Squ<br>are <sup>3</sup> | Adjuste<br>d R<br>Square <sup>4</sup> | Std. Error<br>of the<br>Estimate <sup>5</sup> | R<br>Square<br>Change | F<br>Change | df1 | df2 | Sig. F<br>Change |
| 1                                      | .024(a) | .001                         | -.003                                 | 2.188   | .001                  | .182        | 1   | 305 | .670             |

a Predictors: (Constant), Point3powerAreaowned

b Dependent Variable: I. OF P. CNTR. OF SALES OF AGRIC. EST.

## Fotnoter til føregående tabell

<sup>1</sup> Standard-avviket til gjennomsnittet (mean)

<sup>2</sup> Talet av case brukt i analysen

<sup>3</sup> Determinasjonskoeffesienten

<sup>4</sup> Den justerte determinasjonskoeffesienten,  
sjå Hamilton side 41

<sup>5</sup> Standard-avviket til residualen  $s_e = \text{SQRT}(\text{RSS}/(n-K))$ ,  
der  $\text{SQRT} = \text{kvadratrota av } (*)$

# Lesing av utskrifter fra SPSS (2)

| Mode<br>I |            | Sum<br>of Squares | df  | Mean<br>Square | F <sup>1</sup> | Sig. <sup>2</sup> |
|-----------|------------|-------------------|-----|----------------|----------------|-------------------|
| 1         | Regression | .870              | 1   | .870           | .182           | .670(a)           |
|           | Residual   | 1460.224          | 305 | 4.788          |                |                   |
|           | Total      | 1461.094          | 306 |                |                |                   |

- Kvadratsummar: TSS = ESS + RSS
- RSS =  $\sum_i (e_i)^2 = \sum_i (Y_i - \hat{Y}_i)^2$  : sum kvadrert (avstand observert – estimert verdi)
- Mean Square = RSS / df For RSS har vi at df=n-K  
K er lik talet på parametrar som modellen estimerer (dvs  $b_0$  og  $b_1$ )  
Her er n=307 og K=2, dvs. Df = 305

## Fotnoter til føregående tabell

<sup>1</sup> F-observatoren for nullhypotesa  $\beta_1 = 0$   
(sjå Hamilton side 45)

<sup>2</sup> p-verdien for F-observatoren: dvs sannsynet for å finne ein så stor eller større F-verdi gitt at nullhypotesa er rett

### Kvadratsummar

$$TSS = ESS + RSS$$

$$RSS = \sum_i (e_i)^2 = \sum_i (Y_i - \hat{Y}_i)^2$$

$$ESS = \sum_i (\hat{Y}_i - \bar{Y})^2$$

$$TSS = \sum_i (Y_i - \bar{Y})^2$$

avstand observert – estimert verdi

avstand estimert verdi – gjennomsnitt

avstand observert verdi – gjennomsnitt

## Lesing av utskrifter fra SPSS (3)

| Model |                         | Unstandardized Coefficients |                         | Standardized Coefficients<br>Beta <sup>3</sup> | t <sup>4</sup> | Sig. <sup>5</sup> | 95% Confidence Interval for B |             |
|-------|-------------------------|-----------------------------|-------------------------|--|----------------|-------------------|-------------------------------|-------------|
|       |                         | B <sup>1</sup>              | Std. Error <sup>2</sup> |  |                |                   | Lower Bound                   | Upper Bound |
| 1     | (Constant)              | 4.524                       | .236                    |  | 19.187         | .000              | 4.060                         | 4.988       |
|       | Point3-powerAre a-owned | .010                        | .024                    | .024   | .426           | .670              | -.036                         | .056        |

## Fotnoter til føregående tabell

<sup>1</sup> Estimat av regresjonskoeffisientane  $b_0$  og  $b_1$

<sup>2</sup> Standardavviket (standardfeilen) til parameterstimata  $b_0$  og  $b_1$

<sup>3</sup> Dei standardiserte regresjonskoeffisientane:  
 $b_1^{st} = b_1 * (s_x/s_y)$  sjå Hamilton side 38-40

<sup>4</sup> t-observatoren for nullhypotesa  
 $\text{beta1} = 0$  (sjå Hamilton side 44)

<sup>5</sup> p-verdien for t-observatoren: dvs sannsynet for å finne ein så stor eller større t-verdi gitt at nulhypotesa er rett

# Kurvelienær regresjon

- I eksempelet ovanfor brukte vi variabelen "Point3powerAreaowned", dvs 0.3 potensen av antall dekar areal ein eig. Dvs.:
  - $\text{Point3powerAreaowned} = (\text{NUMBER OF DEKAR LAND OWNED})^{0.3}$


Modellen vi har estimert er altså

$$y_i = b_0 + b_1 x_i + e_i$$

$$y_i = b_0 + b_1 \text{Point3powerAreaowned}_i + e_i$$

$$\hat{y}_i = 4.524 + 0.010 * (\text{NUMBER OF DEKAR LAND OWNED})^{0.3}$$

**Bruk av potenstransformerte variablar betyr at regresjonen blir kurvelineær**



# Oppsummering

- I bivariat regresjon kan ein seie at OLS-metoden freisar finne den beste LINJA eller KURVA som passar til eit to-dimensjonalt spreiingsmønster
- Scatter-plott og residualanalyse er hjelpemiddel for å diagnostisere problem i regresjonen
- Transformasjonar er eit generelt hjelpemiddel mot fleire typer problem, som t.d.:
  - Kurvelinearitet
  - Heteroskedastisitet
  - Ikke-normalitet
  - Case med stor innverknad
- Regresjon med transformerte variablar er alltid kurvelineær. Vi tolkar resultatet letast ved hjelp av grafar

## Multippel regresjon: modell (1)

- Sett  $K =$  talet på parametrar i modellen (dvs.  $K-1$  er talet på variablar).  
Da kan (populasjons) modellen skrivast
- $y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3} + \dots + \beta_{K-1} x_{i,K-1} + \varepsilon_i$

## Multippel regresjon: modell (2)

- Dette kan skrivast

$$y_i = E[y_i] + \varepsilon_i ,$$

dette tyder at

- $E[y_i] = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3} + \dots + \beta_{K-1} x_{i,K-1}$   
 $E[y_i]$  les vi som forventa verdi av  $y_i$
- Målet med multippel regresjon er å finne nettoeffekten av ein variabel, kontrollert for variasjonen i alle dei andre

## Multippel regresjon: modell (3)

- Vi finn OLS estimata av modellen som dei b-verdiane i


$$\hat{y}_i = b_0 + b_1 x_{i1} + b_2 x_{i2} + b_3 x_{i3} + \dots + b_{K-1} x_{i,K-1}$$

( $\hat{y}_i$  les vi som estimert eller "predikert" verdi av  $y_i$ ) som minimerer kvadratsummen av residualane

$$RSS = \sum_i (y_i - \hat{y}_i)^2 = \sum_i e_i^2$$

# Meir om hypotesetesting

- Frå ein populasjon kan det trekkjast mange utval
- I kvart nytt utval vil vi kunne estimere nye regresjonsparametrar
- Lager vi eit histogram over ulike estimerte verdiar av t.d.  $\beta_1$  vil vi sjå at  $b_1$  har ei fordeling (ei samplingfordeling)
- Ulike parametrar og observatorar har ulike samplingfordelingar
- Regresjonsparametrane ( $b$ 'ane) er t-fordelt



Sampling fordeling for regresjonsparametren  $b$ :  $E[b] = \beta$

# Om partielle effektar (1)

- Eit eksempel med 2 variablar
- Dersom vi estimerer ein modell

$$y_i = b_0 + b_1 x_{i1} + b_2 x_{i2} + e_i$$

er det i prinsippet 3 ulike korrelasjonar som er involvert:

- Mellom  $y$  og  $x_1$
- Mellom  $y$  og  $x_2$
- Mellom  $x_1$  og  $x_2$

# Om partielle effektar (2)

- Dette kan teoretisk gi opphav til 3 ulike bivariate regresjonar der vi held den tredje variabelen konstant (t.d. for "gitt  $x$ " skrive " $|x$ ")

$$(1) y = a_{ylx1} + b_{ylx1}x_1 + e_{ylx1}$$

$$(2) y = a_{ylx2} + b_{ylx2}x_2 + e_{ylx2}$$

$$(3) x_1 = a_{x1lx2} + b_{x1lx2}x_2 + e_{x1lx2}$$

indeksen "ylx1" les vi "regresjonen av  $y$  på  $x_1$ "

- Likningane (2) og (3) kan vi skrive om

## Om partielle effektar (3)

$$(2) e_{y|x_2} = y - (a_{y|x_2} + b_{y|x_2}x_2)$$

$$(3) e_{x_1|x_2} = x_1 - (a_{x_1|x_2} + b_{x_1|x_2}x_2)$$

Vi ser da at vi så å seie "fjernar" effekten av  $x_2$  fra  $y$  og fra  $x_1$

Vi ser også at  $e_{y|x_2}$  og  $e_{x_1|x_2}$  vert nye variablar der effekten av  $x_2$  er fjerna

## Om partielle effektar (4)

- Dersom vi no lagar ein ny regresjon

$$\hat{e}_{y|x_2} = a + b e_{x_1|x_2}$$

finn vi at

$$a = 0$$

b =  $b_1$  fra den bivariate regresjonen

$$y_i = b_0 + b_1 x_{i1} + b_2 x_{i2} + e_i$$

- $b_1$  er altså effekten av  $x_1$  på  $y$  etter at vi har "fjerna" effekten av  $x_2$

# Eksperiment og partielle effektar

- I eksperiment granskas ein kausalsamband mellom to variable med kontroll for alle mogelege andre kausale faktorar
- Multippel regresjon er ei form for etterlikning av eksperimentet – ei nest beste løysing - og ligg nært opp til det som heiter kvasi-eksperimentelt forskingsdesign

## KAUSALANALYSE

- Eksperiment
  - randomisering av påverknad (“behandling”) gir presise kausale konklusjonar om verknader (“respons”) ved signifikant skilnad i gjennomsnitt
  - kan vere umogeleg på grunn av
    - praktisk tilhøve
    - økonomiske skrankar
    - etiske vurderingar
- Kvasi-eksperiment der eksperiment er umogeleg
  - t.d. regresjonsanalyse

# Eksperimetet plasserer "case" tilfeldig i ei av to grupper:

- **BEHANDLING (T)**
  - med observasjon
    - FØR behandling
    - ETTER behandling
- **KONTROLL (C)**
  - med observasjon
    - FØR "ikkje-behandling"
    - ETTER "ikkje-behandling"

## Modell av kausaleffektar<sup>Ref.:</sup>

- Studiar av observasjonsdata brukar omgrep fra eksperimentell design
- "Påverknad/ Behandling", "Stimulus" (Treatment/ Stimulus)
- "Effekt", "Utfall" (Effect/ Outcome)

Ref.:

Winship, Christopher, and Stephen L. Morgan 1999 "The Estimation of Causal Effects from Observational Data", Annual Review of Sociology Vol 25: 659-707

# Modell av kausaleffektar:

Den "Kontrafaktiske" hypotesa for studiet av kausalitet

- Individet "i" kan i utgangspunktet tenkast "selektert" til ei av to grupper
  - behandlingsgruppa, T, eller kontrollgruppa, C.
- Behandlinga, t (treatment), så vel som ikkje-behandling, c, kan i utgangspunktet tenkast gitt til individ både i T- og C-gruppa
- Faktisk vil vi berre kunne observere t i T-gruppa og c i C-gruppa

# Modell av kausaleffektar:

Den "Kontrafaktiske" hypotesa

- For kvart individ "i" kan ein tenkje seg fire mogelege utfall
  - $Y_i(c, C)$  eller  $Y_i(t, C)$ ; ved plassering i kontrollgruppe
  - $Y_i(c, T)$  eller  $Y_i(t, T)$ ; ved plassering i behandlingsgruppa
- Berre  $Y_i(c)$ , gitt "i" er med i C) eller  $Y_i(t)$ , gitt "i" er med i T) kan observerast for eit gitt individ

# Modell av kausaleffektar:

## Den “Kontrafaktiske” hypotesa

Litt meir formelt kan ein skrive dei mogelege utfalla for person i:

|          |               |               |
|----------|---------------|---------------|
|          | Behandling: t | Ikkje beh.: c |
| T-gruppa | $Y_i^t \in T$ | $Y_i^c \in C$ |
| C-gruppa | $Y_i^t \in C$ | $Y_i^c \in T$ |

# Modell av kausaleffektar:

## Den “Kontrafaktiske” hypotesa

- Kausaleffekten for individ i er da
- $\delta_i = Y_i(t) - Y_i(c)$
- Berre ein av desse to storleikane kan observerast for eit gitt individ  
Derfor ”Den kontrafaktiske hypotesa”

## Modell av kausaleffektar:

Den “Kontrafaktiske” hypotesa

- Vi kan til dømes observere  
 $Y_i(c | i \in C)$ , men ikkje  $Y_i(t | i \in C)$
- Problemet kan seiast å vere manglande data
- I staden for individeffektar vil ein estimere gjennomsnittseffektar i heile populasjonen

## Modell av kausaleffektar:

- Gjennomsnittseffektar lar seg estimere, men som regel berre med store vanskar
- Ein føresetnad er at effekten av påverknad vil vere den samme for eit gitt individ uansett kva gruppe individet er plassert i
- Dette er imidlertid ikkje sjølv sagt

# Modell av kausaleffektar:

Den “Kontrafaktiske” hypotesa antar:

- at endring av behandlingsgruppe for eitt individ ikkje verkar inn på utfallet for andre individ (fravær av interaksjon)
- at behandlinga, “påverknaden”, faktisk er manipulerbar (t.d.: kjønn er ikkje manipulerbar)

# Modell av kausaleffektar:

- Ein av vanskane er at i eit utval vil den prosessen som plasserer personen ”i” i kontroll- eller behandlings-gruppa kunne verke inn på det estimerte gjennomsnittsutfallet (seleksjonsproblemet)
- I somme høve er imidlertid den interessante størrelsen gjennomsnitts-effekten for dei som faktisk får påverknaden

## Modell av kausaleffektar:

- Det kan visast at det er to kjelder til feil (bias) i estimata av gjennomnositseffekten
  - ein eksisterande skilnad mellom C- og T-gruppene
  - behandlinga verkar i prinsippet ulikt for dei som er i T-gruppa samanlikna med dei som er i C -gruppa
- For å handtere dette må vi utvikle modellar for korleis folk hamnar i C- og T-gruppene

## Modell av kausaleffektar:

- Ein generell klasse metodar som kan nyttast til å estimere kausaleffektar er regresjonsmodellane
- Dei vil kunne “kontrollere” for observerbare skilnader mellom T- og C-gruppene, men ikkje for ulik respons på behandling