

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

Erling Berge  
Institutt for sosiologi og statsvitenskap  
NTNU

Vår 2004

© Erling Berge 2004

1

## Forelesing IX

- Robust Regresjon  
Hamilton kap 6 s183-212

Vår 2004


© Erling Berge 2004

2

# Robust Regresjon


- Er utvikla for å fungere godt i situasjonar der OLS regresjonen bryt saman. Der OLS føresetnadene er oppfylt gir robust regresjon dårlegare resultat enn OLS, men ikkje mye
- Sjølv om robust regresjon høver betre for den som ikkje vil leggje mye arbeid i å teste føresetnader er metodane førebels vanskelege å gjere seg bruk av
- Robust regresjon har fokusert mest på fordelingar av residualar med tunge halar (mange case med stor innverknad på regresjonen)

## Regresjon av mortalitet på luftureining



Figur 6.1  
Hamilton

## Robust regresjon av mortalitet på luftureining



Figur 6.2  
Hamilton

Vår 2004

© Erling Berge 2004

5

## Robust regresjon og SPSS

- Det er ikkje noko rutine i SPSS som gjer robust regresjon direkte
- Den kan gjerast ved hjelp av vekta regresjon, men det krev at vi lagar vektfunksjon og går igjennom iterasjonane ein for ein med utrekning av nye vektorer for kvar gong
- Framgangsmåte kjem vi til nedanfor

Vår 2004

© Erling Berge 2004

6

# ROBUST OG RESISTENT

- RESISTENTE metodar lar seg ikkje påverke av små feil/ endringar i utvalsdata
- ROBUSTE metodar lar seg ikkje påverke av små avvik frå føresetnadene til modellen
- Dei fleste resistente estimatorane er også robuste i høve til føresetnaden om normalfordeling av residualane
- **OLS er verken ROBUST eller RESISTENT**

## Utliggjarar er eit problem for OLS

Utliggjarar verkar inn på estimat av

- Parametrar
- Standardfeil (standardavvik til parameter)
- Determinasjonskoeffesient
- Testobservatorar
- Og mange andre observatorar

Robust regresjon freistar verne mot dette ved å gi mindre vekt til slike case,

ikkje ved å ekskludere dei

## Hjelp mot IKKJE-NORMALE residualar

Robuste metodar kan vere til hjelp når

- Halane i residualfordelinga er "tunge" dvs. når det er "for mange" utliggjarar i høve til normalfordelinga
- Uvanlege X-verdiar gir påverknad (leverage) problem

Ved andre årsaker til ikkje-normalitet hjelper dei ikkje.

## Estimeringsmetodar for robust regresjon

- M-estimering (maximum likelihood) minimerer ein vekta sum av residualane. Kan tilnærmast med vekta minste kvadrat metoden (WLS)
- R-estimering (basert på rang) minimerer ein sum der ein vekta rang inngår. Metoden er vanskelegare å bruke enn M-estimeringa
- L-estimering (basert på kvantilar) brukar lineære funksjonar av utvalsordnings-observatorane (kvantilane)

# IRLS-

## Iterativt Revekta Minste Kvadrat

M-estimat ved hjelp av IRLS treng

1. Startverdiar fra OLS. Ta vare på residualane.
2. Bruk OLS residualane til å finne vekter. Til større residual, til mindre vekt
3. Finn nye parameterverdiar og residualar med WLS
4. Gå til 2 og finn nye vekter frå dei nye residualane, fortsett til steg 3 og 4, heilt til endringane i parametranne vert små

Iterasjon: å gjenta ein sekvens av operasjonar

# IRLS

- IRLS er i teorien ekvivalent med M-estimering
- For å nytte metoden treng vi å rekne ut
- Skalerte residualar,  $u_i$ , og ein
- Vektfunksjon,  $w_i$ , som gir minst vekt til dei største residualane

# Skalering av residualar I

- Skalert residual  $u_i$ 
  - $s$  er skaleringsfaktoren og  $e_i$  residualen
- Skaleringsfaktoren i OLS er estimatet av standardfeilen til residualen: nb!  $s_e$  er ikkje resistant
- Eit resistant alternativ er basert på MAD, "median absolute deviation"

$$u_i = \frac{e_i}{s}$$

$$s_e = \sqrt{\frac{RSS}{n-K}}$$

$$MAD = \text{median} | e_i - \text{median}(e_i) |$$

# Skalering av residualar II

$$MAD = \text{median} | e_i - \text{median}(e_i) |$$

Skaleringsfaktoren (standardfeilen i fordelinga) vert med bruk av eit resistant estimat

- $s = MAD / 0.6745 = 1.483MAD$   
og den skalerte residualen

- $u_i = [e_i / s] = (0.6745 * e_i) / MAD$

I ei normalfordeling vil  $s = MAD / 0.6745$  estimere standardfeilen korrekt slik som  $s_e$

Ved ikkje-normale feil vil  $s = MAD / 0.6745$  vere betre.

Det er eit resistant estimat,  $s_e$  er ikkje resistant

# Vektfunksjonar I

- Eigenskapane vert målt i høve til OLS på normalfordelte feil. Metoden skal vere "nesten like god" som OLS ved normalfordelte feil og mye bedre når feila er ikkje-normale
- Eigenskapane vert fastlagt ved ein "kalibreringskonstant" ( $c$ , i formlane)

# Vektfunksjonar II

- **OLS-vektar**:  $w_i = 1$  for alle  $i$
- **Huber-vektar**: vektar ned når den skalerte residualen er større enn  $c$ ,  $c=1,345$  gir 95% av OLS sin effektivitet på normalfordelte feil
- **Tukey's bivekta** estimat får 95% av OLS sin effektivitet på normalfordelte feil ved gradvis nedvekting av skalerte feil opp til  $|u_i| \leq c = 4.685$  og ved å droppe case der residualen er større.

## Huber-vektor

$$w_i = 1 \quad \forall |u_i| \leq c$$

$$w_i = \frac{c}{u_i} \quad \forall |u_i| > c$$

$\forall$  = for alle

## Tukey vektor

$$w_i = \left[ 1 - \left( \frac{u_i}{c} \right)^2 \right]^2 \quad \forall |u_i| \leq c$$

$$w_i = 0 \quad \forall |u_i| > c$$

$\forall$  = for alle

- Tukey vekting i IRLS er sensitiv for startverdiane av parametrane (ein kan finne lokale minimum)

# Standardfeil og testar ved IRLS


- WLS program vil ikkje estimere standardfeil og testobservatorar rett ved IRLS
- Ein prosedyre som fungerer er gitt av Hamilton på side 198-199

## Bruk av Robust Estimering

- Dersom OLS estimat og Robuste estimat er ulike tyder det at utliggjarar verka inn på OLS slik at vi ikkje kan stole på resultatata
- Robuste predikerte verdiar reflekterer betre hovudmassen av data
- Robuste residualar vil derfor betre avsløre kva som er uvanlege case
- Vektene frå den robuste regresjonen vil vise kva for case som er utliggjarar
- OLS og RR kan stø kvarandre

Fig 6.9 Hamilton: OLS og RR på data utan transformasjon

Mortalitet på luftureining  
Effekt av høg leverage




Vår 2004

© Erling Berge 2004

21

Fig 6.10 Hamilton: OLS og RR på data utan transformasjon med to utliggjalar fjerna

Mortalitet på luftureining



Vår 2004

© Erling Berge 2004

22


# RR vernar ikkje mot leverage

- RR med M-estimering vernar mot uvanlege y-verdiar (utliggjarar) men ikkje nødvendigvis mot uvanlege x-verdiar (leverage)
- Innsats på testing og diagnose trengst framleis (heteroskedastisitet er td. problematisk ved IRLS)
- Studiar av datamaterialet og symmetri-transformasjon reduserer sjansen for at problem dukkar opp
- Ingen metode er "trygg" om den blir brukt utan omtanke og studiar av data

## Robust Multippel Regresjon


X <sub>1</sub>	RELATIVE HC POLLUTION POTENTIAL	(natural log)
X <sub>2</sub>	AVG. YEARLY PRECIP. INCHES	
X <sub>3</sub>	AVG. JANUARY TEMPERATURE, F	
X <sub>4</sub>	MEDIAN EDUCATION OF POP 25+	
X <sub>5</sub>	% NON-WHITE	(square root)
X <sub>6</sub>	POPULATION PER HOUSEHOLD	
X <sub>7</sub>	% 65 AND OVER	
X <sub>8</sub>	% SOUND HOUSING UNITS	
X <sub>9</sub>	PEOPLE PER SQUARE MILE	(natural log)
X <sub>10</sub>	AVG. JULY TEMPERATURE, F	
X <sub>11</sub>	% WHITE COLLAR EMPLOYMENT	
X <sub>12</sub>	% FAMILIES WITH INCOME<\$3000	(negative reciprocal root)
X <sub>13</sub>	AVG RELATIVE HUMIDITY, %	

## Multipel OLS regresjon med transformerte variable: effekten av transformasjon



In av luftureining

Vår 2004



Kvadratrot av % ikkje-kvite

© Erling Berge 2004

25

## OLS med baklengs eliminering gir

Dependent Variable: AGE-ADJUSTED MORTALITY/100K	B	Std. Error	t	Sig.
(Constant)	986,261	82,674	11,929	,000
LN_hc_pollution	17,469	4,636	3,768	,000
AVG. YEARLY PRECIP. INCHES	2,352	,640	3,677	,001
AVG. JANUARY TEMPERATURE, F	-2,132	,504	-4,228	,000
MEDIAN EDUCATION OF POP 25+	-17,958	6,204	-2,895	,005
SQRT_pct_non_white	27,335	4,398	6,215	,000

- Robust regresjon gir predikert y  
 $= 1001.8 + 17.77x_{1i} + 2.32x_{2i} - 2.11x_{3i} - 19.1x_{4i} + 26.2x_{5i}$

Vår 2004


© Erling Berge 2004

26

## Multipel OLS regresjon med transformerte variable

Leverage plott av residual av mortalitet (y) og residual av ln\_lufuring (x)

Los Angeles og San Francisco er ikkje lenger utliggjarar



Vår 2004

© Erling Berge 2004

27

## Fire estimat av samanhengen mortalitet - lufuring

Effekten av luftureining

	OLS	Robust
1 variabel	7.97	19.46
5 variablar	17.47	17.77

- Legg merke til at RR i den bivariate regresjonen kjem ganske nær resultatet i den multivariate regresjonen

- I fem-variabel modellen er det nye case som verkar inn på regresjonslina
- Fjerning av dei 5 casa som har høgast leverage parameter ( $h_i$ ) gir ikkje substansielle endringar i koeffesientane

Vår 2004

© Erling Berge 2004

28

## Robust Regresjon vs Avgrensa Innflytelse Regresjon

- Robust Regresjon vernar mot effekt av utliggarar (Uvanlege y-verdiar) dersom dei ikkje kjem saman med uvanlege x-verdiar
- Bounded Influence Regression  
(Regresjon med avgrensa innflytelse)
  - vernar i tillegg mot innflytelse (uvanlege kombinasjonar av x-verdiar)

## BI (bounded influence) - Avgrensa påverknad regresjon

- BI-metodane er laga for å avgrense verknaden av stort potensiale for påverknad (stor  $h_i$  - leverage)
- Den aller enklaste tilnærminga til problemet er å modifisere Huber-vektene eller Tukey-vektene med ein faktor basert på leverage observatoren

## Avgrensa påverknad: vektmodifikasjon

- Vi utvidar vektfunksjonen med ei vekt basert på innflytelse (leverage) observatoren  $h_i$



Påverknads-faktoren i vektinga kan t.d. setjast til

- $w_i^H = 1$                     hvis  $h_i \leq c^H$
- $w_i^H = (c^H / h_i)$         hvis  $h_i > c^H$
- $c^H$  vert ofte sett lik 90% persentilen i fordelinga av  $h_i$
- IRSL vekta vert da  $w_i w_i^H$  der  $w_i$  er enten Tukey- eller Huber-vekter som endrar seg frå iterasjon til iterasjon medan  $w_i^H$  er konstant

## Avgrensa påverknad som diagnoseverktøy


- Estimering av standardfeil og test-observatorar vert no enno meir komplisert enn for dei M-estimatorane vi omtala ovanfor
- Vi kan bruke BI estimat som deskriptivt verktøy for å sjekke opp ande estimat
- Eit (litt) ekstremt eksempel: PCB ureining i elvemunningar i 1984 og 1984 (Hamilton tabell 6.4)

# Fig 6.15 og 6.16 Hamilton



# Fig 6.17 Hamilton

OLS og BI  
estimat med  
transformerte  
variablar gir  
om lag same  
resultat



# Konklusjonar

- Når data har mange utliggjarar vil robuste metodar ha betre eigenskapar enn OLS.
  - Dei er meir effektive og gir meir nøyaktige konfidensintervall og testar
- Robust regresjon kan brukast som diagnoseverktøy.
  - Er OLS og RR einige kan vi ha større tiltru til OLS resultatata
  - Er dei ueinige vil vi
    - Vere merksame på at eit problem eksisterer
    - Ha ein modell som passar betre med data og identifiserer utliggjarar betre
- Robuste metodar verkar ikkje mot problem som skuldast kurvelineære eller ikkje-lineære modellar, heteroskedastisitet og autokorrelasjon