



Dagens program:

Mandag den 2. maj

Hierarkiske generaliserede lineære modeller

- Eksempel: hierarkisk Poissonfordelingsmodel
Eksempel: hierarkisk binomialfordelingsmodel
- Hierarkisk model for exponentiel dispersionsfamilie
- Flere eksempler på hierarkiske modeller
- Aposteriorifordeling for middelværdiparameter μ
- Eksempel Aposteriorifordeling for Poisson-Gamma model
prædiktiv fordeling



Hierarkisk model for Poisson fordeling med overdispersion

$$Y|\mu \sim P(\mu) \text{ Poisson-fordeling}$$

Hvad skal vi vælge som fordeling af μ ?

Det er usmart med en normalfordeling af μ , da $0 < \mu$.

Likelihood'en for μ fra Poissonfordelingen er proportional med

$$p_Y(y; \mu) \propto \mu^y \exp(-\mu)$$

Vi vælger en fordeling af μ , hvis tæthed har samme form som likelihood'en fra Poissonfordelingen, nemlig

$$g_\mu(\mu) \propto (\mu)^{\alpha-1} \exp(-\mu/\beta)$$

Det er jo tætheden for en **Gammafordeling**, dvs

$$g_\mu(\mu; \alpha, \beta) = \frac{1}{\Gamma(\alpha)\beta} \left(\frac{\mu}{\beta}\right)^{\alpha-1} \exp(-\mu/\beta)$$



Fordeling af dagligt antal tordenvejr ved Cape Kennedy

Antal episoder	Antal dage	Poisson forventet
y_i	$\#i$	
0	803	791.85
1	100	118.78
2	14	8.91
3+	3	0.46

Tællel, naturlig fordeling er Poissonfordeling med frekvensfunktion

$$P[Y = y] = p_Y(y; \mu) = \frac{\mu^y}{y!} \exp(-\mu)$$

for $y = 0, 1, 2, \dots$ og middeltallet μ episoder/dag.

MEN observeret fordeling har **tykkere haler** end Poissonfordelingen.

Atså **overdispersion**



Marginal fordeling

Frekvensfunktionen for den marginale fordeling af μ fås ved at integrere $p_Y(y; \mu)$ med hensyn til $g_\mu(\mu; \alpha, \beta)$

$$\begin{aligned} f_Y(y) &= \int_{\mu=0}^{\infty} p_Y(y; \mu) g_\mu(\mu; \alpha, \beta) d\mu \\ &= \int_{\mu=0}^{\infty} \frac{\mu^y}{y!} \exp(-\mu) \frac{1}{\Gamma(\alpha)\beta} \left(\frac{\mu}{\beta}\right)^{\alpha-1} \exp(-\mu/\beta) d\mu \\ &= \int_{\mu=0}^{\infty} \frac{\mu^{y+\alpha-1}}{y! \Gamma(\alpha) \beta^\alpha} \exp\left\{-\mu/\left(\beta/(1+\beta)\right)\right\} d\mu \end{aligned}$$

Vi bemærker nu, at de faktorer i integranden, der afhænger af μ er, $\mu^{y+\alpha-1}$ og $\exp\left\{-\mu/\left(\beta/(1+\beta)\right)\right\}$, som netop er kernen i en Gammafordeling med formparameteren $y + \alpha$ og skalaparameter $\beta/(1 + \beta)$



Marginal fordeling

Udtrykket kan reorganiseres til

$$f_Y(y) = \frac{\Gamma(y+\alpha)}{y!\Gamma(\alpha)} \frac{\beta^y}{(1+\beta)^{y+\alpha}}$$

$$\int_{\mu=0}^{\infty} \frac{1}{\Gamma(y+\alpha)\beta/(1+\beta)} \left(\frac{\mu}{\beta/(1+\beta)}\right)^{y+\alpha-1} \exp\left\{-\mu/\left(\beta/(1+\beta)\right)\right\} d\mu$$

$$= \frac{\Gamma(y+\alpha)}{y!\Gamma(\alpha)} \frac{\beta^y}{(1+\beta)^{y+\alpha}},$$

hvor integranden netop er tætheden for en gammafordeling, (med integralet 1).

$$f_Y(y) = \frac{\Gamma(y+\alpha)}{y!\Gamma(\alpha)} \left(\frac{1}{1+\beta}\right)^\alpha \left(1 - \frac{1}{1+\beta}\right)^y$$

For heltallige positive værdier af α er $f_Y(y)$ netop frekvensfunktionen for en negativ binomialfordeling (fordelingen af "ventetiden" y til den α 'te succes i en følge af Bernoulli forsøg, hvor sandsynligheden for succes er $1/(1+\beta)$)



Momenter

Vi har fra gammafordelingen at $E[\mu] = \alpha\beta$ og $V[\mu] = \alpha\beta^2$, og fra Poissonfordelingen har vi $E[Y|\mu] = V[Y|\mu] = \mu$. Momenterne i den marginale fordeling af Y bliver derfor

$$E[Y] = E_\mu[E[Y|\mu]] = E[\mu] = \alpha\beta$$

$$V[Y] = E_\mu[V[Y|\mu]] + V_\mu[E[Y|\mu]] = E_\mu[\mu] + V_\mu[\mu]$$

$$= \alpha\beta + \alpha\beta^2 = m + m^2/\alpha$$

hvor vi har sat $E[\mu] = m$.



Marginal fordeling

For heltallige positive α bliver frekvensfunktionen

$$f_Y(y) = \frac{(y+\alpha-1)!}{y!(\alpha-1)!} \left(\frac{1}{1+\beta}\right)^\alpha \left(1 - \frac{1}{1+\beta}\right)^y = \binom{y+\alpha-1}{y} \left(\frac{1}{1+\beta}\right)^\alpha \left(1 - \frac{1}{1+\beta}\right)^y$$

Vi kan definere en negativ binomialfordeling også for ikke-heltallige værdier af α .



Parametriseringer

Undertiden er det smartere at parametrisere gammafordelingen ved middelværdi $m = \alpha\beta$, og reciprok formlparameter $k = 1/\alpha$, eller ved middelværdi $m = \alpha\beta$ og "signal/støj" forhold

$$\gamma = \frac{V_\mu[E[Y|\mu]]}{E_\mu[V[Y|\mu]]} = \frac{V_\mu[\mu]}{E[V_P(\mu)]} = \frac{\alpha\beta^2}{\alpha\beta} = \beta = mk$$

hvor $V_P(\cdot)$ angiver variansfunktionen for Poissonfordelingen, $V_P(\mu) = \mu$. Giver mulighed for grænseovergang til en etpunktsfordeling i m for fast m og $k \rightarrow 0$ eller, alternativt fast m og $\gamma \rightarrow 0$

Ved denne grænseovergang går NB-fordelingen mod en Poissonfordeling med middelværdi m .



Flere observationer fra samme gruppe (samme μ)

Optræder fx. ved bakterietællinger, målinger i "rene rum"

Betragt summen $Z = X_1 + X_2 + \dots + X_n$, hvor X_i 'erne for fastholdt μ (dag, lokalitet el. lgn.) er uafhængige $P(\mu)$ -fordelte variable.

Modellen for Z bliver da

$$Z|\mu \sim P(n\mu), \quad \mu \sim G(1/k, m/k)$$

Den marginale fordeling af Z er en NB-fordeling (på ikke-negative heltal).

Det er naturligt at betragte gennemsnittet $Y = Z/n$

$$V[Y] = \frac{1}{n^2} V[Z] = \frac{m}{n} = m \left(mk + \frac{1}{n} \right) = E[V_P(\mu)] \left(\gamma + \frac{1}{n} \right)$$

lissom formen i normalfordelingsituationen



Binomialfordeling, eksempel

Eksempel, Z_i antal dimensionsafvigende låg i stikprøver á 770 låg fra hvert af 229 partier.

Hvis proces i kontrol, naturligt at forvente Z_i er uafhængige ensfordelte med $Z_i \sim B(770, p)$ (binomialfordeling).




Estimation

Parametrene m og k (eller m og γ) kan estimeres ved momentmetoden fra gennemsnit og empirisk varians for observationerne (hvis designet er balanceret, dvs. samme n i alle grupper).

Man kan også maksimum-likelihood estimere.

PROC GENMOD, dist= NEGBIN estimerer m og k og kalder k for "dispersion" (men det er den ikke).



Fordeling af antal afvigende låg



Tykkere haler end binomialfordeling med samme middelværdi.

Hierarkisk model:

$$Z|p \sim B(n, p),$$

$$p_Z(z) = \binom{n}{z} p^z (1-p)^{n-z}$$

$$p \sim ????$$

Upraktisk med normalfordeling af p , da $0 < p < 1$.

Evt kunne man vælge normalfordeling af den kanoniske parameter, logit'en.

Marginal fordeling



Lad $Z|\mu \sim B(n, \mu)$ og $\mu \sim Be(\alpha, \beta)$. Da kaldes den marginale fordeling af Z for **Polyafordeelingen** (efter Polya's urnemodell).

Undertiden betegnes Polyafordeelingen "binomial-beta" fordelingen fordi den er en **compound** fordeling fremkommet ved at mixe binomialfordelinger ved en betafordeling

Fordeling af p 


Vi vælger $p \sim Be(\alpha, \beta)$ (betafordeling) med tæthed

$$g_p(p) = \frac{1}{B(\alpha, \beta)} p^{\alpha-1} (1-p)^{\beta-1} \quad \text{for } 0 < p < 1$$

($B(\alpha, \beta)$ er **Betafunktionen**), altså samme form af **kernen** af tætheden, som likelihoodfunktionen for binomialfordelingen.

$$E[p] = \frac{\alpha}{\alpha + \beta} \quad V[p] = \frac{\alpha\beta}{(\alpha + \beta)^2(\alpha + \beta + 1)}$$

Marginal fordeling





Momenter i marginal fordeling

Betragt den relative hyppighed, $Y = Z/n$

Middelværdi, $\pi = E[\mu] = \alpha/(\alpha + \beta)$ og "signal/støjforhold"

$$\gamma = \frac{V_{\mu}[E[Y|\mu]]}{E_{\mu}[V[Y|\mu]]} = \frac{V_{\mu}[\mu]}{E[\mu(1-\mu)]} = \frac{1}{\alpha + \beta}$$

Vi får derfor

$$E[Y] = \pi = \frac{\alpha}{\alpha + \beta}$$

$$V[Y] = \frac{\pi(1-\pi)}{1+\gamma} \left(\gamma + \frac{1}{n} \right)$$

hvor

$$\frac{\pi(1-\pi)}{1+\gamma} = E[\mu(1-\mu)] = E[V_{\text{bin}}(\mu)]$$

udtrykker den "gennemsnitlige" binomialvarians



Marginal fordeling af gruppegennemsnit

$$E[Y_i] = E[E[Y_i|\mu]] = E[\mu] = m$$

$$V[Y_i] = E[V(\mu)] \left(\gamma + \frac{1}{n_i} \right) = E[V(\mu)] \left(\gamma + \frac{1}{n_i} \right),$$

Konjugeret fordeling giver simpelt analytisk udtryk for den marginale fordeling. Man kunne godt vælge at lave normalfordeling for kanonisk parameter, men det giver komplicerede udtryk for marginalfordelinger.



Fortolkning af parametre i konjugeret fordeling

For parametrene m og γ gælder:

$$m = E[\mu]$$

$$\gamma = \frac{V[\mu]}{E[V(\mu)]},$$

hvor $\mu = E[Y|\theta]$, og hvor $V(\mu)$ angiver variansfunktionen $\kappa''(\tau^{-1}(\mu))$



Eksempel, Monocyttælling


Som led i en undersøgelse af et lægemiddel udtoges en gruppe personer (73 rygere) i en given aldersklasse. For hver person tog man 100 hvide blodlegemer (leukocytter) fra en blodprøve fra personen og optalte antallet af monocytter (encellede). Fordelingen var:

Antal monoc.	0	1	2	3	4	5	6	7	8	9
Antal pers.	4	11	14	14	15	5	6	2	0	2


Snit 3.21,

Det kunne være naturligt at sammenligne med en binomialfordeling, $B(n = 100, p = 0.032)$.


Monocytælling, sammenligning med binomial fordeling




Monocytælling, simultan fordeling



Monocytælling, sammenligning med Polyafordeling



Monocytælling, niveaukurver





Generelt princip for valg af konjugeret fordeling

Betragt en eksponentialdispersionsfamilie (af observationer)

$$f_Y(y; \theta, \lambda) = c(y, \lambda) \exp[\lambda\{\theta y - \kappa(\theta)\}] \quad \text{for } \theta \in \Omega$$

Vælg fordeling af kanonisk parameter θ med tæthed

$$g_\theta(\theta; m, \gamma) = \frac{1}{C(m, \gamma)} \exp\{\{\theta m - \kappa(\theta)\}/\gamma\}$$

hvor kumulantfrembringeren $\kappa(\cdot)$ er den samme i de to udtryk.

Fordelingen af θ kaldes den **konjugerede fordeling**

I Bayes-sammenhænge kaldes den konjugeret apriorifordeling.

I hierarkiske modeller kaldes den undertiden konjugeret strukturfordeling.



Aposteriorifordelinger under hierarkisk model

Lad $X_1, X_2, \dots, X_n$ være uafhængige (for givet θ), frembragt med samme θ og med tæthed

$$g(x|\theta) = d(x) \exp\{[\theta x - \kappa(\theta)]/\sigma^2\},$$

og lad fordelingen af θ være den konjugerede fordeling med tæthed

$$w(\theta; m, \gamma) = \frac{1}{C(m, \gamma)} \exp\{[\theta m - \kappa(\theta)]/\gamma\}$$

Da er aposteriorifordelingen af θ efter observation af $X_1 = x_1, \dots, X_n = x_n$ e

$$w(\theta | \sum X_i/n = \bar{x}) = \frac{1}{C(m_1, \gamma_1)} \exp\{[\theta m_1 - \kappa(\theta)]/\gamma_1\}$$

med

$$m_1 = m_{\text{apost}} = \frac{m/\gamma + n\bar{x}/\sigma^2}{1/\gamma + n/\sigma^2}$$

$$\gamma_1 = \gamma_{\text{apost}} = \frac{1}{1/\gamma + n/\sigma^2}$$



Andre eksempler på hierarkiske modeller

Fordeling af empiriske varianser, afsnit 7.3

Normalfordeling med tilfældigt varierende varians, afsnit 7.4:

$$Y_i | \sigma_i^2 \sim N(\mu, \sigma_i^2)$$

$$1/\sigma_i^2 \sim G(\alpha, 1/\beta)$$

hvor σ_i^2 er indbyrdes uafhængige.

Da gælder for den marginale fordeling af Y_i , at

$$\frac{Y_i - \mu}{\sqrt{\beta/\alpha}} \sim t(2\alpha)$$

hvor $t(2\alpha)$ er en t-fordeling med 2α frihedsgrader, dvs en fordeling med **tykkere haler** end normalfordelingen.



Aposteriorifordelinger

For den konjugerede apriorifordeling gælder altså at aposteriorifordelingen for θ er af samme form som apriorifordelingen, blot med opdaterede parametre m og γ ved brug af den sædvanlige opdateringsformel.

$$\frac{1}{\gamma_{\text{apost}}} = \frac{1}{\gamma_{\text{apriori}}} + n/\sigma^2$$

$$\frac{m_{\text{apost}}}{\gamma_{\text{apost}}} = \frac{m_{\text{apriori}}}{\gamma_{\text{apriori}}} + n \bar{x}/\sigma^2$$

$$\gamma_{\text{apost}} = \frac{V[\mu|\bar{x}]}{E[V(\mu)|\bar{x}]}, \quad (0.1)$$



Eksempel på opdatering af aprioriinformation

Poisson-gamma model:
Vævefejl i stof.

For en given produktion er fejlene tilfældigt spredt over stoffet i overensstemmelse med en Poisson-fordeling.

Gennemsnitligt antal fejl pr m², μ varierer fra produktion til produktion i overensstemmelse med en gammafordeling med middelværdi 2.5 og varians 2.0825

Prædiktiv fordeling

Der udtages en stikprøve, og antallet af fejl bestemmes. Dette bruges til bestemmelse af aposteriorifordeling for μ , som derefter bruges til bestemmelse af **prædiktiv fordeling** af antal fejl i hhv een, 10 og 20 m² stof fra denne produktion.

Prædiktiv fordeling, mixtur af stikprøvefordeling og apost.



Vi så, at

- Variansen i aposteriorifordelingen af μ afhang ikke kun af stikprøvestørrelsen, men også af fejlniveauet (fordi variansen i Poissonfordelingen stiger med middelværdien)
- Det væsentligste bidrag til **spredningen** i den prædiktive fordeling for det totale antal fejl hidrører fra aposteriorivariansen for μ . Bidraget er proportionalt med "prædiktionslængden" og er væsentligt større end bidraget fra Poissonusikkerheden.
For det totale antal fejl er jo ikke summen af **uafhængige** Poissonstørrelser; de kommer jo fra samme produktion



Poisson-gamma

Parameter	Før	Efter observation af		
		$n = 10$ $z = 1$ $\bar{x} = 0.1$	$n = 10$ $z = 60$ $\bar{x} = 6$	$n = 20$ $z = 120$ $\bar{x} = 6$
$m = E[\mu]$	2.5	0.36	5.63	5.80
γ	0.833	0.0893	0.0893	0.0472
$V[\mu] = m \times \gamma$	2.0825	0.03	0.50	0.27
α	3	4	63	123
β	1.2	11.2	11.2	21.2
Fordeling af fejl i én ny m				
$X' \in \text{NB}(\alpha, \beta/(1 + \beta))$				
$E[X'] = m$	2.5	0.36	5.63	5.80
$V[X'] = m(1 + \gamma)$	4.58	0.39	6.13	6.07
Fordeling af fejl i 10 nye m				
$Z' \in \text{NB}(\alpha, \beta/(10 + \beta))$				
$E[Z'] = 10m$	25	3.6	56.3	58.0
$V[Z'] = 10m(1 + 10\gamma)$	233.32	6.81	106.57	85.38
Fordeling af fejl i 20 nye m				
$Z' \in \text{NB}(\alpha, \beta/(20 + \beta))$				
$E[Z'] = 20m$	50	7.2	112.6	116.0
$V[Z'] = 20m(1 + 20\gamma)$	883	20.06	313.7	225.50