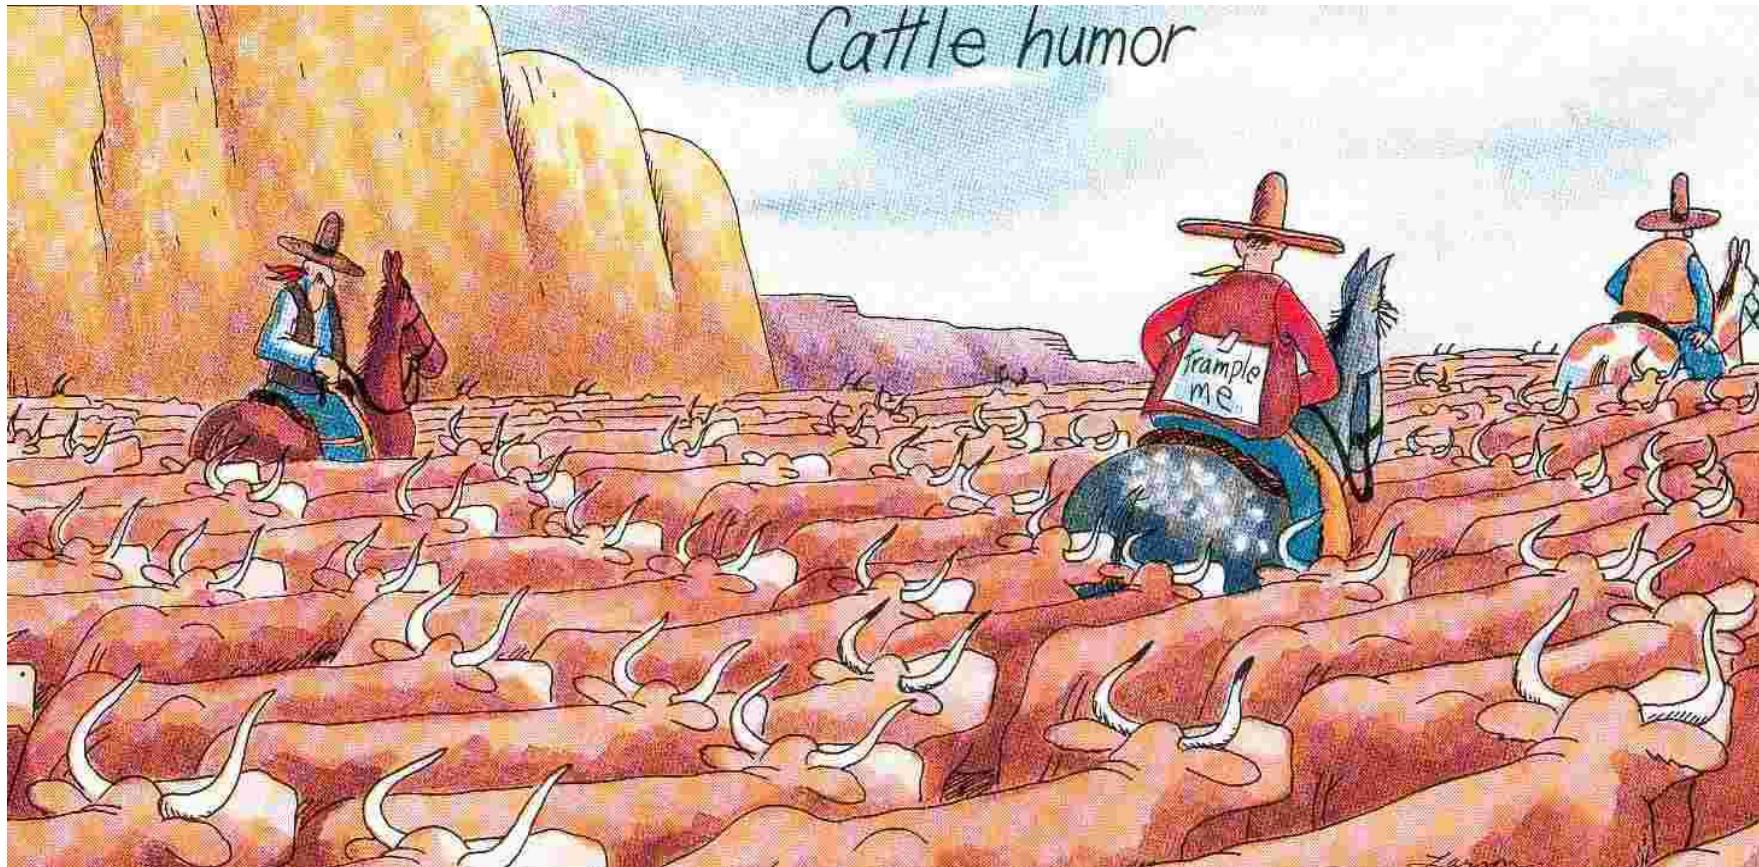


Analyse de données polytomiques



Introduction

Variables polytomiques

- Ordonnées (ordinales)
- Non ordonnées (nominales)

Variables ordinales

- Wright 1934 Polydactylie chez le cobaye
- Pearson 1990 Corrélation tétrachorique
- Article de base: P McCullagh 1980
 - Regression models for ordinal data, JRSS B, 42, 109-142
- Synthèse de Liu & Agresti, 2005

Exemple I/Données

Table 1 : Calving scores in Blonde d'Aquitaine breed by gender of calf and parity of cow

Gender	Parity	I	II	III	Total
Male	1	55	65	33	153
	2	563	535	162	1260
	3	1990	1525	424	3939
	4	488	423	118	1029
	Total	3096 (48.5%)	2548 (39.9%)	737 (11.6%)	6381
Female	1	69	51	11	131
	2	761	433	61	1255
	3	2559	1216	141	3916
	4	300	178	22	500
	Total	3689 (63.6%)	1878 (32.4%)	235 (4.0%)	5802

1=First calving; 2=2nd calving, 3=3rd calving and beyond 4=unknown parity

Exemple 2/Données

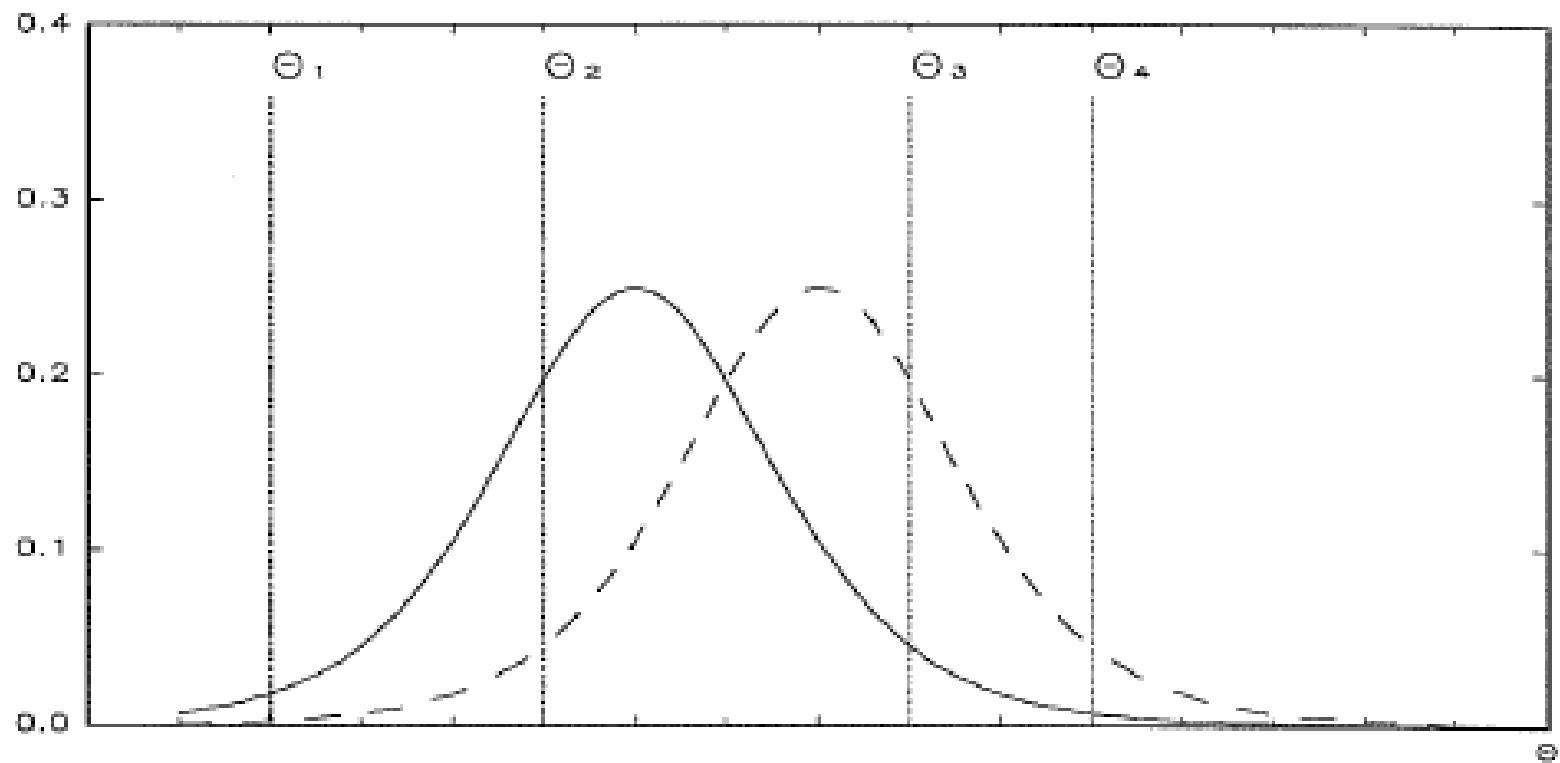
Sex	Parity	Sire	Score1	Score2	Score3
0	1	1	2	3	1
0	1	2	6	5	2
0	1	3	1	2	4
0	1	4	2	2	0
0	1	5	1	4	4
0	1	6	1	1	0
0	1	7	5	3	0
0	1	8	2	4	1
0	1	9	4	3	0
0	0	1	8	9	3
0	0	2	10	8	1
0	0	3	10	13	6
0	0	4	4	9	6
0	0	5	10	11	7
0	0	6	3	9	2
0	0	7	14	12	2
0	0	8	12	10	3
0	0	9	19	10	1
1	1	1	1	2	0
1	1	2	6	1	1
1	1	3	5	4	0
1	1	4	2	1	3
1	1	5	10	3	1
1	1	6	5	3	0
1	1	7	4	4	0
1	1	8	5	0	0
1	1	9	7	5	1
1	0	1	14	10	3
1	0	2	30	12	1
1	0	3	10	3	3
1	0	4	13	3	0
1	0	5	9	10	3
1	0	6	7	6	1
1	0	7	30	6	0
1	0	8	22	6	1
1	0	9	24	10	0

Sex: 0=Male, 1=Female; Parity: 1=Heifers, 0=Adult Cows

Catégories ordonnées/notations

Catégorie:	1	j	$J-1$	J	
Strate:	i	π_{i1}	π_{ij}	π_{iJ-1}	π_{iJ}
	$K_{i1} = \pi_{i1}$	$K_{ij} = \pi_{i1} + \dots + \pi_{ij}$	$K_{iJ-1} = \pi_{i1} + \dots + \pi_{iJ-1}$	$K_{iJ} = 1$	

Modèle à seuils



Modèle à seuils

l_{ir} : observation r de la strate i

On postule l'existence d'une variable latente $L_{ir} \sim \mathcal{N}(\eta_i, \sigma_i^2)$

munie de seuils: $\tau_1, \tau_2, \dots, \tau_j, \dots, \tau_{J-1}$

$$\kappa_{i1} = \pi_{i1} = \Pr(L_{ir} \leq \tau_1) = \Pr\left(\underbrace{\frac{L_{ir} - \eta_i}{\sigma_i}}_{\mathcal{N}(0,1)} \leq \frac{\tau_1 - \eta_i}{\sigma_i}\right) = \Phi\left(\frac{\tau_1 - \eta_i}{\sigma_i}\right)$$

$$\kappa_{i2} = \pi_{i1} + \pi_{i2} = \Pr(L_{ir} \leq \tau_2) = \Phi\left(\frac{\tau_2 - \eta_i}{\sigma_i}\right)$$

$$\sigma_i = \sigma = 1, \quad \boxed{\kappa_{ij} = \Phi(\tau_j - \eta_i)} \Leftrightarrow \tau_j - \eta_i = \Phi^{-1}(\kappa_{ij})$$

Modèle à seuils

$$\boxed{\kappa_{ij} = \Phi(\tau_j - \eta_i)} \Leftrightarrow \tau_j - \eta_i = \Phi^{-1}(\kappa_{ij})$$

$$\tau_j - \eta_i = \underbrace{(\tau_j - \alpha_R)}_{\substack{J-1 \text{ intercepts} \\ \text{ou "cut points"}}} - \underbrace{\mathbf{x}_i' \boldsymbol{\beta}}_{\text{covar sans intercept}} - \mathbf{z}_i' \mathbf{u}_i$$

$$\tau_j - \eta_i = \underbrace{(\tau_j - \tau_1)}_{(\text{J}-2) \text{ seuils en écart au 1er}} - \underbrace{(\alpha_R - \tau_1)}_{\text{population de référence}} - \mathbf{x}_i' \boldsymbol{\beta} - \mathbf{z}_i' \mathbf{u}_i$$

Autres fonctions de liens

Plus généralement

$$\kappa_{ij} = \underbrace{F}_{CDF}(\tau_j - \eta_i) \Leftrightarrow \tau_j - \eta_i = F^{-1}(\kappa_{ij})$$

$F^{-1}(x)$:

1. **logit**: $\ln[x/(1-x)]$
2. **probit**: $\Phi^{-1}(x)$,
3. inverse de la Student (Cauchy)

1,2 & 3 : "invariance palindromique" (inversion de l'ordre des catégories)

3. **gompit**: $\log(-\log(1-x))$ "complementary log log"

pas d'invariance palindromique "group Cox model"

Catégories ordonnées/Inférence

■ Méthodes approchées

- PQL, MQL
- Proc SAS Glimmix

■ Maximum de vraisemblance

- Pas d'intégration (mod fixe)
 - Proc SAS-logistic
- Quadrature de Gauss
 - Proc SAS-nlmixed (modèle fixe ou mixte)
- EM stochastique
 - Natarajan et al, 2000, CSDA

■ Approche bayésienne

Modèle à seuils probit normal/ML

```
proc logistic data=bascores descending ;
    title calving score gender parity gender*parity
fixed model ML via probit;
    freq count;
    class gender parity;
    model score=gender parity gender*parity/
link=probit scale=none;
run;
```

Modèle à seuils probit normal/ML

Type 3 Analysis of Effects			
Effect	DF	Wald Chi-Square	Pr > ChiSq
gender	1	13.1933	0.0003
parity	3	31.3079	<.0001
gender*parity	3	1.3122	0.7262

Analysis of Maximum Likelihood Estimates						
Parameter		DF	Estimate	Standard Error	Wald Chi-Square	Pr > ChiSq
Intercept	3	1	-0.8735	0.0908	92.4952	<.0001
Intercept	2	1	0.4235	0.0906	21.8697	<.0001
gender	F	1	-0.4943	0.1361	13.1933	0.0003
parity	2	1	-0.2801	0.0958	8.5463	0.0035
parity	3	1	-0.4164	0.0922	20.4129	<.0001
parity	4	1	-0.3497	0.0971	12.9761	0.0003
gender*parity	F	2	0.0637	0.1439	0.1960	0.6579
gender*parity	F	3	0.0754	0.1387	0.2957	0.5866
gender*parity	F	4	0.1387	0.1506	0.8476	0.3572

Modèle à seuils probit normal/ML/SAS-NImixed

```
proc nlmixed data=bascores;
parms b0=0 b1=-0.5 b2=-0.5 b3=-0.5 b4=-0.5 b5=0 b6=0
b7=0 tau2=1;
bounds tau2>0;
theta=b0+b1*sex+b2*par2+b3*par3+b4*par4+b5*sex*par2+b
6*sex*par3+b7*sex*par4;
if (score=1) then z=probnorm(-theta);
else if (score=2) then
z=probnorm(tau2-theta)-probnorm(-theta);
else if (score=3) then
z=1-probnorm(tau2-theta);
if (z>1e-10) then ll=log(z);
else ll=-1e100;
model score~general(ll);
estimate 'inter1' -b0;
estimate 'inter2' tau2-b0;
replicate count;
run;
```

Modèle à seuils probit normal/ML/SAS-NImixed

Parameter	Estimate	Standard Error	DF	t Value	Pr > t	Alpha	Lower	Upper	Gradient
b0	0.4235	0.09087	24	4.66	<.0001	0.05	0.2359	0.6110	0.000213
b1	-0.4943	0.1363	24	-3.63	0.0013	0.05	-0.7755	-0.2130	0.000054
b2	-0.2801	0.09610	24	-2.91	0.0076	0.05	-0.4784	-0.08171	0.000121
b3	-0.4163	0.09246	24	-4.50	0.0001	0.05	-0.6072	-0.2255	0.000074
b4	-0.3497	0.09739	24	-3.59	0.0015	0.05	-0.5507	-0.1487	0.000032
b5	0.06369	0.1440	24	0.44	0.6623	0.05	-0.2336	0.3610	0.000063
b6	0.07542	0.1389	24	0.54	0.5921	0.05	-0.2112	0.3621	0.000017
b7	0.1387	0.1508	24	0.92	0.3668	0.05	-0.1725	0.4498	-4.01E-6
tau2	1.2969	0.01719	24	75.47	<.0001	0.05	1.2615	1.3324	-0.00015

Additional Estimates									
Label	Estimate	Standard Error	DF	t Value	Pr > t	Alpha	Lower	Upper	
inter1	-0.4235	0.09087	24	-4.66	<.0001	0.05	-0.6110	-0.2359	
inter2	0.8735	0.09113	24	9.59	<.0001	0.05	0.6854	1.0615	

Catégories ordonnées/Bayes/Réf.

- MAP & approximations
 - GFCAT: Gianola Foulley, 1983, GSE
 - Stiratelli et al, 1984 (binary), Biometrics
- Posterior inference
 - Albert & Chib, 1993, JASA
 - McCulloch & Rossi, 1994, J Econometrics
 - Sorensen et al, 1995, GSE
 - Chipman & Hamada, 1996, Technometrics
 - Girard & Parent, 2000, Technometrics
 - Sorensen & Gianola, 2002

Modèle à seuils probit normal/Bayes

Soit $\phi = (\beta', u')'$ loi a priori $[L, \tau, \phi, G,]$

Lois a priori $[L, \phi, G, \tau] = [L, \phi | G, \tau][G][\tau]$

$[L | \phi, G] \sim$ Normales indtes

1er niveau hiérarchie: modèle var latente

$[\tau] \sim$ Uniforme (ou normales) pour stat d'ordre

$[\phi | G] \sim$ Multinormales

2ème niveau hiérarchie: effets fixes et aléatoires

$[G^{-1}] \sim$ Wishart (gamma) ou Jeffreys

3ème niveau hiérarchie: hyperparamètres

Modèle à seuils probit normal/Bayes

Soit $\phi = (\beta', u')'$ loi a posteriori $[L, \phi, G, \tau | y]$

Lois conditionnelles

$[L | \phi, y] \sim$ Normales tronquées indépendantes entre (τ_{j-1}, τ_j)

$[\tau | \phi, L, y] \sim$ Uniforme tronquée

$$\text{ex } \tau_j \sim U(\max L | y_i = j, \min L | y_i = j + 1)$$

$[\phi | G, L] \sim$ Multinormales (théorie BLUP)

$[G^{-1} | L, \phi] \sim$ Wishart (ou gamma)

Modèle probit cumulé/estimations

Table 2: Parameters estimates under a standard TM (probit)

		ML	Posterior Mean
Intercept	1	-0.423±0.091	-0.420±0.089
	2	0.874±0.091	0.877±0.089
Gender	F vs M	-0.494±0.136	-0.496±0.129
Parity	2 vs 1	-0.280±0.096	-0.277±0.095
	3 vs 1	-0.416±0.092	-0.413±0.091
	4 vs 1	-0.350±0.097	-0.349±0.097
GxP	F2	0.064±0.144	0.065±0.137
	F3	0.075±0.139	0.077±0.132
	F4	0.139±0.151	0.143±0.146
X2		21.9 (7)	
P-value		0.026	0.024*

ML via SAS Proc-Logistic, Posterior mean via Winbugs non informative

*PPP-value

- « Inference under a particular model should be Bayesian »
- « Model assessment can and should involve frequentist ideas »

R Little (2006) Calibrated Bayes: A Bayes/frequentist Roadmap (2005 ASA presidential address), TAS, 60, 213-223



Posterior Predictive Check

- Confrontation des données observées \mathbf{y} et de répliques \mathbf{y}^{rep}
- Les répliques sont obtenues par tirage dans la distribution prédictive a posteriori sachant le modèle
$$p(\mathbf{y}^{rep} | \mathbf{y}) = \int p(\mathbf{y}^{rep}, \boldsymbol{\theta} | \mathbf{y}) d\boldsymbol{\theta} = \int p(\mathbf{y}^{rep} | \boldsymbol{\theta}, \mathbf{x}) \pi(\boldsymbol{\theta} | \mathbf{y}) d\boldsymbol{\theta}$$
- Elles intègrent l'incertitude liée à l'estimation des paramètres $\boldsymbol{\theta}$

Posterior Predictive Check/suite

-Critère de discrépance $T(y, \theta)$

Gelman, Meng & Stern, 1996; Stern, 2000,

Gelman, Carlin, Stern, Rubin, 2004, Chap6

-Confronter la distr. de $T(y^{rep}, \theta) | y$ à celle de $T(y, \theta) | y$

$$\boxed{\text{PPP-value} = \Pr \left[T(y^{rep}, \theta) > T(y, \theta) | y \right]}$$

$$\text{Classical P}_C\text{-value} = \Pr \left[T(y^{rep}) > T(y) | \theta, H \right]$$

θ : null value or point estimate

PPP-value

$$\text{PPP-value} = \Pr \left[T(\mathbf{y}^{rep}, \boldsymbol{\theta}) > T(\mathbf{y}, \boldsymbol{\theta}) \mid \mathbf{y} \right]$$

$$\text{PPP-value} = \int \int I_{[T(\mathbf{y}^{rep}, \boldsymbol{\theta}) > T(\mathbf{y}, \boldsymbol{\theta})]} p(\mathbf{y}^{rep} \mid \boldsymbol{\theta}) p(\boldsymbol{\theta} \mid \mathbf{y}) d\mathbf{y}^{rep} d\boldsymbol{\theta}$$

$$\text{PPP-value} = E \left[I_{[T(\mathbf{y}^{rep}, \boldsymbol{\theta}) > T(\mathbf{y}, \boldsymbol{\theta})]} \mid \mathbf{y} \right]$$

M tirages $\boldsymbol{\theta}^m$ ($m = 1, \dots, M$) dans $[\boldsymbol{\theta} \mid \mathbf{y}]$ donc dans la prédictive $[\mathbf{y}^{rep} \mid \mathbf{y}]$

PPP-value=proportion des tirages pour lesquels $T(\mathbf{y}^{rep,m}, \boldsymbol{\theta}^m) > T(\mathbf{y}, \boldsymbol{\theta}^m)$

PPP/suite

- « Extreme probabilities clearly indicate that data are inconsistent with the model » Stern, 2000
- « Finding an extreme p value & thus rejecting the model is never an end of an analysis; the departure of the test quantity in question from its posterior predictive distribution will often suggests improvements of the model or places to check the data » Gelman et al, 2004

PPP-value/critère de Pearson

Ici : 1ère étape de la hiérarchie étant multinomiale, on peut prendre le critère de Pearson:

$$T(\mathbf{y}, \boldsymbol{\theta}) = \sum_{ik} (O_{ik} - E_{ik})^2 / E_{ik}$$

PPP/Code Winbugs

```
for (i in 1:l) {  
    YREP[i, 1:K]~dmulti(p[i,1:K],n[i])  
    for (k in 1:K) {  
        E[i, k]<-n[i]*p[i,k]  
        TREP[i, k]<-pow(YREP[i, k]-E[i, k],2)/E[i, k]  
        TOBS[i, k]<-pow(Y[i, k]-E[i, k],2)/E[i, k]  
        T[i, k]<-TREP[i, k]-TOBS[i, k]  
    } }  
DT<-sum(T[,])  
PPP<-step(DT)
```



Modèle probit cumulé/qualité d'ajustement

Table 3: Goodness of fit of threshold models applied to calving scores

Observed (O) vs Expected (E)				X=(O-E)/√E		
I	II	III		I	II	III
55	51.7	65	72.1	33	29.3	-0.48
563	558.2	535	545.0	162	156.8	-0.22
1990	1958.0	1525	1592.0	424	388.4	-0.72
488	484.3	423	430.7	118	113.9	-0.18
69	69.3	51	50.4	11	11.3	+0.02
761	769.3	433	414.6	61	71.1	+0.29
2559	2583.0	1216	1161.0	141	171.5	+0.48
300	305.5	178	165.8	22	28.71	+0.30

Modèle à seuils à variance hétérogène (HTM)

McCullach, 1982, JRSS; Foulley & Gianola, 1996, GSE;

Jaffrézic Robert Foulley, 1999, GSE; Derquenne, 1995, 2007

Soit π_{ij} probabilité de réponse dans la catégorie j pour une observation r de la strate i

$$\pi_{ij} = \Phi\left(\frac{\tau_j - \eta_i}{\sigma_i}\right) - \Phi\left(\frac{\tau_{j-1} - \eta_i}{\sigma_i}\right)$$

$$\eta_i = \mathbf{x}_i' \boldsymbol{\beta} \text{ or } \boxed{\eta_i = \mathbf{x}_i' \boldsymbol{\beta} + \mathbf{z}_i' \mathbf{u}}; \boxed{\ln(\sigma_i) = \mathbf{p}_i' \boldsymbol{\delta}}$$

Equivaut à:

$$l_{ir} = \mathbf{x}_i' \boldsymbol{\beta} + \mathbf{z}_i' \mathbf{u} + \sigma_i e_{ir}^* \text{ and } y_{ijr} = 1 \Leftrightarrow \tau_{j-1} < l_{ir} \leq \tau_j$$

$\Phi(x)$ peut être remplacé par $F(x) = (1 + \exp(-x))^{-1}$

Modèle à seuils hétérogène/estimations

Table 6: Parameters estimates under a heteroskedastic TM (probit)

		ML	Posterior Mean
Intercept	1	-0.350±0.065	-0.348±0.064
	2	0.889±0.065	0.893±0.068
Gender	F vs M	-0.341±0.026	-0.342±0.026
Parity	2 vs 1	-0.236±0.070	-0.234±0.066
	3 vs 1	-0.359±0.065	-0.357±0.064
	4 vs 1	-0.274±0.070	-0.273±0.069
Dispersion	F vs M	-0.123±0.027	-0.121±0.027
X2		3.65 (9)	
P-value		0.93	0.79*
DIC			122 (7) vs 144 (9)

ML via personal APL programme, Posterior mean via Winbugs non informative

*PPP-value

Modèle à seuils hétérogène/ajustement

Table 5: Goodness of fit of threshold models applied to calving scores

Observed (O) vs Expected (E)				X=(O-E)/√E		
I	II	III		I	II	III
55	55.6	65	68.8	33	28.7	0.06
563	572.6	535	523.4	162	164.0	0.39
1990	1983.0	1525	1539.0	424	417.2	-0.16
488	483.6	423	419.7	118	125.7	-0.21
69	65.0	51	55.1	11	10.8	-0.51
761	754.8	433	438.8	61	61.4	-0.23
2559	2561.0	1216	1213.0	141	142.4	+0.03
300	309.2	178	168.5	22	22.3	+0.52

Exemple 2/Données

Sex	Parity	Sire	Score1	Score2	Score3
0	1	1	2	3	1
0	1	2	6	5	2
0	1	3	1	2	4
0	1	4	2	2	0
0	1	5	1	4	4
0	1	6	1	1	0
0	1	7	5	3	0
0	1	8	2	4	1
0	1	9	4	3	0
0	0	1	8	9	3
0	0	2	10	8	1
0	0	3	10	13	6
0	0	4	4	9	6
0	0	5	10	11	7
0	0	6	3	9	2
0	0	7	14	12	2
0	0	8	12	10	3
0	0	9	19	10	1
1	1	1	1	2	0
1	1	2	6	1	1
1	1	3	5	4	0
1	1	4	2	1	3
1	1	5	10	3	1
1	1	6	5	3	0
1	1	7	4	4	0
1	1	8	5	0	0
1	1	9	7	5	1
1	0	1	14	10	3
1	0	2	30	12	1
1	0	3	10	3	3
1	0	4	13	3	0
1	0	5	9	10	3
1	0	6	7	6	1
1	0	7	30	6	0
1	0	8	22	6	1
1	0	9	24	10	0

Sex: 0=Male, 1=Female; Parity: 1=Heifers, 0=Adult Cows

Modèle à seuils mixte homogène/estimations

Table 5: Estimates of fixed effects and prediction of sire effects

	PQL approach		Posterior inference	
	Estimate	SE	Estimate*	SE*
Inter1	-0.198	0.121	-0.199	0.130
Inter2	1.051	0.128	1.053	0.137
Gender: F-M	-0.586	0.114	-0.587	0.114
Parity: H-C	0.162	0.163	0.162	0.164
GxP: FC	-0.026	0.231	-0.026	0.233
Sire 1	0.153	0.154	0.147	0.160
Sire 2	-0.175	0.145	-0.171	0.153
Sire 3	0.217	0.150	0.209	0.161
Sire 4	0.168	0.161	0.162	0.170
Sire 5	0.274	0.144	0.265	0.157
Sire 6	0.125	0.168	0.120	0.173
Sire 7	-0.312	0.147	-0.305	0.164
Sire 8	-0.181	0.151	-0.178	0.161
Sire 9	-0.269	0.145	-0.263	0.159
Sire Variance**	0.0699	0.0455	0.070	0.082
Model check***			0.369	
DIC (pD)			245 (11.5)	

mean and standard deviation of the posterior distribution; ** exp(MAP log(sire var))

***PPP-value

Modèle à seuils mixte hétérogène/estimations

Table: Estimates of fixed effects and prediction of sire effects under a HTM (sex effect)

	Posterior inference	
	Estimate*	SE*
Inter1	-0.218	0.137
Inter2	1.094	0.147
Gender	-0.680	0.158
Parity	0.167	0.165
GxP	-0.015	0.251
Disp/ Gender F-M	0.117	0.123
Sire 1	0.150	0.173
Sire 2	-0.189	0.168
Sire 3	0.230	0.172
Sire 4	0.186	0.183
Sire 5	0.292	0.168
Sire 6	0.138	0.188
Sire 7	-0.323	0.173
Sire 8	-0.179	0.172
Sire 9	-0.297	0.170
Sire Variance	0.081#	0.087
Model check**	0.403	
DIC	246 (12)***	

mean and standard deviation of the posterior distribution:

PPP-value * 245 (11.5) pour le modèle à seuils homogène

#exp(MAP logvar)

Discussion

- Autres modèles
 - Modèles logit séquentiels
 - Tutz, 1990, 1991
 - Modèles logistiques PLS
 - Bastien et al, 2005
- Modèles multivariés
 - Plusieurs variables ordinaires
 - Variables ordinaires et continues
- Inférence
 - Approximées vs exactes
 - Modèles marginaux (GEE) vs modèles mixtes



Bibliographie

- Fahrmeir L, Tutz G (1994) Multivariate statistical modelling based on GLM, Springer-Verlag
- Liu I, Agresti A (2005) The analysis of ordered categorical data: an overview and a survey of recent developments. *Societas de Estadistica e Investigacion Operativa*, 14, 1-73
- Marin JM, Robert CP (2007) A practical approach to computational Bayesian statistics, Springer Verlag
- Molenberghs G, Verbeke G (2005) Models for discrete longitudinal data. Springer-Verlag
- McCullagh P (1980) Regression models for ordinal data. *JRSS B* 42, 109-142
- Stokes ME, Davis CS, Koch GG (2000) Categorical data analysis using the SAS system, 2nd edition, SAS Institute #57998