

SOS3003

Anvendt statistisk dataanalyse i samfunnsvitenskap

Forelesingsnotat 01

Erling Berge
Institutt for sosiologi og statsvitenskap
NTNU

Haust 2004

© Erling Berge 2004

1

PENSUM SOS 3003

- Hamilton, Lawrence C. 1992 "Regression with graphics", Belmont, Duxbury, Kap. 1-7 .
- Hardy, Melissa A. 1992 "Regression with dummy variables" Sage University Paper: QASS 93, London, Sage,
- Allison, Paul D. 2002 "Missing Data" Sage University Paper: QASS 136, London, Sage,

Haust 2004

© Erling Berge 2004

2

Forelesing I

- Opplegg
 - Føresetnader: SOS 1002 eller tilsvarende
 - Målsetting: lese faglitteratur
 - Pensum
 - Semesteroppgåve: del av eksamen
- Variabelfordelingar. Hamilton Kap 1 s1-23
- Bivariat regresjon I Hamilton Kap 2 s29-50

Mål for kurset

- Kunne lese og vurdere faglitteratur som drøftar ”kvantitative” data
 - Vi skal kjenne fallgruvene
- Gjennomføre enkle analysar av samvariasjon i ”kvantitative” og ”kvalitative” data
 - Vi skal demonstrere at vi kjenner fallgruvene

Kort repetisjon av grunnleggjande omgrep

- Årsak
- Modell
- Populasjon
- Utval
- Variabel: målenivå
- Variabel: sentraltendens
- Variabel: spreiing

Data-analyse

- Deskriptive bruk av data
 - Utvikling av klassifikasjoner
- Analytisk bruk av data
 - Beskrive fenomen som ikke kan observerast direkte (inferens)
 - Årsaksamband mellom direkte eller indirekte observerbare fenomen (teori eller modellutvikling)

KAUSALANALYSE: frå samvariasjon til årsak

- fra daglegsspråk til teori
 - fantasi og intuisjon, etablert fagleg tradisjon
- fra teori til modell
 - operasjonalisering
- fra observasjon til generalisering
 - kausalanalyse

Haust 2004

© Erling Berge 2004

7

3 SENTRALE SKILNADER

<u>Observert</u>		<u>Interesse</u>
TEORI/ MODEL	-	RØYNDOM
UTVAL	-	POPULASJON
SAMVARIASJON	-	ÅRSAK

På eine sida har vi det vi faktisk kan sette på papiret,
på andre sida det vi gjerne vil seie noko om.

Haust 2004

© Erling Berge 2004

8

Sentrale feilkjelder

- Feil i teori/ modell
 - Modellspesifikasjonskravet
- Feil i utval
 - Seleksjonsproblemet
- Måleproblem
 - Frafall og målefeil
 - Validitet og reliabilitet
- Multiple komparasjonar
 - Utvalsspesifikke konklusjonar

Frå populasjon til utval

- POPULASJON (ALLE EININGAR)
enkel tilfeldig trekking
- UTVAL (UTVALTE EININGAR)

Eining og variabel

- Eininga, beraren av data, er kontekstuellt definert
 - SUPER - EINING: t.d. lokalsamfunnet
 - EINING: t.d. hushald
 - SUB - EINING: t.d. person
- Variabel: empirisk omgrep brukt til å karakterisere undersøkte einingar. Kvar eining vert karakterisert ved å tilordne den ein variabelverdi.

Haust 2004

© Erling Berge 2004

11

Datamatrise og målenivå

- Matrise definert av Einingar * Variablar
 - Tabell over eigenskapane til alle undersøkte einingar ordna slik at alle variabelverdiane kjem i same rekkefølgje for alle einingar.
- Målenivå av ein variabel
 - nominal *klassifisering
 - ordinal *klassifisering og rang
 - intervall *klassifisering, rang og **avstand**
 - forholdstal *klassifisering, rang, **avstand** og nullpunkt

Haust 2004

© Erling Berge 2004

12

Variabelanalyse

- Beskrivelse
 - Sentraltendens og spreiing
 - Fordelingsform
 - Frekvensfordelingar og histogram
- Samanlikning av fordelingar
 - Kvantilplott
 - Boxplott

Haust 2004

© Erling Berge 2004

13

VARIABEL: SENTRALTENDENS

- **GJENNOMSNITT**
Summen av verdiane på variabelen for alle
einingane dividert på talet av einingar
$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$
- **MEDIAN**
Den verdien i ei ordna fordeling som har
halvparten av einingane på kvar side
- **MODUS**
Den typiske verdien. Den verdien i ei
fordeling som har høgst frekvens.

Haust 2004

© Erling Berge 2004

14

VARIABEL: SPREDNINGSMÅL I

- MODALPROSENTEN
- Prosent av einingane som har verdi lik modus
- VARIASJONSBREDDA
- Differansen mellom høgaste og lågaste verdi i ei ordna fordeling
- KVARTILDIFFERENSEN
- Variasjonsbreidda for dei 50% av einingane som ligg rundt medianen ($Q_3 - Q_1$)
- MAD - Median Absolute Deviation
- Medianen til absoluttverdien til skilnaden mellom median og observert verdi: $MAD(x_i) = \text{median} |x_i - \text{median}(x_i)|$

VARIABEL: SPREDNINGSMÅL II

- STANARDAVVIKET
- Kvadratrot av gjennomsnittleg kvadrert avvik frå gjennomsnittet $s_y = \sqrt{(\sum_i (Y_i - \tilde{Y})^2)/(n - 1)}$
- GJENNOMSNITSAVVIKET
- Gjennomsnittet av absoluttverdien til avviket frå gjennomsnittet
- VARIANSEN
- Kvadratet av standardavviket: $s_y^2 = (\sum_i (Y_i - \tilde{Y})^2)/(n - 1)$
(ps: her er \tilde{Y} gjennomsnittet av Y)

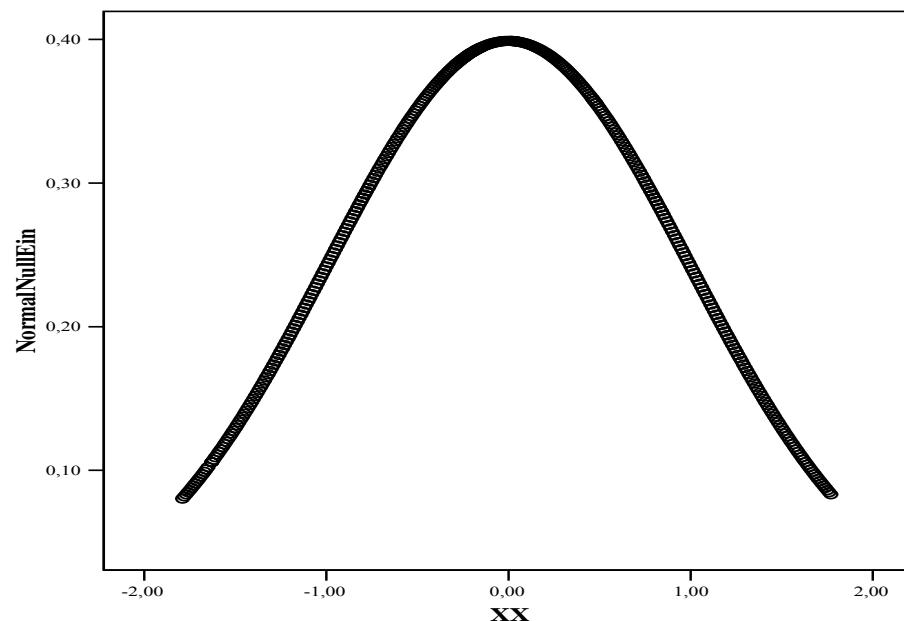
Variabel: fordelingsform I

- Symmetriske fordelingar
- Skeive fordelingar
 - ”Tunge” og ”lette” halar
- Normalfordelingar
 - Er ikke ”normale”
 - Er eintydig fastlagt av gjennomsnitt og standardavvik (μ og σ)

Haust 2004

© Erling Berge 2004

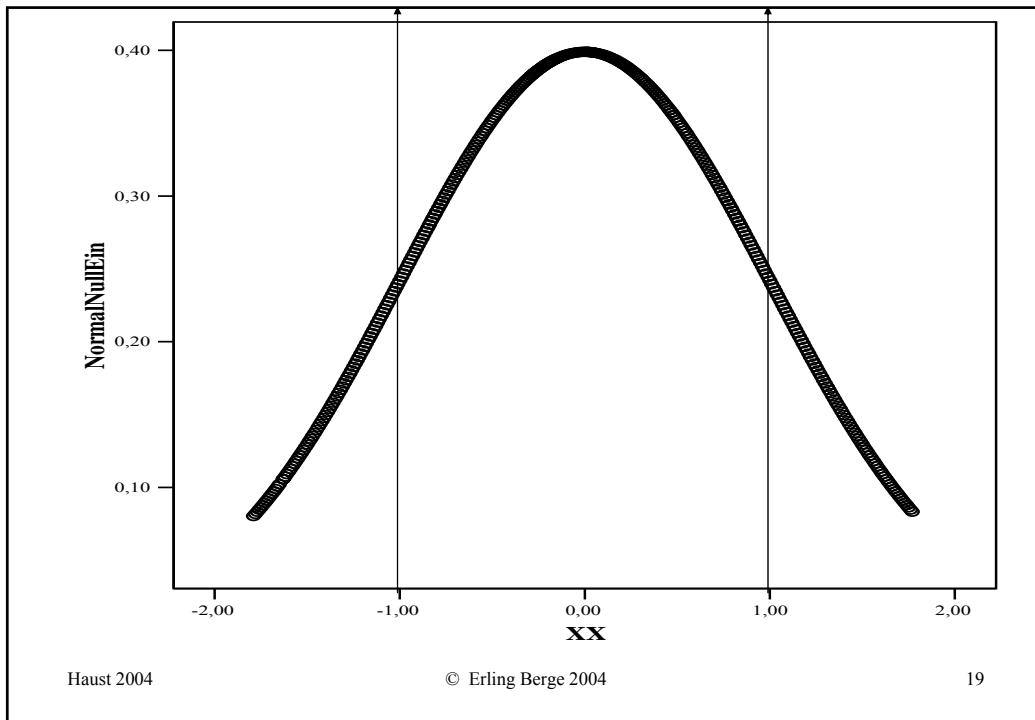
17



Haust 2004

© Erling Berge 2004

18



Skeive fordelingar

- Positivt skeive har $\tilde{Y} > M_d$
- Negativt skeive har $\tilde{Y} < M_d$
- Symmetriske fordelingar har $\tilde{Y} \approx M_d$

Symmetriske fordelingar

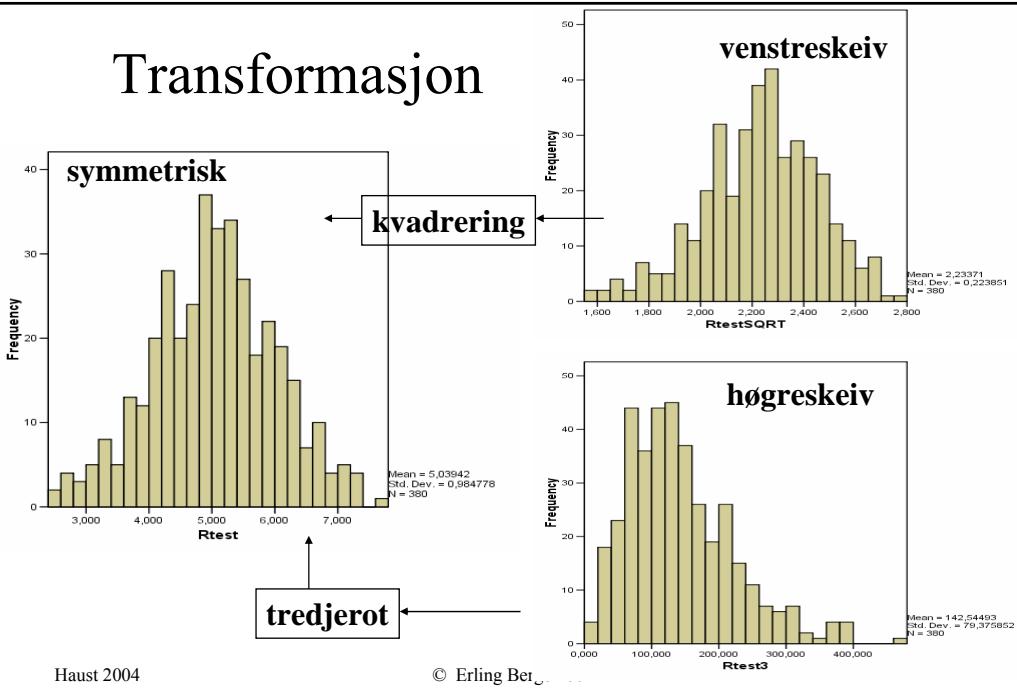
- Medianen og IQR er resistente mot verknader av ekstreme verdiar. Gjennomsnitt og standardavvik er det ikkje
- I normalfordelinga er $s_y \approx IQR/1.35$
- Dersom vi i ei symmetrisk fordeling finn
 - $s_y > IQR/1.35$ er halane tyngre enn i normalfordelinga
 - $s_y < IQR/1.35$ er halane lettare enn i normalfordelinga
 - $s_y \approx IQR/1.35$ er halane omlag slik som i normalfordelinga

Haust 2004

© Erling Berge 2004

21

Transformasjon



Haust 2004

© Erling Ber

Variabel: fordelingsanalyse I

- Boxplott
 - Basert på kvartilverdiane og interkvartilavviket
 - Definerer nærliggjande utliggarar som dei som ligg innanfor intervalla $\langle Q_1 - 1.5IQR, Q_1 \rangle$ og $\langle Q_3 + 1.5IQR, Q_3 \rangle$ og fjerntliggjande utliggarar dei som ligg utanfor grensene $\langle Q_1 - 1.5IQR, Q_3 + 1.5IQR \rangle$

Variablar: fordelingsform II

- Kvantilar er ei generalisering av kvartilar og percentilar
- Kvartilverdiane er variabelverdiane som svarar til gitte fraksjonar av det samla utvalet eller observasjonsmaterialet, t.d.
 - Medianen er 0.5 kvantilen (eller 50% percentilen)
 - Nedre kvartil er 0.25 kvantilen
 - 10% percentilen er 01 kvantilen osv.

Variabel: fordelingsanalyse II

- Kvantilplott
 - Kvantilverdi mot variabelverdi
 - Lorentzkurva er ein spesialvariant av dette (gir oss Gini-indeksen)
- Kvantil-Normalplott
 - Plott av kvantilverdiar på ein variabel mot kvantilverdiane i ei normalfordeling med same gjennomsnitt og spreiing

Eksempel: Frå Randaberg

- Spørreskjema: spørsmål X
- 27 ANTALL DEKAR GRUNN DU
eier: _____

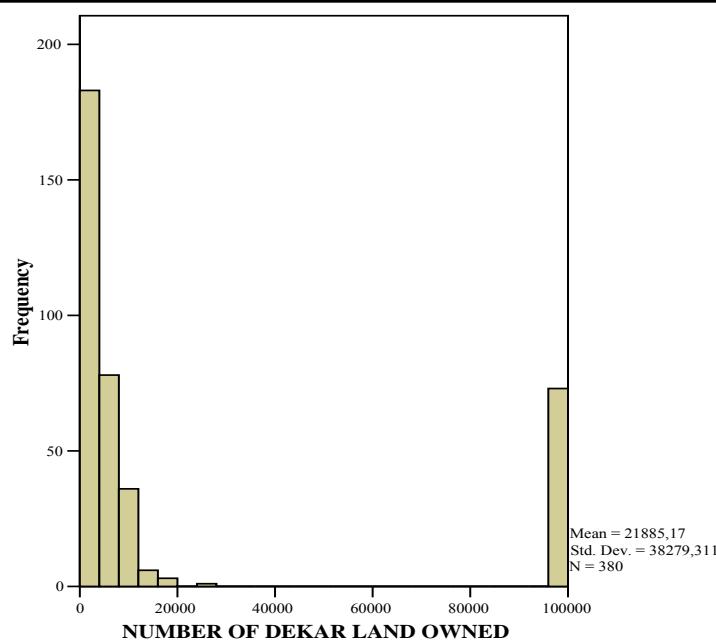
NUMBER OF DEKAR LAND OWNED

	NUMBER OF DEKAR LAND OWNED	Valid N (listwise)
N	380	380
Minimum	0	
Maximum	99900	
Mean	21885.17	
Std. Deviation	38279.311	

Haust 2004

© Erling Berge 2004

27



Haust 2004

© Erling Berge 2004

28

XAreaOwned

(NUMBER OF DEKAR LAND OWNED)

	XAreaOwned	Valid N (listwise)
N	307	307
Minimum	.00	
Maximum	25000.00	
Mean	3334.4104	
Std. Deviation	4201.54943	

Haust 2004

© Erling Berge 2004

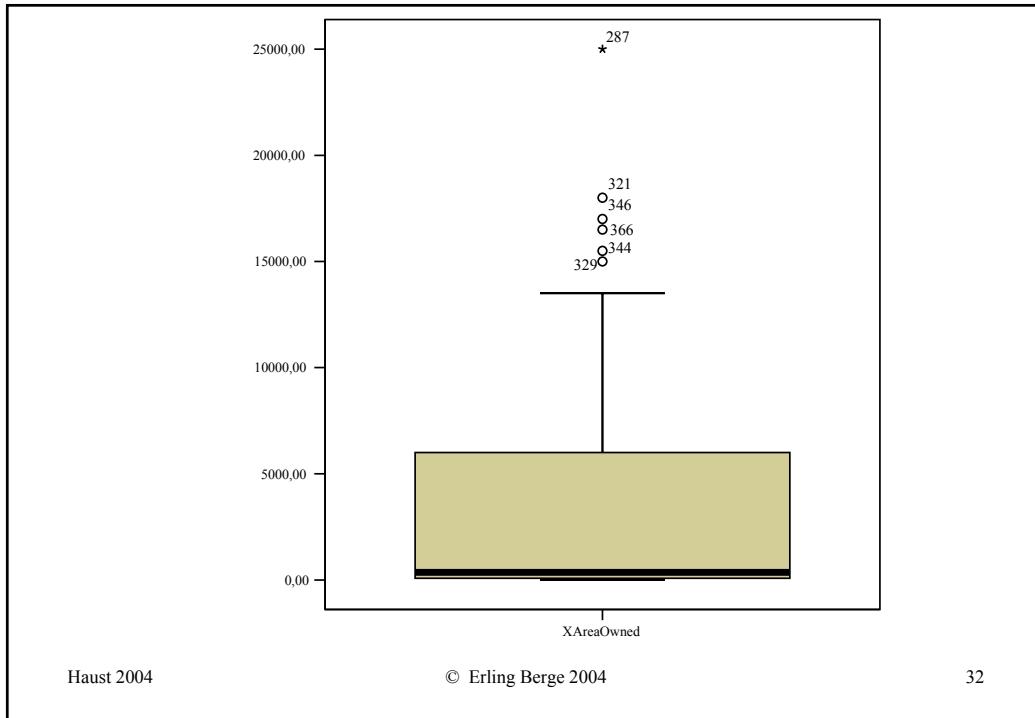
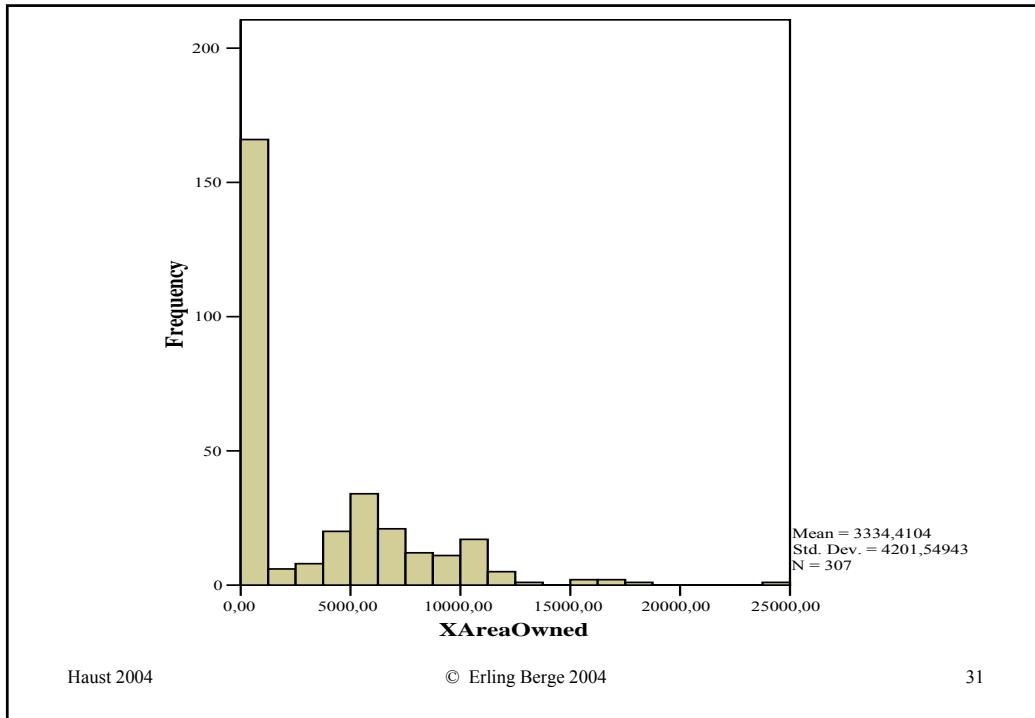
29

	Statistic	XAreaOwned	Valid N (listwise)
N	307	307	307
Range	25000.00		
Minimum	.00		
Maximum	25000.00		
Sum	1023664.00		
Mean	3334.4104		
	239.79509		
Std. Deviation	4201.54943		
Variance	17653017.596		
Skewness	1.352		
	.139		
Kurtosis	2.194		
	.277		

Haust 2004

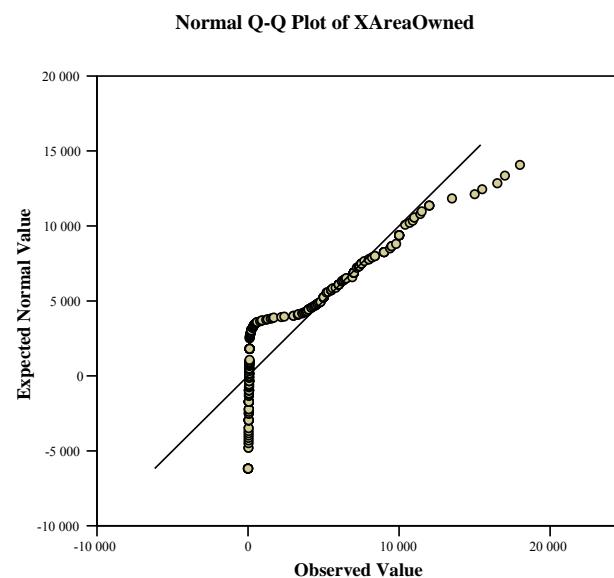
© Erling Berge 2004

30



NB

SPSS sine
figurar er
spegelvendt
i høve til
Hamilton
sine

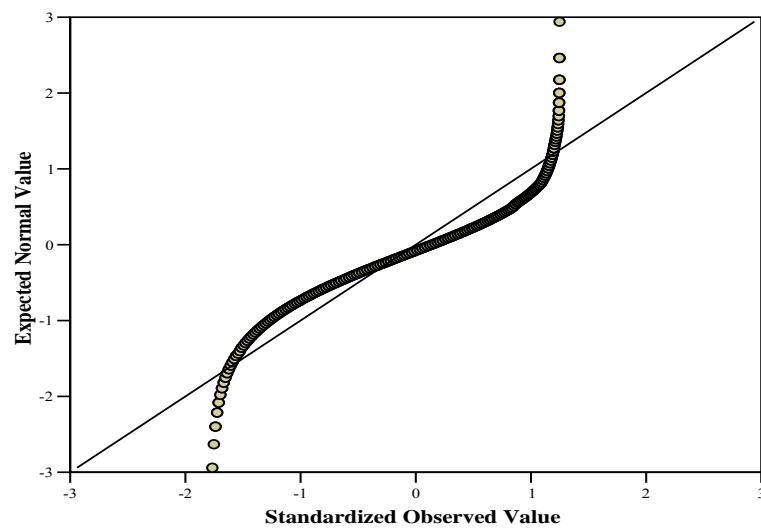


Haust 2004

© Erling Berge 2004

33

Normal Q-Q Plot of NormalNullEin



Haust 2004

© Erling Berge 2004

34

Spørreskjema: spørsmål Y

- Hvor viktig er det at myndighetene kontrollerer og regulerer bruken av arealer gjennom for eksempel kontroll av**
- av tomtetildelinger (kommunal formidl.)**

1	2	3	4	5	6	7	8
---	---	---	---	---	---	---	---
- avkjørsler fra hus til vei**

1	2	3	4	5	6	7	8
---	---	---	---	---	---	---	---
- kjøp og salg av landbrukseiendommer**

1	2	3	4	5	6	7	8
----------	----------	----------	----------	----------	----------	----------	----------

Haust 2004

© Erling Berge 2004

35

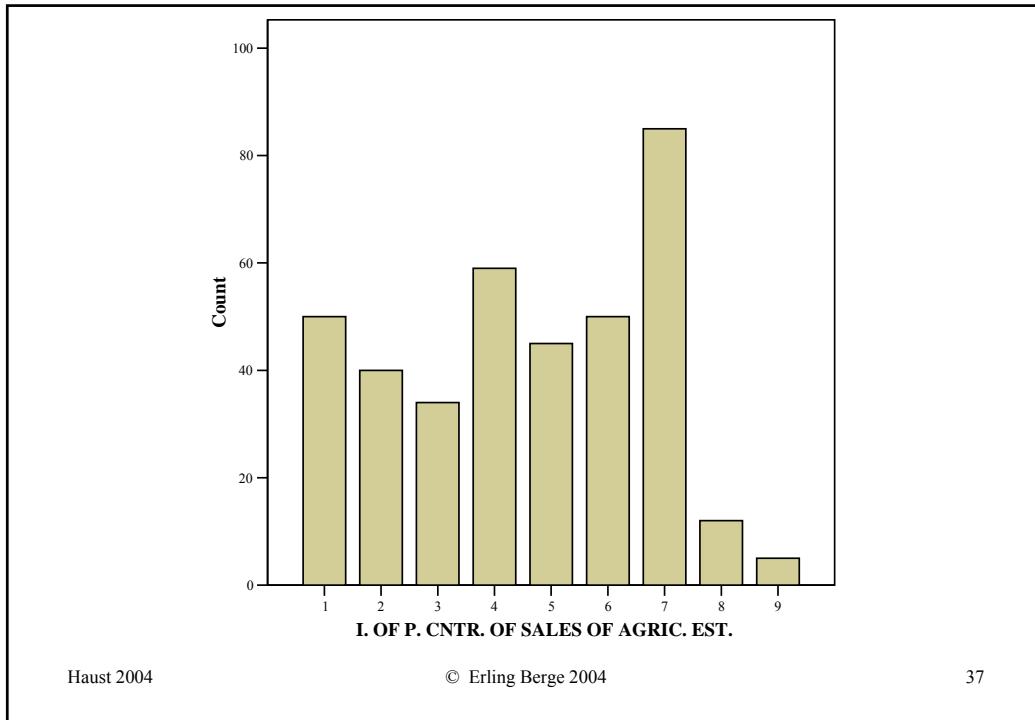
Importance of public control of sales of agric. estates

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	1	50	13.2	13.2	13.2
	2	40	10.5	10.5	23.7
	3	34	8.9	8.9	32.6
	4	59	15.5	15.5	48.2
	5	45	11.8	11.8	60.0
	6	50	13.2	13.2	73.2
	7	85	22.4	22.4	95.5
	8	12	3.2	3.2	98.7
	9	5	1.3	1.3	100.0
	Total	380	100.0	100.0	

Haust 2004

© Erling Berge 2004

36



Spørreskjema: koding

Ved utfylling: sett ring rundt et tall som synes å gi passelig uttrykk for viktigheten når 1 betyr svært lite viktig og 7 særdeles viktig, eller sett et kryss inne i parantesene () som står bak svaret du velger

På noen spørsmål kan du krysse av flere svar

	lykkes dårlig/ lite viktig					lykkes godt/ svært viktig	vet ikke
Kodeverdi	1	2	3	4	5	6	7

Dei som ikkje kryssar av noko svar vert koda 9

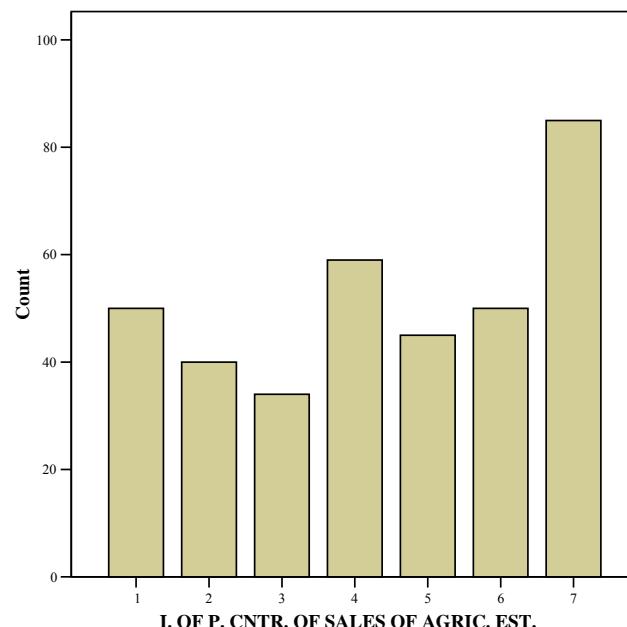
I. OF P. CNTR. OF SALES OF AGRIC. EST.

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	1	50	13.2	13.8	13.8
	2	40	10.5	11.0	24.8
	3	34	8.9	9.4	34.2
	4	59	15.5	16.3	50.4
	5	45	11.8	12.4	62.8
	6	50	13.2	13.8	76.6
	7	85	22.4	23.4	100.0
	Total	363	95.5	100.0	
Missing	8	12	3.2		
	9	5	1.3		
	Total	17	4.5		
Total		380	100.0		

Haust 2004

© Erling Berge 2004

39



Haust 2004

© Erling Berge 2004

40

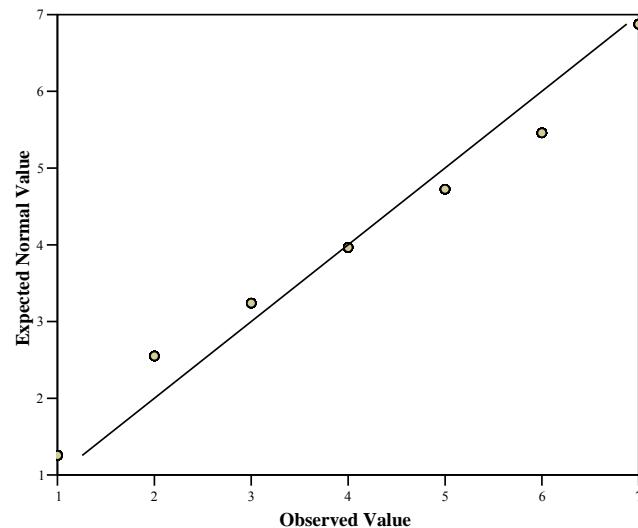
		I. OF P. CNTR. OF SALES OF AGRIC. EST.	YControlSalesAgricEstate Valid N (listwise)
N	Statistic	380	363
Range	Statistic	8	6.00
Minimum	Statistic	1	1.00
Maximum	Statistic	9	7.00
Sum	Statistic	1729	1588.00
Mean	Statistic	4.55	4.3747
	Std. Error	.114	.11045
Std. Deviation	Statistic	2.213	2.10435
Variance	Statistic	4.897	4.428
Skewness	Statistic	-.171	-.234
	Std. Error	.125	.128
Kurtosis	Statistic	-1.148	-1.267
	Std. Error	.250	.255

Haust 2004

© Erling Berge 2004

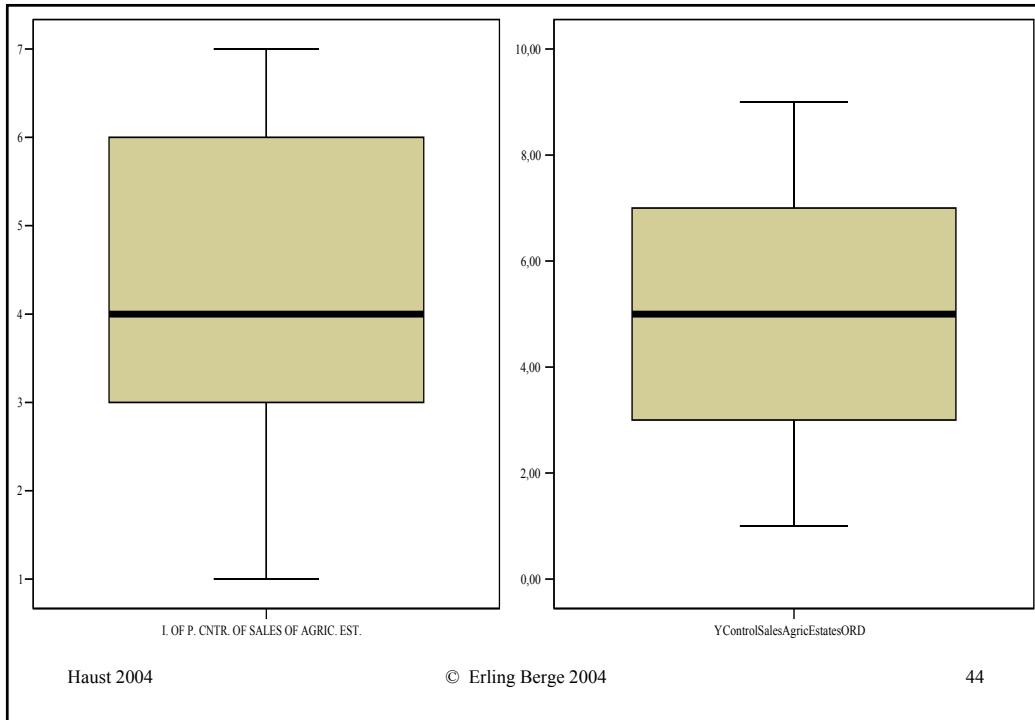
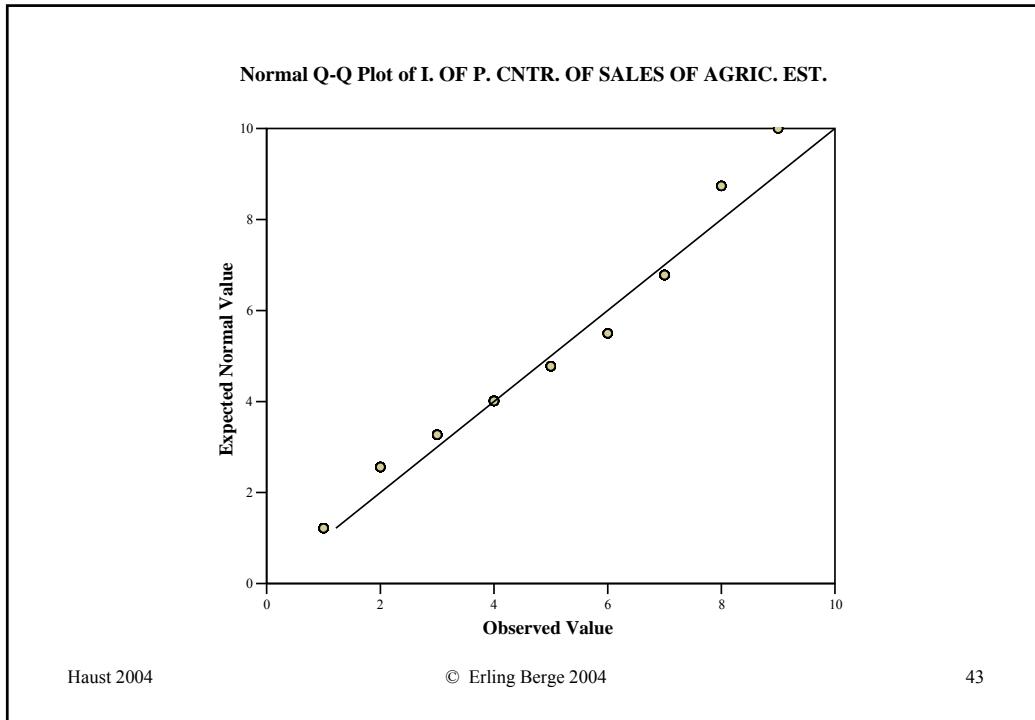
41

Normal Q-Q Plot of I. OF P. CNTR. OF SALES OF AGRIC. EST.



Haust 2004

42



Box-plott

- Boksen vert konstruert ut frå kvartilverdiane Q_1 og Q_3
- Nærliggjande store verdiar vert definert som dei som ligg utanfor boksen men innan for $Q_3 + 1.5 \cdot IQR$ eller $Q_1 - 1.5 \cdot IQR$
- Utliggjarar (alvorlege ekstremverdiar) er dei som ligg utanfor $Q_3 + 1.5 \cdot IQR$ eller $Q_1 - 1.5 \cdot IQR$

Haust 2004

© Erling Berge 2004

45

Om datainnsamling og datakvalitet

- Spørsmåla – teknikkane for å spørre vil vi ikkje diskutere
- Utvalet
 - Frå trekking til ferdig datamatrise, seleksjon, nekting og manglande svar
- Kva er viktig for kvaliteten av data?
 - Samanhengen mellom manglande observasjonar og fenomenet som vert studert
- Kva skal vi gjere når data er mangelfulle?

Haust 2004

© Erling Berge 2004

46

Formulering av modellar

- Definisjon av elementa i modellen
 - variablar, feilledd, populasjon og utval
- Definisjon av relasjonar mellom elementa
 - utvalsprosedyre, tidsrekkefølgje av hendingar og observasjonar, likninga som bind elementa saman
- Presisering av føresetnader for bruk av gitt estimeringsmetode
 - tilhøve til substanssteori (spesifikasjon)
 - fordeling og eigenskapar ved feilledd

Elementa i modellen

- Populasjon:
- Utval:
- Variablar:
- Feilledd:

Relasjonar mellom elementa

- Utvalsprosedyre: skeive (biased) utval
- Tidsrekkefølgje av hendingar og observasjonar
- Samvariasjon, genuin vs. spuriøs samvariasjon
 - Konklusjonar om kausalsamband krev genuin samvariasjon
- Likninga:

Bivariat Regresjon: Modell for populasjon

- $Y_i = \beta_0 + \beta_1 x_{1i} + \varepsilon_i$
- $i=1, \dots, n$ $n = \# \text{ case i populasjonen}$
- Y og X må definerast eintydig, og Y må ha målenivå intervallskala i ordinær regresjon

Bivariat Regresjon: Modell for utval

- $Y_i = b_0 + b_1 x_{1i} + e_i$
- $i=1,\dots,n$ $n = \# \text{ case i utvalet}$
- Y og X må definerast ein tydig, og Y må ha målenivå intervallskala eller høvestalskala (målevariabel) i ordinær regresjon

Regresjonseksempelet

- Eksempelet som følgjer inneholder ei rekke feil. Ein slik regresjon kvalifiserer til stryk
- Det blir lesaren si oppgåve å identifisere feila så fort som råd er, og så aldri gjere slike feil sjølv
- Tips: sjå tilbake på fordelingane av variablane ovanfor

Importance of public control of sales of agric. Estates Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.047(a)	.002	.000	2.213

a Predictors: (Constant), NUMBER OF DEKAR LAND OWNED

Importance of public control of sales of agric. Estates ANOVA(b)

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	4.145	1	4.145	.846	.358(a)
	Residual	1851.905	378	4.899		
	Total	1856.050	379			

a Predictors: (Constant), NUMBER OF DEKAR LAND OWNED

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

Importance of public control of sales of agric. Estates Coefficients(a)

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	4.610	.131		35.233	.000
	NUMBER OF DEKAR LAND OWNED	.000	.000	-.047	-.920	.358

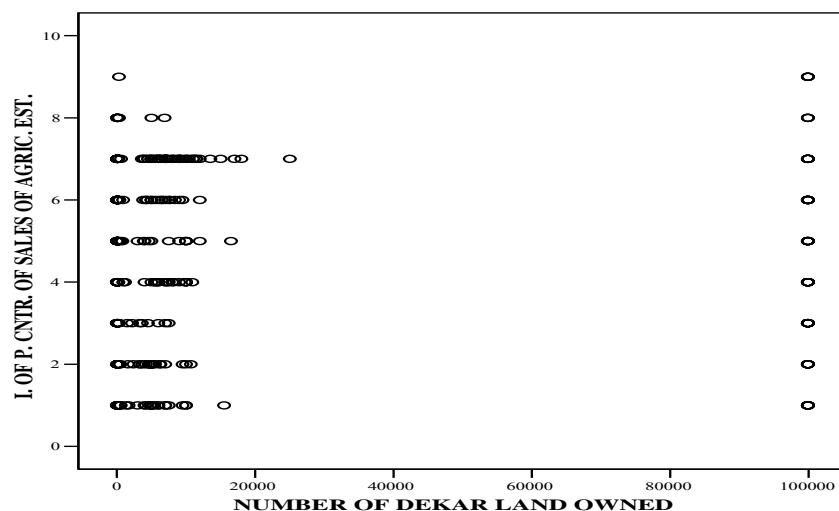
a Dependent Variable: I. OF P. CNTR. OF SALES OF AGRIC. EST.

Haust 2004

© Erling Berge 2004

55

Spreiingsdiagram

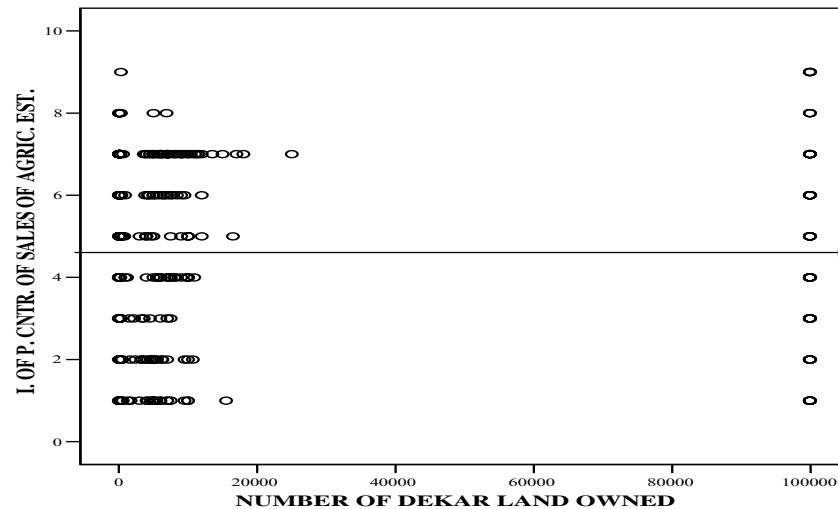


Haust 2004

© Erling Berge 2004

56

Spredningsdiagram med regresjonslinje



Haust 2004

© Erling Berge 2004

57

FØRESETNADER FOR OLS REGRESJON

OLS: ordinary least squares (minste kvadrat metoden)

Krava til regresjonsanalysen kan kort oppsummerast ved

- Vi føreset at den lineære modellen er korrekt med uavhengige og identisk normalfordelte feil ("normal i.i.d. errors")

Haust 2004

© Erling Berge 2004

58

OLS metoden

Observert feil

- $e_i = (Y_i - b_0 - b_1 x_{1i})$

Kvadrert og summert observert feil

- $\sum_i (e_i)^2 = \sum_i (Y_i - b_0 - b_1 x_{1i})^2$

Finn b_0 og b_1 som minimerer kvadratsummen

Tilhøvet utval - populasjon (1)

- Forventa verdi: vi skriv $E[*]$ der * står for eitt eller anna uttrykk som inneholdt minst ein variabel, t.d.
- $E[Y_i] = E[b_0 + b_1 x_{1i} + e_i]$
 $= \beta_0 + \beta_1 x_{1i}$
- $E[b_0] = \beta_0 ; E[b_1] = \beta_1 ; E[e_i] = \varepsilon_i$

Tilhøvet utval - populasjon (2)

- Tilhøvet utval - populasjon er fastlagt gjennom dei eigenskapane som feilleddet har fått gjennom utvalsprosedyren og observasjonsplanen
- Ved reint tilfeldige utval og fullstendig observasjon vil

$$E[\varepsilon_i] = 0 \text{ for alle } i, \text{ og}$$

$$\text{var}[\varepsilon_i] = \sigma^2 \text{ for alle } i$$

Fullstendig observasjon

- Gjer det mulig å sette opp ein fullstendig spesifisert modell. Dette tyder at alle variablar som kausalt påverkar det fenomenet vi studerer (Y) er observert, dvs. inkludert i likninga
- Dette er i praksis umogeleg. Derfor nyttar vi feilleddet til å samle opp uobserveerde faktorar

Hypotesetesting I

	I røynda er H_0 sann	I røynda er H_0 usann
Vi konkluderer med at H_0 er sann	Metoden gir rett konklusjon med sannsyn $1 - \alpha$	<u>Feil av type II</u> (sannsyn $1 - \beta$)
Vi konkluderer med at H_0 er usann	<u>Feil av type I</u> Testnivået α er sannsynet for feil av type I	β = styrken til testen

Haust 2004

© Erling Berge 2004

63

Hypotesetesting II

- Ein test er alltid konstruert ut frå føresetnaden at H_0 er rett
- Testkonstruksjonen fører fram til ein
 - **testobservator**
- Testobservatoren er konstruert slik at den har ei kjent sannsynsfordeling, ei
 - **samplingfordeling**

Haust 2004

© Erling Berge 2004

64

T-test og F-test

- Kvadratsummar
 - $TSS = ESS + RSS$
 - $RSS = \sum_i (e_i)^2 = \sum_i (Y_i - \hat{Y}_i)^2$ avstand observert – estimert verdi
 - $ESS = \sum_i (\hat{Y}_i - \bar{Y})^2$ avstand estimert verdi – gjennomsnitt
 - $TSS = \sum_i (Y_i - \bar{Y})^2$ avstand observert verdi – gjennomsnitt
 - Testobservator
 - $t = (\mathbf{b} - \boldsymbol{\beta}) / SE_{\mathbf{b}}$ $SE = \text{standard error}$
 - $F = [ESS/(K-1)]/[RSS/(n-K)]$ $K = \text{talet av parametrar}$

Testen sin p-verdi

- Testen sin p-verdi gir oss det estimerte sannsynet for å observere dei verdiane vi har i utvalet eller verdiar som er enno meir gunstige ut frå teorien om at H_0 er gal dersom utvalet vårt er reint tilfeldig trekt frå ein populasjon det H_0 er rett
 - Svært låge p-verdiar gjer at vi ikkje kan tru at H_0 er rett

Konfidensintervall for β

- Vel ein t_α - verdi frå tabellen over t-fordelinga med $n-K$ fridomsgrader slik at intervallet
 $b - t_\alpha(SE_b), b + t_\alpha(SE_b)$
 i ein tosidig test gir eit sannsyn på α for å gjere feil av type I
- Dette tyder at $b - t_\alpha(SE_b) \leq \beta \leq b + t_\alpha(SE_b)$ med sannsyn $1 - \alpha$

Determinasjonskoeffisienten

Determinasjonskoeffisienten:

- $R^2 = ESS/TSS = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 / \sum_{i=1}^n (Y_i - \bar{Y})^2$
 - Fortel kor stor del av variasjonen rundt gjennomsnittet vi ”forklarer” ved hjelp av variablane vi nyttar i regresjonen (\hat{Y}_i = predikert y)
- I bivariat regresjon er determinasjonskoeffisienten lik korrelasjonskoeffisienten: $r_{yu}^2 = s_{yu} / s_y s_u$
- Kovariansen $s_{yu} = \frac{1}{n-1} \sum_{i=1}^n (Y_i - \bar{Y})(U_i - \bar{U})$