

**Modèle poissonnien avec sur-représentation de zéros
et dépendance spatiale :
application à l'étude de la répartition spatiale de juveniles
en forêts tropicales humides**

Frédéric Mortier & Olivier Flores

Plan

- ▣ Contexte.
- ▣ Sur-représentation de zeros et modèle de mélange : *Zero Inflated Model*.
- ▣ Prise en compte de la dépendance spatiale.
- ▣ Estimation et implémentation WinBUGS.
- ▣ Application.
- ▣ Conclusions et perspectives.

Contexte

Exploitation durable des forêts

☞ Quelle vitesse de reconstitution des stocks ?

☞ Processus de régénération ?

⇒ processus biologiques impliqués ?

⇒ quel impact de l'environnement ?

Richesse spécifique Forêts tropicales

☞ 50% des espèces ; + de 100 espèces à l'hectare

☛ compréhension difficile des écosystèmes : construction de groupe d'espèces fondés sur les stades adultes.

- besoin en lumière
- stratégie de dispersion


☞ stades juvéniles peu ou mal connus :

☛ Quelles sont les conditions environnementales qui expliquent la répartition spatiale des stades juvéniles ?

☛ les groupes fondés sur les adultes sont-ils valables pour les stades jeunes ?

Site expérimental et observations

- 👉 Paracou en Guyane française
- 👉 nombre d'individus d'une espèce dont la taille $\in [1, 10cm]$ de dbh sur des quadrats 10×10



- 👉 conditions environnementales pour chaque quadrat résumées en 15 variables environnementales.

- ➡ Approche classique pour des données de comptage : modèle de Poisson.
- ➡ Mais le nombre de quadrats vides sur représenté : sur-dispersion : mauvais ajustement d'un modèle de Poisson.

**une proportion p des observations est issue
d'une poisson d'espérance nulle (masse de dirac en zero) et
une proportion $(1 - p)$ issue d'une poisson d'intensité μ**

Zero Inflated Model

Z suit un Zeros Inflated Modèle, $Z \sim ZIP(p, \mu)$

si

$$\mathbb{P}(Z = z|p, \mu) = \begin{cases} p + (1 - p)\mathbb{P}(Z = 0|\mu), & \text{si } z = 0 \\ (1 - p)\mathbb{P}(Z \neq 0|\mu), & \text{si } z > 0 \end{cases}$$

\Updownarrow

$$f(z|p, \mu) = pP(0) + (1 - p)P(\mu)$$

$$\mathbb{E} = (1 - p)\mathbb{E}_P(Z|\mu) \quad \mathbb{V} = p(1 - p) [\mathbb{E}_P(Z|\mu)]^2 + (1 - p)\mathbb{V}_P(Z|\mu)$$

Vraisemblance

Soit $C = (C_1, \dots, C_n)$ un vecteur latent

C_i prend la valeur $c_i = 0$ si $Z_i > 0$ ou si Z_i nul et issu de $P(\mu)$ et $c_i = 1$ si Z_i nul et issu de $P(0)$.

Marginales $C_i \sim \text{Bern}(p)$ ($p = P(C_i = 1)$). la vraisemblance jointe s'écrit alors

$$\begin{aligned} \ell(Z, C|p, \mu) &= \prod_{i=1}^n \ell(Z_i|C_i = c_i, p, \mu) \pi(C_i|p) \\ &= \prod_{i=1}^n p^{c_i} [(1-p) P(\mu)]^{1-c_i} \end{aligned}$$

Prise en compte de variables explicatives

La présence/absence et l'abondance dépendent de l'environnement :


☞ la proportion du mélange dépend de variables environnementales :

$$\text{logit}(p_i) = B_i\gamma$$

☞ l'intensité dépend également de variables environnementales :

$$\log(\mu_i) = X_i\beta$$

Prise en compte de la dépendance spatiale



Comment décrire le fait $\mathbb{P}(Z_i, Z_j) \neq \mathbb{P}(Z_i)\mathbb{P}(Z_j)$.

Modèle hiérarchique :

1. Data level : $Z_i | p_i, \mu_i \sim ZIP(p_i, \mu_i)$ et $(Z_i | p_i, \mu_i) \perp (Z_j | p_j, \mu_j)$
2. Process Level :
 - proportion du mélange : $(\text{logit}(p_i) | \gamma) = B_i \gamma$
 - intensité : $(\log(\mu_i) | \beta_i, \alpha_i) = X_i \beta + \alpha_i$
3. Prior : $\beta, \gamma \sim \mathcal{N}(0, 1000)$ et l'effet Spatial : $\alpha_i \sim F(\theta)$
4. hyper-prior $\theta \sim g$:

Composante spatiale

Données à support discret (lattice).

Processus conditional autoregressive (CAR) :

$$\alpha_i | \alpha_j, j \in V_i \sim \mathcal{N} \left(\sum_{j \in V_i} \rho c_{ij} \alpha_j, \sigma^2 \right)$$

- V_i voisinage de i (8 voisins)
- $E(\alpha_i) = 0$
- σ^2 : variance conditionnelle
- ρ : paramètre qui pondère la dépendance spatiale
- $C = (c_{ij})$: matrice de poids

$$\theta = (\rho, \sigma^2)$$

$$\text{hyper-prior : } \rho \sim U]a, b[, \sigma^2 \sim IG(0.0001, 0.0001)$$

Estimation et implémentation Winbugs

simuler loi *a posteriori*

$$\pi(\beta, C, \gamma, \alpha, \rho, \sigma^2 | Z) = f(Z | C, \gamma, \beta, \rho, \sigma^2, \alpha) \pi(C | \gamma) \pi(\alpha | \rho, \sigma^2) \pi(\beta) \pi(\gamma) \pi(\rho) \pi(\sigma^2).$$

Utilisation de WinBUGS.

Winbugs

- ☞ logiciel libre
- ☞ compatible R (R2WinBUGS ou OpenBUGS)
- ☞ flexible et bien adapté à la modélisation hiérarchique

```
#y = ax + b + e\\
model{
  for(i in 1 : N){
    y[i] ~ dnorm(mu[i], tau)
    mu[i] <- a*x[i] + b
  }
  a ~ dnorm(0,0.00001)
  b ~ dnorm(0,0.00001)
  tau ~dgamma(0.0001,0.0001)
  sigma <- 1/tau
}
```


Cas du ZIP(ω, μ)

```
model{
  for (i in 1:N){
    Z[i] ~ dpois(lambda[i])
    lambda[i] <- (1 - C[i])*mu[i]
    C[i] ~ dbern(omega[i])
    logit(omega[i]) <- ab[1] + ab[2]*sDL[i]
    log(mu[i]) <- ap[2]*Ax2[i] + ap[3]*Sb[i] + alpha[i]
  }
}
```

```
# prior spatial : CAR
alpha[1:N] ~ car.proper(delta[],C[],adj[],
                        num[],M[],tau.s,gamma)
# priors LAMBDA
for(i in 1:2){ap[i] ~dnorm(0, 0.01)}
# priors OMEGA
for(i in 1:3){ab[i] ~dnorm(0, 0.01)}
for(i in 1:N) {delta[i] <- ap[1] }
#hyper-prior
tau.s~dgamma(0.1, 0.01)
var.s<-1/tau.s
gamma.min <- min.bound(C[],adj[],num[],M[])
gamma.max <- max.bound(C[],adj[],num[],M[])
gamma ~ dunif(gamma.min,gamma.max)
}
```


Application

Eperua Falcata ; dispersion non assistée et limitée, hemi-tolérante, $n=2500$, $[0,18]$ individus par quadrat, 83% de zéros dans les observations. 72,4% attendus $P(0.323)$;







DIC

ZIP = 3067

Sglm = 2742

SZIP = **2499**





Conclusions et perspectives

Conclusions

- ☞ *ZIP* tient bien compte de la sur-dispersion
- ☞ *CAR* comme *a priori* rend bien compte de la structure spatiale
- ☞ Approche hiérarchique bayésienne intéressante en écologie
- ☞ effet spatial très fort ! pouvoir prédictif en écologie ?
- ☞ selection variable, RJMCMC ?

