

SOS3003
**Anvendt statistisk
dataanalyse i
samfunnsvitenskap**

Forelesingsnotat 11

Erling Berge
Institutt for sosiologi og statsvitenskap
NTNU

Fall 2004

© Erling Berge 2004

1

Forelesing XI

- Logistisk regresjon II
Hamilton Kap 7 s217-235

Fall 2004

© Erling Berge 2004

2

LOGIT REGRESJON eller LOGISTISK REGRESJON

- **Skal nyttast når avhengig variabel er på nominalnivå**
- Føreset at Y har verdiane 0 eller 1
- Modellen av den betinga forventninga til Y, $E[Y | X]$, nyttar den logistiske funksjonen
- Den lineære sannsynsmodellen (LPM) er substansielt sett feil modell

Den logistiske funksjonen

Den generelle logistiske funksjonen er

- $Y_i = \alpha / (1 + \gamma * \exp[-\beta X_i])$

$\alpha > 0$ gir den øvre grensa for Y, dvs vi har at $0 < Y < \alpha$

γ fastlegg det horisontale punkt for rask vekst

Set ein $\alpha = 1$ og $\gamma = 1$

Vil ein alltid ha

- $0 < 1 / (1 + \exp[-\beta X_i]) < 1$

Den logistiske funksjonen vil for alle verdiar av x ligge mellom 0 og 1

MODELL (1)

Definisjonar

- Sannsynet for at person i skal ha verdien 1 på variabelen Y_i skriv vi $\Pr(Y_i=1)$. Da er $\Pr(Y_i \neq 1) = 1 - \Pr(Y_i=1)$
- Oddsen for at person i skal ha verdien 1 på variabelen Y_i , her kalla O_i , er tilhøvet mellom to sannsyn:

$$O_i(y_i=1) = \frac{\Pr(y_i=1)}{1-\Pr(y_i=1)} = \frac{p_i}{1-p_i}$$

Fall 2004

© Erling Berge 2004

5

MODELL (2)

Definisjonar:

- LOGITEN , L_i , er den naturlege logaritmen til oddsen, O_i , for person i:

$$L_i = \ln(O_i)$$
- Modellen føreset at L_i er ein lineær funksjon av forklaringsvariablane x_j ,
- dvs:
- $L_i = \beta_0 + \sum_j \beta_j x_{ji}$, der $j=1,\dots,K-1$, og $i=1,\dots,n$

Fall 2004

© Erling Berge 2004

6

MODELL (3)

- Sett $X = (\text{samlinga av alle } x_j)$. Da er sannsynet for at $Y_i = 1$ for person nr i

$$\Pr(y_i = 1) = E[y_i | X] = \frac{1}{1 + \exp(-L_i)} = \frac{\exp(L_i)}{1 + \exp(L_i)}$$

$$\text{der } L_i = \beta_0 + \sum_{j=1}^{K-1} \beta_j X_{ji}$$

Grafen til dette sambandet er nyttig for tolkinga av kva ei endring i x tyder

Estimering ved ML metoden

- Metoden brukt for å estimere parametrane i modellen heiter Maximum Likelihood
- ML-metoden gir oss dei parametrane som maksimerer sannsynet (Likelihood) for å finne dei observasjonane vi faktisk har
- Dette sannsynet skal vi kalle \mathcal{L}
- Kriteriet for å velje regresjonsparametrar er at likelihooden (\mathcal{L}) skal vere størst mogeleg

Maximum Likelihood (1)

- Likelihooden er lik produktet av sannsynet for kvar einskild observasjon. For ein dikotom variabel der $\Pr(Y_i = 1) = P_i$ kan dette skrivast

$$\mathcal{L} = \prod_{i=1}^n \left\{ P_i^{Y_i} (1 - P_i)^{(1-Y_i)} \right\}$$

Maximum Likelihood (2)

- For lettare å kunne maksimere sannsynet \mathcal{L} tar ein den naturlege logaritmen til \mathcal{L} :

$$\ln(\mathcal{L}) = \sum_{i=1}^n \left\{ y_i \ln P_i + (1 - y_i) \ln(1 - P_i) \right\}$$

- Den naturlege logaritmen til \mathcal{L} kallar vi LogLikelihooden, Vi skriv det som \mathcal{LL} .
- \mathcal{LL} har ei sentral rolle i logistisk regresjon.

Maximum Likelihood (3)

- $\mathcal{L}\mathcal{L}$ er alltid negativ.
- Maksimering av $\mathcal{L}\mathcal{L}$ er derfor likeverdig med minimering av den positive LogLikelihooden dvs. minimering av $-\mathcal{L}\mathcal{L}$
- Å finne parameterverdiar som minimerer $-\mathcal{L}\mathcal{L}$ kan gjerast berre ved "prøving og feiling", gjennom ein iterativ prosedyre

Iterativ estimering

Estimeringa vart i dette høvet avslutta ved iterasjon nr 4 sidan parameterestimata endra seg med mindre enn 0,001.

From Hamilton Tabell 7.1	Iteration	-2 Log Likelihood	Coefficients	
			Constant	lived
Initial	0	209,212	,276	
Step	1	195,684	,376	-,034
	2	195,269	,455	-,041
	3	195,267	,460	-,041
	4	195,267	,460	-,041

Utgangspunktet er ein modell med konstantledd

Legg merke til kolonnen med tittel -2 LogLikelihood

Tolking (1)

- Skilnaden mellom den lineære modellen og den logistiske er stor i nærleiken av 0 og 1
- LPM er lett å tolke: $Y_i = \beta_0$ når $x_{1i} = 0$, og når x_{1i} veks med ei eining veks Y_i med β_1 eininger
- Logitmodellen er vanskelegare å tolke. Den er ikke-lineær både i høve til oddsen og sannsynet.

ODDS og ODDSRATER

- Logiten, L_i , ($L_i = \beta_0 + \sum_j \beta_j x_{ji}$) er definert som den naturlege logaritmen til oddsen.

Det tyder at

- **oddsen** = $O_i(Y_i=1) = \exp(L_i) = e^{L_i}$
og
- **oddsraten** = $O_i(Y_i=1|L'_i) / O_i(Y_i=1|L_i)$
– der L'_i og L_i har ulik verdi for ein $x_{j\cdot}$

Tolking (2)

- Når alle x er lik 0 er $L_i = \beta_0$. Det tyder at oddsen for at $y_i = 1$ i det høvet er $\exp\{\beta_0\}$
- Dersom ein held alle x -ane fast (set dei lik ein konstant) medan x_1 aukar med 1 vil oddsen for at $y_i = 1$ verte multiplisert med $\exp\{\beta_1\}$. Det tyder at den vil endre seg med $100(\exp\{\beta_1\} - 1) \%$
- Sannsynet $\Pr\{y_i = 1\}$ vil derimot endre seg med ein faktor som er påverka av alle elementa i logiten, alle effektar er interaksjonseffektar

FØRESETNADER

1. Modellen er korrekt spesifisert
 1. logiten er lineær i parametrane
 2. alle relevante variablar er med
 3. ingen irrelevante er med
2. x-variablane er målt utan feil
3. Observasjonane er uavhengige
 - Ikkje perfekt multikollinearitet
 - Ikkje perfekt diskriminering
 - Stort nok utval

FØRESETNADER som ikke kan testast

- Modellen er korrekt spesifisert
 - alle relevante variablar er med
 - x-variablane er målt utan feil
 - Observasjonane er uavhengige
- To vil teste seg sjølve
- Ikke perfekt multikollinearitet
 - Ikke perfekt diskriminering

Statistiske problem kan komme av

- For lite utval
- Høg grad av **multikollinearitet**
 - Fører til store standardfeil (usikre estimat)
 - Vert oppdaga og handtert på same måten som i OLS regresjon
- Høg grad av **diskriminering** (eller separasjon)
 - fører til store standardfeil (usikre estimat)
 - Vert oppdaga automatisk av SPSS

Diskriminering/ separasjon

- Problem med diskriminering dukkar opp når vi for ein gitt x-verdi får nesten perfekt prediksjon av y-verdien (nesten alle med ein gitt x-verdi har same y-verdi)
- I SPSS kan dette gi følgjande melding:

Warnings

- There is possibly a quasi-complete separation in the data. Either the maximum likelihood estimates do not exist or some parameter estimates are infinite.
- The NOMREG procedure continues despite the above warning(s). Subsequent results shown are based on the last iteration. Validity of the model fit is uncertain.

Diskriminering Hamilton tabell 7.5

- Odds for svakare krav er $44/202 = 0,218$ mellom kvinner utan småbarn
- Odds for svakare krav er $0/79 = 0$ mellom kvinner med småbarn
- Oddsraten er $0/0,218 = 0$ slik at $\exp\{b_{\text{kvinne}}\}=0$
- Dette tyder at $b_{\text{kvinne}} = \text{minus uendelig}$

	Kvinne utan små barn	Kvinne med små barn
Ikkje svakare krav	202	79
Svakare krav OK	44	0

LOGISTISK REGRESJON: TESTING (1)

To testar er aktuelle

- (1) Sannsynsratetesten "Likelihood ratio test"
 - Denne kan nyttast analogt med F-testen
- (2) Wald testen
 - Kvadratrota av denne kan nyttast analogt med t-testen

LOGISTISK REGRESJON: TESTING (2)

- Sannsynsratetesten :
- Differansen mellom **LogLikelihooden** ($\mathcal{L}\mathcal{L}$) til to nester modellar estimert på same datamaterialet kan nyttast til å teste to modellar mot kvarandre omlag som F observatoren i OLS regresjon
- Testen kan også nyttast på ein skildkoeffisientar. I små utval er den betre enn Wald-testen

LOGISTISK REGRESJON: TESTING (3)

Sannsynsrate testobservatoren

$$\square \chi^2_H = -2[\mathcal{L}\mathcal{L}(\text{modell1}) - \mathcal{L}\mathcal{L}(\text{modell2})]$$

vil, dersom nullhypotesa om ingen skilnad mellom modellane er rett, vere tilnærma (for store n) kjikvadratfordelt med fridomsgrader lik differansen i talet på parametrar i dei to modellane (H)

Eksempel på Sannsynsratetest

- Modell 1: berre konstant
- Modell 2: konstant pluss ein variabel
- $\chi^2_H = -2[\mathcal{L}\mathcal{L}(\text{modell1}) - \mathcal{L}\mathcal{L}(\text{modell2})]$
- Finn verdien av Kjikvadratet og talet på fridomsgrader
- Eks.: LogLikelihood (mod1) = 209,212/(-2)
- LogLikelihood (mod2) = 195,267/(-2)

Frå	
Tab 7.1:	
-2 Log	
likelihood	
209,212	
195,684	
195,269	
195,267	
195,267	

LOGISTISK REGRESJON: TESTING (4)

Waldtesten

- Wald (kjikvadrat) observatoren (oppgett av SPSS) = $t^2 = (b_k / SE(b_k))^2$ (t brukt av Hamilton)
- Observatoren $t = b_k / SE(b_k)$ vil kunne nyttast til testing av enkelte parametrar omlag som t-observatoren i OLS regresjon
- Gitt at nullhypotesa er rett vil t (for store n) i logistisk regresjon vere tilnærma normalfordelt
- Gitt at nullhypotesa er rett vil Wald observatoren (for store n) i logistisk regresjon vere tilnærma kjikvadratfordelt med df=1

Utdrag fra Hamilton Tabell 7.2

Iterasjon	-2 Log likelihood					
0	209,212					
1	152,534					
2	149,466					
3	149,382					
4	149,382					
5	149,382					
Variables	B	S.E.	Wald	df	Sig.	Exp(B)
Lived	-,046	,015	9,698	1	,002	,955
Educ	-,166	,090	3,404	1	,065	,847
Contam	1,208	,465	6,739	1	,009	3,347
Hsc	2,173	,464	21,919	1	,000	8,784
Constant	1,731	1,302	1,768	1	,184	5,649

Konfidensintervall for parameterestimat

- Konfidensintervall for parameterestimat kan konstruerast ut frå at kvadratrota av Wald-observatoren med 1 fridomsgrad er tilnærma normalfordelt (sjå bilde 9)
- $b_k - t_{\alpha} * SE(b_k) < \beta_k < b_k + t_{\alpha} * SE(b_k)$
der t_{α} er tabellverdien teken frå **normalfordelinga** med signifikansnivå α

Konfidensintervall basert på t-fordelinga (1)

- I mangel av tabellar over normalfordeling kan ein gjere seg nytte av at **t-fordelinga** er tilnærma lik normalfordelinga ved store $n-K$ (t.d. $n-K > 120$)

Utdrag frå Hamilton Tabell 7.3

		B	S.E.	Wald	df	Sig.	Exp(B)
Step 1	lived	-,047	,017	7,550	1	,006	,954
	educ	-,206	,093	4,887	1	,027	,814
	contam	1,282	,481	7,094	1	,008	3,604
	hsc	2,418	,510	22,508	1	,000	11,223
	female	-,052	,557	,009	1	,926	,950
	kids	-,671	,566	1,406	1	,236	,511
	nodad	-2,226	,999	4,964	1	,026	,108
	Constant	2,894	1,603	3,259	1	,071	18,060

Fall 2004

© Erling Berge 2004

29

Meir om Hamilton Tabell 7.3

Iteration		-2 Log likelihood	Coefficients							
			Const	lived	educ	contam	hsc	female	kids	nodad
Step0		209,212	-0,276							
Step1	1	147,028	1,565	-,027	-,130	,782	1,764	-,015	-,365	-1,074
	2	141,482	2,538	-,041	-,187	1,147	2,239	-,037	-,580	-1,844
	3	141,054	2,859	-,046	-,204	1,269	2,401	-,050	-,662	-2,184
	4	141,049	2,893	-,047	-,206	1,282	2,418	-,052	-,671	-2,225
	5	141,049	2,894	-,047	-,206	1,282	2,418	-,052	-,671	-2,226

Fall 2004

© Erling Berge 2004

30

Er modellen i tabell 7.3 betre enn modellen i tabell 7.2 ?

- $\mathcal{LL}(\text{modell i 7.3}) = 141,049/(-2)$
- $\mathcal{LL}(\text{modell i 7.2}) = 149,382/(-2)$

- $\chi^2_H = -2[\mathcal{LL}(\text{modell i 7.2}) - \mathcal{LL}(\text{modell i 7.3})]$
- Finn χ^2_H verdien
- Finn H
- Slå opp i tabellen over kjikvadratfordelinga

Modellen av sannsynet for at vi skal observere $y=1$ for person i

$$\Pr(y_i = 1) = E[y_i | x] = \frac{1}{1 + \exp(-L_i)} = \frac{\exp(L_i)}{1 + \exp(L_i)}$$

der logiten $L_i = \beta_0 + \sum_{j=1}^{K-1} \beta_j X_{ji}$ er ein lineær funksjon
av forklaringsvariablane

Ut frå formelen er det ikkje lett å tolke kva
koeffisientane β tyder

Oddsrate

- Oddsrate, O , kan tolkast som den **relative effekten** av å ha **ein** variabelverdi heller enn ein annan
- t.d. dersom $x_{ki} = t+1$ i L_i' og $x_{ki} = t$ i L_i
- $O = O_i(Y_i=1|L_i')/O_i(Y_i=1|L_i)$
 $= \exp[L_i']/\exp[L_i]$
 $= \exp[\beta_k]$
- Kvifor β_k ?

Oddsrate: eksempel I

- Oddsen for å svare ja =
 $e^{b_0+b_1*Alder+b_2*Kvinne+b_3*E.utd+b_4*Barn_i_HH}$
- Oddsrate for å svare ja mellom kvinner og menn =

$$\frac{e^{b_0+b_1*Alder+b_2*1+b_3*E.utd+b_4*Barn_i_HH}}{e^{b_0+b_1*Alder+b_2*0+b_3*E.utd+b_4*Barn_i_HH}} = e^{b_2}$$

Hugs reknereglane for potensar

Oddsrate: eksempel II

- Oddsrate for å svare ja for eit års tilvekst i utdanning

$$\frac{e^{b_0 + b_1 * Alder + b_2 * Kvinne + b_3 * (E.utd + 1) + b_4 * Barn_i_HH}}{e^{b_0 + b_1 * Alder + b_2 * Kvinne + b_3 * E.utd + b_4 * Barn_i_HH}} = e^{b_3}$$

Hugs reknereglane for potensar

Fall 2004

© Erling Berge 2004

35

Eksempel frå Hamilton tabell 7.2

- Kva er oddsrate for å gå inn for å stengje skolen ved eitt års auke i skolegangen?
- Oddsrate er kvotienten mellom to odds der den eine er oddsen for den som har eitt år meir utdanning

$$\frac{e^{b_0 + b_1 * \text{ÅrBuddIByen} + b_2 * (\text{Utdanning} + 1) + b_3 * \text{UreiningEigEigedom} + b_4 * \text{MangeHSCmøter}}}{e^{b_0 + b_1 * \text{ÅrBuddIByen} + b_2 * \text{Utdanning} + b_3 * \text{UreiningEigEigedom} + b_4 * \text{MangeHSCmøter}}} = e^{b_2}$$

Oddsrate = $\text{Exp}\{b_2\} = \exp(-0,166) = 0,847$

Eitt ekstra år utdanning fører til at oddsen vert redusert med ein faktor 0,847

Ein kan og seie at oddsen "aukar" med $100(0,847 - 1)\% = -15,3\%$ (dvs. minkar med 15,3%)

Fall 2004

© Erling Berge 2004

36

BETINGA EFFEKT PLOTT

- Gi faste verdiar til alle x variablar unntake ein, t.d. variabel x_k og set desse inn i likninga for logiten
- Plott $\text{Pr}(Y=1)$ som funksjon av x_k , dvs
- $P = 1/(1+\exp[-L]) = 1/(1+\exp[-\text{konst} - b_k x_k])$ for rimelege verdiar av x_k
"konst" er konstanten ein får ved innsetting i logiten av dei valde faste variabelverdiane

Fall 2004

© Erling Berge 2004

37

Utdrag frå Hamilton Tabell 7.4

	B	S.E.	Wald	df	Sig.	Exp(B)	Minimum	Maximum	Mean
lived	-.040	.015	6,559	1	,010	,961	1,00	81,00	19,2680
educ	-.197	,093	4,509	1	,034	,821	6,00	20,00	12,9542
contam	1,299	,477	7,423	1	,006	3,664	,00	1,00	,2810
hsc	2,279	,490	21,591	1	,000	9,763	,00	1,00	,3072
nodad	-1,731	,725	5,696	1	,017	,177	,00	1,00	,1699
Constant	2,182	1,330	2,692	1	,101	8,866			

Logiten:

$$L = 2.182 - 0.04 * \text{lived} - 0.197 * \text{educ} + 1.299 * \text{contam} + 2.279 * \text{hsc} - 1.731 * \text{nodad}$$


Her lar vi "lived" variere og set inn høveleg valde verdiar for dei andre

Fall 2004

© Erling Berge 2004

38

Betinga effekt plott frå Hamilton tabell 7.4 (fig7.5)
effekten av å bu lenge i byen




Fall 2004

© Erling Berge 2004

39

Betinga effekt plott frå Hamilton tabell 7.4 (fig7.6)
effekten av ureining på eigen eigedom



Fall 2004

© Erling Berge 2004

40

Determinasjonskoeffisientar

- I logistiske regresjonsmodellar finst ikkje mål tilsvarande determinasjonskoeffisienten i OLS regresjon
- Fleire analoge mål har vore foreslått
- Dei er vert ofte kalla pseudo R²
- Hamilton nyttar Aldrich og Nelson sitt

$$\text{pseudo } R^2 = \chi^2 / (\chi^2 + n)$$

der χ^2 = testobservatoren for testen av heile modellen mot ein modell med berre konstant, og
 n = er talet på case

Fall 2004

© Erling Berge 2004

41

Ulike pseudo R² i SPSS

- SPSS rapporterer Cox og Snell, Nagelkerke, og i multinomisk logistisk regresjon også McFadden sine framlegg til R²
- Aldrich og Nelson sitt kan vi rekne ut sjølv

Model Summary

Step	-2 Log likelihood	Cox & Snell R Square	Nagelkerke R Square
1	***	***	***

Pseudo R-Square	
Cox and Snell	***
Nagelkerke	***
McFadden	***

Fall 2004

© Erling Berge 2004

42