

SOS3003
**Anvendt statistisk
dataanalyse i
samfunnsvitenskap**

Forelesingsnotat 12

Erling Berge
Institutt for sosiologi og statsvitenskap
NTNU

Fall 2004

© Erling Berge 2004

1

Forelesing XII

- Logistisk regresjon III
Hamilton Kap 7 s235-242

Fall 2004

© Erling Berge 2004

2

LOGISTISK REGRESJON: FØRESETNADER

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

Fall 2004

© Erling Berge 2004

3

FØRESETNADER som ikkje 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
- Ikkje perfekt multikollinearitet
 - Ikkje perfekt diskriminering

Fall 2004

© Erling Berge 2004

4

FØRESETNADER som kan testast

- Modellspesifikasjonen
 - logiten er lineær i parametrane
 - ingen irrelevante er med
- Stort nok utval
 - Kva som er stort nok vil avhenge av kor mange ulike mønster det er i utvalet og korleis casa fordeler seg på desse
- Testinga impliserer vurdering av om statistiske problem fører til brot på føresetnadene

Fall 2004

© Erling Berge 2004

5

LOGISTISK REGRESJON

Statistiske problem kan komme av

- For lite utval
 - Td. Kan det gjere at ein skildcase får stor innverknad
- Høg grad av **multikollinearitet**
 - Fører til store standardfeil (usikre estimat)
 - Vert oppdaget og handtert på same måten som i OLS regresjon
- Høg grad av **diskriminering** (eller separasjon)
 - fører til store standardfeil (usikre estimat)
 - Vert oppdaget automatisk av SPSS

Fall 2004

© Erling Berge 2004

6

Statistiske problem: linearitet i logiten?

- Kurvelinearitet i logiten kan gi skeive parameterestimat
- Spreiingsplott for y-x er lite informative sidan y berre har to verdiar
- For å teste om Logiten er lineær i ein x-variabel kan vi gjere følgjande
 - Gruppere x-variabelen
 - For kvar gruppe finne y-gjennomsnitt og rekne det om til logit
 - Lag ein graf av logitane mot gruppert x

Definisjonar I

- Sannsynet for at person i skal ha verdien 1 på variabelen Y 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:

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

Definisjonar II

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

$$L_i = \ln(O_i) = \ln(p_i / (1-p_i))$$
- Modellen føreset at L_i er ein lineær funksjon av forklaringsvariablane x_j ,
 • dvs:


$$L_i = \beta_0 + \sum_j \beta_j x_{ji} , \text{ der } j=1,\dots,K-1, \text{ og } i=1,\dots,n$$

Fall 2004

© Erling Berge 2004

9

$Y = \text{Lukke skolen mot } x = \text{år budd i byen}$



Fall 2004

© Erling Berge 2004

10

Linearitet i logiten: eksempel

| SCHOOLS SHOULD CLOSE | | YEARS LIVED IN WILLIAMSTOWN (Banded) | | | | | | |
|----------------------------|-------------|--------------------------------------|-----|-------|--------|--------|--------|--------|
| | | <= 3 | 4-6 | 7-11 | 12-22 | 23-33 | 34-44 | 45+ |
| | | | | | | | | |
| N | OPEN | 7 | 14 | 7 | 22 | 11 | 13 | 13 |
| N | CLOSE | 13 | 14 | 10 | 17 | 8 | 2 | 2 |
| Within group | Mean (=p) | ,65 | ,50 | ,59 | ,44 | ,42 | ,13 | ,13 |
| Logit | Ln(p/(1-p)) | 0,619 | 0 | 0,364 | -0,241 | -0,323 | -1,901 | -1,901 |


Fall 2004

© Erling Berge 2004

11

Er
logiten
lineær i
"år
budd i
byen"?

Tja,
kanskje
det.



Fall 2004

© Erling Berge 2004

12

Ved kurvelinearitet er ikkje oddsraten konstant

La logiten vere kurvelineær i utdanning. Da er oddsraten for å svare ja ved eit års tilvekst i utdanning:

$$\frac{e^{b_0 + b_a * Alder + b_k * Kvinne + b_{utd} * (E.utd + 1) + b_{utd2} * (E.utd + 1)^2}}{e^{b_0 + b_a * Alder + b_k * Kvinne + b_{utd} * E.utd + b_{utd2} * E.utd^2}} = \frac{e^{b_{utd} + b_{utd2} * (E.utd^2 + 2E.utd + 1)}}{e^{b_{utd2} * E.utd^2}} = \frac{e^{b_{utd} + b_{utd2} * (2E.utd + 1)}}{e^0} = e^{b_{utd} + b_{utd2} * (2E.utd + 1)}$$

Hugs reknerreglane for potensar

Fall 2004

© Erling Berge 2004

13

Statistiske problem: påverknad

- Påverknad frå utliggjarar og uvanlege x-verdiar er like problematisk i logistisk regresjon som i OLS regresjon
- Transformasjon av x-variablar til symmetri vil minimere innverknaden til ekstreme variabelverdiar
- Store residualar er indikator på stor innverknad

Fall 2004

© Erling Berge 2004

14

Påverknad: residualar

- Det finst ulike måtar å standardisere residualar på:
 - "Pearsonresidualar" og
 - "Avviksresidualar"
- Påverknad kan baserast på
 - Pearsonresidualen
 - Avviksresidualen
 - Leverage (potensiale for påverknad): dvs. observatoren h_j

Fall 2004

© Erling Berge 2004

15

Diagnosegrafar

Utliggjarplott kan baserast på plott av estimert sannsyn for $Y_i=1$ (estimert P_i) mot

- Delta B , ΔB_j , eller
- Delta Pearson Kjikvadratet, $\Delta \chi^2_{P(j)}$, eller
- Delta Avviks Kjikvadratet, $\Delta \chi^2_{D(j)}$

Fall 2004


© Erling Berge 2004

16

SPSS output

- **Cook's = delta B hos Hamilton**
 - The logistic regression analog of Cook's influence statistic. A measure of how much the residuals of all cases would change if a particular case were excluded from the calculation of the regression coefficients.
- **Leverage Value = h hos Hamilton**
 - The relative influence of each observation on the model's fit.
- **DfBeta(s) er ikke nytta av Hamilton i logistisk regresjon**
 - The difference in beta value is the change in the regression coefficient that results from the exclusion of a particular case. A value is computed for each term in the model, including the constant.

Delta B



SPSS output frå "Save" (1)

- **Unstandardized Residuals.**
 - The difference between an observed value and the value predicted by the model.
- **Logit Residual.** (ukjen tolking)
 - Den storleiken programmet rapporterer er ikkje i samsvar med dokumentasjonen

SPSS output frå "Save" (2)

- **Standardized = Pearson residual**
 - På komandoen "standardized" vil SPSS skrive ut noko som vert kalla **ZRE_1** (normalized residual)
 - Dette er det same som Pearson residualen hos Hamilton
- **Studentized = [SQRT(delta avvikskjikvadrat)]**
 - På komandoen "Studentized" vil SPSS skrive ut noko det kallar **SRE_1** (standard residual)
 - Dette er det same som kvadratrota av "delta Avvikskjikvadrat" hos Hamilton, dvs. "delta Avvikskjikvadrat" = $(SRE_1)^2$
- **Deviance = Avviksresidual**
 - På komandoen "Deviance" vil SPSS skrive ut noko det kallar **DEV_1** (Deviance value)
 - Dette er det same som avviksresidualen hos Hamilton

Utrekning av $\Delta\chi^2_{P(i)}$

- Med utgangspunkt i dei storleikane SPSS gir oss kan vi rekne ut "delta Pearson-kjikvadratet"
- Der det står r_j i formelen set vi inn ZRE_1 og der det står h_j set vi inn LEV_1


$$\Delta\chi^2_{P(j)} = \frac{r_j^2}{(1 - h_j)}$$

Utrekning av $\Delta\chi^2_{D(i)}$

Med utgangspunkt i dei storleikane SPSS gir oss kan vi rekne ut "delta Avvikskjikvaratet"

- For å finne "delta avvikskjikvadratet" $\Delta\chi^2_{D(j)} = SRE_1 * SRE_1$ kvadrerer vi SRE_1
- Alternativt set vi inn $d_i = DEV_1$ og $h_i = LEV_1$ i formelen $\Delta\chi^2_{D(j)} = \frac{d_j^2}{(1 - h_j)}$

DeltaAvviksKjikvadrat (m/CaseNO)




Fall 2004

© Erling Berge 2004

23

DeltaAvviksKjikvadrat (m/delta B)




Fall 2004

© Erling Berge 2004

24

Delta Pearson KjiKvadrat (m/CaseNO)




Fall 2004

© Erling Berge 2004

25

Delta Pearson KjiKvadrat (m/ delta B)



Fall 2004

© Erling Berge 2004

26

Case med stor innverknad

| Variables | Case No 96 | Case No 65 | Case No 99 |
|----------------|-------------|------------|------------|
| Y=close | 1,00 | ,00 | ,00 |
| lived | 68,00 | 40,00 | 1,00 |
| educ | 12,00 | 12,00 | 12,00 |
| contam | ,00 | 1,00 | 1,00 |
| hsc | ,00 | 1,00 | 1,00 |
| nodad | ,00 | ,00 | ,00 |
| PRE_1 | ,05 | ,86 | ,97 |
| COO_1 | ,64 | ,34 | ,41 |
| RES_1 | ,95 | -,86 | -,97 |
| SRE_1 | 2,46 | -2,04 | -2,62 |

| Variables | Case No 96 | Case No 65 | Case No 99 |
|-------------------|------------|------------|------------|
| ZRE_1 | 4,21 | -2,48 | -5,36 |
| DEV_1 | 2,42 | -1,98 | -2,61 |
| DFB0_1 | -,32 | ,01 | -,36 |
| DFB1_1 | ,01 | ,00 | ,00 |
| DFB2_1 | ,02 | ,01 | ,02 |
| DFB3_1 | -,08 | -,15 | -,18 |
| DFB4_1 | -,06 | -,17 | -,19 |
| DFB5_1 | -,08 | ,16 | ,14 |
| DeltaPearsonKjiKv | 18,34 | 6,47 | 29,20 |
| DeltaAvviksKjiKv | 6,07 | 4,14 | 6,89 |

Frå Case til Mønster

- Figurane ovanfor er ikkje identisk med Hamilton sine figurar
- Hamilton har korrigert for effekten av identiske mønster

Påverknad ved felles mønster av x-variablar

- I logistisk regresjon med få variablar vil mange case ha dei same verdiane på alle x-variablane. Kvar kombinasjon av x-variabel verdiar kallar vi eit mønster.
- Når mange case har same mønster, kan kvart case ha liten innverknad medan dei samla kan ha uvanleg stor innverknad på parameterestimata
- Påverknadsrike mønster i x verdiane kan dermed gi skeive parameterestimat

Påverknad: Mønster i x-verdiar

- Predikert verdi, og dermed residualen vil vere lik for alle case som har same mønster
- Påverknad frå mønster j kan finnast ved hjelp av
 - Frekvensen til mønsteret
 - Pearsonresidualen
 - Avviksresidualen
 - Leverage: dvs. observatoren h_j

Finne X-Mønster ved hjelp av SPSS

- I "Data" – menyen finn vi kommandoen "Identify duplicate cases"
- Marker dei x-variablane som skal nyttast i modellen og flytt dei til "Define matching cases by"
- Kryss av for "Sequential count of matching cases in each group" og "Display frequencies for created variables"
- Dette lagar to nye variablar. Den eine, "MatchSequence", nummerer sekvensielt 1, 2, ... der fleire mønster er identiske. Der mønsteret er unikt får variabelen verdien 0.
- Den andre variabelen "Primary..." har verdien 0 for duplikat og 1 for unike mønster

Fall 2004

© Erling Berge 2004

31

X-Mønster i SPSS i Hamilton s238-242

| | Frequency | Percent | Valid Percent | Cumulative Percent |
|------------------------------------|------------|--------------|---------------|--------------------|
| Duplicate Case | 21 | 13,7 | 13,7 | 13,7 |
| Primary Case | 132 | 86,3 | 86,3 | 100,0 |
| Total | 153 | 100,0 | 100,0 | |
| Sequential count of matching cases | Frequency | Percent | Valid Percent | Cumulative Percent |
| 0 [115 mønster med 1 case] | 115 | 75,2 | 75,2 | 75,2 |
| 1 [17 mønster med 2 eller 3 case] | 17 | 11,1 | 11,1 | 86,3 |
| 2 [17 – 4=13 mønster med 2 case] | 17 | 11,1 | 11,1 | 97,4 |
| 3 [4 mønster med 3 case] | 4 | 2,6 | 2,6 | 100,0 |
| Total | 153 | 100,0 | 100,0 | |

Fall 2004

© Erling Berge 2004

32

Hamilton tabell 7.6 Symbolbruk

| | |
|-------------|--|
| J | Talet av unike mønster av x-verdiar i data ($J \leq n$) |
| m_j | Talet av case med mønsteret j ($m \geq 1$) |
| \hat{P}_j | Predikert sannsyn for $Y=1$ for case med mønster j |
| Y_j | Sum av y-verdiar for case med mønster j (=talet av case med mønster j og $y=1$) |
| r_j | Pearsonresidual for mønster j |
| χ_P^2 | Pearsonkjikkvadrat observator |
| d_j | Avviksresidual for mønster j |
| χ_D^2 | Avvikskjikkvadrat observator |
| h_i | Leverage for case i |
| h_j | Leverage for mønster j |

Fall 2004

© Erling Berge 2004

33

Nye verdiar for $\Delta\chi^2_{P(i)}$ og $\Delta\chi^2_{D(i)}$

- Ved "Compute" kan ein no rekne ut Pearson residualen (formel 7.19 i Hamilton) og delta Pearson kjikkvadratet (formel 7.24 i Hamilton) på nytt og vil da finne korrigerte verdiar
- Tilsvarande kan gjerast for avviksresidualen (formel 7.21) og delta avvikskjikkvadratet (formel 7.25a)

Fall 2004

© Erling Berge 2004

34

Leverage og residualar (1)

- Leverage til eit mønster finn vi som talet av case med mønsteret gonger leverage for eit av casa med mønsteret. Leverage for eit case er det same som i OLS regresjonen
- $h_j = m_j * h_i$
- Pearson residualen finn vi som

$$r_j = \frac{Y_j - m_j \hat{P}_j}{\sqrt{m_j \hat{P}_j (1 - \hat{P}_j)}}$$

Fall 2004

© Erling Berge 2004

35

Leverage og residualar (2)

- Avviksresidualen finn vi som

$$d_j = \pm \sqrt{\left\{ 2 \left[Y_j \ln \left(\frac{Y_j}{m_j \hat{P}_j} \right) + (m_j - Y_j) \ln \left(\frac{m_j - Y_j}{m_j (1 - \hat{P}_j)} \right) \right] \right\}}$$

Fall 2004

© Erling Berge 2004

36

To Kji-kvadrat observatorar

- Pearson Kji-kvadrat observatoren
- Avviks kjikvadrat observatoren
- Formlane er dei same anten vi reknar case eller mønster

$$\chi_P^2 = \sum_{j=1}^J r_j^2$$

$$\chi_D^2 = \sum_{j=1}^J d_j^2$$

Fall 2004

© Erling Berge 2004

37

Kjikvadrat observatorane

Begge kjikvadrat observatorane

1. Pearson-kjikvadratet χ_P^2 og
 2. Avviks-kjikvadratet χ_D^2
- Kan lesast som ein test av nullhypotesa om ingen skilnad mellom den estimerte modellen og ein "metta modell", dvs. ein modell med like mange parametrar som case / mønster

Fall 2004

© Erling Berge 2004

38

Meir om mål for påverknad

- Mål for påverknad ved endring (Δ) i observator/ parameterverdi pga utelatne case med mønster j
 - ΔB_j "delta B" - analog til Cook's D
 - $\Delta \chi^2_{P(i)}$ "delta Pearsonkjikvadrat"
 - $\Delta \chi^2_{D(i)}$ "delta Avvikskjikvadrat"

Kva er store verdiar av $\Delta \chi^2_{P(i)}$ og $\Delta \chi^2_{D(i)}$

- $\Delta \chi^2_{P(i)}$ og $\Delta \chi^2_{D(i)}$ måler begge kor dårlig modellen passar med mønsteret j. Store verdiar indikerer at modellen ville passe til data mye betre dersom alle case med mønsteret vart utelatne.
- Sidan begge måla er asymptotisk kjikvadratfordelt vil verdiar større enn 4 indikere at eit mønster påverkar parameterestimata "signifikant"

ΔB_j "delta B"


- Måler den standardiserte endringa i dei estimerte parametane (b_k) som oppstår når ein utelet alle case med eit gitt mønster j

$$\Delta B_j = \frac{r_j^2 h_j}{(1 - h_j)^2}$$

Til større verdi til meir påverknad.

$\Delta B_j \geq 1$ må i alle fall reknast som "stor påverknad"

delta B (m/caseNO)



$\Delta\chi^2_{P(i)}$ "delta Pearsonkjikvadrat"

- Måler minken i Pearson χ^2 som følgjer av utelating av alle case med mønster j


$$\Delta\chi^2_{P(j)} = \frac{r_j^2}{(1 - h_j)}$$

Fall 2004

© Erling Berge 2004

43

delta Pearsonkjikvadrat (m/delta B)



Fall 2004

© Erling Berge 2004

44

$\Delta\chi^2_{D(i)}$ "delta Avvikskjikvadrat"

- Måler endring i avvik som følge av å utelate alle case med mønster j


$$\Delta\chi^2_{D(j)} = \frac{d_j^2}{(1-h_j)}$$

- Dette er ekvivalent med

$$\Delta\chi^2_{D(j)} = -2 \left[\mathcal{LL}_K - \mathcal{LL}_{K(j)} \right]$$

\mathcal{LL}_K er LogLikelihooden for ein modell med K parametrar estimert på heile utvalet og $\mathcal{LL}_{K(j)}$ er frå estimateat av same modellen etter at alle case med mønster j er utelatne

delta Avvikskjikvadrat (m/delta B)



Effekten av utelatne case/mønster


| Variable i modellen | Logit koeffesient | | |
|------------------------|-------------------|--|--|
| | Heile utvalet | Minus case 99 $\Delta\chi^2 P(i) = 18,34$ | Minus case 96 $\Delta\chi^2 P(i) = 29,20$ |
| lived | -,040 | -,045 | -,052 |
| educ | -,197 | -,224 | -,214 |
| contam | 1,299 | 1,490 | 1,382 |
| hsc | 2,279 | 2,492 | 2,347 |
| nodad | -1,731 | -1,889 | -1,658 |
| Constant | 2,182 | 2,575 | 2,530 |
| 2*LL(modell) | -142,652 | -135,425 | -136,124 |

Fall 2004

© Erling Berge 2004

47

Effekten av utelatne case/mønster



$$y=1/(1+\exp(-(2.18-0.04x-0.2\times13+1.3\times0.28+2.28\times0.31-1.73\times0.17)))$$

$$y=1/(1+\exp(-(2.53-0.05x-0.21\times13+1.38\times0.28+2.35\times0.31-1.65\times0.17)))$$

$$y=1/(1+\exp(-(2.58-0.04x-0.22\times13+1.49\times0.28+2.49\times0.31-1.89\times0.17)))$$

Fall 2004

© Erling Berge 2004

48

Konklusjonar (1)

Vanleg OLS verkar därleg ved dikotome avhengige variablar sidan vi

- umogeleg kan få normalfordelte feil eller homoskedastisitet, og sidan
- modellen gir sannsyn utanfor intervallet 0-1

Logit-modellen er betre

- Likelihoodrateobservatoren kan teste nesto modellar omlag som F-observatoren
- I store utval vil Wald-observatoren [eller $t=\text{SQRT}(\text{Wald})$] kunne teste einskildkoeffisientar og konfidensintervall kan konstruerast
- Det finst ikkje nokon determinasjonskoeffisient

Konklusjonar (2)

- Koeffisientane i estimerte modellar kan tolkast ved
 1. Log-odds (direkte tolking)
 2. Odds
 3. Oddsraten
 4. Sannsyn (betinga effekt plott)
- Ikkje-linearitet, case med innverknad, og multikollinearitet gir same typen problem som i OLS regresjon (usikre parameterverdiar)
- Diskriminering gir problem av same typen (høge varianseestimat, dvs. usikre parameterverdiar)
- Diagnosearbeid er viktig