

Les modèles linéaires généralisés à effets mixtes: Les prévisions sont-elles fiables?

Mathieu Fortin
UMR LERFoB
AgroParisTech/INRA

Journées CAQ-CAPSIS 8-10 avril 2013



Un modèle linéaire généralisé ?

- La grande famille des modèles dont la variable réponse est discrète
 - Par exemple
 - Régression logistique (oui/non)
 - Régression de Poisson (fréquence)

Un modèle linéaire, mais une forme non linéaire

$$\Pr(y_{ij} = 1|u_i) = \frac{e^{x_{ij}\beta + u_i}}{1 + e^{x_{ij}\beta + u_i}}$$

$$x_{ij}\beta = \beta_0 + \beta_{1,s} + (\beta_{2,s} + \beta_{3,s}\text{merch}_{ij})\Delta\text{dbh}_{ij}$$

Modèle linéaire généralisé à effets mixtes (fixes et aléatoires)

- Une extension des modèles linéaires généralisés pour tenir compte de l'autocorrélation
- Une technique statistique relativement récente
<10 ans

Un modèle linéaire, mais une forme non linéaire

$$\Pr(y_{ij} = 1|u_i) = \frac{e^{x_{ij}\beta + u_i}}{1 + e^{x_{ij}\beta + u_i}} \quad u_i \sim N(0, \sigma_u^2)$$

$$\mathbf{x}_{ij}\boldsymbol{\beta} = \beta_0 + \beta_{1,s} + (\beta_{2,s} + \beta_{3,s}\text{merch}_{ij})\Delta\text{dbh}_{ij}$$

Des packages statistiques

- SAS
 - Procédure NLMIXED
 - Procédure GLIMMIX
- R
 - Fonction glmer – package lme4

En pratique,


- On ne connaît que très rarement l'effet aléatoire
- Que faire?

$$\Pr(y_{ij} = 1|u_i) = \frac{e^{x_{ij}\beta + u_i}}{1 + e^{x_{ij}\beta + u_i}} \quad u_i \sim N(0, \sigma_u^2)$$

$$\mathbf{x}_{ij}\boldsymbol{\beta} = \beta_0 + \beta_{1,s} + (\beta_{2,s} + \beta_{3,s}\text{merch}_{ij})\Delta\text{dbh}_{ij}$$

En pratique,

- On remplace l'effet aléatoire par la valeur la plus probable, soit zéro!
- Ca cause des biais (Groom et al. 2012)




D'un point de vue statistique,

$$\begin{aligned} E[y_{ij}|\mathbf{x}_{ij}] &= \int E[y_{ij}|\mathbf{x}_{ij}, u_i] \text{pdf}(u_i; \sigma_u^2) du_i \\ &= \int f(\mathbf{x}_{ij}\boldsymbol{\beta} + z_{ij}u_i) \text{pdf}(u_i; \sigma_u^2) du_i \end{aligned}$$

Quadratures de Gauss

$$f(v_i) = w(v_i)h(v_i)$$

$$\int f(v_i)dv_i \approx \sum_{k=1}^r w'_k h(v_{i,k})$$



Quadrature de Gauss-Hermite

- On peut corriger l'estimation
- On peut obtenir un intervalle de confiance sans biais

Etude par simulation

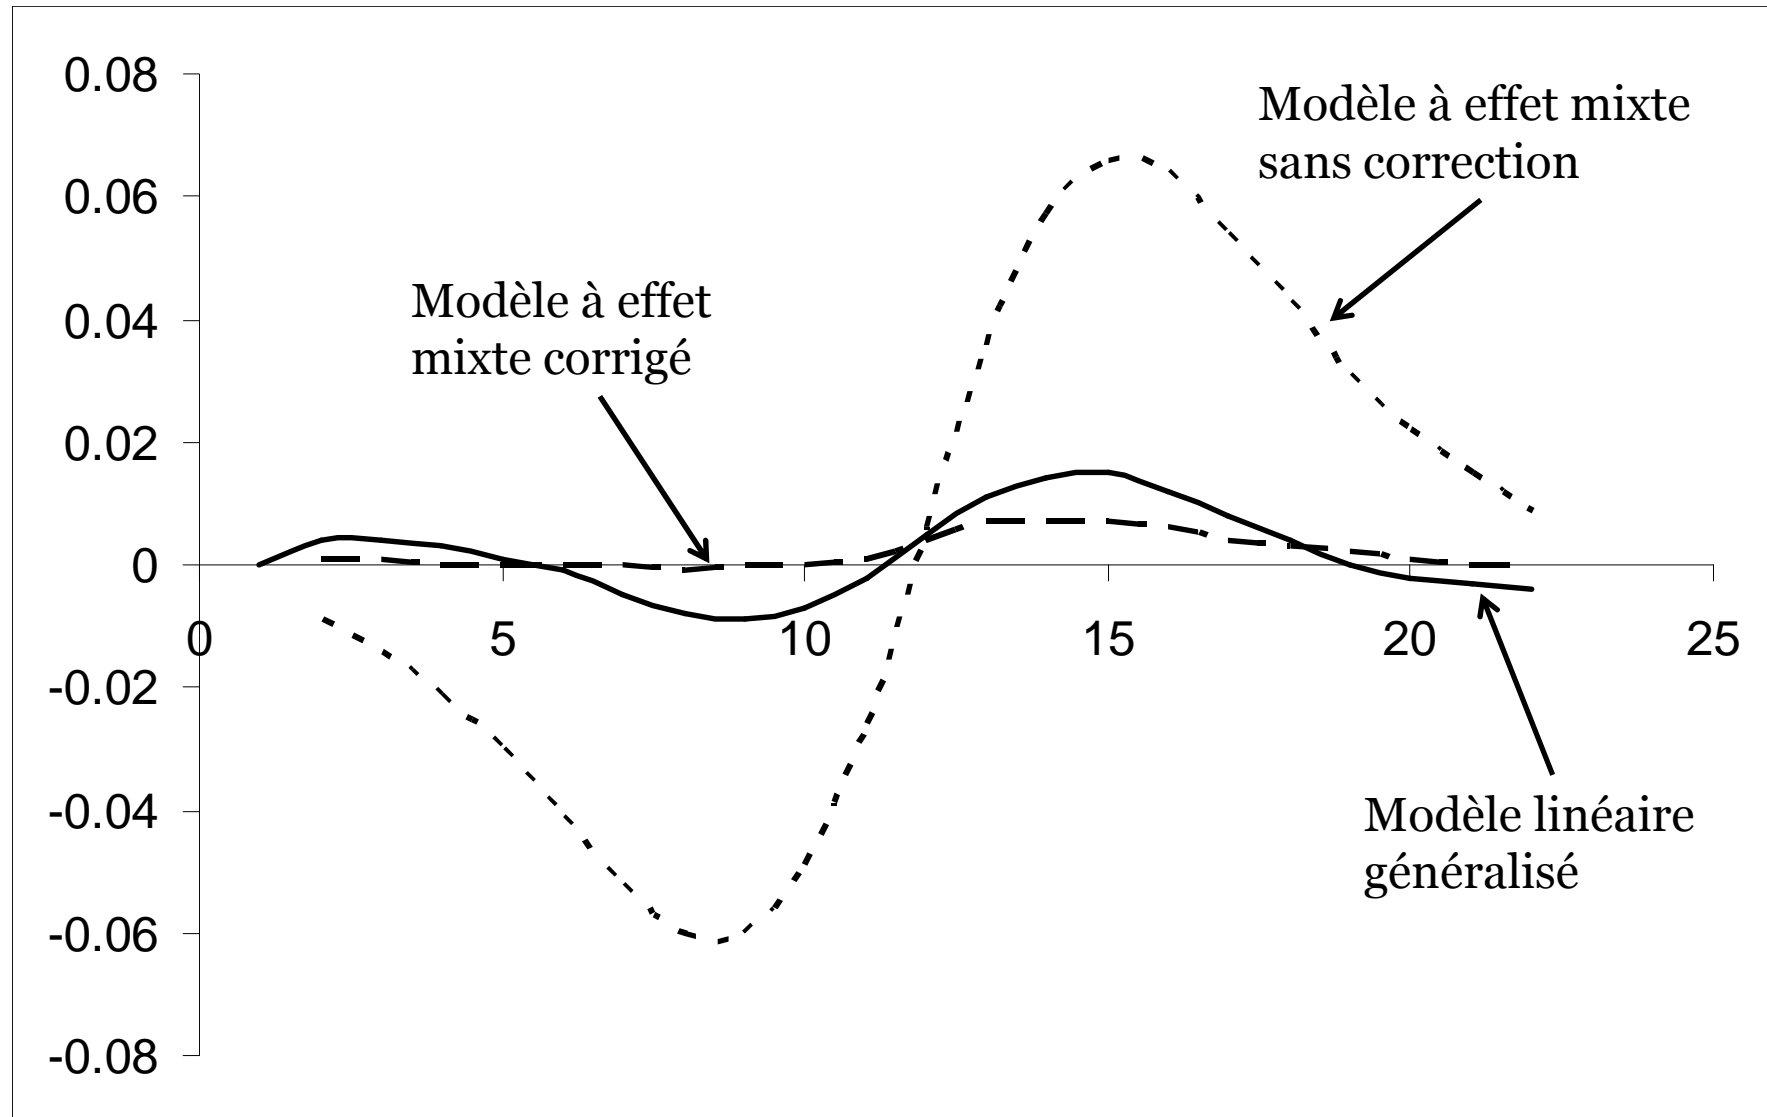
- On tire 1000 échantillons d'une population dont on connaît les paramètres


$$E[y_{ij} | \mathbf{x}_{ij}, u_i] = f(\mathbf{x}_{ij}\boldsymbol{\beta} + z_{ij}u_i) = \frac{e^{\beta_0 + \beta_1 x_{ij} + u_i}}{1 + e^{\beta_0 + \beta_1 x_{ij} + u_i}}$$

$$u_i \sim N(0, \sigma_u^2)$$

Etude par simulation

- On ajuste un modèle linéaire généralisé
- On ajuste un modèle linéaire généralisé à effet mixte
 1. On corrige avec le nouvel estimateur
 2. On ne corrige pas et on fixe l'effet aléatoire à zéro





Conclusions

- En ce qui concerne la moyenne
 - L'estimateur corrigé et la méthode traditionnelle sont sans biais
 - Un modèle mixte sans correction est la pire option
 - Plus la variance de l'effet aléatoire est élevée, plus la divergence est grande

Conclusions

- En ce qui concerne les intervalles de confiance
 - L'estimateur corrigé est sans biais
 - La méthode traditionnelle tend à sous-estimer la couverture des intervalles
 - Plus la variance de l'effet aléatoire est élevée, plus la sous-estimation est importante

Publication

- Fortin, M. 2013. *Population-averaged predictions with generalized linear mixed-effects models in forestry: an estimator based on Gauss-Hermite quadrature.* Canadian Journal of Forest Research 43: 129-138.
- Programmes disponibles pour adapter la fonction R glmer et la procédure SAS GLIMMIX