

Forelesning 10 STK3100

3. november 2008

S. O. Samuelsen

Plan for forelesning:

1. Multinomisk fordeling
2. Multinomisk regresjon - ikke-ordnede kategorier
3. Multinomisk regresjon - ordnede kategorier

Forelesning 10 STK3100 - p. 1/22

Momenter i multinomisk fordeling

Spesielt er $Y_j \sim \text{Bin}(n, \pi_j)$ marginalt. Derfor får vi

$$E[Y_j] = n\pi_j \quad \text{og} \quad \text{Var}[Y_j] = n\pi_j(1 - \pi_j)$$

Dessuten er, for $k \neq j$,

$$\text{Cov}[Y_j, Y_k] = -n\pi_j\pi_k$$

Dette følger ved å se på Y_{ij} = indikator for kjennetegn j i forsøk i . Da blir

$$\begin{aligned} \text{Cov}[Y_{ij}, Y_{ik}] &= P(Y_{ij} = 1, Y_{ik} = 1) - P(Y_{ij} = 1)P(Y_{ik} = 1) \\ &= 0 - \pi_j\pi_k \end{aligned}$$

og

$$\text{Cov}[Y_j, Y_k] = \text{Cov}\left[\sum_{i=1}^n Y_{ij}, \sum_{i=1}^n Y_{ik}\right] = \sum_{i=1}^n \text{Cov}[Y_{ij}, Y_{ik}] = -n\pi_j\pi_k$$

Forelesning 10 STK3100 - p. 3/22

Multinomisk fordeling:

- n uavhengige forsøk
- Observerer ett av J ulike kjennetegn i hvert forsøk
- Sannsynligheten for kjennetegn j er lik π_j i hvert forsøk der altså $\pi_1 + \pi_2 + \dots + \pi_J = 1$

Med Y_j = antall forsøk med kjennetegn j sier vi at $Y = (Y_1, Y_2, \dots, Y_J)$ er multinomisk fordelt

$$Y \sim \text{Multinom}(n, \pi_1, \pi_2, \dots, \pi_J)$$

Punktsannsynlighetene for Y gis da ved

$$f(y|n) = \frac{n!}{y_1!y_2!\dots y_J!} \pi_1^{y_1} \pi_2^{y_2} \dots \pi_J^{y_J}$$

for $y_j \in \{0, 1, \dots, n\}$ og $\sum_{j=1}^J y_j = n$

Forelesning 10 STK3100 - p. 2/22

Sammenheng med Poissonfordeling

Anta at $Y_j \sim \text{Po}(\mu_j)$, $j = 1, \dots, J$ er uavhengige. Da er

$$(Y_1, \dots, Y_J | \sum_{j=1}^J Y_j = n) \sim \text{Multinom}(n, \pi_1, \dots, \pi_J)$$

der sannsynlighetene $\pi_j = \mu_j / \sum_{k=1}^J \mu_k$.

Dette følger av at $\sum_{j=1}^J Y_j \sim \text{Po}(\sum_{k=1}^J \mu_k)$. Dermed

$$\begin{aligned} P(Y_1 = y_1, \dots, Y_J = y_J | \sum_{j=1}^J Y_j = n) &= \frac{P(Y_1 = y_1, \dots, Y_J = y_J)}{P(\sum_{j=1}^J Y_j = n)} \\ &= \frac{\prod_{j=1}^J \left[\frac{\mu_j^{y_j}}{y_j!} \exp(-\mu_j) \right]}{\frac{(\sum_{j=1}^J \mu_j)^n}{n!} \exp(-\sum_{j=1}^J \mu_j)} \\ &= \frac{n!}{y_1!y_2!\dots y_J!} \frac{\mu_1^{y_1} \mu_2^{y_2} \dots \mu_J^{y_J}}{(\sum_{j=1}^J \mu_j)^n} \\ &= \frac{n!}{y_1!y_2!\dots y_J!} \pi_1^{y_1} \pi_2^{y_2} \dots \pi_J^{y_J} \end{aligned}$$

Forelesning 10 STK3100 - p. 4/22

"Multinomisk regresjon"

Eks. (Faraway, "Extending the linear model with R"):

Undersøkelse om hvem som stemte på Demokrater, Republikanerne eller Uavhengige ved valg i USA i 1996 etter utdanning og inntekt.

```
> table(sPID)
sPID
  Democrat Independent Republican
      380           239           325

> table(nes96$educ)
  MS HSdrop  HS Coll CCdeg BAdeg MAdeg
  13   52   248  187   90   227   127

> table(nes96$income)
 $3Kminus $3K-$5K $5K-$7K $7K-$9K $9K-$10K $10K-$11K
      19      12      17      19      18      13
$11K-$12K $12K-$13K $13K-$14K $14K-$15K $15K-$17K $17K-$20K
      11      17      10      15      23      35
$20K-$22K $22K-$25K $25K-$30K $30K-$35K $35K-$40K $40K-$45K
      26      39      68      70      62      48
$45K-$50K $50K-$60K $60K-$75K $75K-$90K $90K-$105K $105Kplus
      51      100      103      53      47      68
Forelesning 10 STK3100 - p. 5/22
```

Nominell multinomisk logit modell:

Med π_{ji} = sannsynlighet for responskategori j for individ med kovariat x_i :

$$\pi_{1i} = \frac{1}{1 + \sum_{j=2}^J \exp(\beta'_j x_i)}$$
$$\pi_{ji} = \frac{\exp(\beta'_j x_i)}{1 + \sum_{k=2}^J \exp(\beta'_k x_i)} \text{ for } j > 1$$

Merk:

- $\sum_{j=1}^J \pi_{ji} = 1$
- $\frac{\pi_{ji}}{\pi_{1i}} = \exp(\beta'_j x_i)$
- Ulike $\beta_j = (\beta_{j1}, \dots, \beta_{jp})'$ for hvert nivå $j = 2, 3, \dots, J$

Likelihood: Med responsvektor $Y^i = (Y_1^i, \dots, Y_J^i)$

$$L = \prod_{i=1}^n \frac{n_i!}{Y_1^i! Y_2^i! \dots Y_J^i!} \pi_{1i}^{Y_1^i} \pi_{2i}^{Y_2^i} \dots \pi_{Ji}^{Y_J^i}$$

Forelesning 10 STK3100 - p. 7/22

Eks. Faraway, forts.

- Respons: Partivalg
 - 3 kategorier: Demokrater, Republikanerne eller Uavhengige
 - Multinomiske data
 - Ikke opplagt ordning mellom kategoriene
- Forklaringsvariable: Utdanning og inntekt
 - → Regresjon

Regresjon for multinomiske responser med ikke-ordnede kategorier:

Nominell multinomisk logit modell

Nominell multinomisk logit modell: R-implementasjon

Optimering av likelihooden for nominelle multinomiske data kan gjøres i R med rutinen `multinom` som finnes i standard-R-biblioteket `nnet` (kort for "nevralt nett").

```
> library(nnet)
> mmmod <- multinom(sPID ~ neduc + nincome, nes96)
> mmmod
> multinom(sPID~neduc+nincome)
# weights: 12 (6 variable)
initial value 1037.090001
iter 10 value 992.514868
final value 992.514853
converged
```

```
Coefficients:
      (Intercept)      neduc      nincome
Independent  -1.161305 -0.003621094 0.01614688
Republican   -1.052716 0.028144037 0.01709310
```

Residual Deviance: 1985.030

AIC: 1997.030

Eks: Utdannelse spiller ingen rolle gitt inntekt

```
> multinom(sPID~1)$dev
# weights: 6 (2 variable)
initial value 1037.090001
final value 1020.636052
converged
[1] 2041.272
> multinom(sPID~neduc)$dev
[1] 2030.478
> multinom(sPID~nincome)$dev
[1] 1985.424
> multinom(sPID~nincome+neduc)$dev
[1] 1985.030
```

- Dev.endring 2041.27-2030.48 = 10.79 med bare utdannelse
- Dev.endring 2041.27-1985.42 = 55.75 med bare inntekt
- Dev.endring 1985.42-1985.03 = 0.39 med utdannelse i tillegg til inntekt

Forelesning 10 STK3100 – p. 9/22

Eks: Må selv lage tabell med

estimer, standardfeil, t-verdier og p-verdier:

```
koefstab<-function(nnetmod){
  koef<-summary(nnetmod)$coefficients
  se<-summary(nnetmod)$standard.errors
  koefb<-c(koef[1,],koef[2,])
  seb<-c(se[1,],se[2,])
  tval<-koefb/seb
  pval<-2*pnorm(-abs(koefb/seb))
  tab<-cbind(koefb,seb,tval,pval)
  tab
}
> round(koefstab(mod),4)

           koefb   seb   tval   pval
(Intercept) -1.1613 0.2561 -4.5339 0.0000
nincome      0.0161 0.0031  5.2401 0.0000
neduc       -0.0036 0.0571 -0.0634 0.9495
(Intercept) -1.0527 0.2380 -4.4227 0.0000
nincome      0.0171 0.0029  5.9747 0.0000
neduc        0.0281 0.0526  0.5353 0.5925
```

Forelesning 10 STK3100 – p. 11/22

Eks: Standardfeil fra summary.multinom

```
mod<-multinom(sPID~nincome+neduc)
# weights: 12 (6 variable)
initial value 1037.090001
iter 10 value 992.514868
final value 992.514853
converged
> summary(mod,cor=F)
Call:
multinom(formula = sPID ~ nincome + neduc)

Coefficients:
              (Intercept)      nincome      neduc
Independent  -1.161305  0.01614688 -0.003621094
Republican   -1.052716  0.01709310  0.028144037

Std. Errors:
              (Intercept)      nincome      neduc
Independent   0.2561357  0.003081403  0.05712273
Republican    0.2380262  0.002860900  0.05257820

Residual Deviance: 1985.030
```

Forelesning 10 STK3100 – p. 10/22

Sammenheng vanlig og nominell multinomisk logit

Vi har at $Y_j^i | Y_1^i + Y_j^i = m_i \sim \text{Bin}(m_i, \pi_{ji} / (\pi_{1i} + \pi_{ji}))$ og

$$\frac{\pi_{ji}}{\pi_{1i} + \pi_{ji}} = \frac{\frac{\exp(\beta'_j x_i)}{1 + \sum_{k=2}^J \exp(\beta'_k x_i)}}{\frac{1}{1 + \sum_{j=2}^J \exp(\beta'_j x_i)} + \frac{\exp(\beta'_j x_i)}{1 + \sum_{k=2}^J \exp(\beta'_k x_i)}} = \frac{\exp(\beta'_j x_i)}{1 + \exp(\beta'_j x_i)}$$

dvs. vanlig logistisk regresjons-modell for $Y_j^i | Y_1^i + Y_j^i = m_i$.

- $\exp(\beta_{jl}) = \text{OR}_{jl}$ = oddsratio mellom nivå j og 1 for kovariat l
- Parametrene kan også estimeres ved separate logistiske regresjoner.

Forelesning 10 STK3100 – p. 12/22

Eks: Separate logistiske regresjoner

```
> Rep<-1*(sPID=="Republican")
> Ind<-1*(sPID=="Independent")

> summary(glm(Ind~nincome+neduc,family=binomial,subset=Rep!=1))
      Estimate Std. Error z value Pr(>|z|)
(Intercept) -1.106370   0.250014  -4.425 9.63e-06 ***
nincome      0.015536   0.003063   5.073 3.92e-07 ***
neduc       -0.009809   0.056135  -0.175  0.861

Null deviance: 825.71  on 618  degrees of freedom
Residual deviance: 794.50  on 616  degrees of freedom
AIC: 800.5

> summary(glm(Rep~nincome+neduc,family=binomial,subset=Ind!=1))
      Estimate Std. Error z value Pr(>|z|)
(Intercept) -1.052653   0.241909  -4.351 1.35e-05 ***
nincome      0.017754   0.002966   5.985 2.17e-09 ***
neduc       0.021639   0.054081   0.400  0.689

Null deviance: 973.04  on 704  degrees of freedom
Residual deviance: 924.26  on 702  degrees of freedom
AIC: 920.26
```

Forelesning 10 STK3100 – p. 13/22

Ordnete (ordinale) kategoriske responser

Eks: Fødselsvekt ble kategorisert i et eksempel til mindre (større) enn 2800 g. Kan også benytte flere terskelverdier, f.eks. 3500 g.

Eks: Muligens en skala fra Demokrater via Uavhengige til Republikanere

Generelt: en underliggende (typisk latent) skala Z og et sett av terskelverdier $C_1 < C_2 < \dots < C_{J-1}$ slik at individet kategoriseres til

$$\text{nivå 1 dersom } Z \leq C_1 \quad \Leftrightarrow Y = 1$$

$$\text{nivå } j \text{ dersom } C_{j-1} < Z \leq C_j \quad \Leftrightarrow Y = j$$

$$\text{nivå } J \text{ dersom } C_{J-1} < Z \quad \Leftrightarrow Y = J$$

Merk: Y defineres på annen måte enn for nominelle data.

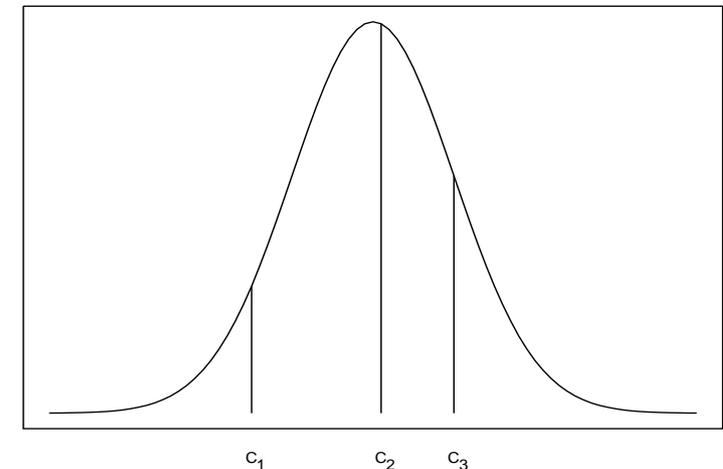
Forelesning 10 STK3100 – p. 15/22

Eks: Sammendrag separate logistiske regresjoner

- Estimater med multinomisk og separate logistisk regresjon er tilsvarende, men ikke identiske
- Standardfeil er også tilsvarende, men ikke identiske
- Multinomisk regresjon er en full likelihood analyse
- Kan være like oversiktlig å gjøre de separate logistisk regresjonene

Forelesning 10 STK3100 – p. 14/22

Underliggende skala og terskelverdier



Her vil Z flyttes fram og tilbake langs x-aksen ettersom kovariater varierer.

Forelesning 10 STK3100 – p. 16/22

Modellering av ordinale multinomiske data

Siden det er mer struktur i ordnede kategoriske data kan man modellere med færre parametre.

Vi antar, at gitt kovariat x_i , er den latente variabelen

$Z_i = \beta'x_i + Z_{0i}$ der $P(Z_{0i} \leq z) = F(z)$ for en passende kumulativ fordelingsfunksjon $F(z)$.

Da fås

$$P(Y_i \leq j) = P(Z_i \leq C_j) = P(Z_{0i} \leq C_j - \beta'x_i) = F(C_j - \beta'x_i)$$

- Merk at det bare er en parametervektor β
- Dessuten er C_j -ene ukjente, dvs. parametre
- Vi får ulike modeller med ulike valg av (invers) "link"-funksjon $F(z)$

Eks: "Democrats" < "Independent" < "Republican"

Proporsjonale oddsmodeller tilasses i R med rutinen `polr` som finnes i MASS-biblioteket.

Spesielt skal responsen - den ordnede faktoren - være spesifisert som en faktor.

```
> library(MASS)
> summary(polr(as.factor(sPID)~nincome+neduc))
```

Coefficients:

	Value	Std. Error	t value
nincome	0.01261746	0.002126369	5.9338071
neduc	0.02565506	0.040922490	0.6269184

Intercepts:

	Value	Std. Error	t value
Democrat Independent	0.3025	0.1867	1.6204
Independent Republican	1.3853	0.1921	7.2108

Residual Deviance: 1994.970

AIC: 2002.970

Proporsjonal oddsmodell: Logit-link

Anta at $F(z) = \exp(z)/(1 + \exp(z))$. Da blir

$$P(Y_i \leq j) = \exp(C_j - \beta'x_i)/(1 + \exp(C_j - \beta'x_i))$$

og med $\pi_{ji} = P(Y_i = j)$ (som ved nominelle responser) og

$\gamma_{ji} = P(Y_i \leq j) = \pi_{1i} + \dots + \pi_{ji}$ fås

$$\frac{\gamma_{ji}}{1 - \gamma_{ji}} = \exp(C_j - \beta'x_i)$$

og dermed blir odds-ratioen

$$\frac{\frac{\gamma_{ji'}}{1 - \gamma_{ji'}}}{\frac{\gamma_{ji}}{1 - \gamma_{ji}}} = \exp(\beta'(x_{i'} - x_i))$$

uavhengig av nivået C_j .

Eks: Sammendrag

- Estimatorene for `nincome` og `neduc` har lignende koeffisienter som ved nominell logit modell
- Estimatorene for `nincome` og `neduc` har også tilsvarende grad av signifikans
- Residual Devians var 1985.03 for nominell logit og altså mindre enn 1994.97 proporsjonale odds

Utvidelser: Probit og Cloglog

Spesifikasjonen

$$P(Y_i \leq j) = F(C_j - \beta' x_i)$$

tillater andre (inverse) linkfunksjoner

- Probit: $F(z) = \Phi(z) = \int_{-\infty}^z \frac{\exp(-z^2/2)}{\sqrt{2\pi}} dz$
- Clog-log: $F(z) = 1 - \exp(-\exp(z))$
- Cauchit: $F(z) = \int_{-\infty}^z \frac{dz}{\pi(1+z^2)} = \frac{\arctan(z)}{\pi} + \frac{1}{2}$

Forelesning 10 STK3100 – p. 21/22

Eks: Probit og Cloglog

```
> summary(polr(as.factor(sPID)~nincome+neduc,method="probit"))
Coefficients: Value Std. Error t value
nincome 0.007887085 0.001312480 6.0092976
neduc 0.014567640 0.025430970 0.5728307
Intercepts: Value Std. Error t value
Democrat|Independent 0.1812 0.1154 1.5704
Independent|Republican 0.8505 0.1173 7.2519

Residual Deviance: 1994.564
AIC: 2002.564
```

```
> summary(polr(as.factor(sPID)~nincome+neduc,method="cloglog"))
Coefficients: Value Std. Error t value
nincome 0.009374659 0.001431614 6.5483141
neduc 0.007236995 0.028933467 0.2501254
Intercepts: Value Std. Error t value
Democrat|Independent 0.5669 0.1303 4.3503
Independent|Republican 1.3610 0.1366 9.9613

Residual Deviance: 1989.348
AIC: 1997.348
```

Forelesning 10 STK3100 – p. 22/22