

Estimation de paramètres démographiques à partir d'individus non marqués

Marc J. Mazerolle

Centre d'étude de la forêt, Institut de recherche sur les forêts, Université du Québec en Abitibi-Témiscamingue, QC



Jour 2

Utilisation du package `unmarked`

- préparation du jeu de données
- modèles d'occupation à une saison
- modèles d'occupation dynamiques
- modèles N -mixture à une saison
- modèles N -mixture dynamiques
- sélection de modèles et inférence multimodèle avec AICcmodavg
- tests d'ajustement

Une approche unifiante

Peu importe l'analyse, les mêmes étapes reviennent :

- importer les données
- exécuter les modèles
- vérifier les suppositions
- visionner les résultats (β , SE)
- représenter graphiquement les résultats

Possible d'exécuter les analyses dans des programmes indépendants, sauvegarder les projets, copier-coller ensuite pour traitement ultérieur (graphiques, inférence multimodèle)

- pénible si les données changent et risque d'erreur
- peut être difficile à répéter (superviseur)

Il y a une meilleure façon d'organiser le travail ...

Plan

Utilisons R

Exemple 1 — Modèle d'occupation à une saison

Exemple 2 — Modèle d'occupation dynamique

Exemple 3 — Modèle N -mixture

Autres modèles dans `unmarked`

Packages utiles

Le mot de la fin

Utilisons R

Rédiger un script de codes

- transparent
- une feuille de route qui documente tout ce qu'on a fait
- permet de facilement répéter le traitement de A à Z

Utiliser un éditeur de texte intelligent

- petit logiciel qui reconnaît la syntaxe de R
- envoie les codes directement à R
- coloration de différents termes, reconnaît les parenthèses, fournit de l'aide, complétion automatique des commandes
- plusieurs disponibles (e.g., Tinn-R, RStudio, Emacs)

Sauvegarder les commandes complètes (importation, chargement de packages, graphiques) dans un fichier .R (un script)

- ajouter des commentaires (#)
- peut être recyclé pour différentes analyses

Utilisons R

Exemple 1 — Modèle d'occupation à une saison

Exemple 1 — Modèle d'occupation à une saison

Occupation à une saison

Grenouilles vertes (*Lithobates clamitans*) en étangs de tourbières



Photo M. Mazerolle

Échantillonnage à l'aide de points d'écoute

- 34 étangs
- 5 visites

Exemple 1 — Modèle d'occupation à une saison

Utilisation de unmarked

À l'aide du package unmarked

Les étapes principales :

- installer et charger package
- importer les données
- formater les données à l'aide des fonctions
- exécuter l'analyse
- sélection de modèle et inférence multimodèle
- vérifier l'ajustement
- faire des graphiques

Exemple 1 — Modèle d'occupation à une saison

Utilisation de unmarked

Installer le package

```
> install.packages(pkgs = "unmarked")
```

Charger le package afin d'utiliser les fonctions lors de la session de travail en R

```
> library(unmarked)
```

Exemple 1 — Modèle d'occupation à une saison

Importation des données

Importer les données de détection

```
> gfrog <- read.table("Single_season_detection.csv",
  header = TRUE)
> head(gfrog)
  Pond Visit1 Visit2 Visit3 Visit4 Visit5
1    1      0      0      1      0      0
2    2      0      0      1      1      0
3    3      0      0      0      0      1
4    4      0      0      0      1      1
5    5      0      0      0      1      0
6    6      0      0      0      0      0
```

Exemple 1 — Modèle d'occupation à une saison

Importation des données

Importer variables de sites

```
> site.covs <- read.table("Single_season_siteCovs.csv",
  header = TRUE)
> head(site.covs)
  Pond Perimeter Dist.pond
1    1        79       27
2    2       159       2
3    3       105       8
4    4       628       3
5    5        75       3
6    6       141       58
```

Exemple 1 — Modèle d'occupation à une saison

Importation des données

Importer les variables d'échantillonnage

```
> airtemp <- read.table("Single_season_sampingCovs.csv",
  header = TRUE)
> head(airtemp)
  Pond Visit1 Visit2 Visit3 Visit4 Visit5
1    1     4.5    11.0   22.0   16.5    21
2    2     5.0    10.0   20.0   23.0    21
3    3     4.0     9.5   19.0   22.0    20
4    4     4.0    10.0   19.5   24.0    20
5    5     4.0    10.0   19.5   20.5    21
6    6     6.0    10.0   21.5   17.0    20
```

Exemple 1 — Modèle d'occupation à une saison

Importation des données

Vérifier la moyenne des variables de sites

```
> colMeans(site.covs[, c("Perimeter", "Dist.pond")])  
Perimeter Dist.pond  
190.206    29.676
```

Vérifier la moyenne des variables d'échantillonnage

```
> mean(as.vector(as.matrix(airtemp[, -1])))  
[1] 15.397
```

Préférable d'avoir des moyennes près de 0

- centrer
- centrer et réduire
- diviser par une constante
- utiliser le log

Exemple 1 — Modèle d'occupation à une saison

Formatage des données

Centrer les variables de sites

```
> moy.sites <- colMeans(site.covs[, c("Perimeter",  
"Dist.pond")])  
> site.covs$Perim.cent <- site.covs$Perimeter -  
moy.sites[1]  
> site.covs$Dist.pond.cent <- site.covs$Dist.pond -  
moy.sites[2]
```

Centrer la température de l'air

```
> air.mean <- mean(as.vector(as.matrix(airtemp[,  
-1])))  
> airtemp.cent <- airtemp[, -1] - air.mean
```

Exemple 1 — Modèle d'occupation à une saison

Formatage des données

Formater les données avec unmarkedFrameOccu

```
> gfrog.data <- unmarkedFrameOccu(y = gfrog[, -1],  
siteCovs = site.covs,  
obsCovs = list(Airtemp.cent =  
airtemp.cent))
```

Points importants :

- y doit être une matrice ou un data.frame constitué des observations (0, 1)
- siteCovs doit être un data.frame
- obsCovs doit être une liste de data.frame

Exemple 1 — Modèle d'occupation à une saison

Objet unmarkedFrameOccu

Résumé des données

```
> summary(gfrog.data)  
  
unmarkedFrame Object  
  
34 sites  
Maximum number of observations per site: 5  
Mean number of observations per site: 5  
Sites with at least one detection: 18
```

```
Tabulation of y observations:  
   0     1 <NA>  
 138    32    0
```

Site-level covariates:

Pond	Perimeter	Dist.pond
Min. : 1.00	Min. : 50.0	Min. : 0.0
1st Qu.: 9.25	1st Qu.: 91.2	1st Qu.: 8.0

...

Exemple 1 — Modèle d'occupation à une saison

Utilisation de occu

Exécutons un modèle nul

```
> ##null  
> m0 <- occu(~ 1 ~ 1, data = gfrog.data)
```

Formule double ~ Airtemp.cent ~ Dist.pond.cent

- première formule pour la détection
 - deuxième formule pour l'occupation

```
> summary(m0)
Call:
occu(formula = ~1 ~ 1, data = gfrog.data)
```

Occupancy (logit-scale):

Estimate	SE	z	P(> z)
0.59	0.517	1.14	0.254

```
Detection (logit-scale):
  Estimate      SE      z P(>|z|)
-0.883 0.282 -3.13 0.00176
```

AIC: 162.8
Number of sites: 34

Exemple 1 — Modèle d'occupation à une saison

Utilisation de occu

Les objets de unmarked sont plus complexes et de type S4

```
> str(m0)
```

On accède au sous-éléments à l'aide de @ (au lieu de \$)

Exemple 1 — Modèle d'occupation à une saison

Utilisation de occu

Réalisons les mêmes modèles qu'avec PRESENCE

```

> ##psi(.) p(Airtemp.cent)
> m1 <- occu(~ Airtemp.cent ~ 1, data = gfrog.data)

> ##psi(Dist.pond.cent) p_()
> m2 <- occu(~ 1 ~ Dist.pond.cent, data = gfrog.data)

> ##psi(Dist.pond.cent) p(Airtemp.cent)
> m3 <- occu(~ Airtemp.cent ~ Dist.pond.cent, data = gfrog.data)

```

Exemple 1 — Modèle d'occupation à une saison

Occupation à une saison

Important d'inspecter les sorties

```

> summary(m1)
Call:
occu(formula = ~Airtemp.cent ~ 1, data = gfrog.data)

Occupancy (logit-scale):
Estimate     SE     z P(>|z|)
0.475  0.46  1.03  0.302

Detection (logit-scale):
                  Estimate     SE     z P(>|z|)
(Intercept)    -1.164  0.3307 -3.52  0.000434
Airtemp.cent   0.215  0.0562  3.83  0.000130

AIC: 141.99
Number of sites: 34
optim convergence code: 0
optim iterations: 42
Bootstrap iterations: 0

```

Exemple 1 — Modèle d'occupation à une saison

Inspection de l'objet unmarkedFitOccu

Important d'inspecter les sorties

```
> summary(m2)
Call:
occu(formula = ~1 ~ Dist.pond.cent, data = gfrog.data)

Occupancy (logit-scale):
Estimate     SE      z P(>|z|)
(Intercept) 0.6824 0.6511 1.05  0.295
Dist.pond.cent -0.0347 0.0226 -1.54  0.124

Detection (logit-scale):
Estimate     SE      z P(>|z|)
-0.908 0.294 -3.08 0.00204

AIC: 161.16
Number of sites: 34
optim convergence code: 0
optim iterations: 22
Bootstrap iterations: 0
```

Exemple 1 — Modèle d'occupation à une saison

Inspection de l'objet unmarkedFitOccu

Important d'inspecter les sorties

```
> summary(m3)
Call:
occu(formula = ~Airtemp.cent ~ Dist.pond.cent, data = gfrog.data)

Occupancy (logit-scale):
Estimate     SE      z P(>|z|)
(Intercept) 0.4889 0.5106 0.958  0.338
Dist.pond.cent -0.0311 0.0195 -1.593  0.111

Detection (logit-scale):
Estimate     SE      z P(>|z|)
(Intercept) -1.160 0.328 -3.53 0.000415
Airtemp.cent 0.213 0.056 3.80 0.000144

AIC: 140.57
Number of sites: 34
optim convergence code: 0
optim iterations: 59
Bootstrap iterations: 0
```

Exemple 1 — Modèle d'occupation à une saison

Test d'ajustement

Test de MacKenzie et Bailey pour vérifier l'ajustement du modèle global dans le package AICcmodavg

```
> library(AICcmodavg)
> gof <- mb.gof.test(m3, nsim = 10000, plot.hist = TRUE)

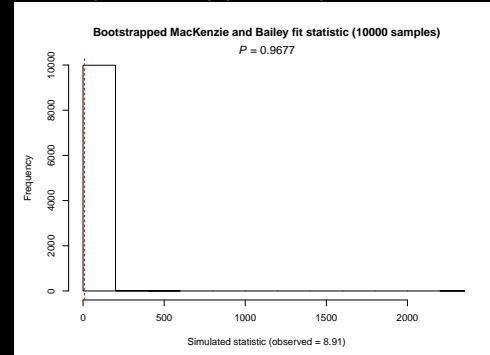
> gof$chisq.table
   Cohort Observed Expected Chi-square
00000    0      16 15.88443  0.0008408
00001    0      3  1.73238  0.9275466
00010    0      3  2.63258  0.0512790
00011    0      1  1.59623  0.2227048
00100    0      2  2.87143  0.2644622
00101    0      1  1.70712  0.2929045
00110    0      3  2.52541  0.0891859
00111    0      3  1.50934  1.4722128
01100    0      1  0.32393  1.4109786
01110    0      1  0.33727  1.3022534

> gof$c.hat.est
[1] 0.32928
```

Exemple 1 — Modèle d'occupation à une saison

Test d'ajustement

Graphique de la distribution du χ^2 observé par rapport aux χ^2 obtenus par bootstrap paramétrique



Exemple 1 — Modèle d'occupation à une saison

Sélection de modèles

Effectuer la sélection de modèle à l'aide des fonctions du package AICcmodavg

```
> ##set up models in list
> Candidates <- list(m0, m1, m2, m3)
> ##assign names to the models
> Names <- c("m0", "m1", "m2", "m3")
```

Ajuster la sélection de modèle par \hat{c} si $\hat{c} > 1$

```
> ##model selection
> aictab(cand.set = Candidates, modnames = Names, c.hat = 1)
Model selection based on AICc :

  K   AICc Delta_AICc AICcWt Cum.Wt     LL
m3 4 141.95      0.00    0.6    0.6 -66.28
m1 3 142.79      0.84    0.4    1.0 -67.99
m2 3 161.96     20.01    0.0    1.0 -77.58
m0 2 163.19     21.25    0.0    1.0 -79.40
```

Exemple 1 — Modèle d'occupation à une saison

Inférence multimodèle

Estimé pondéré ($\bar{\theta}$) de la température de l'air

```
> modavg(cand.set = Candidates, modnames = Names,
  c.hat = 1, parm = "Airtemp.cent",
  parm.type = "detect")
```

Ajuster les SE par \hat{c} si $\hat{c} > 1$

```
Multimodel inference on "p(Airtemp.cent)" based on AICc

AICc table used to obtain model-averaged estimate:

  K   AICc Delta_AICc AICcWt Estimate   SE
m1 3 142.79      0.84    0.4    0.21 0.06
m3 4 141.95      0.00    0.6    0.21 0.06

Model-averaged estimate: 0.21
Unconditional SE: 0.06
 95 % Unconditional confidence interval: 0.1 , 0.32
```

Exemple 1 — Modèle d'occupation à une saison

Inférence multimodèle – prédictions

Pour faire des prédictions pondérées en utilisant tous les modèles :

On crée un nouveau jeu de données

```
> range(airtemp.cent)
[1] -11.897 10.603
> ##create newdata data frame
> ##centered air temperature
> new.dats <- data.frame(Airtemp.cent =
  seq(from = min(airtemp.cent),
      to = max(airtemp.cent),
      length.out = 30))
> ##uncentered air temperature
> new.dats$Airtemp <- new.dats$Airtemp.cent + air.mean
```

Exemple 1 — Modèle d'occupation à une saison

Inférence multimodèle – prédictions

On peut ensuite faire les prédictions avec modavgpred()

```
> preds <- modavgpred(cand.set = Candidates, modnames = Names,
  c.hat = 1, newdata = new.dats,
  type = "response", parm.type = "detect")
```

> preds

```
Model-averaged predictions based on entire model set:

  mod.avg.pred uncond.se
  1          0.02    0.02
  2          0.03    0.02
  3          0.03    0.02
  4          0.04    0.03
  ...
  
```

On peut ajouter les valeurs prédites et SE inconditionnelles

```
> new.dats$mod.avg.pred <- preds$mod.avg.pred
> new.dats$uncond.se <- preds$uncond.se
```

Exemple 1 — Modèle d'occupation à une saison

Inférence multimodèle – prédictions

Pour calculer les intervalles de confiance, on utilise l'échelle logit

```
> preds.logit <- modavgpred(cand.set = Candidates,
   modnames = Names,
   c.hat = 1, newdata = new.dats,
   type = "link", parm.type = "detect")
> ##add to data set
> new.dats$mod.avg.pred.logit <- preds.logit$mod.avg.pred
> new.dats$uncond.se.logit <- preds.logit$uncond.se
```

On calcule les limites et on convertit sur l'échelle originale avec
plogis()

```
> ##95% CI
> new.dats$low95 <- plogis(new.dats$mod.avg.pred.logit -
  1.96 * new.dats$uncond.se.logit)
> new.dats$upp95 <- plogis(new.dats$mod.avg.pred.logit +
  1.96 * new.dats$uncond.se.logit)
```

Exemple 1 — Modèle d'occupation à une saison

Inférence multimodèle – prédictions

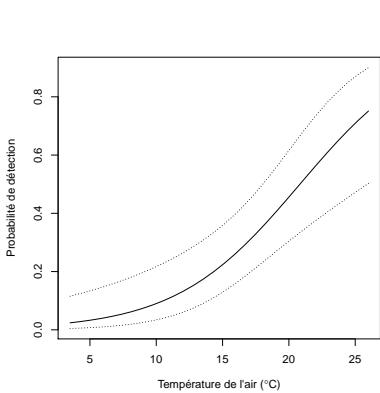
On peut présenter les résultats dans un graphique

```
> ##create plot
> plot(new.dats$mod.avg.pred ~ new.dats$Airtemp,
  ylab = "Probabilité de détection",
  xlab = expression(paste("Température de l'air (",
  degree, "C)")),
  ylim = range(c(new.dats$low95, new.dats$upp95)),
  type = "l")
> ##add confidence bands
> lines(y = new.dats$low95, x = new.dats$Airtemp,
  lty = "dotted")
> lines(y = new.dats$upp95, x = new.dats$Airtemp,
  lty = "dotted")
```

Exemple 1 — Modèle d'occupation à une saison

Inférence multimodèle – prédictions

Le graphique



Exemple 1 — Modèle d'occupation à une saison

Modèles avec unmarked

Plusieurs autres types de modèles dans `unmarked` pour des individus non marqués

- occupation dynamique (multiples saisons)
- modèle d'hétérogénéité de Royle-Nichols
- modèle N -mixture pour décomptes à une saison
- modèle N -mixture dynamique pour décomptes (multiples saisons)
- occupation avec identification erronée lorsqu'espèce n'est pas bien identifiée (*false-positive occupancy model*)
- échantillonnage de la distance (*distance sampling*)

Exemple 1 — Modèle d'occupation à une saison

Exemple 2 — Modèle d'occupation dynamique

Occupation dynamique

Le modèle d'occupation dynamique (MacKenzie et al. 2003) permet de quantifier les changements d'occupation entre saisons

Adaptation du modèle robuste de Pollock de CMR pour le cas de l'occupation (périodes primaires, périodes secondaires)

Paramétrisation principale comprend 4 groupes de paramètres

- probabilité d'occupation à la première saison (ψ_{init})
- probabilité de colonisation (γ)
- probabilité d'extinction (ε)
- probabilité de détection (p)

Dans `unmarked`, la fonction `colext()` estime les paramètres de ce modèle

Exemple 2 — Modèle d'occupation dynamique

Exemple 2 — Modèle d'occupation dynamique

Occupation dynamique

Ouaouaron (*Lithobates catesbeianus*) et roseau commun



Points d'écoute en 2009 et 2010

- 50 milieux humides de la région de Montréal
- 3 visites par année

Importation des données

On importe les données de détection

```
> bfrog <- read.table("OUA_bin.csv", header = TRUE)
> head(bfrog)
   Location          Nom V1 V2 V3 V4 V5 V6
1 Arbo Mc gill    Gill1 0 0 0 0 0 0
2 Beauharnois, cic beau cic 1 bassin haut 0 0 0 0 0 0
3 Beauharnois, cic beau cic2 chemin 0 0 0 0 0 0
4 Bois de liesse      B-L elec 0 0 0 0 0 0
5 Bois de liesse      B-L grand 0 0 0 0 0 0
6 ile bizard        barbara 0 0 0 0 0 0
```

Exemple 2 — Modèle d'occupation dynamique

Exemple 2 — Modèle d'occupation dynamique

Importation des données

On importe les variables de sites

```
> site.covs <- read.table("Site_covariates_centered.csv",
                           header = TRUE)
> head(site.covs)
  Location           Nom Reed.presence
1   Arbo Mc gill      Gill1          0
2 Beauharnois, cic beau cic 1 bassin haut 1
3 Beauharnois, cic     beau cic2 chemin 1
4   Bois de liesse      B-L elec    1
5   Bois de liesse      B-L grand    0
6     ile bizard       barbara    0
Wetland.area.ha Wetland.area.cent
1     1.011761      0.22707
2     0.314233     -0.47046
3     0.317195     -0.46750
4     0.070684     -0.71401
5     2.425139      1.64045
6     0.476673     -0.30802
```

Exemple 2 — Modèle d'occupation dynamique

Importation des données

On importe les variables d'échantillonnage déjà centrées

```
> ##airtemp centered and ordered according to site name
> airtemp <- read.table("Airtemp_centered.csv",
                           header = TRUE)
> ##effort centered and ordered according to site name
> effort <- read.table("Effort_centered.csv",
                           header = TRUE)
> head(airtemp, 3)
  Airtemp1 Airtemp2 Airtemp3 Airtemp4 Airtemp5 Airtemp6
1   -5.7804   -1.5804   6.2796  -5.93044  0.33956   4.9596
2    4.5896    4.2096   4.6096  -0.12044  1.15956   6.5596
3    5.4896    3.9096   4.4396   0.65956  3.17956   8.3496
> head(effort, 3)
  Effort1 Effort2 Effort3 Effort4 Effort5 Effort6
1     0.88     0.88     0.88     0.88     0.88     0.88
2    -1.12    -1.12    -1.12    -1.12    -1.12    -1.12
3    -1.12    -1.12    -1.12    -1.12    -1.12    -1.12
```

Exemple 2 — Modèle d'occupation dynamique

Importation des données

On peut créer une variable catégorique année

```
> ##set up yearly site covariate
> year <- matrix(data = c("2009", "2010"),
                     nrow = nrow(site.covs), ncol = 2, byrow = TRUE)
> head(year)
  [,1] [,2]
[1,] "2009" "2010"
[2,] "2009" "2010"
[3,] "2009" "2010"
[4,] "2009" "2010"
[5,] "2009" "2010"
[6,] "2009" "2010"
```

Exemple 2 — Modèle d'occupation dynamique

Formatage des données

On formate les données à l'aide de `unmarkedMultFrame()`

```
> bfrog.data <- unmarkedMultFrame(y = bfrog[, 3:8],
                                       siteCovs = site.covs[, -c(1,2)],
                                       obsCovs = list(Airtemp =
                                         airtemp, Effort = effort),
                                       yearlySiteCovs =
                                         list(Year = year),
                                       numPrimary = 2)
```

Points importants :

- `siteCovs` doit être un `data.frame`
- `obsCovs` doit être une liste avec des `data.frame`
- `numPrimary` indique le nombre de saisons (périodes primaires)
- `yearlySiteCovs` indique une matrice avec les années

Exemple 2 — Modèle d'occupation dynamique

Objet unmarkedMultFrame

On peut résumer le jeu de données

```
> summary(bfrog.data)

unmarkedFrame Object

50 sites
Maximum number of observations per site: 6
Mean number of observations per site: 5.88
Number of primary survey periods: 2
Number of secondary survey periods: 3
Sites with at least one detection: 20

Tabulation of y observations:
 0   1 <NA>
262 32   6

Site-level covariates:
Reed.presence Wetland.area.ha  Wetland.area.cent
Min. :0.0    Min. :0.0707    Min. :-0.714
1st Qu.:0.0   1st Qu.:0.3521   1st Qu.:-0.433
...
...
```

Exemple 2 — Modèle d'occupation dynamique

Avant de lancer les modèles

S'assurer que les variables ne sont pas corrélées entre elles

- éviter d'inclure des variables corrélées ($|r| > 0.7$) sur le même paramètre (ψ_{init} , γ , ϵ , p)
- possible d'ajouter la même variable sur différents paramètres

On peut formuler différents modèles :

nul : $\psi_{init} \cdot \gamma \cdot \epsilon \cdot p \cdot \text{Airtemp} + \text{Effort}$

effet additif sur ψ_{init} : $\psi_{init} \cdot \text{Wetland.area} + \text{Reed.presence} \cdot \gamma \cdot \epsilon \cdot p \cdot \text{Airtemp} + \text{Effort}$

interaction sur ψ_{init} :

$\psi_{init} \cdot \text{Wetland.area} \cdot \text{Reed.presence} + \text{Wetland.area} \cdot \text{Reed.presence} \cdot \gamma \cdot \epsilon \cdot p \cdot \text{Airtemp} + \text{Effort}$

effet additif sur ϵ : $\psi_{init} \cdot \gamma \cdot \epsilon \cdot \text{Wetland.area} + \text{Reed.presence} \cdot p \cdot \text{Airtemp} + \text{Effort}$

interaction sur ϵ :

$\psi_{init} \cdot \gamma \cdot \epsilon \cdot \text{Wetland.area} \cdot \text{Reed.presence} + \text{Wetland.area} \cdot \text{Reed.presence} \cdot p \cdot \text{Airtemp} + \text{Effort}$

Exemple 2 — Modèle d'occupation dynamique

Occupation dynamique – m0 I

On commence avec le modèle nul

```
> m0 <- colexit(psiformula = ~ 1,
+                  gammaformula = ~ 1,
+                  epsilonformula = ~ 1,
+                  pformula = ~ Effort + Airtemp, data = bfrog.data)
> summary(m0)
Call:
colexit(psiformula = ~1, gammaformula = ~1, epsilonformula = ~1,
        pformula = ~Effort + Airtemp, data = bfrog.data)

Initial (logit-scale):
Estimate SE z P(>|z|)
0.129 0.398 0.324 0.746

Colonization (logit-scale):
Estimate SE z P(>|z|)
-8.93 31.6 -0.282 0.778
```

Exemple 2 — Modèle d'occupation dynamique

Occupation dynamique – m0 II

Extinction (logit-scale):
Estimate SE z P(>|z|)
0.384 0.63 0.608 0.543

Detection (logit-scale):
Estimate SE z P(>|z|)
(Intercept) -0.9632 0.306 -3.15 0.00164
Effort 0.9070 0.295 3.07 0.00214
Airtemp -0.0636 0.051 -1.25 0.21232

AIC: 177.24
Number of sites: 50
optim convergence code: 0
optim iterations: 48
Bootstrap iterations: 0

Exemple 2 — Modèle d'occupation dynamique

Occupation dynamique – m1 I

On fait rouler les autres modèles et on inspecte les sorties

```
> m1 <- colext(psiformula = ~ Wetland.area.cent + Reed.presence,
+                 gammaformula = ~ 1,
+                 epsilonformula = ~ 1,
+                 pformula = ~ Effort + Airtemp, data = bfrog.data)
> summary(m1)
Call:
colext(psiformula = ~Wetland.area.cent + Reed.presence, gammaformula =
~1, epsilonformula = ~1, pformula = ~Effort + Airtemp, data = bfrog
Initial (logit-scale):
Estimate SE z P(>|z|)
(Intercept) 1.48 1.06 1.40 0.1630
Wetland.area.cent -1.95 1.03 -1.89 0.0583
Reed.presence -1.73 1.19 -1.45 0.1468

Colonization (logit-scale):
Estimate SE z P(>|z|)
```

Exemple 2 — Modèle d'occupation dynamique

Occupation dynamique – m1 II

```
-9.33 32.4 -0.288 0.774
```

```
Extinction (logit-scale):
Estimate SE z P(>|z|)
0.419 0.638 0.657 0.511

Detection (logit-scale):
Estimate SE z P(>|z|)
(Intercept) -1.1396 0.3234 -3.52 0.000425
Effort 1.0195 0.2811 3.63 0.000287
Airtemp -0.0594 0.0495 -1.20 0.230086

AIC: 173.53
Number of sites: 50
optim convergence code: 0
optim iterations: 56
Bootstrap iterations: 0
```

Exemple 2 — Modèle d'occupation dynamique

Occupation dynamique – m2 I

```
> m2 <- colext(psiformula = ~ Wetland.area.cent + Reed.presence +
+                 Wetland.area.cent:Reed.presence,
+                 gammaformula = ~ 1,
+                 epsilonformula = ~ 1,
+                 pformula = ~ Effort + Airtemp, data = bfrog.data)
> summary(m2)
Call:
colext(psiformula = ~Wetland.area.cent + Reed.presence + Wetland.area.cent:Reed.presence,
gammaformula = ~1, epsilonformula = ~1, pformula = ~Effort +
Airtemp, data = bfrog.data)

Initial (logit-scale):
Estimate SE z
(Intercept) 1.647 1.26 1.302
Wetland.area.cent -2.213 1.32 -1.678
Reed.presence -1.875 1.34 -1.401
Wetland.area.cent:Reed.presence 0.844 1.98 0.427
```

Exemple 2 — Modèle d'occupation dynamique

Occupation dynamique – m2 II

```
P(>|z|)
(Intercept) 0.1929
Wetland.area.cent 0.0934
Reed.presence 0.1613
Wetland.area.cent:Reed.presence 0.6697

Colonization (logit-scale):
Estimate SE z P(>|z|)
-9.33 32.8 -0.284 0.776

Extinction (logit-scale):
Estimate SE z P(>|z|)
0.422 0.637 0.662 0.508

Detection (logit-scale):
Estimate SE z P(>|z|)
(Intercept) -1.1330 0.3197 -3.54 0.000394
Effort 1.0106 0.2814 3.59 0.000329
Airtemp -0.0593 0.0495 -1.20 0.230664
```

Exemple 2 — Modèle d'occupation dynamique

Occupation dynamique – m2 III

```
AIC: 175.35
Number of sites: 50
optim convergence code: 0
optim iterations: 63
Bootstrap iterations: 0
```

Exemple 2 — Modèle d'occupation dynamique

Occupation dynamique – m3 I

```
> m3 <- coext(psiformula = ~ 1,
+ gammaformula = ~ 1,
+ epsilonformula = ~ Wetland.area.cent +
+ Reed.presence,
+ pformula = ~ Effort + Airtemp, data = bfrog.data)
> summary(m3)
Call:
coext(psiformula = ~1, gammaformula = ~1, epsilonformula = ~Wetlan-
Reed.presence, pformula = ~Effort + Airtemp, data = bfrog.data)

Initial (logit-scale):
Estimate SE z P(>|z|)
0.175 0.405 0.432 0.666

Colonization (logit-scale):
Estimate SE z P(>|z|)
-8.6 32 -0.268 0.788
```

Exemple 2 — Modèle d'occupation dynamique

Occupation dynamique – m3 II

```
Extinction (logit-scale):
Estimate SE z P(>|z|)
(Intercept) -0.277 0.902 -0.307 0.759
Wetland.area.cent 0.151 1.459 0.104 0.917
Reed.presence 1.964 1.525 1.287 0.198

Detection (logit-scale):
Estimate SE z P(>|z|)
(Intercept) -0.9826 0.3105 -3.16 0.00156
Effort 0.9101 0.2964 3.07 0.00213
Airtemp -0.0599 0.0514 -1.17 0.24359
```

```
AIC: 179.16
Number of sites: 50
optim convergence code: 0
optim iterations: 53
Bootstrap iterations: 0
```

Exemple 2 — Modèle d'occupation dynamique

Occupation dynamique – m4 I

```
> m4 <- coext(psiformula = ~ 1,
+ gammaformula = ~ 1,
+ epsilonformula = ~ Wetland.area.cent +
+ Reed.presence + Wetland.area.cent:Reed.presence,
+ pformula = ~ Effort + Airtemp, data = bfrog.data)
> summary(m4)
Call:
coext(psiformula = ~1, gammaformula = ~1, epsilonformula = ~Wetlan-
Reed.presence + Wetland.area.cent:Reed.presence, pformula = ~Ef-
Airtemp, data = bfrog.data)

Initial (logit-scale):
Estimate SE z P(>|z|)
0.161 0.406 0.396 0.692

Colonization (logit-scale):
Estimate SE z P(>|z|)
```

Exemple 2 — Modèle d'occupation dynamique

Occupation dynamique – m4 II

```
-22.4 355 -0.0633 0.95

Extinction (logit-scale):
              Estimate      SE      z
(Intercept)    -0.203  0.837 -0.243
Wetland.area.cent   -0.481  1.555 -0.309
Reed.presence     46.720 104.282  0.448
Wetland.area.cent:Reed.presence 107.027 233.372  0.459
                               P(>|z|)
(Intercept)          0.808
Wetland.area.cent   0.757
Reed.presence        0.654
Wetland.area.cent:Reed.presence 0.647

Detection (logit-scale):
              Estimate      SE      z P(>|z|)
(Intercept)  -0.9655  0.3063 -3.15 0.00162
Effort       0.9160  0.2943  3.11 0.00186
Airtemp      -0.0644  0.0521 -1.24 0.21630
```

Exemple 2 — Modèle d'occupation dynamique

Occupation dynamique – m4 III

```
AIC: 177
Number of sites: 50
optim convergence code: 1
optim iterations: 146
Bootstrap iterations: 0
```

```
Message d'avertissement :
In function (object) :
  Model did not converge. Try providing starting values or
increasing maxit control argument.
```

On remarque le message d'avertissement

- On ne fait pas confiance aux résultats du modèle m5 (à la poubelle)

Exemple 2 — Modèle d'occupation dynamique

Problèmes de convergence

Causes possibles :

- variable sur échelle inappropriée (e.g., 10 000 m² au lieu de ha)
- classification parfaite (aucune détection dans certaines classes)
- modèle trop complexe pour les données (ou l'information contenue dans les données)

Signes de problèmes d'estimation ou de convergence :

- β très gros ou très petits ($|20|$)
- SE des estimés démesurées par rapport à l'estimé (> 50)
- β ou SE avec NaN
- message à propos de la matrice hessienne (*Hessian is singular*)

Exemple 2 — Modèle d'occupation dynamique

Problèmes de convergence

Autre diagnostic : le nombre de condition (*condition number, CN*)

Correspond au ratio des eigenvalues (λ) de la matrice hessienne

$$CN = \max(\lambda)/\min(\lambda)$$

On peut l'obtenir facilement dans R

```
> extract.CN <- function(mod) {
  hess <- mod@opt$hessian
  eigenvals <- eigen(hess)$values
  CN <- max(eigenvals)/min(eigenvals)
  return(CN)
}
```

CN trop élevé (> 1000000) indique des problèmes

Exemple 2 — Modèle d'occupation dynamique

Problèmes de convergence

Vérifions le *CN* pour les modèles

```
> extract.CN(m0)
[1] 389514
> extract.CN(m1)
[1] 437459
> extract.CN(m2)
[1] 449113
> extract.CN(m3)
[1] 402434
> extract.CN(m4)
[1] 48551776
```

On remarque la valeur très élevée pour *m4*

Exemple 2 — Modèle d'occupation dynamique

Problèmes de convergence

Possible de modifier le modèle pour réduire les problèmes

- en spécifiant des valeurs initiales avec *starts* en se basant sur valeurs obtenues dans des modèles plus simples
- changer d'algorithme avec *method* (*BFGS*, *Nelder-Mead*, *SANN*)
- en fixant les valeurs de certains paramètres (dans *PRESENCE* et *MARK*, mais pas encore dans *unmarked*)

Toutefois, ne fonctionne pas toujours et on doit mettre le modèle à la poubelle

Exemple 2 — Modèle d'occupation dynamique

Test d'ajustement

Tests d'ajustement en développement

- tests d'ajustement sur chaque année séparément à l'aide de modèles à une saison
- test d'ajustement sur chaque année séparément à l'aide du modèle dynamique
- nouvelle fonction à venir dans le package *AICcmodavg* d'ici janvier 2014

Exemple 2 — Modèle d'occupation dynamique

Sélection de modèles

On assemble les modèles dans une liste (excluant *m4*)

```
> Cand.mods <- list(m0, m1, m2, m3)
> Mod.names <- c("nul", "psi(Wetland+Reed)", "psi(Wetland*Reed)",
  "eps(Wetland+Reed)")
```

Sélection de modèles

```
> aictab(cand.set = Cand.mods, modnames = Mod.names)
Model selection based on AICc :
```

	K	AICc	Delta_AICc	AICcWt	Cum.Wt	LL
psi(Wetland+Reed)	8	177.04	0.00	0.61	0.61	-78.76
nul	6	179.19	2.16	0.21	0.81	-82.62
psi(Wetland*Reed)	9	179.85	2.82	0.15	0.96	-78.68
eps(Wetland+Reed)	8	182.67	5.63	0.04	1.00	-81.58

Le modèle additif sur ψ a le plus de poids

```
> evidence(aictab(cand.set = Cand.mods, modnames = Mod.names))
Evidence ratio between models 'psi(Wetland+Reed)' and 'nul' :
2.94
```

Exemple 2 — Modèle d'occupation dynamique

Inférence multimodèle

Effet de Wetland.area.cent sur ψ_{init}

```
> print(modavg(cand.set = Cand.mods, modnames = Mod.names,
    parm = "Wetland.area.cent", parm.type = "psi",
    exclude = list("Wetland.area.cent:Reed.presence")), 4)
Multimodel inference on "psi(Wetland.area.cent)" based on AICc

AICc table used to obtain model-averaged estimate:

      K   AICc Delta_AICc AICcWt Estimate   SE
psi(Wetland+Reed) 8 177.04          0     1 -1.9467
                  SE
psi(Wetland+Reed) 1.0281

Model-averaged estimate: -1.9467
Unconditional SE: 1.0281
95 % Unconditional confidence interval: -3.9617 , 0.0682
```

La probabilité d'occupation initiale du Ouaouaron diminue marginalement avec Wetland.area.cent.

Exemple 2 — Modèle d'occupation dynamique

Inférence multimodèle

Effet de Reed.presence sur ψ_{init}

```
> modavg(cand.set = Cand.mods, modnames = Mod.names,
    parm = "Reed.presence", parm.type = "psi",
    exclude = list("Wetland.area.cent:Reed.presence"))
Multimodel inference on "psi(Reed.presence)" based on AICc

AICc table used to obtain model-averaged estimate:

      K   AICc Delta_AICc AICcWt Estimate   SE
psi(Wetland+Reed) 8 177.04          0     1 -1.73  1.19

Model-averaged estimate: -1.73
Unconditional SE: 1.19
95 % Unconditional confidence interval: -4.06 , 0.61
```

ψ_{init} ne varie pas avec Reed.presence.

Exemple 2 — Modèle d'occupation dynamique

Inférence multimodèle

Effet de Airtemp sur p

```
> modavg(cand.set = Cand.mods, modnames = Mod.names,
    parm = "Airtemp", parm.type = "detect")
Multimodel inference on "p(Airtemp)" based on AICc

AICc table used to obtain model-averaged estimate:

      K   AICc Delta_AICc AICcWt Estimate   SE
nul       6 179.19      2.16  0.21   -0.06 0.05
psi(Wetland+Reed) 8 177.04      0.00  0.61   -0.06 0.05
psi(Wetland*Reed) 9 179.85      2.82  0.15   -0.06 0.05
eps(Wetland+Reed) 8 182.67      5.63  0.04   -0.06 0.05

Model-averaged estimate: -0.06
Unconditional SE: 0.05
95 % Unconditional confidence interval: -0.16 , 0.04
```

La probabilité de détection du Ouaouaron ne varie pas avec Airtemp.

Exemple 2 — Modèle d'occupation dynamique

Inférence multimodèle

Effet de Effort sur p

```
> modavg(cand.set = Cand.mods, modnames = Mod.names,
    parm = "Effort", parm.type = "detect")
Multimodel inference on "p(Effort)" based on AICc

AICc table used to obtain model-averaged estimate:

      K   AICc Delta_AICc AICcWt Estimate   SE
nul       6 179.19      2.16  0.21   0.91 0.30
psi(Wetland+Reed) 8 177.04      0.00  0.61   1.02 0.28
psi(Wetland*Reed) 9 179.85      2.82  0.15   1.01 0.28
eps(Wetland+Reed) 8 182.67      5.63  0.04   0.91 0.30

Model-averaged estimate: 0.99
Unconditional SE: 0.29
95 % Unconditional confidence interval: 0.43 , 1.56
```

La probabilité de détection du Ouaouaron augmente avec Effort.

Exemple 2 — Modèle d'occupation dynamique

Inférence multimodèle – prédictions

On crée un nouveau jeu de données

```
> range(effort)
[1] -5.12 1.88
> ##create newdata data frame
> ##centered effort
> new.dats <- data.frame(Effort =
+     seq(from = min(effort),
+          to = max(effort),
+          length.out = 30),
+     Airtemp = 0)
> ##uncentered effort
> new.dats$Effort.orig <- new.dats$Effort + 9.12
```

On doit donner une valeur à chaque variable apparaissant dans au moins un modèle

- Airtemp et Effort sur p

On fait varier une variable en gardant les autres constantes

- si on a centré les variables, on utilise 0 (la moyenne)

Exemple 2 — Modèle d'occupation dynamique

Inférence multimodèle – prédictions

Prédictions avec `modavgpred()`

```
> preds <- modavgpred(cand.set = Cand.mods, modnames = Mod.names,
+ c.hat = 1, newdata = new.dats,
+ type = "response", parm.type = "detect")
```

Ajouter les valeurs prédites et SE inconditionnelles

```
> new.dats$mod.avg.pred <- preds$mod.avg.pred
> new.dats$uncond.se <- preds$uncond.se
```

Pour calculer les intervalles de confiance, on utilise l'échelle logit

```
> preds.logit <- modavgpred(cand.set = Cand.mods,
+ modnames = Mod.names,
+ c.hat = 1, newdata = new.dats,
+ type = "link", parm.type = "detect")
> ##add to data set
> new.dats$mod.avg.pred.logit <- preds.logit$mod.avg.pred
> new.dats$uncond.se.logit <- preds.logit$uncond.se
```

Exemple 2 — Modèle d'occupation dynamique

Inférence multimodèle – prédictions

On calcule les limites et on convertit sur l'échelle originale

```
> ##95% CI
> new.dats$low95 <- plogis(new.dats$mod.avg.pred.logit -
+     1.96 * new.dats$uncond.se.logit)
> new.dats$upp95 <- plogis(new.dats$mod.avg.pred.logit +
+     1.96 * new.dats$uncond.se.logit)
```

Exemple 2 — Modèle d'occupation dynamique

Inférence multimodèle – prédictions

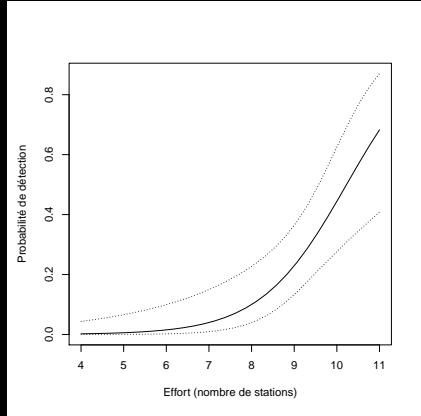
Préparation du graphique

```
> ##create plot
> plot(new.dats$mod.avg.pred ~ new.dats$Effort.orig,
+       ylab = "Probabilité de détection",
+       xlab = "Effort (nombre de stations)",
+       ylim = range(c(new.dats$low95, new.dats$upp95)),
+       type = "l")
> ##add confidence bands
> lines(y = new.dats$low95, x = new.dats$Effort.orig,
+        lty = "dotted")
> lines(y = new.dats$upp95, x = new.dats$Effort.orig,
+        lty = "dotted")
```

Exemple 2 — Modèle d'occupation dynamique

Inférence multimodèle – prédictions

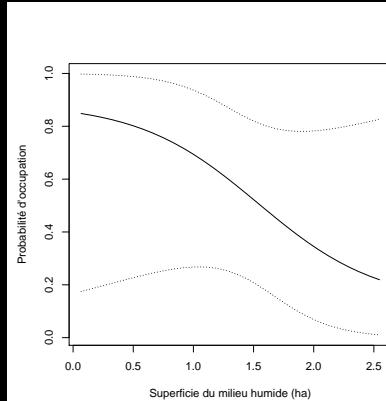
Le graphique de l'effort sur la détection



Exemple 2 — Modèle d'occupation dynamique

Inférence multimodèle – prédictions

Le graphique de la superficie du milieu humide sur ψ_{init}



Exemple 2 — Modèle d'occupation dynamique

Exemple 3 — Modèle *N*-mixture

Exemple 3 — Modèle *N*-mixture

Origine du modèle *N*-mixture

Développé par Royle (2004)

Principe : le nombre d'individus détectés lors d'un inventaire à un site i au temps t est le résultat d'une expérience binomiale

$$C_{i,t} \sim \text{Binomial}(N_i, p)$$

- où $C_{i,t}$ correspond au nombre d'individus détectés au site i au temps t (c'est le nombre de succès)
- où N_i est le nombre total d'individus présents au site i et correspond au nombre total d'essais
- N_i provient d'une distribution de Poisson ($N \sim \text{Pois}(\lambda)$)
- où p correspond à la probabilité de détecter (ou capturer) un individu (P d'observer 1 succès)

Exemple 3 — Modèle *N*-mixture

Origine du modèle *N*-mixture

On modélise le processus biologique (*N*) et le processus d'erreur d'observation (*p*).

La fonction de vraisemblance :

$$L(p, \theta | n_{i,t}) = \prod_{i=1}^R \left\{ \sum_{N_i=\max_t n_{i,t}}^{\infty} \left(\prod_{t=1}^T \text{Binomial}(n_{i,t}; N_i, p) f(N_i; \theta) \right) \right\}$$

- où on imbrique une distribution $f(N_i; \theta)$ pour les abondances à l'intérieur même d'une distribution binomiale
- on peut modéliser N_i à l'aide la distribution de Poisson, binomiale négative ou Poisson gonflée de 0 (*zero-inflated Poisson*)
- on peut substituer ∞ par une valeur très grande qui représente le nombre maximal possible d'individus qu'on puisse observer à un site (K)

Exemple 3 — Modèle *N*-mixture

Applications

On estime N_i à partir d'individus non marqués, pourvu qu'on ait au moins deux visites par site.

À chaque visite, on dénombre les individus différents détectés à chacun des sites.

- tout comme pour les modèles d'occupation, une visite peut correspondre à un observateur. Ex. Si trois observateurs échantillonnent indépendamment et en même temps le même site, on a trois visites.

Ce type de modèle nécessite un minimum de sites (> 30) et permet aussi la présence de données manquantes (attention à la sélection de modèles)

Exemple 3 — Modèle *N*-mixture

Suppositions

Suppositions

- fermeture de la population : il n'y a aucun changement d'abondance entre la première et dernière visite à un site
- la détection des individus est constante à tous les sites, sinon, l'hétérogénéité est modélisée à l'aide de variables appropriées
- la probabilité de détecter (ou capturer) un individu à un site est indépendante pour toutes les visites
- l'abondance est modélisée à l'aide d'une distribution appropriée, soit une distribution de Poisson (P), binomiale négative (NB) ou Poisson gonflée de 0 (*zero-inflated Poisson*, ZIP)

Exemple 3 — Modèle *N*-mixture

Modèle *N*-mixture

Abondance du Grand Polatouche (*Glaucomys sabrinus*) en forêt boréale



Piégeage de septembre à décembre 2008 (2 visites)

- 56 sites dans la région de Rouyn-Noranda
- 8 stations par site
- pièges Tomahawk à 1.5 m et 4 m à chaque station

Exemple 3 — Modèle *N*-mixture

Importation des données

Données de décompte et de sites

```
> ##import data set
> pola <- read.table("pola.txt", header = TRUE)
> head(pola, 3)
  S1V1   S1V2   S1V3   S1V4
1     0     0     0     0
2     0     0     0     0
3     0     0     0     0

> ##import site covariates
> pola.site <- read.table("covsite.txt", header = TRUE)
> head(pola.site, 3)
    Snag Conifer Boxes
1 -1.7676  1.87572     1
2  5.0368  0.11927     0
3  3.4882 -0.98885     1
```

Exemple 3 — Modèle *N*-mixture

Importation des variables d'échantillonnage I

Précipitation

```
> ##import prec
> pola.prec <- read.table("obscov.prectot.txt", header = TRUE)
> head(pola.prec, 3)
  S1V1   S1V2   S1V3   S1V4
1 -3.4531 -3.4531 -1.9531 -1.9531
2 -3.4531 -3.4531 -1.9531 -1.9531
3 -3.4531 -3.4531 -1.9531 -1.9531
```

Hauteur du piège

```
> ##import ht
> pola.ht <- read.table("obscov.ht.txt", header = TRUE)
> head(pola.ht, 3)
  S1V1   S1V2   S1V3   S1V4
1     0     1     0     1
2     0     1     0     1
3     0     1     0     1
```

Exemple 3 — Modèle *N*-mixture

Importation des variables d'échantillonnage II

Jour julien

```
> ##import Jday
> pola.jday <- read.table("Jday.txt", header = TRUE)
> head(pola.jday, 3)
  S1V1   S1V2   S1V3   S1V4
1 -44.571 -44.571 3.4286 3.4286
2 -44.571 -44.571 3.4286 3.4286
3 -44.571 -44.571 3.4286 3.4286
```

Exemple 3 — Modèle *N*-mixture

Formatage des données I

On utilise la fonction unmarkedFramePCount()

```
> pola.data <- unmarkedFramePCount(y = pola, siteCovs = pola.site,
  obsCovs = list(
    Prec = pola.prec,
    Ht = pola.ht,
    Jday = pola.jday))

> summary(pola.data)
unmarkedFrame Object

56 sites
Maximum number of observations per site: 4
Mean number of observations per site: 4
Sites with at least one detection: 33

Tabulation of y observations:
  0   1   2   3   4   5 <NA>
163  37  17   5   1   1   0
```

Exemple 3 — Modèle *N*-mixture

Formatage des données II

```
Site-level covariates:
  Snag      Conifer      Boxes
Min.   :-3.43   Min.   :-1.409   Min.   :0.000
1st Qu.:-2.53   1st Qu.:-1.235   1st Qu.:0.000
Median :-0.73   Median :-0.360   Median :1.000
Mean   : 0.00   Mean   : 0.000   Mean   :0.518
3rd Qu.: 1.19   3rd Qu.: 0.706   3rd Qu.:1.000
Max.   : 9.72   Max.   : 4.499   Max.   :1.000

Observation-level covariates:
    Prec      Ht      Jday
Min.   :-7.953   Min.   :0.0   Min.   :-44.571
1st Qu.:-5.953   1st Qu.:0.0   1st Qu.:-23.571
Median :-1.953   Median :0.5   Median : 0.429
Mean   :-0.868   Mean   :0.5   Mean   : 0.000
3rd Qu.: 5.172   3rd Qu.:1.0   3rd Qu.: 18.429
Max.   : 8.547   Max.   :1.0   Max.   : 40.429
```

Exemple 3 — Modèle *N*-mixture

Formulation du modèle *N*-mixture I

On peut formuler différents modèles :

- m0** : λ_p
- m1** : $\lambda_p P_{Prec} + Jday + Ht$
- m2** : $\lambda_{Snag} P_{Prec} + Jday + Ht$
- m3** : $\lambda_{Conifer} P_{Prec} + Jday + Ht$
- m4** : $\lambda_{Snag} + Conifer P_{Prec} + Jday + Ht$
- m5** : $\lambda_p S_{nag} + Conifer$
- m6** : $\lambda_{Snag} P_{Snag} + Conifer$
- m7** : $\lambda_{Conifer} P_{Snag} + Conifer$
- m8** : $\lambda_{Snag} + Conifer P_{Snag} + Conifer$

Exemple 3 — Modèle *N*-mixture

Formulation du modèle *N*-mixture I

Utilisation de `pcount()`

Commençons avec un modèle qui utilise une distribution de Poisson

```
> m0 <- pcount(~ 1 ~ 1, K = 40, mixture = "P", data = pola.data)
```

Points importants :

- double formule ($\sim p \sim \lambda$)
- K correspond au nombre maximum d'individus qu'on peut voir dans un site
 - on peut faire varier K jusqu'à ce que le log \mathcal{L} se stabilise
- si p est faible, peut donner des abondances trop élevées
- mixture correspond à la distribution pour l'abondance (Poisson ici)

Exemple 3 — Modèle *N*-mixture

Structure de l'objet `unmarkedFitPCount`

Pour le modèle m0

```
> str(m0)

Formal class 'unmarkedFitPCount' [package "unmarked"] with 14 slots
..@ K           : num 40
..@ mixture     : chr "P"
..@ fitType     : chr "pcount"
..@ call         : language pcount(formula = ~1 ~ 1, data = po...
..@ formula     :Class 'formula' length 3 ~1 ~ 1
..@ ...          :attr(*, ".Environment")<environment: R_GlobalEnv>
..@ data         :Formal class 'unmarkedFramePCount' [package
..@ ...          :int [1:56, 1:4] 0 0 0 0 0 0 1 0 0 1 ...
..@ ...          :attr(*, "dimnames")=List of 2
..@ ...          :NULL
..@ ...          :chr [1:4] "S1V1" "S1V2" "S1V3" "S1V4"
..@ ...          :obsCovs :'data.frame': 224 obs. of 3 variables:
..@ ...          :Prec: num [1:224] -3.45 -3.45 -1.95 -1.95 -3.45 ...
..@ ...          :Ht : int [1:224] 0 1 0 1 0 1 0 1 ...
..@ ...          :Jday: num [1:224] -44.57 -44.57 3.43 3.43 -44.57 ...
..@ ...          :siteCovs:'data.frame': 56 obs. of 3 variables:
...  
```

Exemple 3 — Modèle *N*-mixture

Inspection de m0

```
> summary(m0)
Call:
pcount(formula = ~1 ~ 1, data = pola.data, K = 40, mixture = "P")

Abundance (log-scale):
Estimate      SE      z P(>|z|)
0.618 0.243 2.54 0.0111

Detection (logit-scale):
Estimate      SE      z P(>|z|)
-1.22 0.311 -3.91 9.34e-05

AIC: 391.05
Number of sites: 56
optim convergence code: 0
optim iterations: 22
Bootstrap iterations: 0
```

Exemple 3 — Modèle N-mixture

Lancement des autres modèles

```
> m1 <- pcount(~ Prec + Jday + Ht ~ 1,
K = 40, mixture = "P", data = pola.data)
> m2 <- pcount(~ Prec + Jday + Ht ~ Snag,
K = 40, mixture = "P", data = pola.data)
> m3 <- pcount(~ Prec + Jday + Ht ~ Conifer,
K = 40, mixture = "P", data = pola.data)
> m4 <- pcount(~ Prec + Jday + Ht ~ Snag + Conifer,
K = 40, mixture = "P", data = pola.data)
> m5 <- pcount(~ Snag + Conifer ~ 1, K = 40,
mixture = "P", data = pola.data)
> m6 <- pcount(~ Snag + Conifer ~ Snag, K = 40,
mixture = "P", data = pola.data)
> m7 <- pcount(~ Snag + Conifer ~ Conifer, K = 40,
mixture = "P", data = pola.data)
> m8 <- pcount(~ Snag + Conifer ~ Snag + Conifer,
K = 40, mixture = "P", data = pola.data)
```

Exemple 3 — Modèle N-mixture

Inspection de m1 I

```
> summary(m1)
Call:
pcount(formula = ~Prec + Jday + Ht ~ 1, data = pola.data, K = 40,
mixture = "P")

Abundance (log-scale):
Estimate      SE      z P(>|z|)
0.502 0.206 2.43 0.0151

Detection (logit-scale):
Estimate      SE      z P(>|z|)
(Intercept) -0.9835 0.32223 -3.05 0.00227
Prec         -0.0812 0.02546 -3.19 0.00143
Jday        -0.0149 0.00613 -2.43 0.01498
Ht          -0.4599 0.25198 -1.83 0.06797

AIC: 372.48
```

Exemple 3 — Modèle N-mixture

Inspection de m1 II

```
Number of sites: 56
optim convergence code: 0
optim iterations: 48
Bootstrap iterations: 0
```

Exemple 3 — Modèle N-mixture

Inspection de m2 I

```
> summary(m2)
Call:
pcount(formula = ~Prec + Jday + Ht ~ Snag, data = pola.data,
       K = 40, mixture = "P")

Abundance (log-scale):
            Estimate      SE      z P(>|z|)
(Intercept)  0.502  0.242  2.07  0.03848
Snag        -0.185  0.057 -3.25  0.00117

Detection (logit-scale):
            Estimate      SE      z P(>|z|)
(Intercept) -1.1588 0.3530 -3.28  0.00103
Prec         -0.0781 0.0247 -3.16  0.00158
Jday         -0.0159 0.0059 -2.69  0.00706
Ht          -0.4388 0.2462 -1.78  0.07469
```

Exemple 3 — Modèle *N*-mixture

Inspection de m2 II

```
AIC: 361.11
Number of sites: 56
optim convergence code: 0
optim iterations: 53
Bootstrap iterations: 0
```

Exemple 3 — Modèle *N*-mixture

Inspection de m3 I

```
> summary(m3)
Call:
pcount(formula = ~Prec + Jday + Ht ~ Conifer, data = pola.data,
       K = 40, mixture = "P")

Abundance (log-scale):
            Estimate      SE      z P(>|z|)
(Intercept)  0.470  0.2085  2.26  0.0241
Conifer     0.121  0.0861  1.41  0.1590

Detection (logit-scale):
            Estimate      SE      z P(>|z|)
(Intercept) -0.9591 0.32300 -2.97  0.00299
Prec         -0.0776 0.02565 -3.03  0.00248
Jday         -0.0147 0.00617 -2.39  0.01707
Ht          -0.4609 0.25234 -1.83  0.06776
```

Exemple 3 — Modèle *N*-mixture

Inspection de m3 II

```
AIC: 372.6
Number of sites: 56
optim convergence code: 0
optim iterations: 40
Bootstrap iterations: 0
```

Exemple 3 — Modèle *N*-mixture

Inspection de m4 I

```
> summary(m4)
Call:
pcount(formula = ~Prec + Jday + Ht ~ Snag + Conifer, data = pola.data,
       K = 40, mixture = "P")

Abundance (log-scale):
Estimate      SE      z P(>|z|)
(Intercept)  0.468 0.2460  1.90 0.05721
Snag        -0.188 0.0572 -3.28 0.00102
Conifer      0.128 0.0853  1.51 0.13187

Detection (logit-scale):
Estimate      SE      z P(>|z|)
(Intercept) -1.1350 0.35590 -3.19 0.00143
Prec         -0.0743 0.02491 -2.98 0.00287
Jday        -0.0156 0.00594 -2.62 0.00880
Ht          -0.4393 0.24644 -1.78 0.07462
```

Exemple 3 — Modèle *N*-mixture

Inspection de m4 II

```
AIC: 360.97
Number of sites: 56
optim convergence code: 0
optim iterations: 47
Bootstrap iterations: 0
```

Exemple 3 — Modèle *N*-mixture

Inspection de m5 I

```
> summary(m5)
Call:
pcount(formula = ~Snag + Conifer ~ 1, data = pola.data, K = 40,
       mixture = "P")

Abundance (log-scale):
Estimate      SE      z P(>|z|)
1.04 0.332 3.14 0.00168

Detection (logit-scale):
Estimate      SE      z P(>|z|)
(Intercept) -1.901 0.4042 -4.70 2.56e-06
Snag        -0.216 0.0620 -3.49 4.84e-04
Conifer      0.158 0.0976  1.62 1.06e-01

AIC: 380.9
Number of sites: 56
```

Exemple 3 — Modèle *N*-mixture

Inspection de m5 II

```
optim convergence code: 0
optim iterations: 35
Bootstrap iterations: 0
```

Exemple 3 — Modèle *N*-mixture

Inspection de m6 I

```
> summary(m6)
Call:
pcount(formula = ~Snag + Conifer ~ Snag, data = pola.data, K = 40,
       mixture = "P")

Abundance (log-scale):
      Estimate     SE     z P(>|z|)
(Intercept)  0.8592 0.510  1.686  0.0919
Snag        -0.0921 0.227 -0.406  0.6847

Detection (logit-scale):
      Estimate     SE     z P(>|z|)
(Intercept) -1.698  0.587 -2.892  0.00382
Snag         -0.119  0.251 -0.474  0.63547
Conifer      0.145  0.105  1.380  0.16771

AIC: 382.78
```

Exemple 3 — Modèle *N*-mixture

Inspection de m6 II

```
Number of sites: 56
optim convergence code: 0
optim iterations: 59
Bootstrap iterations: 0
```

Exemple 3 — Modèle *N*-mixture

Inspection de m7 I

```
> summary(m7)
Call:
pcount(formula = ~Snag + Conifer ~ Conifer, data = pola.data,
       K = 40, mixture = "P")

Abundance (log-scale):
      Estimate     SE     z P(>|z|)
(Intercept)  0.921  0.318  2.89  0.00382
Conifer      0.336  0.254  1.32  0.18688

Detection (logit-scale):
      Estimate     SE     z P(>|z|)
(Intercept) -1.751  0.3892 -4.498 6.85e-06
Snag        -0.199  0.0621 -3.208 1.34e-03
Conifer      -0.192  0.2838 -0.678 4.98e-01

AIC: 380.57
```

Exemple 3 — Modèle *N*-mixture

Inspection de m7 II

```
Number of sites: 56
optim convergence code: 0
optim iterations: 53
Bootstrap iterations: 0
```

Exemple 3 — Modèle *N*-mixture

Inspection de m8 I

```
> summary(m8)
Call:
pcount(formula = ~Snag + Conifer ~ Snag + Conifer, data = pola.data
      K = 40, mixture = "P")

Abundance (log-scale):
Estimate    SE     z P(>|z|)
(Intercept) 0.685 0.336 2.04 0.0414
Snag        -0.180 0.109 -1.66 0.0979
Conifer      0.458 0.291 1.58 0.1150

Detection (logit-scale):
Estimate    SE     z P(>|z|)
(Intercept) -1.47726 0.405 -3.6452 0.000267
Snag        -0.00195 0.126 -0.0155 0.987653
Conifer      -0.34382 0.316 -1.0872 0.276962
```

Exemple 3 — Modèle *N*-mixture

Inspection de m8 II

```
AIC: 381.06
Number of sites: 56
optim convergence code: 0
optim iterations: 64
Bootstrap iterations: 0
```

Exemple 3 — Modèle *N*-mixture

Autres diagnostics

On peut vérifier le *CN* pour les modèles

On met les modèles dans une liste

```
> Cands.pois <- list(m0, m1, m2, m3, m4, m5, m6, m7, m8)
> Mod.pois.names <- c("m0", "m1", "m2", "m3", "m4", "m5",
   "m6", "m7", "m8")
> ##add names to list
> names(Cands.pois) <- Mod.pois.names
> unlist(lapply(Cands.pois, FUN = extract.CN))
      m0      m1      m2      m3      m4      m5
 13.075 4244.329 5391.343 4277.728 5513.127  82.540
      m6      m7      m8
 436.959  88.986 231.858
```

Aucune valeur démesurément élevée

Exemple 3 — Modèle *N*-mixture

Test d'ajustement

On peut utiliser un test d'ajustement basé sur le χ^2 à l'aide de la fonction *Nmix.gof.test()*

- ❶ on calcule le χ^2 observé sur les données originales
- ❷ on simule les données à partir du modèle, on lance le modèle, et on calcule un χ^2 pour ces données simulées
- ❸ on répète les étapes 1 – 3 un grand nombre de fois
- ❹ on détermine la $P(\chi_{obs}^2 \geq \chi_{sim}^2) = \frac{\text{Nombre } \chi_{sim}^2 \geq \chi_{obs}^2}{\text{Nombre simulations}}$

Aussi possible de calculer un \hat{c} ,

$$\hat{c} = \frac{\chi_{obs}^2}{\bar{\chi}_{obs}^2}$$

Exemple 3 — Modèle *N*-mixture

Test d'ajustement I

Ici, nous n'avons pas de modèle global qui englobe toutes les variables (trop petit n)

Dans ce cas, il est possible d'utiliser le modèle au premier rang pour vérifier l'ajustement :

```
> aictab(Cands.pois, Mod.pois.names)
Model selection based on AICc :

  K   AICc Delta_AICc AICcWt Cum.Wt      LL
m2 6 362.82     0.00  0.56  0.56 -174.56
m4 7 363.31     0.48  0.44  1.00 -173.49
m1 5 373.68    10.86  0.00  1.00 -181.24
m3 6 374.32    11.49  0.00  1.00 -180.30
m5 4 381.68    18.86  0.00  1.00 -186.45
m7 5 381.77    18.95  0.00  1.00 -185.29
m8 6 382.77    19.95  0.00  1.00 -184.53
```

Exemple 3 — Modèle N -mixture

Test d'ajustement II

```
m6 5 383.98      21.15  0.00  1.00 -186.39
m0 2 391.28      28.46  0.00  1.00 -193.53
> coef(m2)
  lam(Int)  lam(Snag)  p(Int)  p(Prec)  p(Jday)  p(Ht)
  0.501595 -0.185103 -1.158787 -0.078084 -0.015905 -0.438771
```

Utilisons le modèle m2 pour vérifier l'ajustement

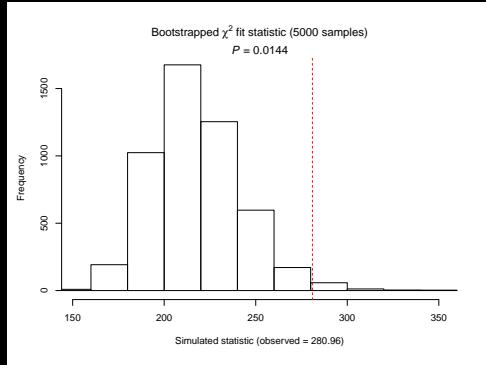
```
> m2.gof <- Nmix.gof.test(mod = m2, nsim = 5000)

> m2.gof$chi.square
[1] 280.96
> m2.gof$c.hat.est
[1] 1.2915
```

Exemple 3 — Modèle N -mixture

Test d'ajustement III

Graphique de la distribution du χ^2 observé par rapport aux χ^2 obtenus par bootstrap paramétrique



Exemple 3 — Modèle N -mixture

Test d'ajustement IV

On remarque que 72 valeurs de χ^2 simulées sont $\geq \chi^2$ ($P = 0.0144$).

Même si le $\hat{c} = 1.29$, le test d'ajustement indique que le modèle ne s'ajuste pas bien aux données.

On conclut qu'on ne peut continuer avec des modèles qui utilisent la distribution de Poisson avec ce jeu de données.

Exemple 3 — Modèle N -mixture

Modèles N -mixture avec binomiale négative

Essayons des modèles avec la même structure sur p et λ avec une distribution binomiale négative

```
> m0.nb <- pcount(~ 1 ~ 1, K = 40, mixture = "NB",
+                     data = pola.data)
> m1.nb <- pcount(~ Prec + Jday + Ht ~ 1, K = 40,
+                     mixture = "NB", data = pola.data)
> m2.nb <- pcount(~ Prec + Jday + Ht ~ Snag, K = 40,
+                     mixture = "NB", data = pola.data)
> m3.nb <- pcount(~ Prec + Jday + Ht ~ Conifer, K = 40,
+                     mixture = "NB", data = pola.data)
> m4.nb <- pcount(~ Prec + Jday + Ht ~ Snag + Conifer, K = 40,
+                     mixture = "NB", data = pola.data)
> m5.nb <- pcount(~ Snag + Conifer ~ 1, K = 40,
+                     mixture = "NB", data = pola.data)
> m6.nb <- pcount(~ Snag + Conifer ~ Snag, K = 40,
+                     mixture = "NB", data = pola.data)
> m7.nb <- pcount(~ Snag + Conifer ~ Conifer, K = 40,
+                     mixture = "NB", data = pola.data)
> m8.nb <- pcount(~ Snag + Conifer ~ Snag + Conifer, K = 40,
+                     mixture = "NB", data = pola.data)
```

Exemple 3 — Modèle N -mixture

Inspectons la sortie du modèle m0 I

```
> summary(m0.nb)
Call:
pcount(formula = ~1 ~ 1, data = pola.data, K = 40, mixture = "NB")

Abundance (log-scale):
Estimate    SE     z P(>|z|)
1.68 0.432 3.89 9.99e-05

Detection (logit-scale):
Estimate    SE     z P(>|z|)
-2.45 0.454 -5.41 6.34e-08

Dispersion (log-scale):
Estimate    SE     z P(>|z|)
-0.00622 0.378 -0.0165 0.987

AIC: 378.35
```

Exemple 3 — Modèle N -mixture

Inspectons la sortie du modèle m0 II

```
Number of sites: 56
optim convergence code: 0
optim iterations: 30
Bootstrap iterations: 0
```

On remarque qu'un paramètre additionnel a été estimé — un paramètre de dispersion pour binomiale négative (permet de modéliser la variance excédentaire par rapport à la Poisson)

Exemple 3 — Modèle N -mixture

Inspectons les sorties des autres modèles I

```
> summary(m1.nb)
Call:
pcount(formula = ~Prec + Jday + Ht ~ 1, data = pola.data, K = 40,
mixture = "NB")

Abundance (log-scale):
Estimate    SE     z P(>|z|)
1.25 0.852 1.47   0.142

Detection (logit-scale):
Estimate    SE     z P(>|z|)
(Intercept) -1.9442 1.00169 -1.94 0.05227
Prec        -0.0666 0.02503 -2.66 0.00782
Jday        -0.0127 0.00597 -2.13 0.03324
Ht          -0.3724 0.23072 -1.61 0.10653

Dispersion (log-scale):
```

Exemple 3 — Modèle N -mixture

Inspectons les sorties des autres modèles II

```
Estimate      SE      z P(>|z|)  
0.118 0.492 0.239  0.811  
  
AIC: 365.52  
Number of sites: 56  
optim convergence code: 0  
optim iterations: 77  
Bootstrap iterations: 0  
> summary(m2.nb)  
Call:  
pcount(formula = ~Prec + Jday + Ht ~ Snag, data = pola.data,  
       K = 40, mixture = "NB")  
  
Abundance (log-scale):  
      Estimate      SE      z P(>|z|)  
(Intercept) 1.081 0.7280 1.48 0.13763  
Snag        -0.199 0.0668 -2.98 0.00285
```

Exemple 3 — Modèle *N*-mixture

Inspectons les sorties des autres modèles III

```
Detection (logit-scale):  
      Estimate      SE      z P(>|z|)  
(Intercept) -1.9142 0.86673 -2.21 0.02720  
Prec         -0.0675 0.02446 -2.76 0.00576  
Jday         -0.0141 0.00579 -2.44 0.01467  
Ht          -0.3747 0.23025 -1.63 0.10369  
  
Dispersion (log-scale):  
      Estimate      SE      z P(>|z|)  
0.57 0.593 0.96  0.337  
  
AIC: 357.73  
Number of sites: 56  
optim convergence code: 0  
optim iterations: 45  
Bootstrap iterations: 0  
> summary(m3.nb)
```

Exemple 3 — Modèle *N*-mixture

Inspectons les sorties des autres modèles IV

```
Call:  
pcount(formula = ~Prec + Jday + Ht ~ Conifer, data = pola.data,  
       K = 40, mixture = "NB")  
  
Abundance (log-scale):  
      Estimate      SE      z P(>|z|)  
(Intercept) 1.1655 0.787 1.482  0.138  
Conifer     0.0946 0.116 0.814   0.415  
  
Detection (logit-scale):  
      Estimate      SE      z P(>|z|)  
(Intercept) -1.8547 0.9352 -1.98 0.04735  
Prec         -0.0656 0.0251 -2.62 0.00892  
Jday         -0.0126 0.0060 -2.11 0.03522  
Ht          -0.3770 0.2321 -1.62 0.10437  
  
Dispersion (log-scale):  
      Estimate      SE      z P(>|z|)  
0.18 0.519 0.347  0.729
```

Exemple 3 — Modèle *N*-mixture

Inspectons les sorties des autres modèles V

```
AIC: 366.86  
Number of sites: 56  
optim convergence code: 0  
optim iterations: 43  
Bootstrap iterations: 0  
> summary(m4.nb)  
Call:  
pcount(formula = ~Prec + Jday + Ht ~ Snag + Conifer, data = pola.data,  
       K = 40, mixture = "NB")  
  
Abundance (log-scale):  
      Estimate      SE      z P(>|z|)  
(Intercept) 0.993 0.6729 1.48 0.14003  
Snag        -0.207 0.0678 -3.05 0.00229  
Conifer     0.124 0.1071 1.16 0.24788  
  
Detection (logit-scale):
```

Exemple 3 — Modèle *N*-mixture

Inspectons les sorties des autres modèles VI

```
Estimate      SE      z P(>|z|)  
(Intercept) -1.8309 0.81228 -2.25 0.02420  
Prec         -0.0655 0.02452 -2.67 0.00755  
Jday        -0.0139 0.00581 -2.40 0.01644  
Ht          -0.3790 0.23144 -1.64 0.10150  
  
Dispersion (log-scale):  
Estimate      SE      z P(>|z|)  
0.672 0.631 1.06  0.287  
  
AIC: 358.41  
Number of sites: 56  
optim convergence code: 0  
optim iterations: 50  
Bootstrap iterations: 0  
> summary(m5.nb)
```

Exemple 3 — Modèle *N*-mixture

Inspectons les sorties des autres modèles VII

```
Call:  
pcount(formula = ~Snag + Conifer ~ 1, data = pola.data, K = 40,  
       mixture = "NB")  
  
Abundance (log-scale):  
Estimate      SE      z P(>|z|)  
1.95 0.413 4.74 2.18e-06  
  
Detection (logit-scale):  
Estimate      SE      z P(>|z|)  
(Intercept) -2.907 0.4403 -6.60 4.04e-11  
Snag        -0.193 0.0664 -2.91 3.56e-03  
Conifer      0.153 0.1145  1.34 1.80e-01  
  
Dispersion (log-scale):  
Estimate      SE      z P(>|z|)  
0.415 0.45 0.922 0.357  
  
AIC: 373.01
```

Exemple 3 — Modèle *N*-mixture

Inspectons les sorties des autres modèles VIII

```
Number of sites: 56  
optim convergence code: 0  
optim iterations: 56  
Bootstrap iterations: 0  
> summary(m6.nb)  
Call:  
pcount(formula = ~Snag + Conifer ~ Snag, data = pola.data, K = 40,  
       mixture = "NB")  
  
Abundance (log-scale):  
Estimate      SE      z P(>|z|)  
(Intercept) 1.9021 0.722  2.633 0.00847  
Snag        -0.0307 0.293 -0.105 0.91656  
  
Detection (logit-scale):  
Estimate      SE      z P(>|z|)  
(Intercept) -2.853 0.754 -3.786 0.000153  
Snag        -0.163 0.300 -0.544 0.586763
```

Exemple 3 — Modèle *N*-mixture

Inspectons les sorties des autres modèles IX

```
Conifer      0.153 0.115  1.329 0.183849  
  
Dispersion (log-scale):  
Estimate      SE      z P(>|z|)  
0.411 0.452 0.911 0.362  
  
AIC: 375  
Number of sites: 56  
optim convergence code: 0  
optim iterations: 60  
Bootstrap iterations: 0  
> summary(m7.nb)
```

Exemple 3 — Modèle *N*-mixture

Inspectons les sorties des autres modèles X

```
Call:  
pcount(formula = ~Snag + Conifer ~ Conifer, data = pola.data,  
      K = 40, mixture = "NB")  
  
Abundance (log-scale):  
    Estimate     SE     z P(>|z|)  
(Intercept)  1.877 0.533 3.521 0.00043  
Conifer      0.177 0.233 0.759 0.44775  
  
Detection (logit-scale):  
    Estimate     SE     z P(>|z|)  
(Intercept) -2.8242 0.5711 -4.9457 7.59e-07  
Snag        -0.1912 0.0661 -2.8908 3.84e-03  
Conifer     -0.0214 0.2389 -0.0895 9.29e-01  
  
Dispersion (log-scale):  
    Estimate     SE     z P(>|z|)  
          0.42 0.46 0.914   0.361
```

Exemple 3 — Modèle *N*-mixture

Inspectons les sorties des autres modèles XI

```
AIC: 374.64  
Number of sites: 56  
optim convergence code: 0  
optim iterations: 59  
Bootstrap iterations: 0  
> summary(m8.nb)  
Call:  
pcount(formula = ~Snag + Conifer ~ Snag + Conifer, data = pola.data,  
      K = 40, mixture = "NB")  
  
Abundance (log-scale):  
    Estimate     SE     z P(>|z|)  
(Intercept)  1.225 0.468 2.62 0.0089  
Snag        -0.267 0.143 -1.87 0.0612  
Conifer      0.297 0.187 1.59 0.1120  
  
Detection (logit-scale):  
    Estimate     SE     z P(>|z|)
```

Exemple 3 — Modèle *N*-mixture

Inspectons les sorties des autres modèles XII

```
(Intercept) -2.1321 0.521 -4.092 4.27e-05  
Snag         0.0801 0.150  0.535 5.93e-01  
Conifer     -0.1490 0.193 -0.774 4.39e-01  
  
Dispersion (log-scale):  
    Estimate     SE     z P(>|z|)  
          0.537 0.495 1.09   0.277  
  
AIC: 375.78  
Number of sites: 56  
optim convergence code: 0  
optim iterations: 73  
Bootstrap iterations: 0
```

Exemple 3 — Modèle *N*-mixture

Autres diagnostics

On peut vérifier le *CN* de chaque modèle

```
> Cands.nb <- list(m0.nb, m1.nb, m2.nb, m3.nb, m4.nb,  
>                      m5.nb, m6.nb, m7.nb, m8.nb)  
> Mod.nb.names <- c("m0.nb", "m1.nb", "m2.nb", "m3.nb",  
>                      "m4.nb", "m5.nb", "m6.nb", "m7.nb", "m8.nb")  
> ##add names to list  
> names(Cands.nb) <- Mod.nb.names  
> unlist(lapply(Cands.nb, extract.CN))  
           m0.nb      m1.nb      m2.nb      m3.nb      m4.nb      m5.nb  
22.473 62580.444 48076.937 54249.669 42719.266 94.433  
           m6.nb      m7.nb      m8.nb  
615.940 167.546 235.758
```

Certains modèles ont un *CN* un peu élevé.

Exemple 3 — Modèle *N*-mixture

Test d'ajustement I

On détermine le modèle au premier rang pour vérifier l'ajustement :

```
> aictab(Cands.nb, Mod.nb.names)
Model selection based on AICc :
```

K	AICc	Delta_AICc	AICcWt	Cum.Wt	LL
m2.nb	7	360.07	0.00	0.65	0.65 -171.87
m4.nb	8	361.47	1.41	0.32	0.97 -171.21
m1.nb	6	367.24	7.17	0.02	0.99 -176.76
m3.nb	7	369.19	9.13	0.01	1.00 -176.43
m5.nb	5	374.21	14.15	0.00	1.00 -181.51
m7.nb	6	376.35	16.29	0.00	1.00 -181.32
m6.nb	6	376.71	16.64	0.00	1.00 -181.50
m8.nb	7	378.11	18.04	0.00	1.00 -180.89
m0.nb	3	378.82	18.75	0.00	1.00 -186.18

```
> coef(m2.nb)
```

Exemple 3 — Modèle N-mixture

Test d'ajustement II

lam(Int)	lam(Snag)	p(Int)	p(Prec)
1.080872	-0.199411	-1.914218	-0.067535
p(Jday)	p(Ht)	alpha(alpha)	
-0.014120	-0.374657	0.569555	

Utilisons le modèle m2.nb pour vérifier l'ajustement

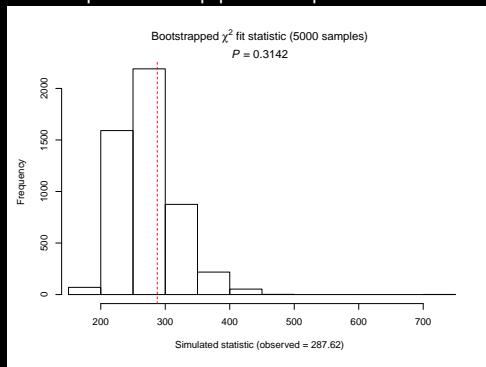
```
> m2.nb.gof <- Nmix.gof.test(mod = m2.nb, nsim = 5000)

> m2.nb.gof$chi.square
[1] 287.62
> m2.nb.gof$c.hat.est
[1] 1.0554
```

Exemple 3 — Modèle N-mixture

Test d'ajustement III

Graphique de la distribution du χ^2 observé par rapport aux χ^2 obtenus par bootstrap paramétrique



Exemple 3 — Modèle N-mixture

Test d'ajustement IV

On remarque que le modèle semble très bien s'ajuster aux données : plusieurs χ^2 simulées sont similaires à ce qu'on obtient avec les données originales ($P = 0.3142$).

De plus, le $\hat{c} = 1.06$, qui est pratiquement 1.

On conclut qu'on peut utiliser la distribution binomiale négative avec ce jeu de données.

Attention :

- la distribution binomiale négative donne parfois des valeurs prédites d'abondance irréalistes (trop grandes)

Exemple 3 — Modèle N-mixture

Test d'ajustement V

- toujours utile de vérifier les valeurs prédites par le modèle pour voir si elles sont réalistes

```
> ##abondances prédites
> abond <- predict(m2.nb, type = "state", backTransform = TRUE)
> head(abond)

   Predicted      SE lower upper
1  4.19269 3.07888 0.99407 17.6835
2  1.07948 0.87481 0.22050  5.2848
3  1.47002 1.13263 0.32470  6.6552
4  4.11233 3.01641 0.97662 17.3160
5  3.30441 2.40553 0.79330 13.7641
6  0.63594 0.57400 0.10843  3.7300

> range(abond$Predicted)
[1] 0.42439 5.84532
```

Exemple 3 — Modèle *N*-mixture

Test d'ajustement VI

Les valeurs prédites d'abondance sont réalistes pour l'espèce : 0 – 6 Grands Polatouches

Exemple 3 — Modèle *N*-mixture

Sélection de modèles

On effectue la sélection de modèles :

```
> aictab(Cands.nb, Mod.nb.names)
Model selection based on AICc :

      K   AICc Delta_AICc AICcWt Cum.Wt      LL
m2.nb 7 360.07     0.00    0.65   0.65 -171.87
m4.nb 8 361.47     1.41    0.32   0.97 -171.21
m1.nb 6 367.24     7.17    0.02   0.99 -176.76
m3.nb 7 369.19     9.13    0.01   1.00 -176.43
m5.nb 5 374.21    14.15    0.00   1.00 -181.51
m7.nb 6 376.35    16.29    0.00   1.00 -181.32
m6.nb 6 376.71    16.64    0.00   1.00 -181.50
m8.nb 7 378.11    18.04    0.00   1.00 -180.89
m0.nb 3 378.82    18.75    0.00   1.00 -186.18
```

On remarque deux modèles avec un poids d'Akaike cumulatif de 0.97.

Exemple 3 — Modèle *N*-mixture

Sélection de modèles

Les deux modèles sont constitués des variables suivantes :

```
> coef(m2.nb)
  lam(Int)    lam(Snag)      p(Int)      p(Prec)
  1.080872   -0.199411   -1.914218   -0.067535
  p(Jday)      p(Ht) alpha(alpha)
  -0.014120   -0.374657   0.569555
> coef(m4.nb)
  lam(Int)    lam(Snag) lam(Conifer)      p(Int)
  0.993042   -0.206651   0.123739   -1.830882
  p(Prec)      p(Jday)      p(Ht) alpha(alpha)
  -0.065504   -0.013930   -0.379015   0.671762
```

La variable Snag apparaît dans les deux modèles sur λ .

Exemple 3 — Modèle *N*-mixture

Inférence multimodèle – Snag

On commence avec Snag sur λ

```
> modavg(cand.set = Cands.nb, modnames = Mod.nb.names,
  parm = "Snag", parm.type = "lambda")
Multimodel inference on " lam(Snag) " based on AICc

AICc table used to obtain model-averaged estimate:

      K   AICc Delta_AICc AICcWt Estimate   SE
m2.nb 7  360.07     0.00   0.67    -0.20 0.07
m4.nb 8  361.47     1.41   0.33    -0.21 0.07
m6.nb 6  376.71    16.64   0.00    -0.03 0.29
m8.nb 7  378.11    18.04   0.00    -0.27 0.14

Model-averaged estimate: -0.2
Unconditional SE: 0.07
95 % Unconditional confidence interval: -0.33 , -0.07
```

L'abondance diminue avec Snag.

Exemple 3 — Modèle *N*-mixture

Inférence multimodèle – Conifer

Pour l'estimé pondéré de Conifer sur λ

```
> modavg(cand.set = Cands.nb, modnames = Mod.nb.names,
  parm = "Conifer", parm.type = "lambda")
Multimodel inference on " lam(Conifer) " based on AICc

AICc table used to obtain model-averaged estimate:

      K   AICc Delta_AICc AICcWt Estimate   SE
m3.nb 7  369.19     7.72   0.02    0.09 0.12
m4.nb 8  361.47     0.00   0.98    0.12 0.11
m7.nb 6  376.35    14.88   0.00    0.18 0.23
m8.nb 7  378.11    16.63   0.00    0.30 0.19

Model-averaged estimate: 0.12
Unconditional SE: 0.11
95 % Unconditional confidence interval: -0.09 , 0.33
```

L'abondance ne varie pas avec Conifer.

Exemple 3 — Modèle *N*-mixture

Inférence multimodèle – Prec

Pour l'estimé pondéré de Prec sur p

```
> modavg(cand.set = Cands.nb, modnames = Mod.nb.names,
  parm = "Prec", parm.type = "detect")
Multimodel inference on " p(Prec) " based on AICc

AICc table used to obtain model-averaged estimate:

      K   AICc Delta_AICc AICcWt Estimate   SE
m1.nb 6  367.24     7.17   0.02    -0.07 0.03
m2.nb 7  360.07     0.00   0.65    -0.07 0.02
m3.nb 7  369.19    9.13   0.01    -0.07 0.03
m4.nb 8  361.47    1.41   0.32    -0.07 0.02

Model-averaged estimate: -0.07
Unconditional SE: 0.02
95 % Unconditional confidence interval: -0.11 , -0.02
```

La probabilité de détection diminue avec la quantité de précipitations.

Exemple 3 — Modèle *N*-mixture

Inférence multimodèle – Ht

Pour l'estimé pondéré de Ht sur p

```
> modavg(cand.set = Cands.nb, modnames = Mod.nb.names,
  parm = "Ht", parm.type = "detect")
Multimodel inference on " p(Ht) " based on AICc

AICc table used to obtain model-averaged estimate:

      K   AICc Delta_AICc AICcWt Estimate   SE
m1.nb 6  367.24     7.17   0.02    -0.37 0.23
m2.nb 7  360.07     0.00   0.65    -0.37 0.23
m3.nb 7  369.19    9.13   0.01    -0.38 0.23
m4.nb 8  361.47    1.41   0.32    -0.38 0.23

Model-averaged estimate: -0.38
Unconditional SE: 0.23
95 % Unconditional confidence interval: -0.83 , 0.08
```

La probabilité de détection ne varie pas avec la hauteur des pièges.

Exemple 3 — Modèle *N*-mixture

Inférence multimodèle – Jday

Pour l'estimé pondéré de Jday sur p

```
> print(modavg(cand.set = Cands.nb, modnames = Mod.nb.names,
+                parm = "Jday", parm.type = "detect"), digits = 4)
Multimodel inference on "p(Jday)" based on AICc

AICc table used to obtain model-averaged estimate:

      K   AICc Delta_AICc AICcWt Estimate     SE
m1.nb 6  367.24    7.1704 0.0181 -0.0127 0.0060
m2.nb 7  360.07    0.0000 0.6525 -0.0141 0.0058
m3.nb 7  369.19    9.1281 0.0068 -0.0126 0.0060
m4.nb 8  361.47    1.4092 0.3226 -0.0139 0.0058

Model-averaged estimate: -0.014
Unconditional SE: 0.0058
95 % Unconditional confidence interval: -0.0254 , -0.0027
```

La probabilité de détection diminue avec le jour julien.

Exemple 3 — Modèle N -mixture

Prédictions - Snag I

On crée un nouveau jeu de données

```
> range(pola.site$Snag)
[1] -3.4340  9.7185
> ##create newdata data frame
> ##centered effort
> new.dats <- data.frame(Conifer = 0,
+                         Snag = seq(from = min(pola.site$Snag),
+                                    to = max(pola.site$Snag),
+                                    length.out = 30))
> ##uncentered Snag
> new.dats$Snag.orig <- new.dats$Snag + 3.4
```

Prédictions avec modavgpred()

```
> preds <- modavgpred(cand.set = Cands.nb, modnames = Mod.nb.names,
+                        c.hat = 1, newdata = new.dats,
+                        type = "response", parm.type = "lambda")
```

Exemple 3 — Modèle N -mixture

Prédictions - Snag II

Ajouter les valeurs prédites et SE inconditionnelles

```
> new.dats$mod.avg.pred <- preds$mod.avg.pred
> new.dats$uncond.se <- preds$uncond.se
```

Pour calculer les intervalles de confiance, on utilise l'échelle logit

```
> preds.log <- modavgpred(cand.set = Cands.nb,
+                            modnames = Mod.nb.names,
+                            c.hat = 1, newdata = new.dats,
+                            type = "link", parm.type = "lambda")
> ##add to data set
> new.dats$mod.avg.pred.log <- preds.log$mod.avg.pred
> new.dats$uncond.se.log <- preds.log$uncond.se
```

On calcule les limites et on convertit sur l'échelle originale

Exemple 3 — Modèle N -mixture

Prédictions - Snag III

```
> ##95% CI
> new.dats$low95 <- exp(new.dats$mod.avg.pred.log -
+                          1.96 * new.dats$uncond.se.log)
> new.dats$upp95 <- exp(new.dats$mod.avg.pred.log +
+                          1.96 * new.dats$uncond.se.log)
```

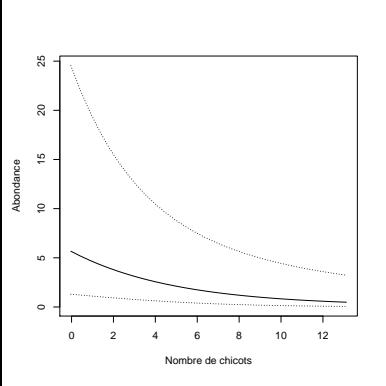
Préparation du graphique

```
> ##create plot
> plot(new.dats$mod.avg.pred ~ new.dats$Snag.orig,
+       ylab = "Abondance",
+       xlab = "Nombre de chictos",
+       ylim = range(c(new.dats$low95, new.dats$upp95)),
+       type = "l")
> ##add confidence bands
> lines(y = new.dats$low95, x = new.dats$Snag.orig,
+        lty = "dotted")
> lines(y = new.dats$upp95, x = new.dats$Snag.orig,
+        lty = "dotted")
```

Exemple 3 — Modèle N -mixture

Prédictions - Snag IV

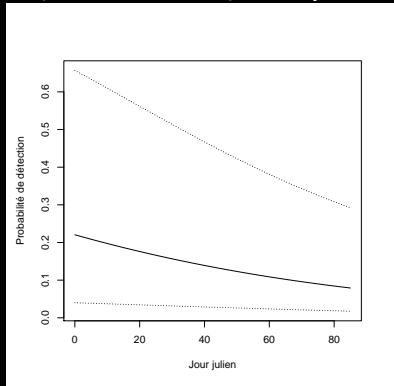
Le graphique



Exemple 3 — Modèle *N*-mixture

Prédictions - Jday

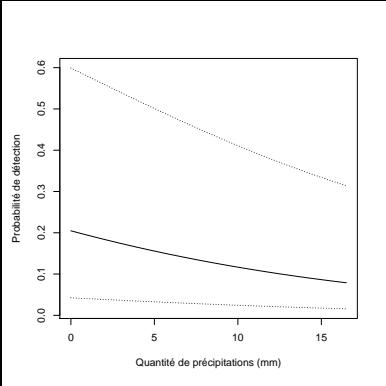
On peut faire de même pour Jday



Exemple 3 — Modèle *N*-mixture

Prédictions - Prec

On peut faire de même pour Prec



Exemple 3 — Modèle *N*-mixture

Modèles *N*-mixture avec zero-inflated Poisson

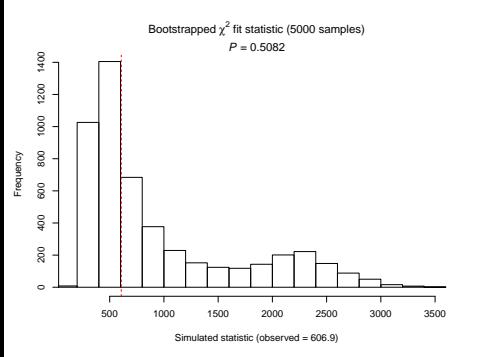
Essayons des modèles avec la même structure sur ρ et λ avec une distribution de Poisson gonflée de zéros (ZIP)

```
> m0.zip <- pcount(~ 1 ~ 1, K = 40, mixture = "ZIP",
+ data = pola.data)
> m1.zip <- pcount(~ Prec + Jday + Ht ~ 1, K = 40,
+ mixture = "ZIP", data = pola.data)
> m2.zip <- pcount(~ Prec + Jday + Ht ~ Snag, K = 40,
+ mixture = "ZIP", data = pola.data)
> m3.zip <- pcount(~ Prec + Jday + Ht ~ Conifer, K = 40,
+ mixture = "ZIP", data = pola.data)
> m4.zip <- pcount(~ Prec + Jday + Ht ~ Snag + Conifer, K = 40,
+ mixture = "ZIP", data = pola.data)
> m5.zip <- pcount(~ Snag + Conifer ~ 1, K = 40, mixture = "ZIP",
+ data = pola.data)
> m6.zip <- pcount(~ Snag + Conifer ~ Snag, K = 40,
+ mixture = "ZIP", data = pola.data)
> m7.zip <- pcount(~ Snag + Conifer ~ Conifer, K = 40,
+ mixture = "ZIP", data = pola.data)
> m8.zip <- pcount(~ Snag + Conifer ~ Snag + Conifer,
+ K = 40, mixture = "ZIP", data = pola.data)
```

Exemple 3 — Modèle *N*-mixture

Alternative — distribution ZIP

Avec le jeu de données, la distribution ZIP aussi appropriée



L'ajustement du modèle aussi est très satisfaisant ($P = 0.5082$) et le $\hat{c} = 0.65$.

Exemple 3 — Modèle N -mixture

Quelques modèles disponibles

Modèle N -mixture dynamique — `pcountOpen()`

- estime l'abondance initiale (λ), le recrutement (γ), la survie apparente (ω), et la probabilité de détection

Modèle d'hétérogénéité — `occuRN()`

- estime l'abondance à partir de données binaires

Modèle d'occupation avec faux-positifs et faux négatifs — `occuFP()`

- estime l'occupation où il y a des faux-positifs

Modèles d'échantillonnage de la distance (*distance sampling*) — `distsamp()` et `gdistsamp()`

- estiment l'abondance à partir de données récoltées dans des intervalles discrets

Autres modèles dans `unmarked`

Packages utiles

Occupation

- hSDM
- pom
- stocc
- unmarked

Approches bayésiennes

- R2WinBUGS
- R2OpenBUGS
- R2jags

Inférence multimodale

- AICmodavg
- MuMIn

CMR

- CARE1
- marked
- mra
- Rcapture
- RMark
- secr
- admbsecr
- SPACECAP

Échantillonnage de la distance

- Distance
- dsm
- DSpat
- hierarchicalDS
- mrds
- mmds
- Rdistance
- unmarked

Packages utiles

Le package RMark

RMark permet de réaliser plusieurs modèles du programme MARK

- occupancy
 - une saison, multisaison
 - multi-états
 - co-occurrence
 - hétérogénéité
- N -mixture
 - une saison, multisaison
- CMR
 - population ouverte, fermée, design robuste
 - multi-états
 - recovery models
 - known fate
 - POPAN

Packages utiles

D'autres avantages à utiliser R

R code, résultats et graphiques intégrés directement dans les documents (e.g., L^AT_EX et Sweave ou knitr, OpenOffice et ODFweave)

- un fichier comprend tout (texte, résultats, et code R)
- pas besoin de copier-coller
- les modifications du jeu de données se reflètent automatiquement dans les résultats et les graphiques dans le texte

Utiliser R comme environnement de travail

- permet d'organiser et d'exécuter les analyses
- documente toutes les étapes du début à la fin
- R est cool, gratuit, et une grande communauté d'utilisateurs

[Le mot de la fin](#)