

Présentation du contexte

Objectifs

- Ajuster un modèle linéaire généralisé sur des données de comptages
- Vérifier l'ajustement du modèle grâce à la technique du "posterior predictive check"
- Changer la vraisemblance des données pour tenir compte de la surdispersion
- Ajouter des effets aléatoires
- Ajouter un effet spatial

Estimer la taille de groupe du dauphin commun dans le golfe de Gascogne

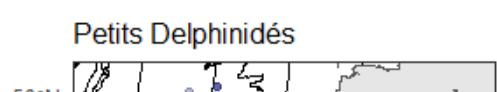
Le dauphin commun (*Delphinus delphis*) est l'espèce la plus abondante de mammifères marins dans le Golfe de Gascogne (Laran et al, 2017).



Depuis 2004, les campagnes océanographiques de l'Ifremer sur le navire Thalassa permettent de recenser et dénombrer les dauphins communs.

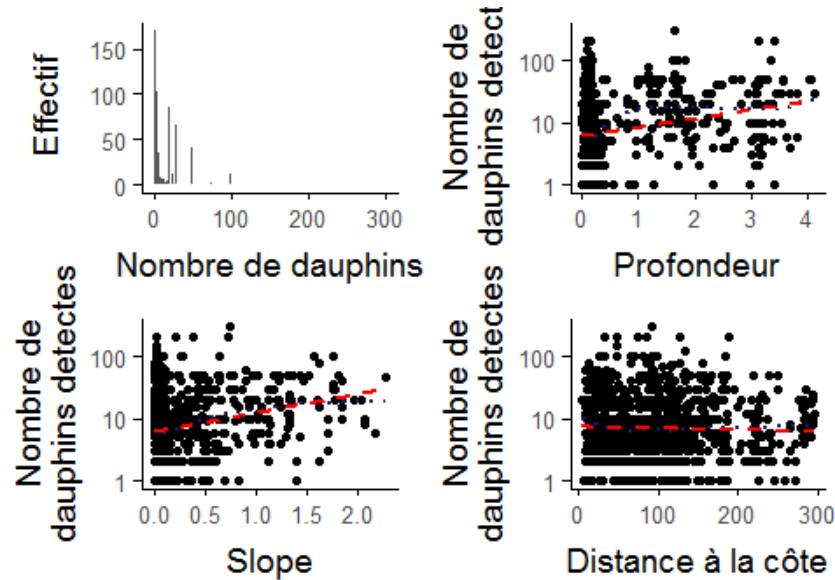


Les données collectées représentent 1269 observations de petits delphinidés (principalement des dauphins communs mais aussi quelques dauphins bleu et blanc *Stenella coeruleoalba*).



Question: Quels sont les facteurs déterminants de l'abondance de dauphins dans le Golfe de Gascogne?

Le but de l'analyse est ici de corrélérer le nombre de dauphins (la variable réponse) à un ensemble de covariables environnementales (par exemple la profondeur/bathymétrie, *etc.*) afin d'expliquer les variations observées.



Les données y_i sont des entiers naturels et la première approche est de considérer un modèle poissonien
 $y_i^{\text{obs}} \sim \mathcal{P}(\lambda_i)$

où $\log(\lambda_i) = \beta_0 + \beta_1 \times \text{Bathy}_i + \dots$

Début de l'analyse

Charger les données et les bibliothèques de fonctions nécessaires à l'analyse

```
In [1]: lapply(c("ggplot2", "ggthemes", "sp", "sf", "loo"), library, character.only=TRUE)
)

### theme for graphics
theme_set(theme_bw(base_size = 20))

### clean up
rm(list = ls())
getwd()
WorkDir <- paste(getwd(), "dauphin_v2", sep = "/")
DataDir <- paste(WorkDir, "data", sep = "/")
OutDir <- paste(WorkDir, "output", sep = "/")

### load the data
load(paste(DataDir, "Filtered_data.RData", sep = "/"))
```

Linking to GEOS 3.6.1, GDAL 2.2.3, PROJ 4.9.3

This is loo version 2.0.0.

**NOTE: As of version 2.0.0 loo defaults to 1 core but we recommend using as many as possible. Use the 'cores' argument or set options(mc.cores = NUM_CORES) for an entire session. Visit mc-stan.org/loo/news for details on other changes

- 1. 'ggplot2' 'stats' 'graphics' 'grDevices' 'utils' 'datasets' 'methods' 'base'
- 2. 'ggthemes' 'ggplot2' 'stats' 'graphics' 'grDevices' 'utils' 'datasets' 'methods' 'base'
- 3. 'sp' 'ggthemes' 'ggplot2' 'stats' 'graphics' 'grDevices' 'utils' 'datasets' 'methods' 'base'
- 4. 'sf' 'sp' 'ggthemes' 'ggplot2' 'stats' 'graphics' 'grDevices' 'utils' 'datasets' 'methods' 'base'
- 5. 'loo' 'sf' 'sp' 'ggthemes' 'ggplot2' 'stats' 'graphics' 'grDevices' 'utils' 'datasets' 'methods' 'base'

'C:/Users/biobayes/Desktop/EC_BIOBAYES/TD2_dauphin'

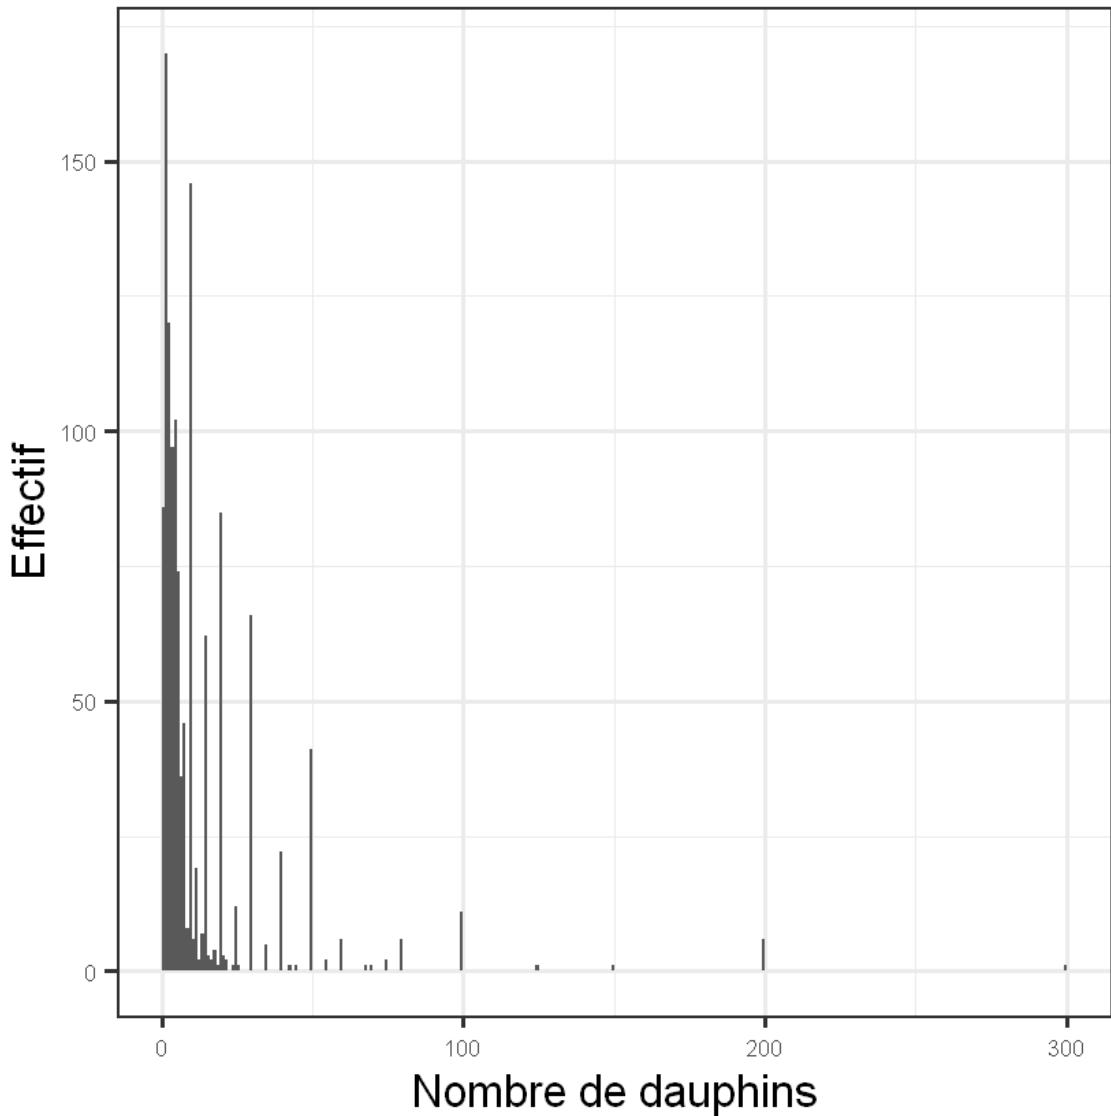
```
In [2]: ### view the different objects in your environment
ls()
```

'A' 'at_sea' 'DataDir' 'grid_at_sea' 'grid_sp' 'neighbors_mat' 'obs' 'OutDir' 'WorkDir'

```
In [3]: ### dataframe of observations
head(obs)
```

Longitude	Latitude	X	Y	an	Famille	nombre	DepthGebco	Slope	DistCot	ce
-6.073679	47.91717	23721.71	6796318	2010	Delphininae	4	0.139192	0.02701630	92.2346	395
-6.069807	47.91725	24010.08	6796294	2010	Delphininae	5	0.139192	0.02701630	92.2346	395
-6.039052	47.91930	26318.33	6796258	2010	Delphininae	4	0.139827	0.01384940	90.5742	395
-6.030971	47.91995	26926.16	6796260	2010	Delphininae	3	0.139827	0.01384940	90.5742	395
-6.018800	47.92077	27839.73	6796247	2010	Delphininae	5	0.135000	0.00834959	88.8965	395
-6.010793	47.92166	28445.18	6796278	2010	Delphininae	5	0.135000	0.00834959	88.8965	395

```
In [4]: ### Exploratory data analysis
ggplot(data = obs,
       aes(x = nombre)
       ) +
  geom_histogram(breaks = 0:300) +
  ylab("Effectif") + xlab("Nombre de dauphins") +
  theme(plot.title = element_text(lineheight = 0.8, face = "bold"),
        axis.text = element_text(size = 10)
       )
```



Travaux préliminaires

L'expérience nous pousse à utiliser une loi de Poisson, commune pour représenter les comptages. Les nombres observés étant toujours positifs, on peut décaler d'une unité. Il est d'usage de centrer et de réduire les variables explicatives.

L'approche fréquentiste consisterait à *caler* un *glm*, ce qu'on fait.

Il nous faut écrire le modèle suivant:

$$y_i^{\text{obs}} \sim \mathcal{P}(\lambda_i)$$

avec $\log(\lambda_i) = \beta_0 + \beta_1 \times \text{Bathy}_i + \beta_2 \times \text{Pente}_i + \beta_3 \times \text{DistanceCote}_i$

```
In [5]: obs$nombreShift <- obs$nombre - 1
dauphin2.glm = glm(nombreShift ~ scale(DepthGebco) + scale(Slope) + scale(DistCot),
                     family = "poisson", data = obs
)
summary(dauphin2.glm)
dauphin2.glm$coefficients

Call:
glm(formula = nombreShift ~ scale(DepthGebco) + scale(Slope) +
    scale(DistCot), family = "poisson", data = obs)

Deviance Residuals:
    Min      1Q  Median      3Q     Max 
-7.384  -3.494  -2.029   0.398  32.342 

Coefficients:
            Estimate Std. Error z value Pr(>|z|)    
(Intercept) 2.472917  0.008339 296.55   <2e-16 ***
scale(DepthGebco) 0.233272  0.007683  30.36   <2e-16 ***
scale(Slope)    0.128827  0.007698  16.74   <2e-16 ***
scale(DistCot)  -0.184177  0.009476 -19.44   <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for poisson family taken to be 1)

Null deviance: 25774  on 1268  degrees of freedom
Residual deviance: 23626  on 1265  degrees of freedom
AIC: 28052

Number of Fisher Scoring iterations: 6

          (Intercept) 2.4729165567972
scale(DepthGebco) 0.233272395505298
scale(Slope)    0.128827100897259
scale(DistCot)  -0.184177449274629
```

Codage du modèle en bayésien avec Jags

Écrivons dans un premier temps le modèle avec le langage spécifique à Jags. Ce language est structuré et la spécification d'un modèle se fait grâce à un ensemble de blocs de type BUGS:

Priors

Dans le paradigme bayésien, les inconnues sont munies de lois a priori qu'il nous faut spécifier. On prendra

$$\beta_0 \sim \mathcal{N}(0.0, 1.0)$$

$$\beta_1 \sim \mathcal{N}(0.0, \frac{\log 2}{2})$$

$$\beta_2 \sim \mathcal{N}(0.0, \frac{\log 2}{2})$$

$$\beta_3 \sim \mathcal{N}(0.0, \frac{\log 2}{2})$$

```
In [6]: library(R2jags)

model.jags <- '
model{
  # Prior
  intercept ~ dnorm(0.0, hyperparam_inter)
  slope[1] ~ dnorm(0.0, hyperparam_slope[1])
  slope[2] ~ dnorm(0.0, hyperparam_slope[2])
  slope[3] ~ dnorm(0.0, hyperparam_slope[3])

  # Likelihood
  for (i in 1:n_obs) {
    lambda[i] <- exp(intercept + slope[1] * X1[i] + slope[2] * X2[i] + slope[3]
* X3[i])
    Y[i] ~ dpois(lambda[i])
  }
}
'
```

Loading required package: rjags

Loading required package: coda

Linked to JAGS 4.3.0

Loaded modules: basemod,bugs

Attaching package: 'R2jags'

The following object is masked from 'package:coda':

traceplot

Préparer les *données* et initialiser les chaînes (en trichant un peu)

```
In [7]: data.jags <- list(n_obs = nrow(obs),
                       Y = obs$nombreShift,
                       X1 = as.vector(scale(obs$DepthGebco)),
                       X2 = as.vector(scale(obs$Slope)),
                       X3 = as.vector(scale(obs$DistCot)),
                       hyperparam_inter = 1.0,
                       hyperparam_slope = 1/rep(log(2)/2, 3)^2
                     )
# Inits function
# On triche un peu: on va prendre les estimations de glm
inits.jags <- function(idchain, glm) {
  list(intercept = rnorm(1, glm$coefficients[1], sqrt(10 * diag(vcov(glm)))[1]),
       slope = rnorm(3, glm$coefficients[2:4], sqrt(10 * diag(vcov(glm)))[2:4]))
}
```

On nomme les inconnues, on va spécifier le nombre d'itérations puis lancer la machinerie d'inférence. On met les sorties au format de sortie de BUGS avant de les regarder sommairement.

```
In [8]: # parameter of inferential interest
params.jags <- c("intercept", "slope")

# MCMC settings
ni <- 2000 # TOTAL Number of iterations including Burn in
nb <- 1000 #Number of iterations for Burn in
nt <- 1
nc <- 3

# Load/check model, load data and inits
# Start Gibbs sampler
temp <- jags(data = data.jags,
               inits = lapply(1:nc, inits.jags, glm = dauphin2.glm),
               param = params.jags,
               model.file = textConnection(model.jags),
               n.chains = nc,
               n.burnin = nb,
               n.iter = ni,
               n.thin = nt
               )

out = temp$BUGSoutput
# Inferences
# After Burn in period let's work inference assuming ergodic regime is reached
print(out$summary, dig = 2)

module glm loaded

Compiling model graph
Resolving undeclared variables
Allocating nodes
Graph information:
  Observed stochastic nodes: 1269
  Unobserved stochastic nodes: 4
  Total graph size: 9591

Initializing model

      mean      sd     2.5%    25%    50%    75%   97.5% Rhat
deviance 30147.60 1.2e+02 3.0e+04 3.0e+04 30149.23 30219.39 30359.12 1
intercept 2.79 9.8e-03 2.8e+00 2.8e+00 2.79 2.80 2.80 1
slope[1] 0.30 8.6e-03 2.8e-01 2.9e-01 0.30 0.30 0.31 1
slope[2] 0.10 7.7e-03 8.9e-02 9.8e-02 0.10 0.11 0.12 1
slope[3] -0.23 8.4e-03 -2.4e-01 -2.3e-01 -0.23 -0.22 -0.21 1

      n.eff
deviance 1100
intercept 3000
slope[1] 490
slope[2] 670
slope[3] 320
```

Avant toute chose

On doit vérifier (rapidement) la convergence du modèle, par exemple en regardant le diagnostic de Gelman-Rubin.

Prendre un moment pour comprendre la construction de cette statistique d'analyse de variance pour les séries dans la partie théorie de l'aide sous R du programme: `?coda::gelman.diag`

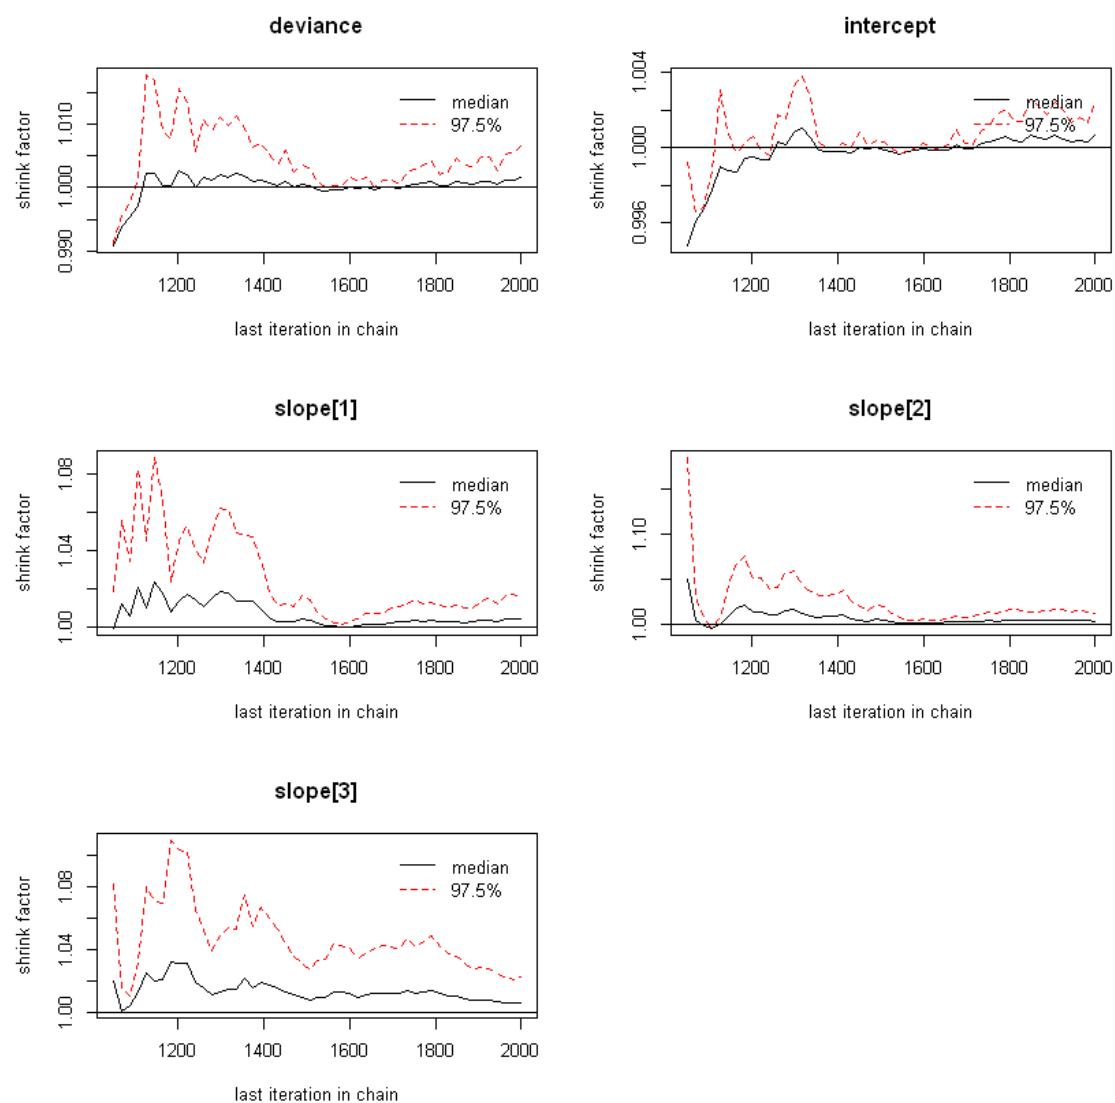
```
In [9]: library(coda)
gelman.diag(x=out, confidence = 0.95, transform=FALSE, autoburnin=TRUE)
gelman.plot(x=out)
```

Potential scale reduction factors:

	Point est.	Upper C.I.
deviance	1.00	1.01
intercept	1.00	1.00
slope[1]	1.00	1.02
slope[2]	1.00	1.01
slope[3]	1.01	1.02

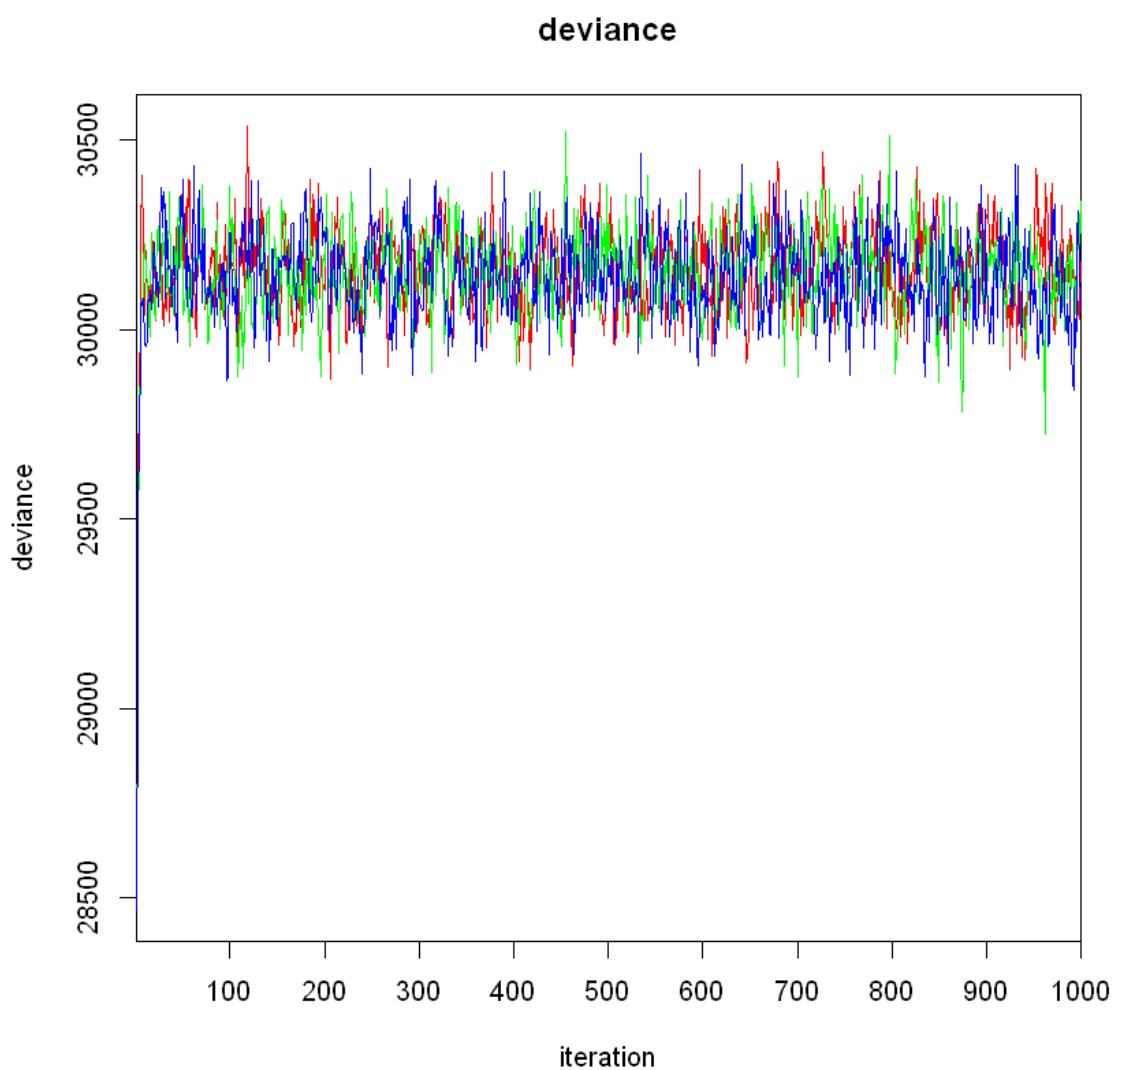
Multivariate psrf

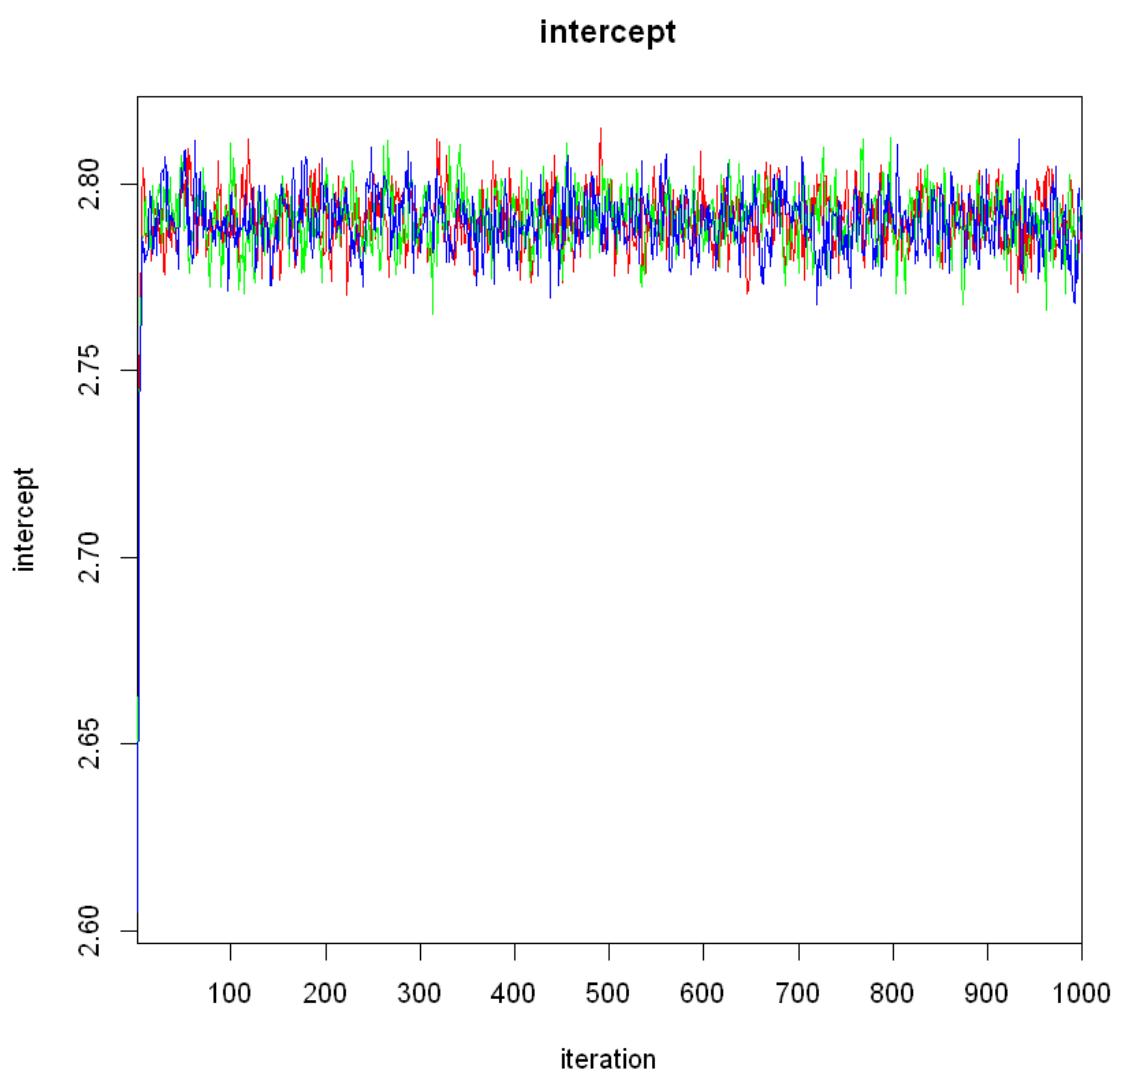
1.01

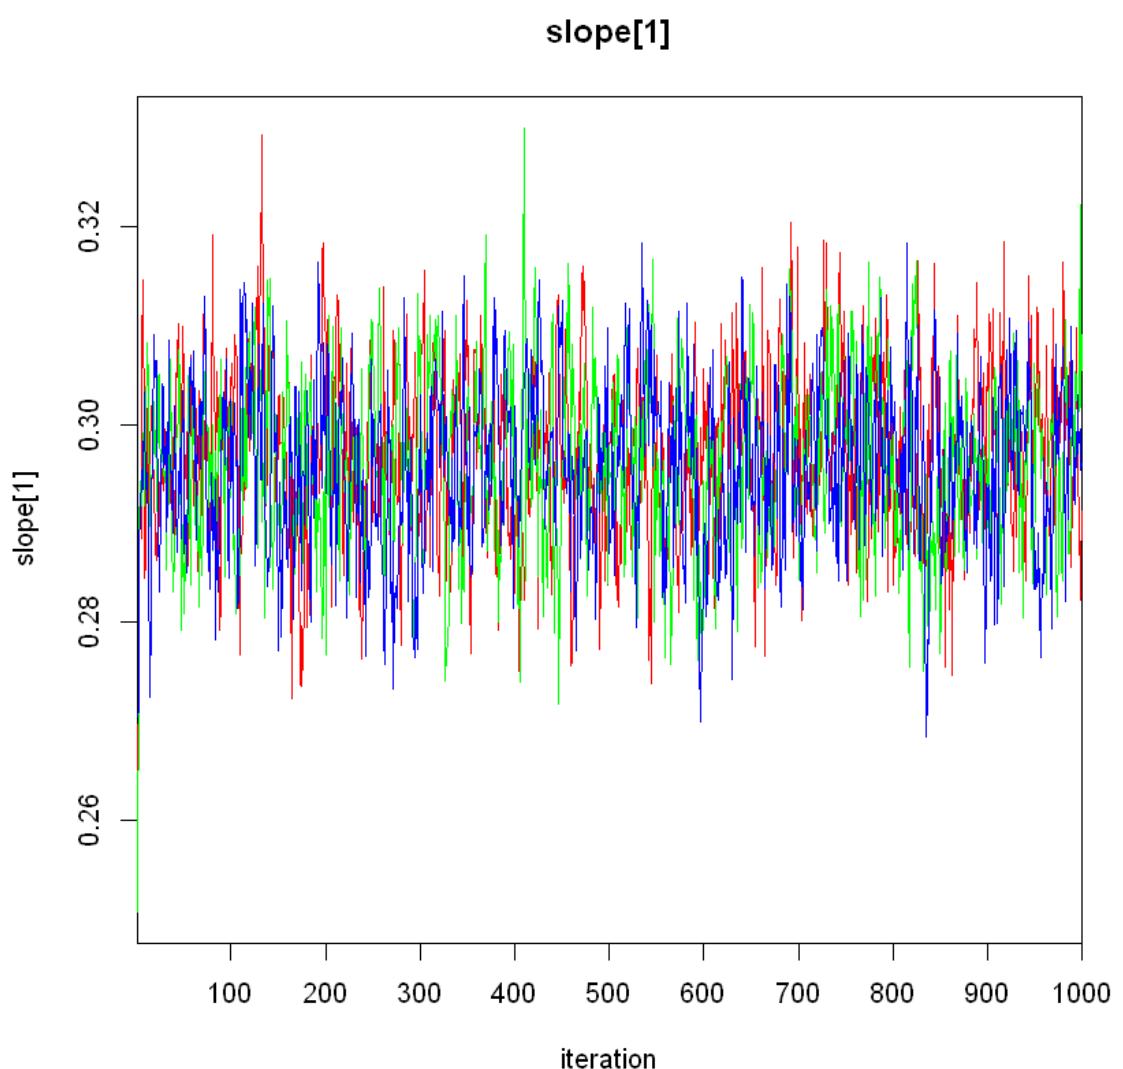


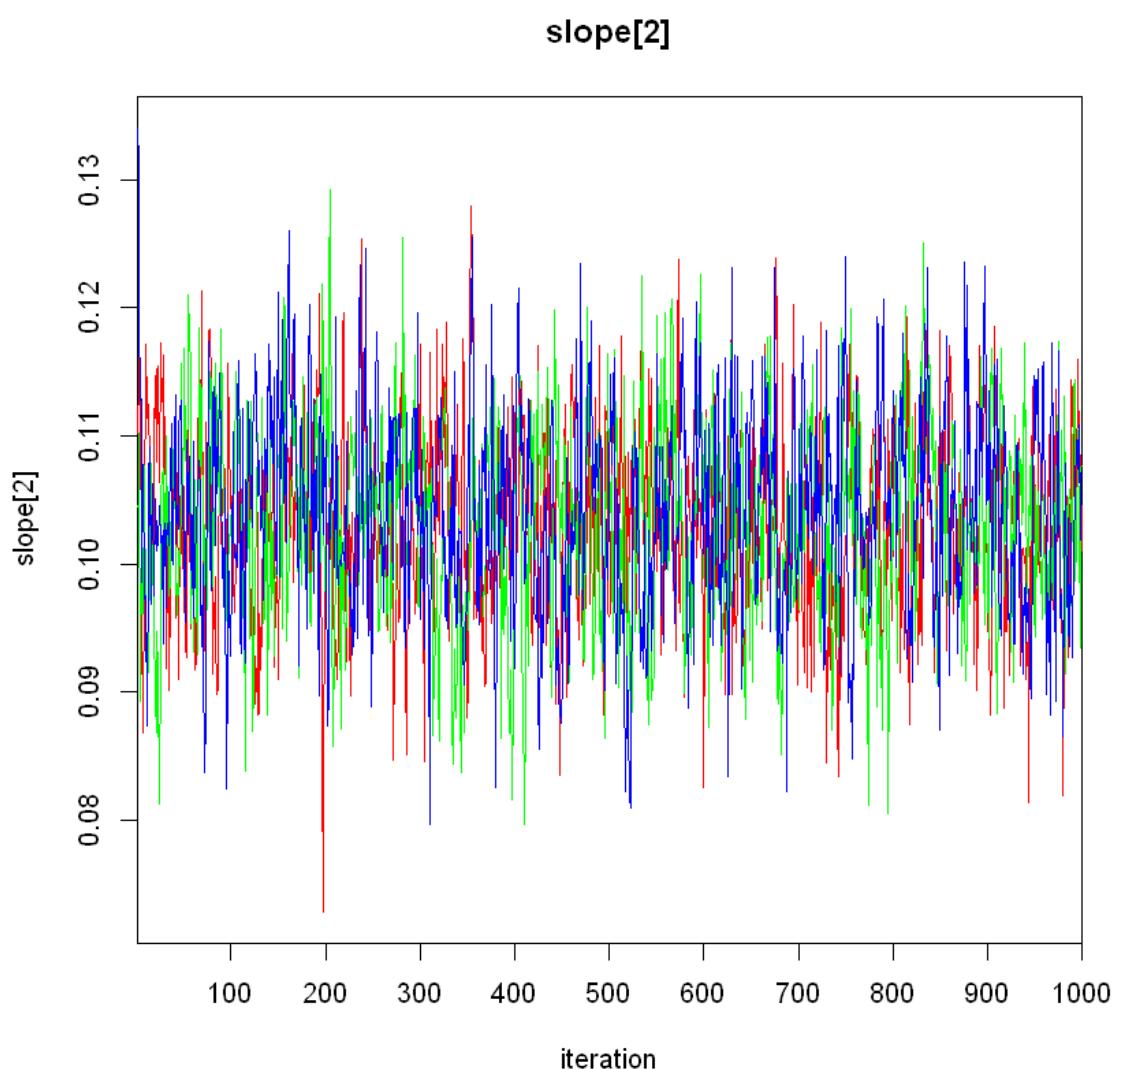
Visualisons la trace des paramètres : on peut voir que les paramètres convergent rapidement (au bout de seulement quelques itérations).

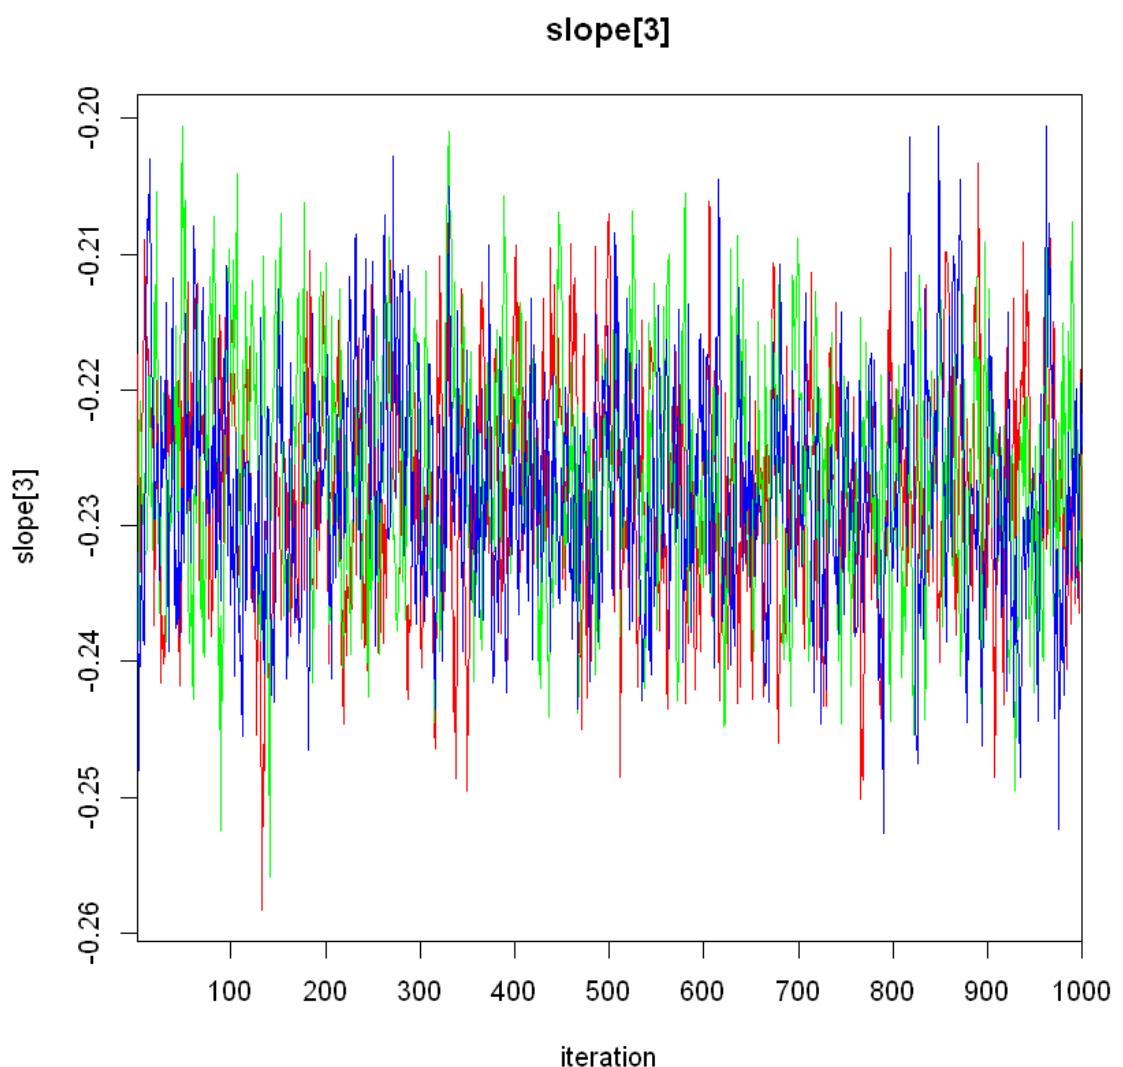
In [10]: `traceplot(out)`











Visualisation des lois a posteriori

On peut faire appel aux potentialités graphiques de R pour représenter les lois a posteriori. Voici un exemple avec ggplot

```
In [11]: library(tidyverse)

other =
  tibble(
    param = paste0("slope[",1:3,"]"),
    class = "slope",
    value = dauphin2.glm$coefficients[2:4],
    type = "mle"
  ) %>%
  rbind(list("intercept", "intercept", dauphin2.glm$coefficients[1], "mle"))

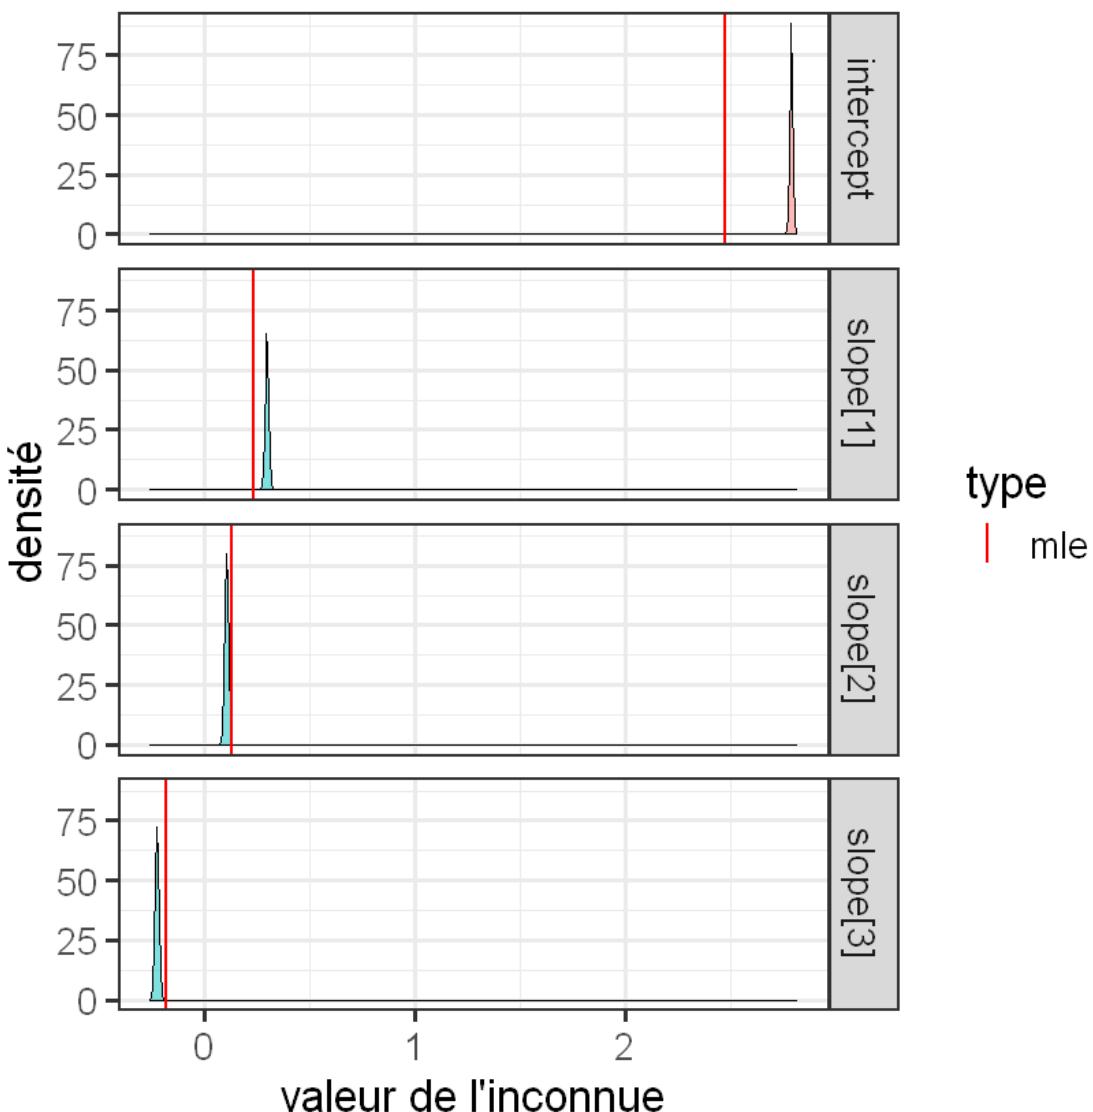
out$sims.matrix[,-1] %>% as_tibble() %>%
  tidyrr::gather(param, value) %>%
  mutate(class = stringr::str_replace(param, "\\\\[\\d+\\]","")) %>%
  ggplot(aes_string(x="value", fill="class")) +
  geom_density(alpha=0.5) +
  facet_grid(param ~ .) +
  geom_vline(data = other, aes_string(xintercept="value", color="type", linetype="type"), size=0.8) +
  scale_colour_manual(values=c("red","purple")) +
  guides(fill=FALSE)+labs(x="valeur de l'inconnue", y="densité")

#essayer   facet_grid(~param, scales = "free")
```

```

Warning message:
"package 'tidyverse' was built under R version 3.5.3"-- Attaching packages ---
----- tidyverse 1.2.1 --
v tibble 2.0.1      v purrr  0.3.0
v tidyr  0.8.2      v dplyr   0.8.0.1
v readr   1.3.1     v stringr 1.4.0
v tibble  2.0.1     vforcats 0.4.0
Warning message:
"package 'readr' was built under R version 3.5.3"Warning message:
"package 'forcats' was built under R version 3.5.3"-- Conflicts -----
----- tidyverse_conflicts() --
x dplyr::filter() masks stats::filter()
x dplyr::lag()    masks stats::lag()

```



Exercice

- dans la matrice des sorties jags , les 3 chaines sont empilées à la suite. Créer une nouvelle variable catégorielle donnant le numéro de la chaîne
- refaire sous ggplot2 l'équivalent de traceplot

Critère d'information

Pour calculer le critère d'information de Watanabee, on a besoin de calculer la log vraisemblance sous le modèle. On fait appel au package loo.

Posterior Predictive Checks

On va extraire directement les valeurs prédictes y^{rep}

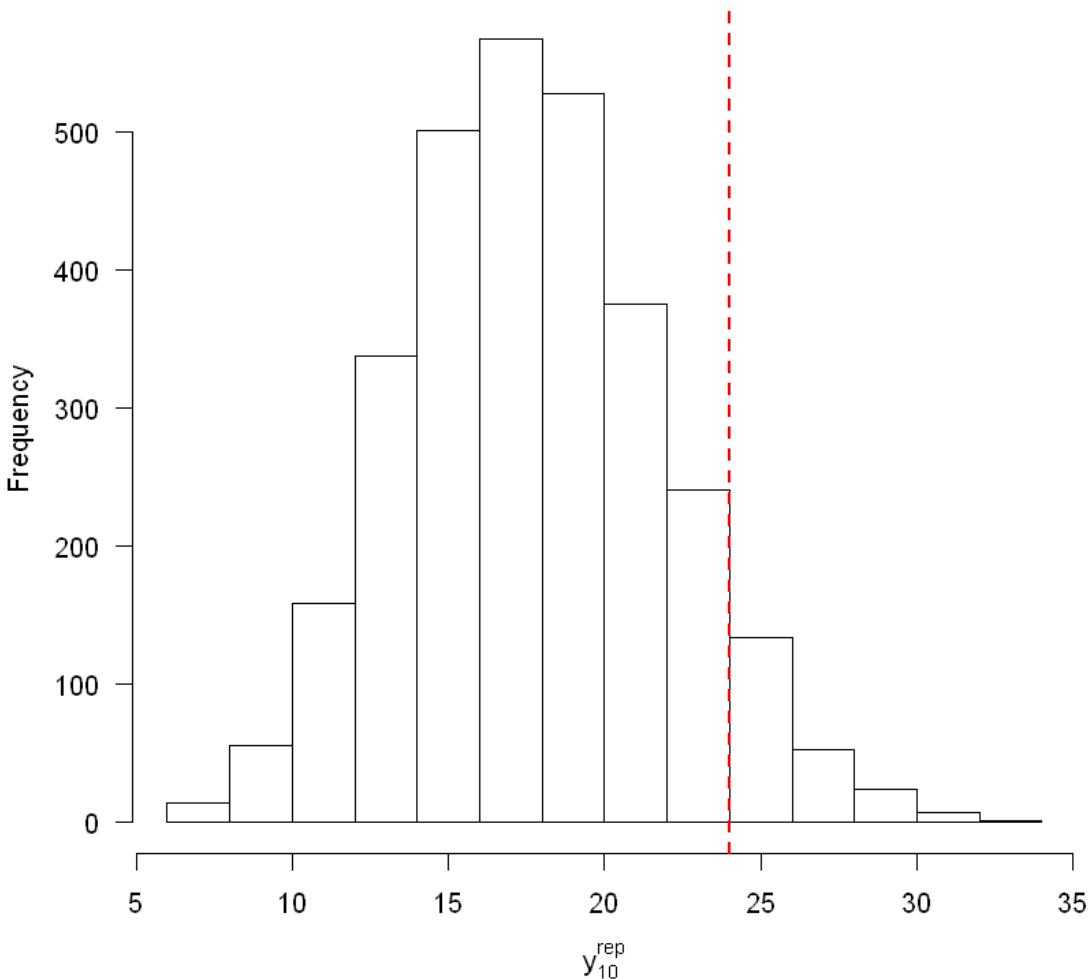
```
In [13]: y_rep_poisson_1 <- y_rep_1  
dim(y_rep_poisson_1)
```

```
3000 1269
```

Cet objet est une matrice de 3000 lignes et 1269 colonnes, soit une colonne pour chaque donnée et une ligne pour chaque itération.

```
In [14]: hist(y_rep_poisson_1[, 10], las = 1, xlab = quote(y[10]^rep), main = "PPC for the  
tenth datum")  
abline(v = obs$nombreShift[10], lty = 2, col = "red", lwd = 2)
```

PPC for the tenth datum



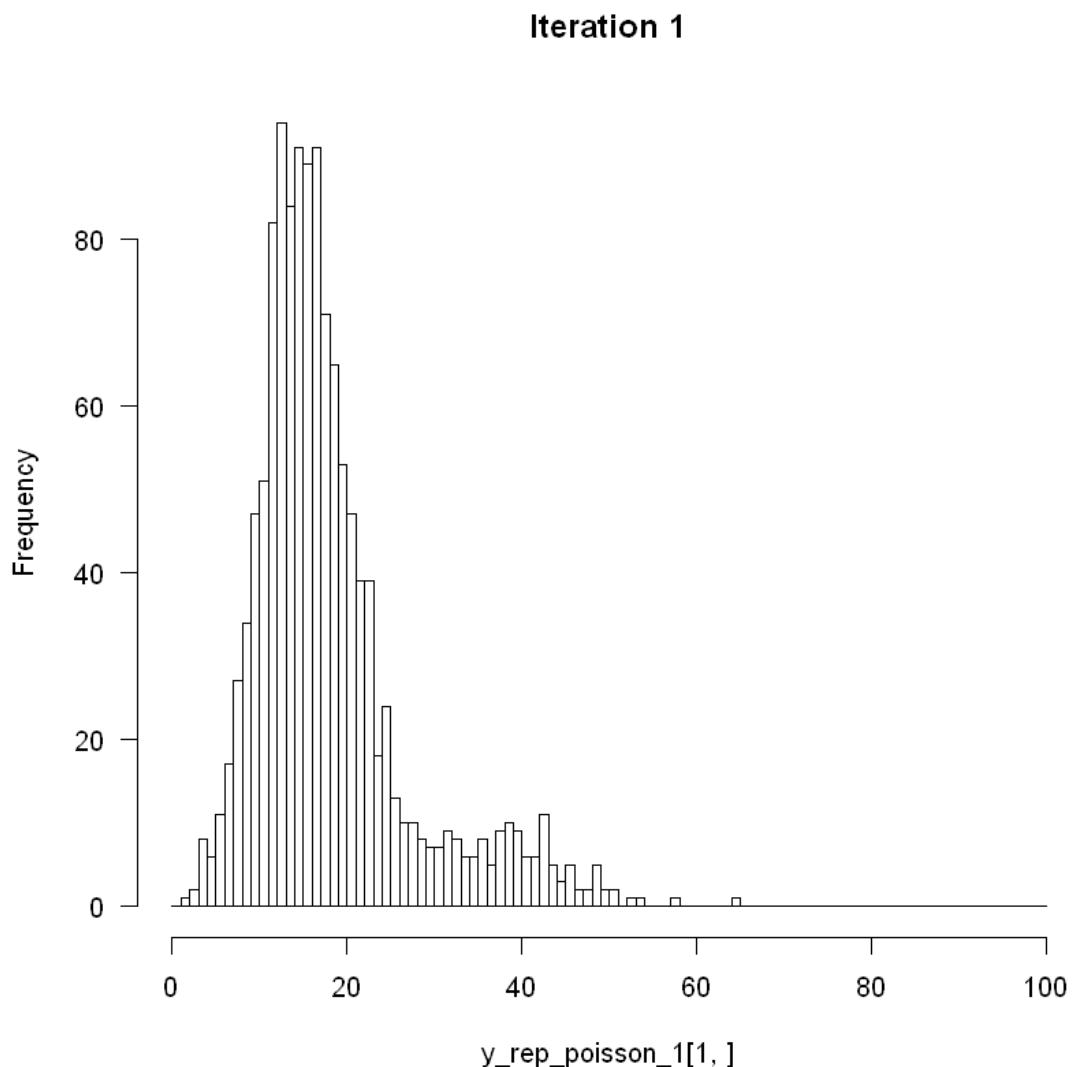
On peut par exemple calculer la probabilité $Pr(y_{10}^{\text{rep}} > y_{10}^{\text{obs}})$

```
In [15]: round(mean(ifelse(y_rep_poisson_1[, 10] > (obs$nombreShift[10]), 1, 0)), dig=3)
```

```
0.073
```

On peut aussi comparer les histogrammes de l'ensemble des données (observées et prédictes) au lieu de regarder donnée par donnée.

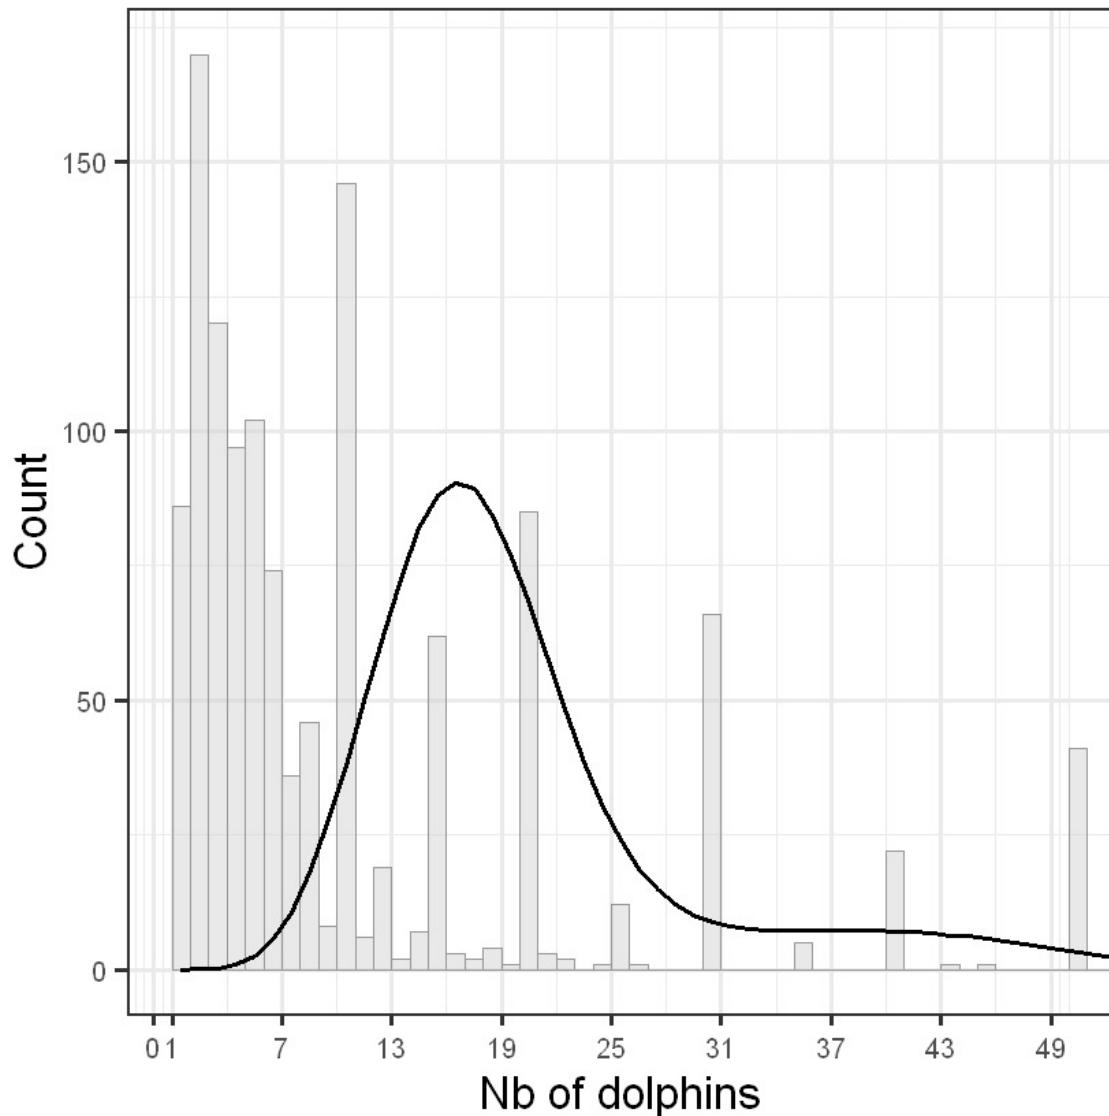
```
In [16]: hist(y_rep_poisson_1[1, ], las = 1, main = "Iteration 1", breaks = c(0:100))
```



On va moyenner l'histogramme sur l'ensemble des itérations en faisant appel à une fonction

```
In [17]: # rootograms
rootogram <- function(countdata, y_rep, min_obs = 1) {
  f_histogram <- function(x, max_obs) { table(factor(x, levels = min_obs:max_obs)) }
  max_obs <- max(countdata, as.numeric(y_rep))
  dd <- ggplot(data.frame(mids = (min_obs:max_obs + (min_obs + 1):(max_obs + 1))/2,
                           y_obs = as.numeric(f_histogram(x = countdata, max_obs = max_obs)),
                           y_rep = apply(apply(y_rep, 1, f_histogram, max_obs = max_obs), 1, mean)),
                aes(x = mids, y = y_rep))
  ) +
  geom_rect(aes(xmin = mids - 0.5, xmax = mids + 0.5,
                 ymax = y_obs, ymin = 0),
            fill = "lightgrey", color = grey(0.6), alpha = 0.5) +
  geom_line(aes(x = mids, y = y_rep), color = "black", size = 1.0) +
  scale_y_continuous(name = "Count") +
  scale_x_continuous(name = "Nb of dolphins", breaks = c(0, seq(1, max_obs, max_obs/50))) +
  guides(size = "none") +
  theme(plot.title = element_text(lineheight = 0.8, face = "bold"),
        axis.text = element_text(size = 12),
        strip.text = element_text(size = 12),
        strip.background = element_rect(fill = grey(0.95)))
  )
  return(dd)
}

rootogram_model_1 <- rootogram(countdata = obs$nombre, y_rep = y_rep_1+1)
rootogram_model_1 +
  coord_cartesian(xlim = c(1, 50))
```

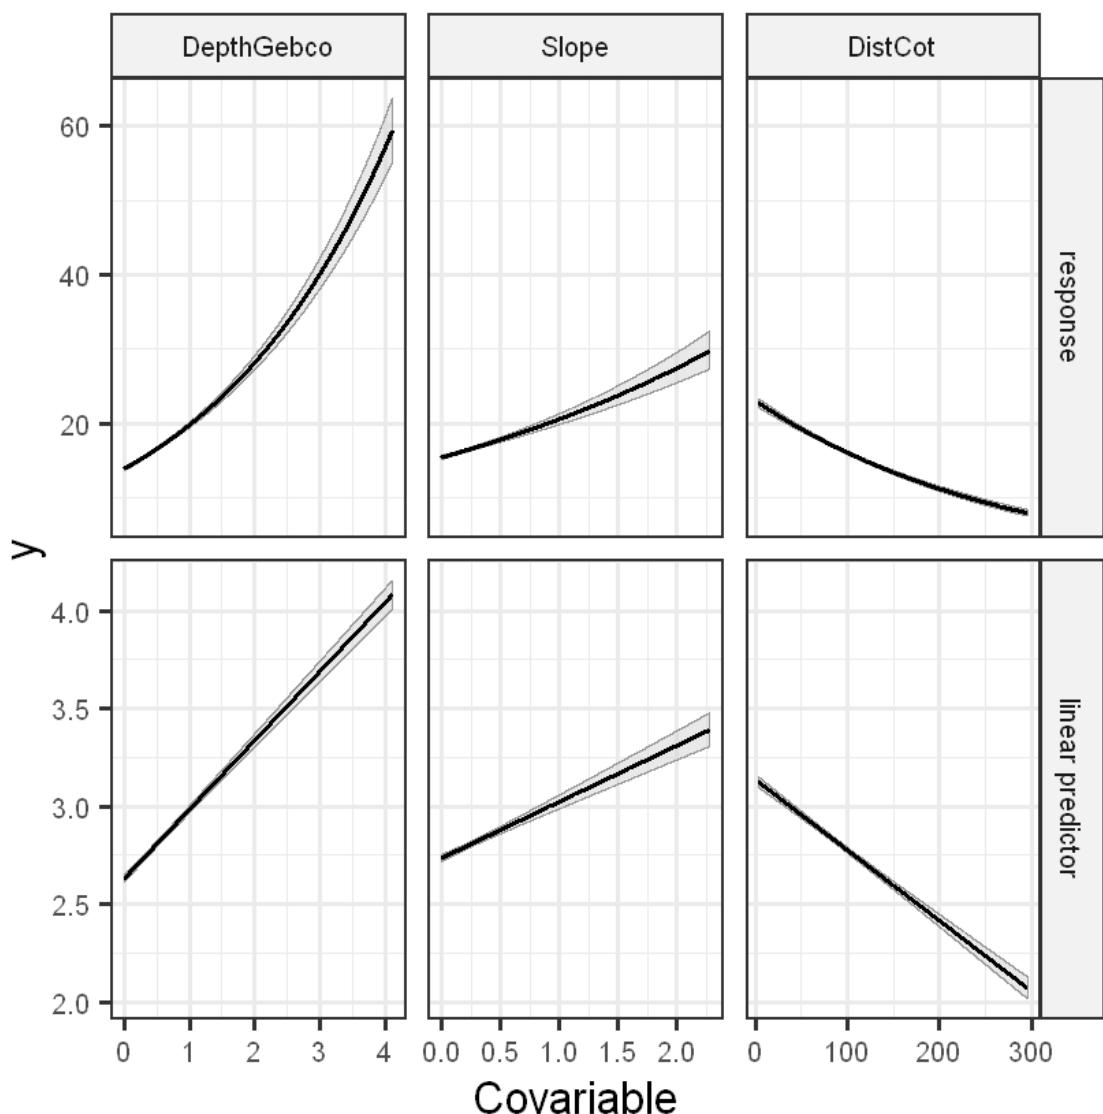


Un ajustement très (trop?) optimiste quant aux incertitudes

Nous allons reconstruire les effets des prédicteurs avec les gammes d'incertitude issues de la connaissance a posteriori des paramètres. *Trop beau pour être honnête?*

```
In [18]: plot_relationships <- function(data_df, jagsfit, cov_name) {
  X <- data_df[, cov_name]
  x_scale <- apply(X, 2, function(x) {c(mean(x), sd(x))})
  x_range <- apply(apply(X, 2, scale), 2, range)
  stdX <- cbind(rep(1, 1e4),
                apply(x_range, 2, function(vec) {seq(vec[1], vec[2], length.out
= 1e4)}))
  )
  beta <- cbind(jagsfit$sims.list$intercept,
                 jagsfit$sims.list$slope
                 )
  if(ncol(stdX) != ncol(beta)) { stop("Please check model and covariate names:\\
n\\tdimension mismatch between slope parameters and covariates") }
  else {
    dd <- data.frame(x = numeric(0),
                      y = numeric(0),
                      lower = numeric(0),
                      upper = numeric(0),
                      what = character(0),
                      covariate = character(0)
                      )
    for(j in 1:length(cov_name)) {
      Xmat <- cbind(rep(1, 1e4),
                     matrix(0, nrow = 1e4, ncol = length(cov_name)))
      )
      Xmat[, j+1] <- stdX[, j+1]
      linpred <- beta %*% t(Xmat)
      dd <- rbind(dd,
                  data.frame(x = Xmat[, j+1] * x_scale[2, cov_name[j]] + x_scale
[1, cov_name[j]],
                  y = apply(linpred, 2, mean),
                  lower = apply(linpred, 2, stats::quantile, prob = 0
.025),
                  upper = apply(linpred, 2, stats::quantile, prob = 0
.975),
                  what = rep("linear predictor", 1e4),
                  covariate = rep(cov_name[j], 1e4)
                  ),
                  data.frame(x = Xmat[, j+1] * x_scale[2, cov_name[j]] + x_scale
[1, cov_name[j]],
                  y = apply(exp(linpred), 2, mean),
                  lower = apply(exp(linpred), 2, stats::quantile, pro
b = 0.025),
                  upper = apply(exp(linpred), 2, stats::quantile, pro
b = 0.975),
                  what = rep("response", 1e4),
                  covariate = rep(cov_name[j], 1e4)
                  )
                  )
    }
    dd$what <- factor(as.character(dd$what), levels = c("response", "linear pred
ictor"))
    dd$covariate <- factor(as.character(dd$covariate), levels = cov_name)

    the_plot <- ggplot(data = dd,
                         aes(x = x, y = y)
                         ) +
      geom_ribbon(aes(x = x, ymin = lower, ymax = upper),
                  fill = "lightgrey", color = grey(0.6), alpha = 0.5
                  ) +
      geom_line(aes(x = x, y = y), color = "black", size = 1.0) +
      scale_y_continuous(name = "y") +
      scale_x_continuous(name = "Covariate") +
      facet_grid(what~covariate, scales = "free") +
      theme(plot.title = element_text(lineheight = 0.8, face = "bold"),
            axis.text = element_text(size = 12),
            strip.text = element_text(size = 12),
            strip.background = element_rect(fill = grey(0.95)))
      '
  }
}
```



Travaux dirigés R

- Retour à la définition: Construire une fonction qui calcule le WAIC à la main à partir d'une matrice comme `log_lik1`. Soit θ le vecteur des paramètres inconnus d'un modèle d'observations $f(\cdot | \theta)$. Soit (y_1, \dots, y_n) un échantillon de réalisations de $f(\cdot | \theta)$. Soit $(\theta^1, \dots, \theta^S)$ un échantillon de valeurs issues de la loi a posteriori jointe de θ et générées à l'aide d'un algorithme MCMC. Le critère d'information WAIC (Watanabe-Akaike ou Widely Applicable Information Criterion) du modèle peut alors être approximé (voir Bayesian Data Analysis, Gelman et al., 2016) en remplaçant les espérances *a posteriori* par des sommes sur les tirages dans le posterior:

$$WAIC = -2\hat{llpd} + 2p_{WAIC}$$

avec

$$\hat{llpd} = \sum_{i=1}^n \log \left(\frac{1}{S} \sum_{s=1}^S f(y_i | \theta^s) \right)$$

et

$$p_{WAIC} = \sum_{i=1}^n V_{s=1}^S (\log f(y_i | \theta^s))$$

$$V_{s=1}^S(a_s) = \frac{1}{S-1} \sum_{s=1}^S (a_s - \bar{a})^2, \bar{a} = \frac{1}{S} \sum_{s=1}^S a_s.$$

- On pourra également y ajouter le DIC comme sortie (qu'on comparera aux résultats de la fonction `dic.samples` de `rjags`).
- Faire un modèle à 2 covariables sous Jags (par exemple, supprimer la distance à la côte).
- Est-ce que ce nouveau modèle est meilleur que le précédent? On pourra utiliser le critère WAIC pour faire une comparaison de modèle.
- Les critères DIC et WAIC mènent-ils aux mêmes conclusions? Quel(s) avantage(s) voyez-vous à l'utilisation du critère WAIC par rapport au critère DIC?

Pour aller plus loin: Les modèles fonctionnent mais l'ajustement est atroce, que faire?

Ici, nous avons un problème d'ajustement sérieux des modèles envisagés aux données. Le problème provient en fait d'une hypothèse implicite lorsque l'on utilise un modèle poissonien: l'équidispersion. Cela signifie que moyenne et variance sont égale. Cependant, le cas général est plutôt d'avoir des données surdispersées, c'est-à-dire des données dont la variance est supérieure à la moyenne. Cette surdispersion peut être le reflet de différents processus, par exemple une structure spatiale non prise en compte par les covariables, etc.

Ici, nous allons modifier le modèle pour ne plus supposer une vraisemblance poissonienne pour les données, mais une vraisemblance Negative Binomiale:

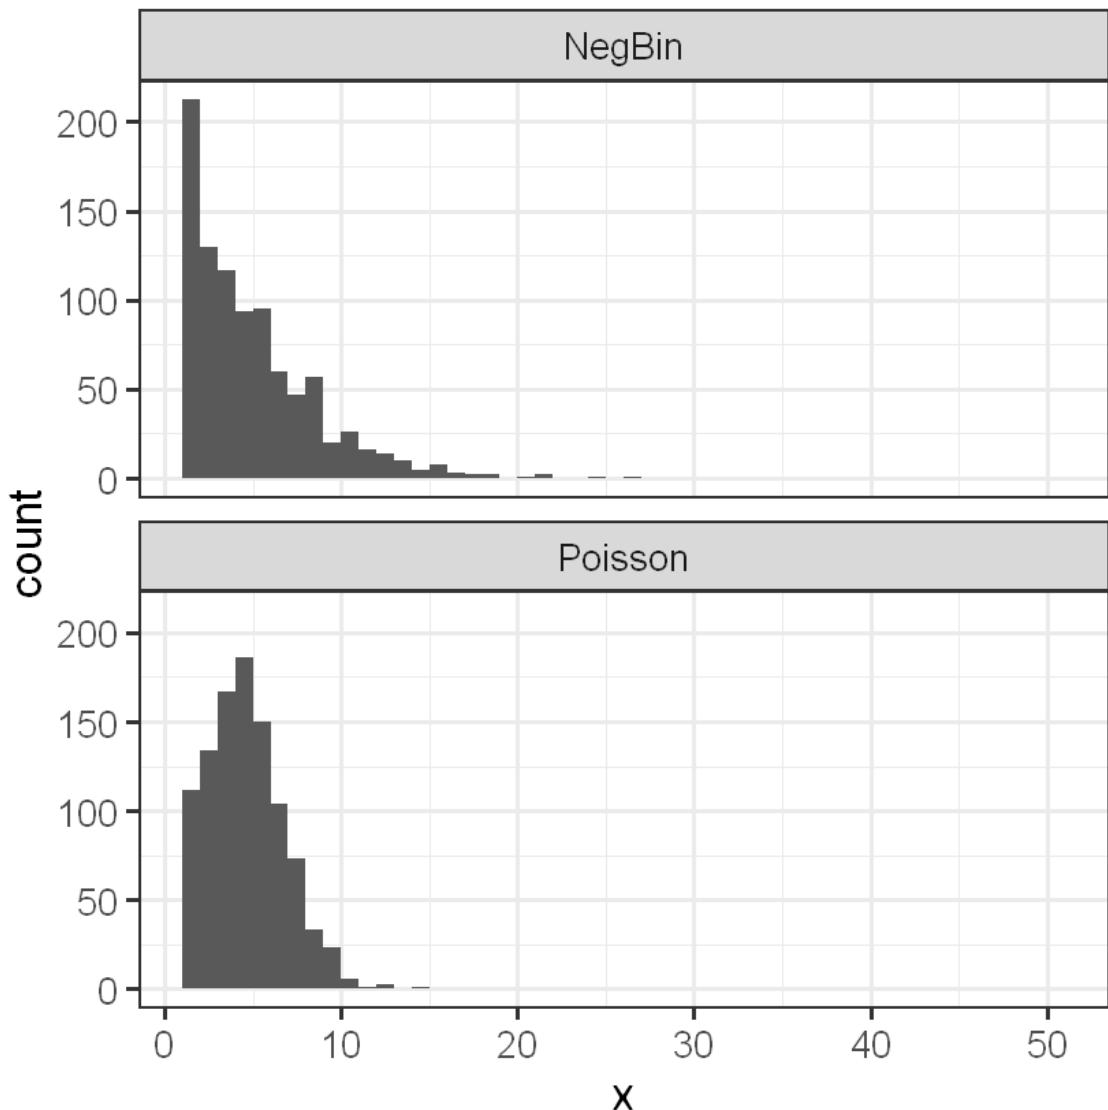
$$y_i^{\text{obs}} \sim \mathcal{NB}(\omega, \lambda_i)$$

où $\omega > 1$ est le paramètre de surdispersion. Il permet de prendre en compte une variance supérieure à la moyenne dans des données de comptages:

$$\mathbb{V}(y) = \omega \mathbb{E}(y)$$

Nous allons simuler quelques données avec R pour regarder la différence entre une distribution Poisson et une distribution Negative Binomiale.

```
In [19]: n <- 1e3 # nombre de données à simuler
lambda <- 5 # moyenne du processus
omega <- 3 # paramètre de surdispersion
ggplot(data = data.frame(x = c(rpois(n, lambda),
                                MASS::rnegbin(n, mu = lambda, theta = lambda/(omega - 1))),
                           ),
       distribution = rep(c("Poisson", "NegBin"), each = n),
       ),
       aes(x = x, group = distribution)
     ) +
geom_histogram(breaks = seq(0:50)) +
facet_wrap(~distribution, ncol = 1)
```



Negative Binomiale et Poisson

La fonction de densité de probabilité d'une variable aléatoire y qui suit une loi de Poisson d'intensité $\lambda (> 0)$ est donnée par :

$$p(y|\lambda) = \frac{e^{\lambda}\lambda^y}{y!}$$

La moyenne de y est égale à la variance : $\mathbb{V}(y) = \mathbb{E}(y) = \lambda$

La fonction de densité de probabilité d'une variable aléatoire y qui suit une loi Negative Binomiale d'intensité $\lambda (> 0)$ et de paramètre de surdispersion $\omega (> 0)$ est donnée par :

$$p(y|\lambda, \omega) = \binom{y + \frac{\lambda}{\omega-1} - 1}{y} \left(\frac{1}{\omega}\right)^{\frac{\lambda}{\omega-1}} \left(1 - \frac{1}{\omega}\right)^y$$

La distribution Negative binomiale peut aussi être vue comme une généralisation de la Poisson avec une intensité qui est elle-même une variable aléatoire suivant une loi Gamma de paramètre de forme $\frac{\lambda}{\omega-1}$ et de paramètre de taux $\frac{1}{\omega-1}$. Cette caractérisation permet d'écrire facilement un modèle sous Jags ou Bugs.

Voir aussi https://www.johndcook.com/negative_binomial.pdf (https://www.johndcook.com/negative_binomial.pdf) pour les différentes paramétrisations possibles.

Pour modifier la distribution dans le code Jags il va falloir faire quelques changements. En particulier, il faut spécifier un prior pour ω .

La paramètre de surdispersion est compris entre 1 et $+\infty$. On va ici mettre un prior uniforme entre 0 et 1 sur l'inverse du paramètre de surdispersion :

$$p\left(\frac{1}{\omega}\right) \propto 1$$

Il faut également modifier le calcul de la vraisemblance. La paramétrisation la plus prisée par les écologistes utilise un paramètre $\phi = \lambda\omega - 1$.

Nota: Ce modèle, plus complexe, nécessite plus de temps pour tourner

```
In [20]: model.jags <- '
model{
  # Prior
  intercept ~ dnorm(0.0, hyperparam_inter)
  slope[1] ~ dnorm(0.0, hyperparam_slope[1])
  slope[2] ~ dnorm(0.0, hyperparam_slope[2])
  slope[3] ~ dnorm(0.0, hyperparam_slope[3])
  inv_overdispersion ~ dunif(0, 1)
  overdispersion <- 1/inv_overdispersion

  # Likelihood
  for (i in 1:n_obs) {
    lambda[i] <- exp(intercept + slope[1] * X1[i] + slope[2] * X2[i] + slope[3]
* X3[i])
    r[i] <- lambda[i] / (overdispersion - 1)
    Y[i] ~ dnegbin(inv_overdispersion, r[i])
  }
}

data.jags <- list(n_obs = nrow(obs),
                  Y = obs$nombreShift,
                  X1 = as.vector(scale(obs$DepthGebco)),
                  X2 = as.vector(scale(obs$Slope)),
                  X3 = as.vector(scale(obs$DistCot)),
                  hyperparam_inter = 1.0,
                  hyperparam_slope = 1/rep(log(2)/2, 3)^2
)
# Inits function
inits.jags <- function(idchain, glm) {
  list(intercept = rnorm(1, glm$coefficients[1], sqrt(10 * diag(vcov(glm)))[1]),
       slope = rnorm(3, glm$coefficients[2:4], sqrt(10 * diag(vcov(glm)))[2:4]),
       inv_overdispersion = runif(1, 0, 1)
  )
}

params.jags <- c("intercept", "slope", "overdispersion")

# Start Gibbs sampler
temp <- jags(data = data.jags,
              inits = lapply(1:nc, inits.jags, glm = dauphin2.glm),
              param = params.jags,
              model.file = textConnection(model.jags),
              n.chains = nc,
              n.burnin = nb,
              n.iter = ni,
              n.thin = nt
)

out3 = temp$BUGSoutput
# Inferences
# After Burn in period let's work inference assuming ergodic regime is reached
print(out3$summary, dig = 2)
```

```

Compiling model graph
  Resolving undeclared variables
  Allocating nodes
Graph information:
  Observed stochastic nodes: 1269
  Unobserved stochastic nodes: 5
  Total graph size: 10501

```

Initializing model

	mean	sd	2.5%	25%	50%	75%	97.5%	Rhat
deviance	8877.892	3.023	8873.925	8875.64	8877.262	8879.594	8885.081	1
intercept	2.498	0.034	2.431	2.47	2.498	2.521	2.563	1
overdispersion	18.069	0.872	16.396	17.48	18.023	18.634	19.819	1
slope[1]	0.143	0.028	0.088	0.12	0.144	0.162	0.196	1
slope[2]	0.124	0.028	0.070	0.11	0.125	0.143	0.177	1
slope[3]	-0.098	0.028	-0.154	-0.12	-0.098	-0.079	-0.044	1
	n.eff							
deviance	1400							
intercept	1600							
overdispersion	1700							
slope[1]	500							
slope[2]	530							
slope[3]	500							

On peut vérifier graphiquement la convergence du modèle.

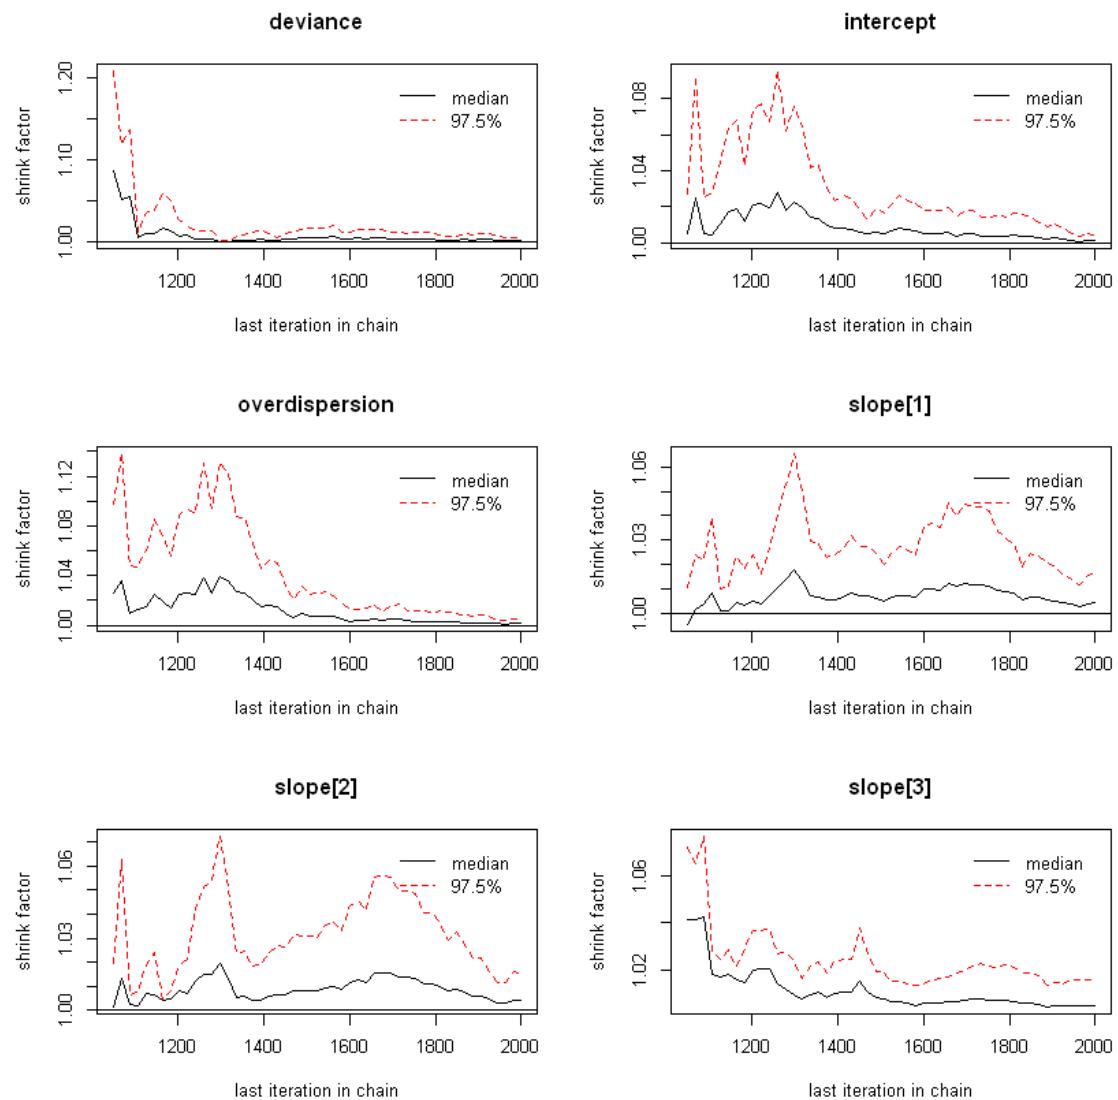
```
In [21]: library(coda)
gelman.diag(x=out3, confidence = 0.95, transform=FALSE, autoburnin=TRUE)
gelman.plot(x=out3)
```

Potential scale reduction factors:

	Point est.	Upper C.I.
deviance	1	1.00
intercept	1	1.00
overdispersion	1	1.00
slope[1]	1	1.02
slope[2]	1	1.02
slope[3]	1	1.02

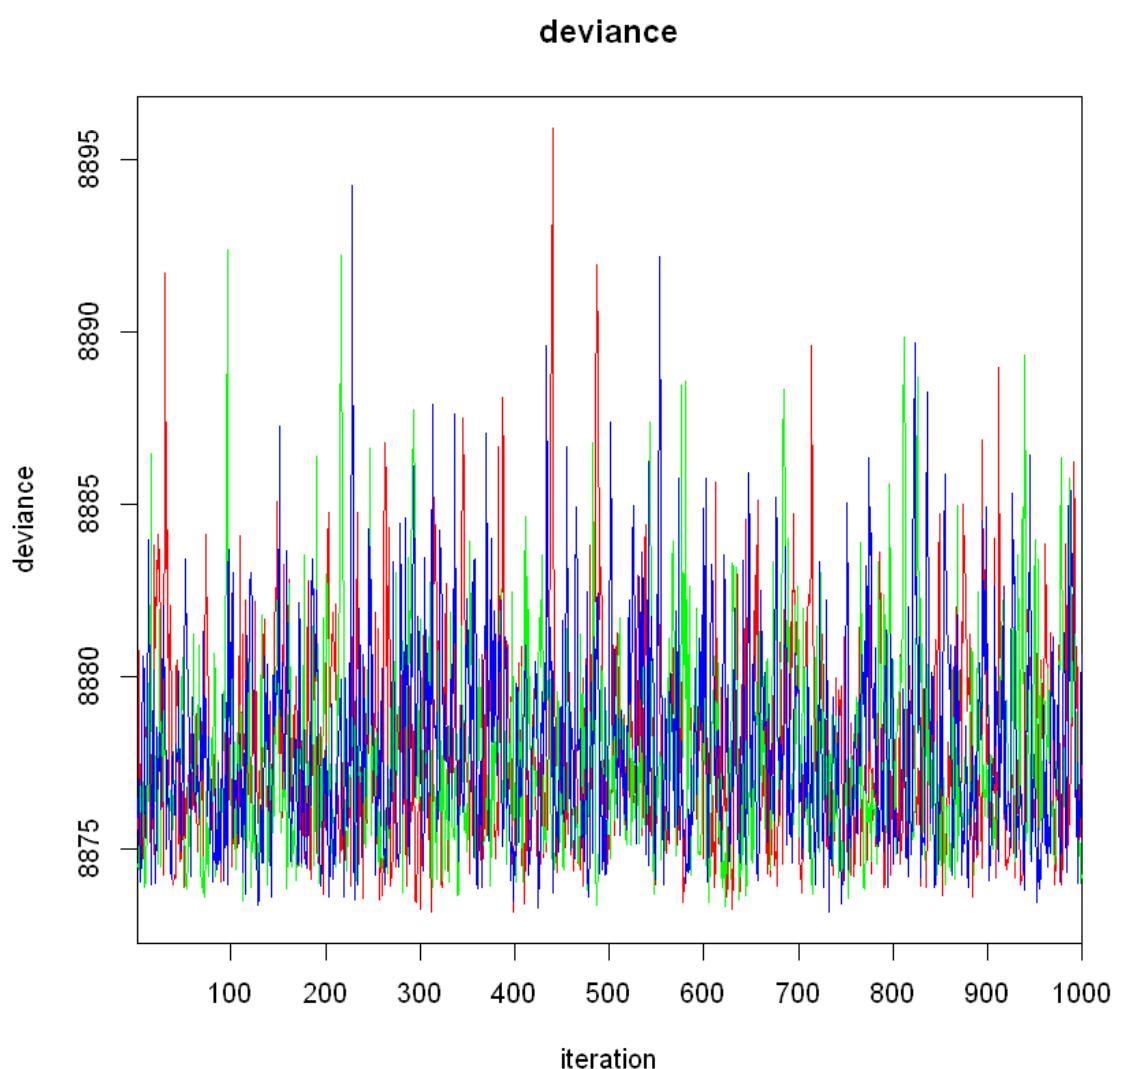
Multivariate psrf

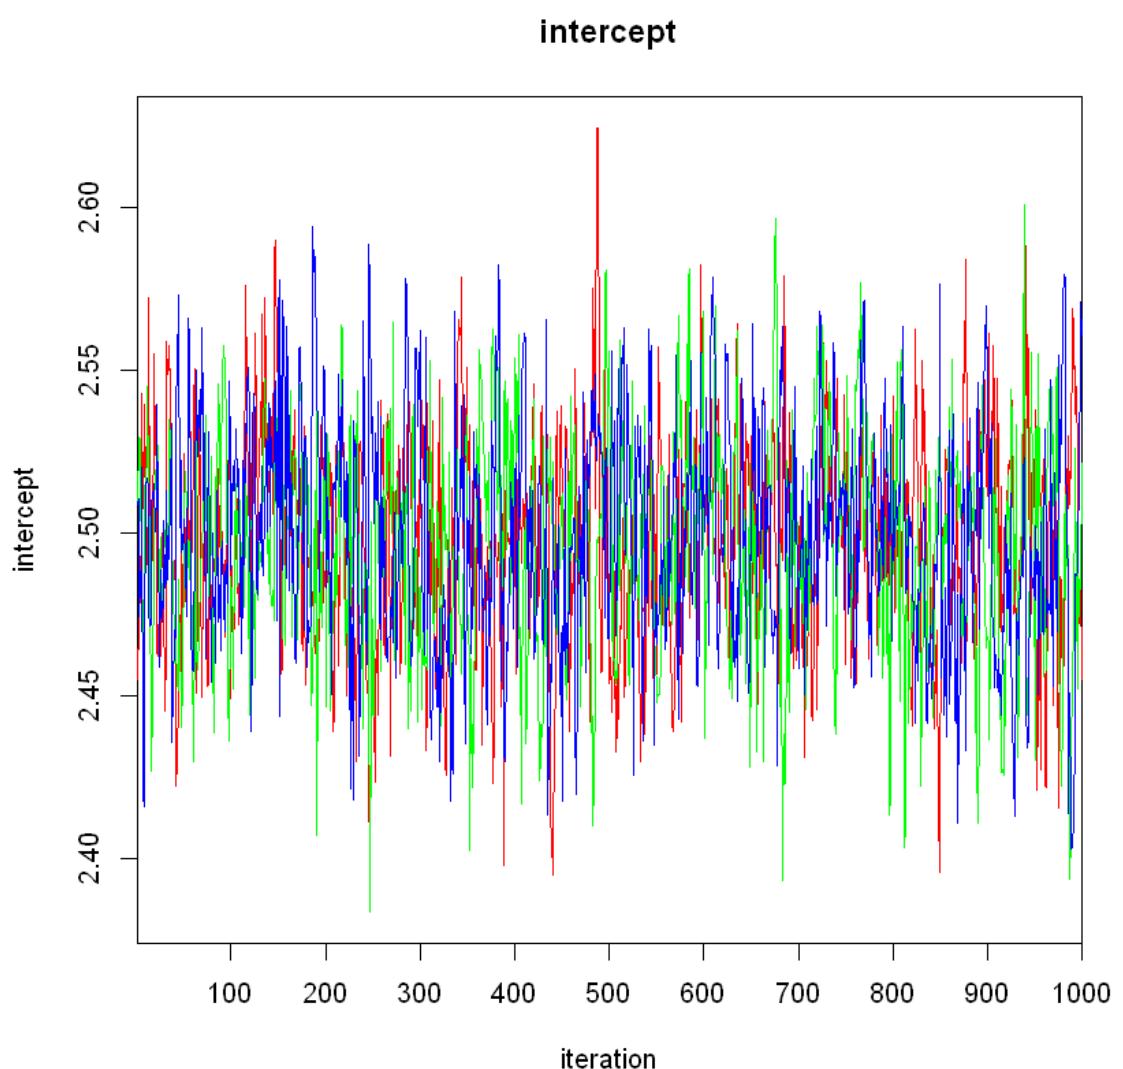
1.01



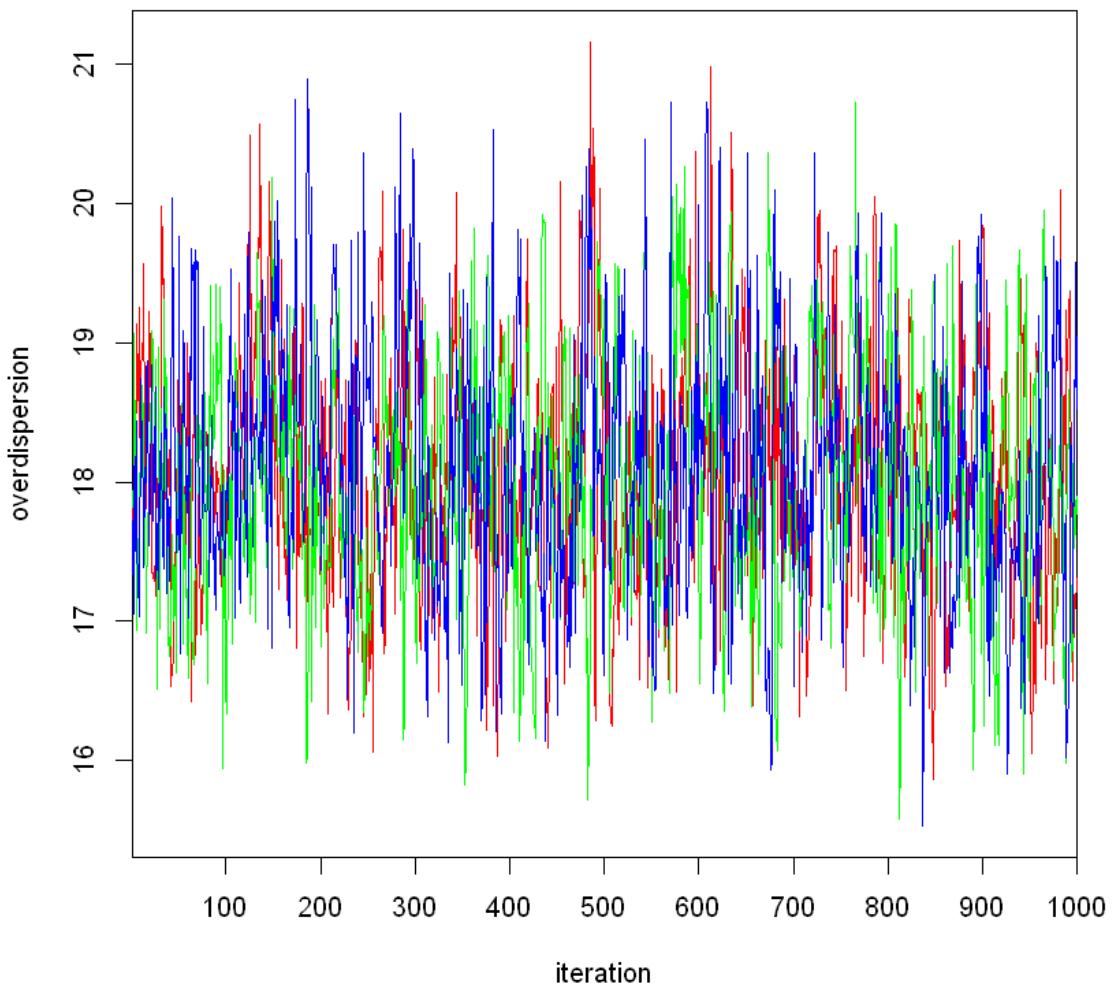
Et la trace des paramètres du modèle :

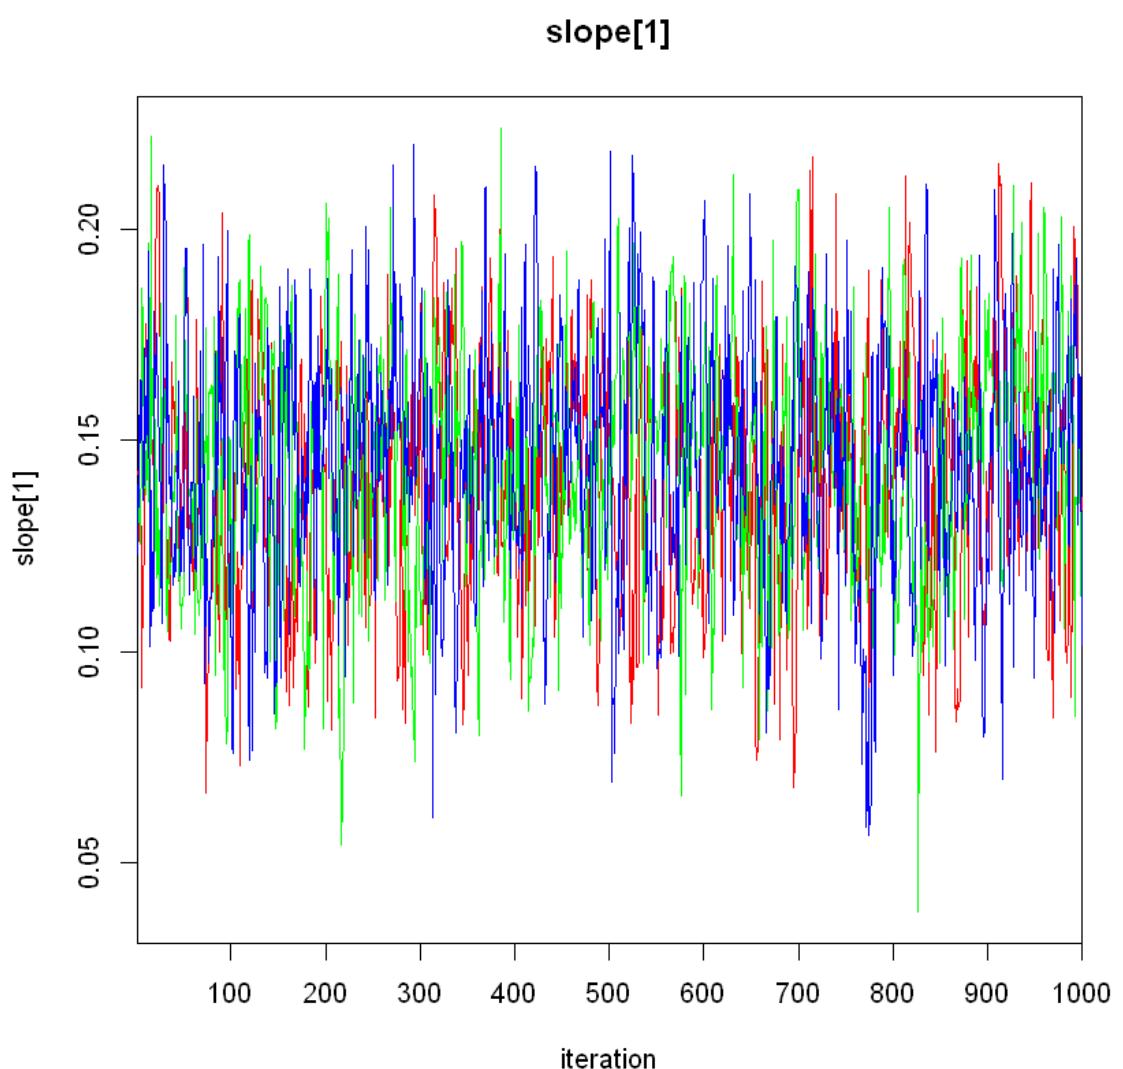
In [22]: `traceplot(out3)`

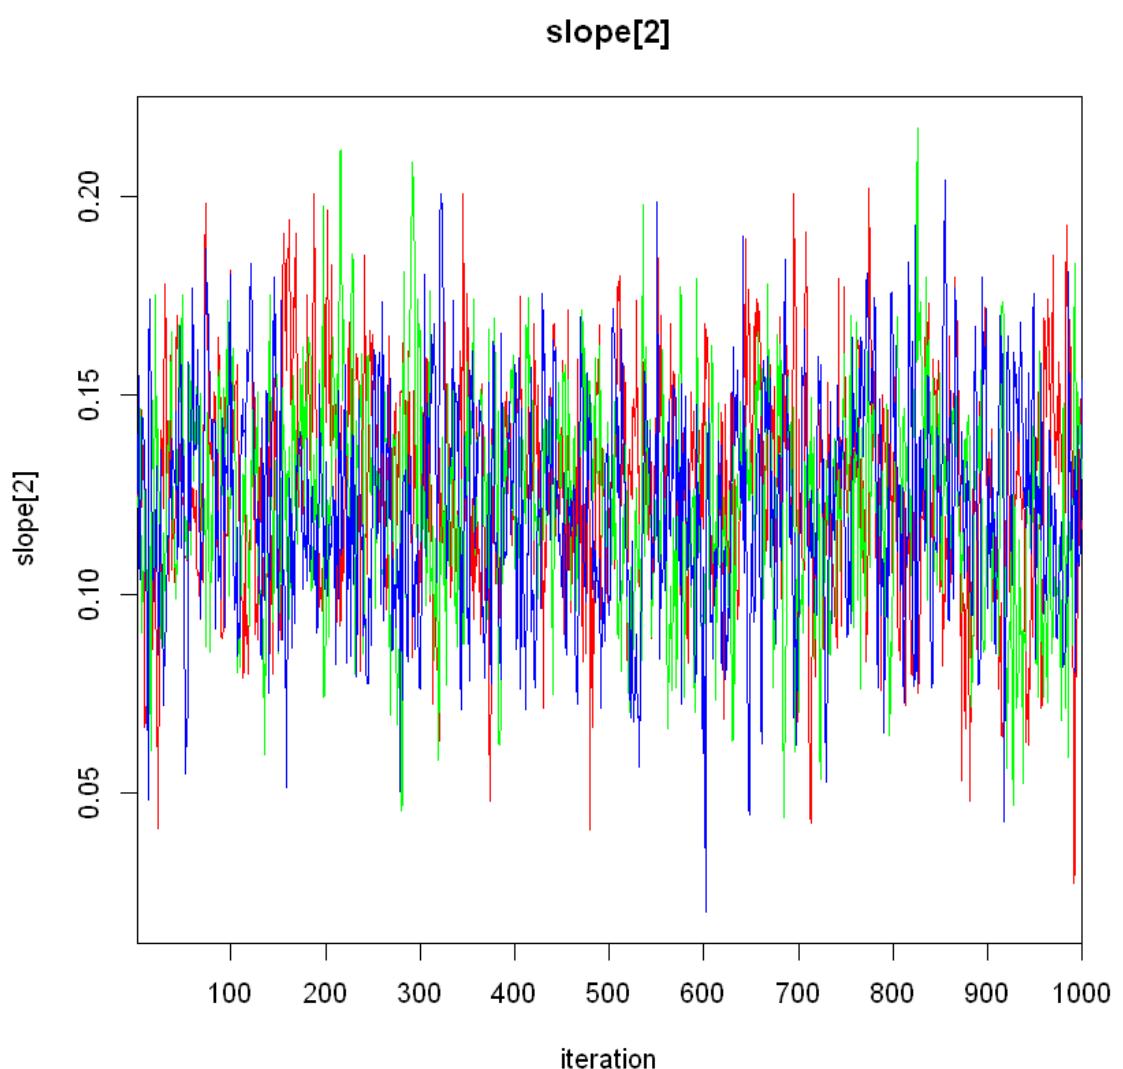


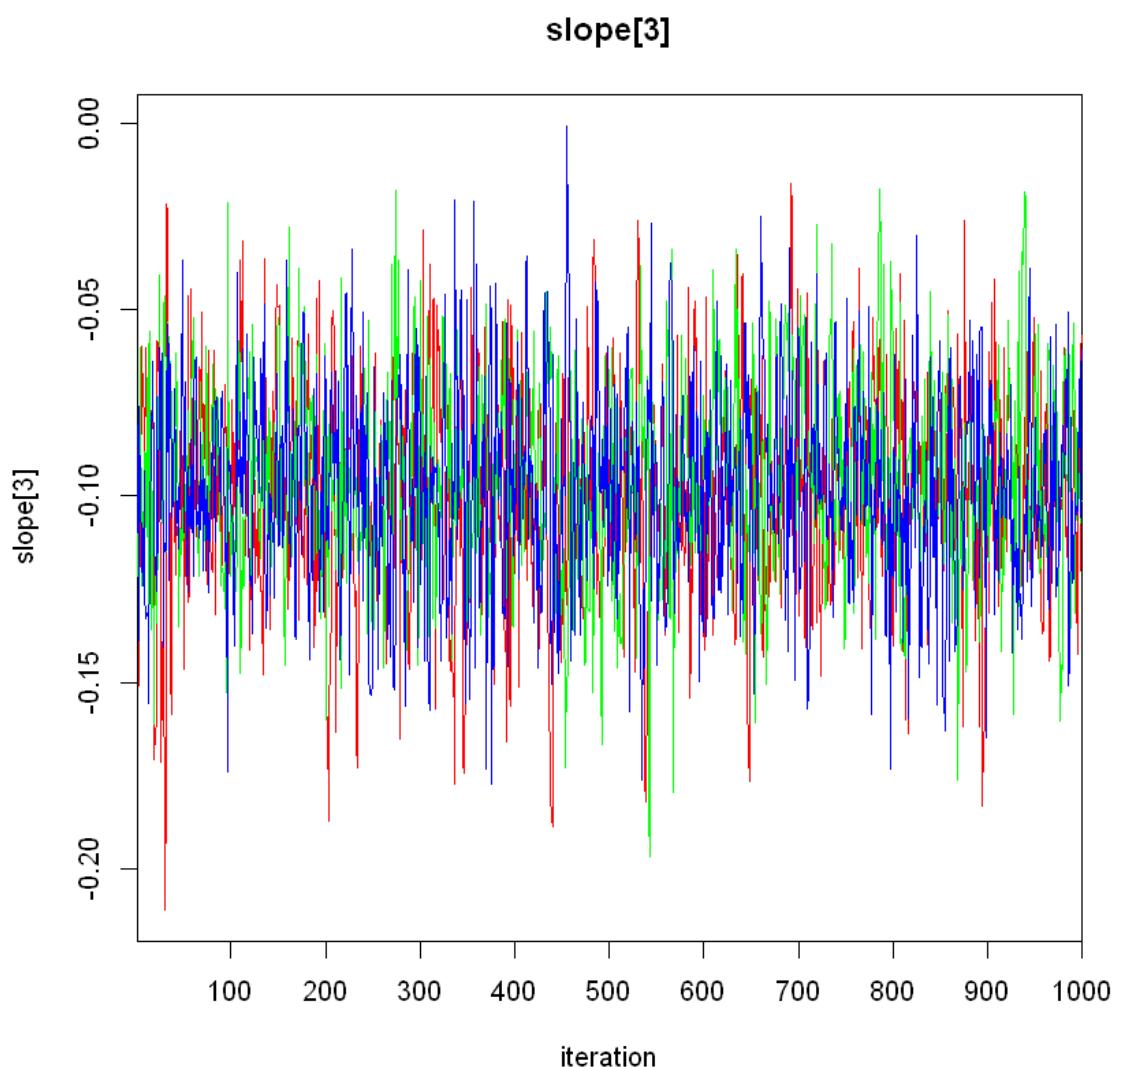


overdispersion









Calcul du critère d'information

Ce résultat est à comparer au modèle poisson sans surdispersion. Se souvenir que pour ces critères : *the lower, the better*

```
In [23]: y_rep_3 <- log_li3 <- array(NA, dim = c(nc * (ni - nb)/nt, nrow(obs)))

for(i in 1:nrow(obs)) {
  overdispersion <- drop(out3$sims.list$overdispersion)
  linpred <- out3$sims.list$intercept +
    out3$sims.list$slope[, 1] * data.jags$X1[i] +
    out3$sims.list$slope[, 2] * data.jags$X2[i] +
    out3$sims.list$slope[, 3] * data.jags$X3[i]
  log_li3[, i] <- dnbnom(data.jags$Y[i],
    prob = 1 / overdispersion,
    size = exp(linpred) / (overdispersion - 1),
    log = TRUE)
  y_rep_3[, i] <- rnbinom(nrow(y_rep_3),
    prob = 1 / overdispersion,
    size = exp(linpred) / (overdispersion - 1)
    ) + 1
}; rm(i, linpred, overdispersion)

loo::waic(log_li3)
loo::loo(log_li3)

Warning message:
"1 (0.1%) p_waic estimates greater than 0.4. We recommend trying loo instead."
Warning message:
"1 (0.1%) p_waic estimates greater than 0.4. We recommend trying loo instead.

Computed from 3000 by 1269 log-likelihood matrix

      Estimate      SE
elpd_waic -4442.1  54.2
p_waic       6.2   0.8
waic        8884.2 108.4

Warning message:
"Relative effective sample sizes ('r_eff' argument) not specified.
For models fit with MCMC, the reported PSIS effective sample sizes and
MCSE estimates will be over-optimistic."

Computed from 3000 by 1269 log-likelihood matrix

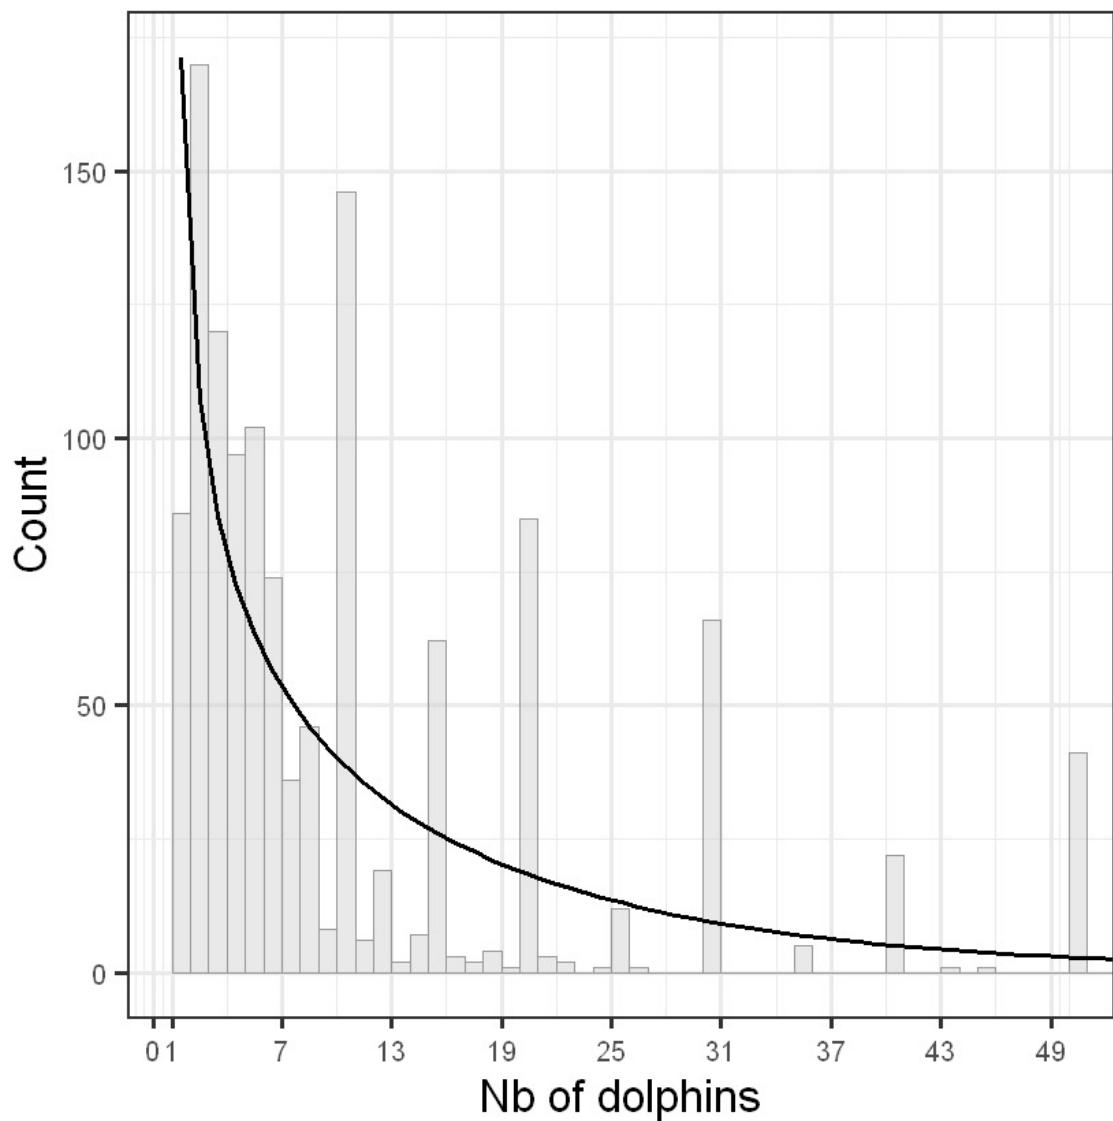
      Estimate      SE
elpd_loo  -4442.1  54.2
p_loo       6.2   0.8
looic       8884.2 108.4
-----
Monte Carlo SE of elpd_loo is 0.0.

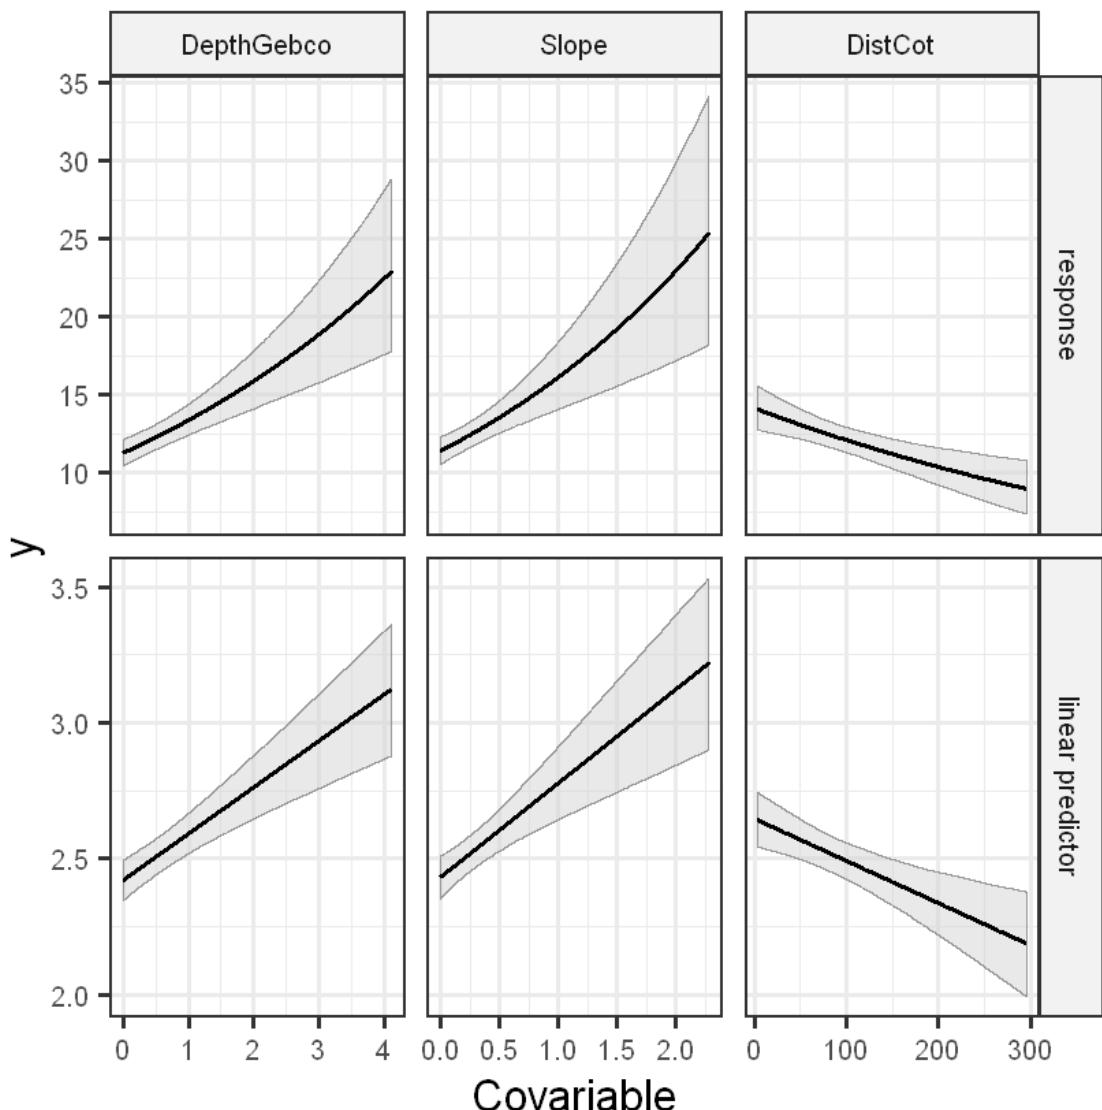
All Pareto k estimates are good (k < 0.5).
See help('pareto-k-diagnostic') for details.
```

Que dire de l'ajustement global du modèle aux données?

```
In [24]: rootogram_model_3 <- rootogram(countdata = obs$nombre, y_rep = y_rep_3)
rootogram_model_3 +
  coord_cartesian(xlim = c(1, 50))

plot_relationships(data_df = obs, jagsfit = out3, cov_name = c("DepthGebco", "Slope",
  "DistCot"))
```





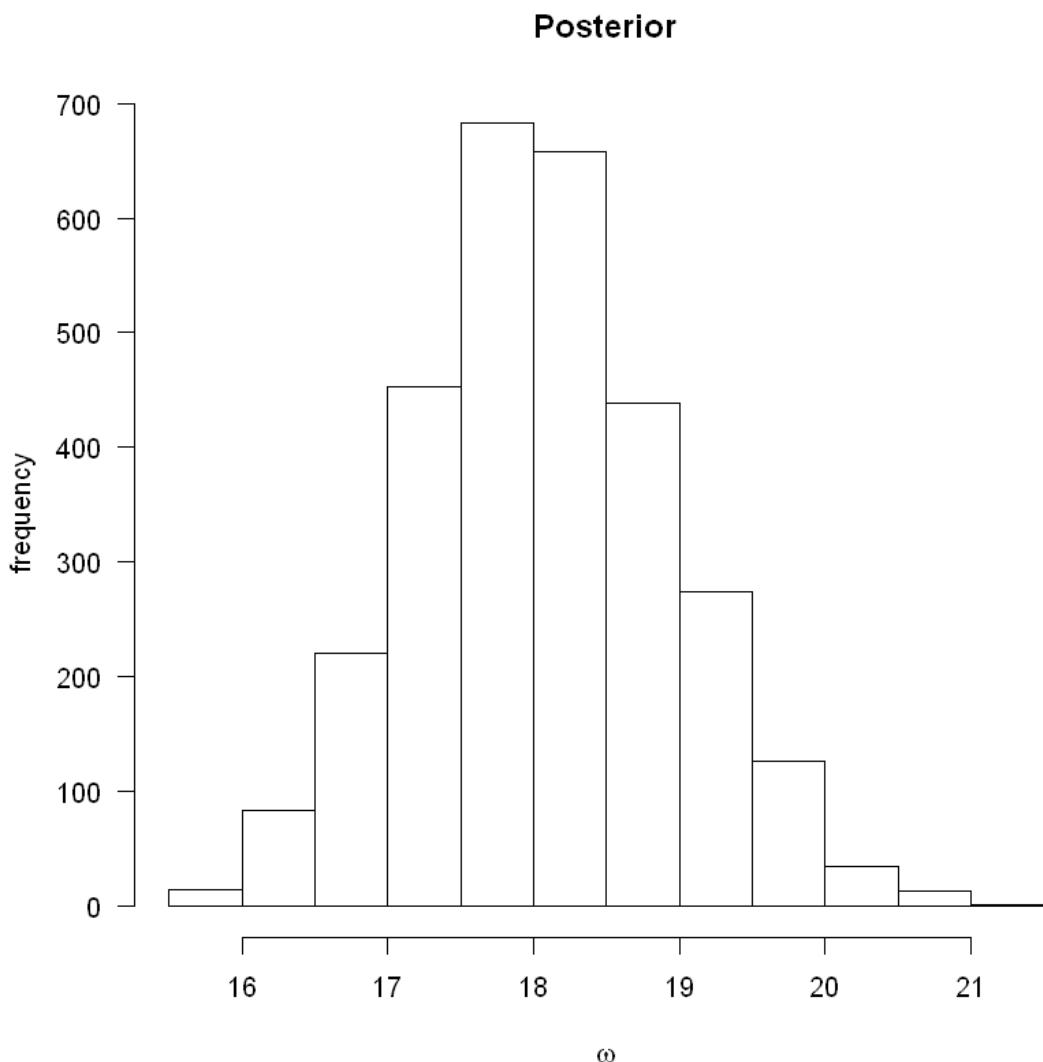
Une première satisfaction

Comme nous le disait le WAIC, l'ajustement est bien meilleur et les zones de crédibilité nous semblent plus réalistes.

- exercice: Est-ce que cela se reflète dans le DIC?
- exercice: tracer les lois a posteriori des inconnues

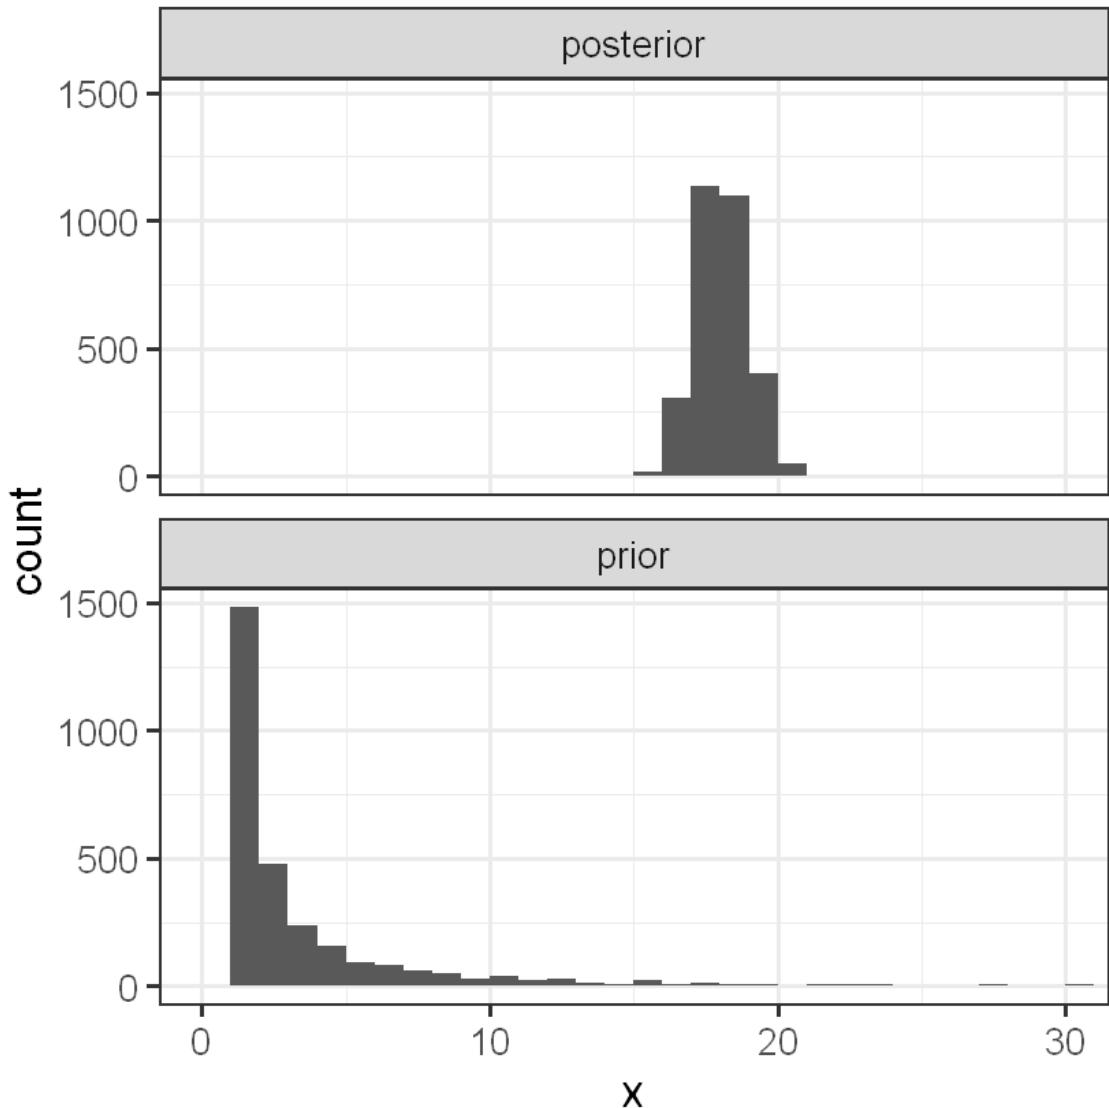
Qu'en est il du paramètres de surdispersion?

```
In [25]: hist(out3$sims.list$overdispersion, las = 1, bty = 'n',
           xlab = quote(omega), ylab = "frequency", main = "Posterior")
```



On peut comparer cette distribution a posteriori à la distribution a priori :

```
In [26]: ggplot(data = data.frame(x = c(1 / runif(length(out3$sims.list$overdispersion),
0.0, 1.0),
out3$sims.list$overdispersion
),
distribution = rep(c("prior", "posterior"), each = length(out3$sims.list$overdispersion))
),
aes(x = x, group = distribution)
) +
geom_histogram(breaks = c(0:100)) +
facet_wrap(~distribution, ncol = 1) +
coord_cartesian(xlim = c(0, 30))
```



Modéliser la surdispersion de manière plus explicite

Il existe plusieurs processus écologiques susceptibles de générer de la surdispersion dans les données de comptage ici, par exemple des structures d'agrégation des proies dont dépendent les dauphins et qui ne seraient que partiellement prises en compte par les covariables, *etc.* On a jusqu'à présent ignoré certaines structures dans les données, notamment le fait que celles-ci correspondent à des années différentes. Or, il est possible que certaines années, pour des raisons que l'on comprend mal, on ait vu plus ou moins de dauphins. En d'autres termes, il est possible qu'il y ait une dépendance temporelle dans les données qui n'a pas été prise en compte.

On va donc tenir compte de cette effet année, et le modéliser en incluant dans le modèle l'année comme effet aléatoire, càd on va supposer que les années sont échangeables : il n'est pas possible *a priori* de classer les années en fonction de l'abondance d'animaux. On va supposer une distribution commune aux effets années, et par convenance on va supposer une distribution normale :

$$\forall t, \text{year}_t \sim \mathcal{N}(0, \sigma_{\text{year}})$$

Le paramètre σ_{year} (> 0) quantifie la variabilité inter-annuelle. On suppose ici que l'effet moyen d'une année prise au hasard est centrée sur 0, mais peut s'écarte de 0 en fonction de ce qui est attendue sous une loi normale d'écart-type σ_{year} . En d'autres termes, en plus d'estimer les paramètres year_t , nous allons estimer l'hyperparamètre σ_{year} qui va gouverner la distribution normale. Il faut donc spécifier des priors pour cet hyperparamètre.

```

In [27]: model.jags <- '
model{
  # Prior
  intercept ~ dnorm(0.0, hyperparam_inter)
  slope[1] ~ dnorm(0.0, hyperparam_slope[1])
  slope[2] ~ dnorm(0.0, hyperparam_slope[2])
  slope[3] ~ dnorm(0.0, hyperparam_slope[3])
  inv_overdispersion ~ dunif(0, 1)
  overdispersion <- 1/inv_overdispersion
  sigma_year ~ dnorm(0.0, 1.0)T(0.0,)
  tau_alpha <- pow(sigma_year, -2)
  for(j in 1:n_year) {
    alpha[j] ~ dnorm(intercept, tau_alpha)
  }

  # Likelihood
  for (i in 1:n_obs) {
    lambda[i] <- exp(alpha[YEAR[i]] + slope[1] * X1[i] + slope[2] * X2[i] + slope[3] * X3[i])
    r[i] <- lambda[i] / (overdispersion - 1)
    Y[i] ~ dnegbin(inv_overdispersion, r[i])
  }
}

data.jags <- list(n_obs = nrow(obs),
                  n_year = length(unique(obs$an)),
                  Y = obs$nombreShift,
                  X1 = as.vector(scale(obs$DepthGebco)),
                  X2 = as.vector(scale(obs$Slope)),
                  X3 = as.vector(scale(obs$DistCot)),
                  YEAR = obs$an - min(obs$an) + 1,
                  hyperparam_inter = 1.0,
                  hyperparam_slope = 1/rep(log(2)/2, 3)^2
                 )

# Inits function
inits.jags <- function(idchain, glm) {
  list(intercept = rnorm(1, glm$coefficients[1], sqrt(10 * diag(vcov(glm)))[1]),
       slope = rnorm(3, glm$coefficients[2:4], sqrt(10 * diag(vcov(glm)))[2:4]),
       inv_overdispersion = runif(1, 0, 1),
       sigma_year = abs(rnorm(1)),
       alpha = rnorm(length(unique(obs$an)))
      )
}

params.jags <- c("intercept", "slope", "overdispersion", "alpha", "sigma_year")

# Start Gibbs sampler
temp <- jags(data = data.jags,
              inits = lapply(1:nc, inits.jags, glm = dauphin2.glm),
              param = params.jags,
              model.file = textConnection(model.jags),
              n.chains = nc,
              n.burnin = nb,
              n.iter = ni,
              n.thin = nt
             )

out4 = temp$BUGSoutput
# Inferences
# After Burn in period let's work inference assuming ergodic regime is reached
print(out4$summary, dig = 2)

```

```

Compiling model graph
Resolving undeclared variables
Allocating nodes
Graph information:
  Observed stochastic nodes: 1269
  Unobserved stochastic nodes: 19
  Total graph size: 11788

```

Initializing model

	mean	sd	2.5%	25%	50%	75%	97.5%	Rha
t								
alpha[1]	2.482	0.224	1.995	2.348	2.493	2.634	2.893	
1								
alpha[2]	2.998	0.189	2.615	2.874	3.004	3.127	3.356	
1								
alpha[3]	2.748	0.188	2.365	2.625	2.753	2.877	3.100	
1								
alpha[4]	2.578	0.248	2.058	2.422	2.587	2.738	3.062	
1								
alpha[5]	2.711	0.099	2.506	2.645	2.713	2.781	2.900	
1								
alpha[6]	2.748	0.092	2.564	2.687	2.749	2.809	2.919	
1								
alpha[7]	2.747	0.066	2.619	2.703	2.749	2.794	2.873	
1								
alpha[8]	2.602	0.084	2.439	2.544	2.604	2.661	2.761	
1								
alpha[9]	2.626	0.068	2.489	2.581	2.628	2.673	2.755	
1								
alpha[10]	2.225	0.089	2.052	2.165	2.225	2.286	2.396	
1								
alpha[11]	2.381	0.091	2.191	2.319	2.383	2.444	2.553	
1								
alpha[12]	2.294	0.111	2.070	2.223	2.297	2.368	2.500	
1								
alpha[13]	2.133	0.065	2.007	2.090	2.132	2.177	2.262	
1								
deviance	8781.529	5.870	8772.066	8777.285	8780.823	8785.192	8794.405	
1								
intercept	2.539	0.098	2.338	2.479	2.541	2.603	2.726	
1								
overdispersion	16.715	0.821	15.208	16.140	16.685	17.267	18.400	
1								
sigma_year	0.308	0.084	0.181	0.247	0.295	0.355	0.501	
1								
slope[1]	0.104	0.030	0.045	0.084	0.104	0.125	0.160	
1								
slope[2]	0.097	0.030	0.034	0.077	0.098	0.118	0.153	
1								
slope[3]	-0.067	0.030	-0.127	-0.087	-0.067	-0.047	-0.011	
1								
	n.eff							
alpha[1]	1200							
alpha[2]	2400							
alpha[3]	3000							
alpha[4]	3000							
alpha[5]	540							
alpha[6]	920							
alpha[7]	2700							
alpha[8]	3000							
alpha[9]	3000							
alpha[10]	2100							
alpha[11]	3000							
alpha[12]	550							
alpha[13]	1300							
deviance	240							
intercept	1900							
overdispersion	800							

On peut également vérifier la convergence des différents paramètres ...

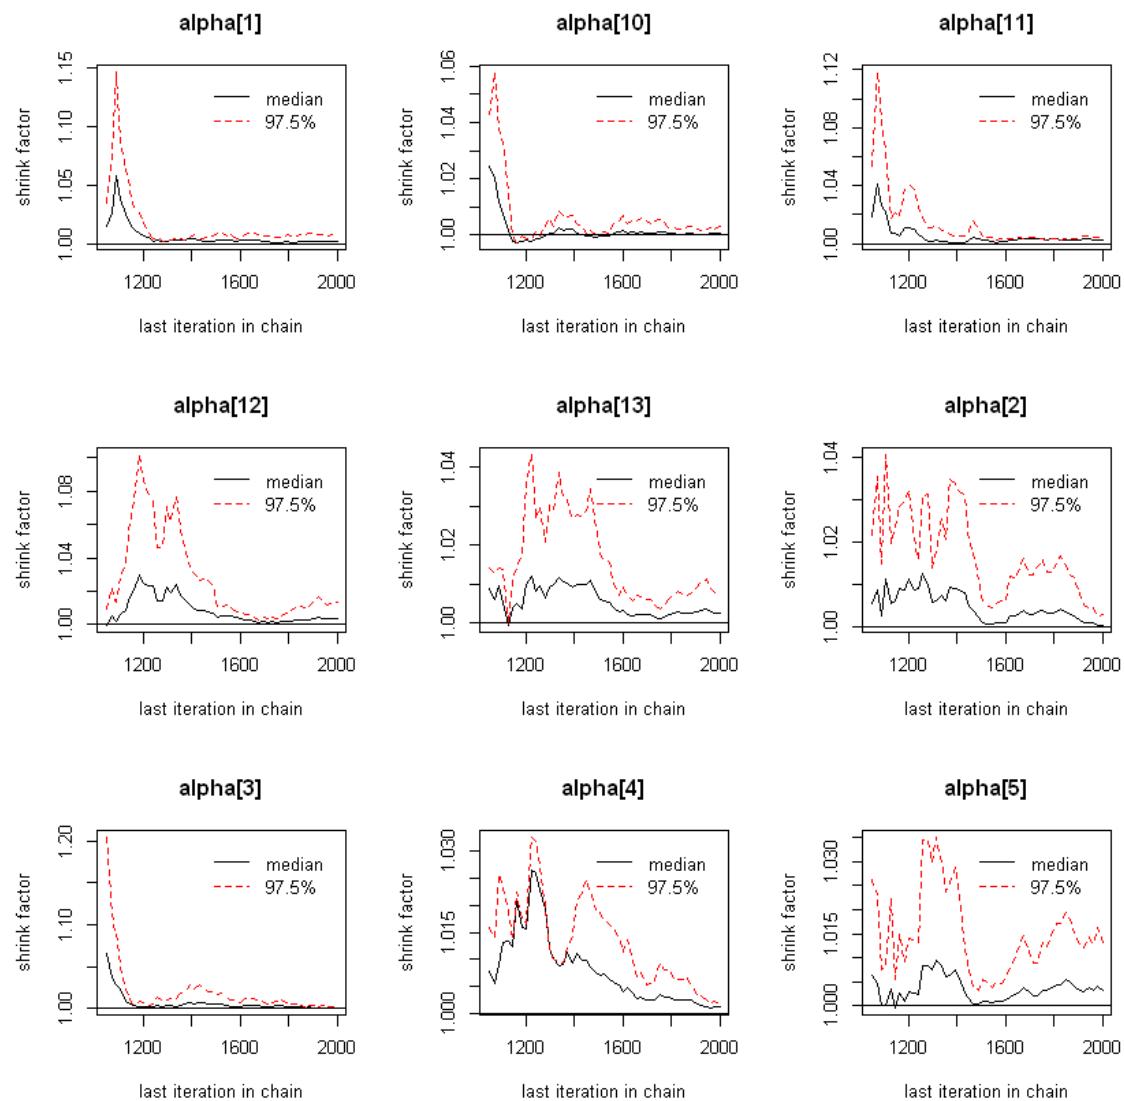
```
In [28]: library(coda)
gelman.diag(x=out4, confidence = 0.95, transform=FALSE, autoburnin=TRUE)
gelman.plot(x=out4)
```

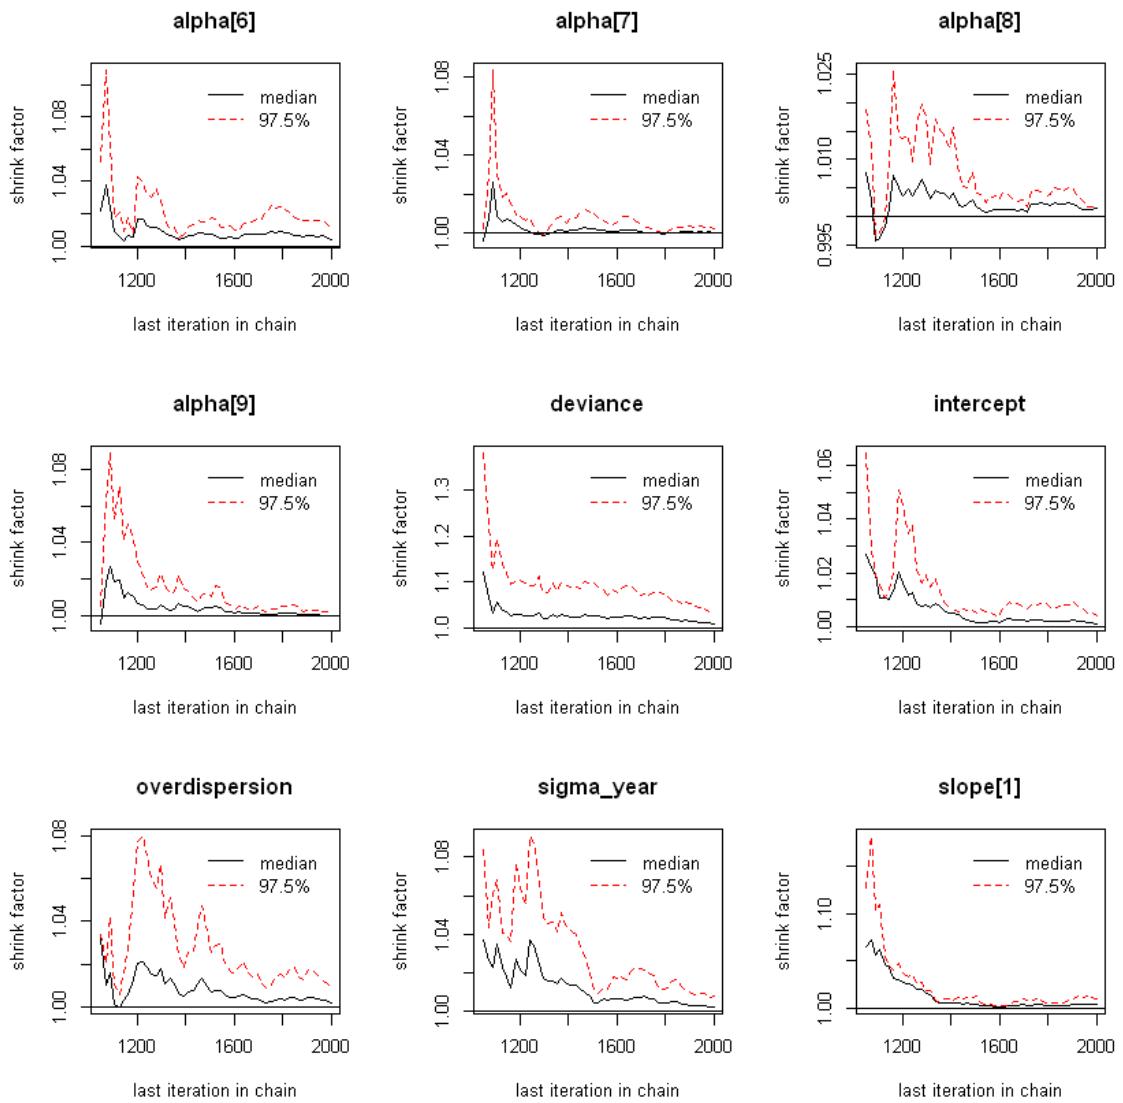
Potential scale reduction factors:

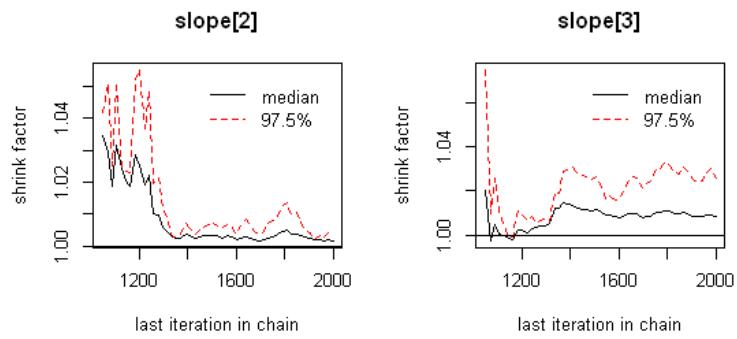
	Point est.	Upper C.I.
alpha[1]	1.00	1.01
alpha[10]	1.00	1.00
alpha[11]	1.00	1.00
alpha[12]	1.00	1.01
alpha[13]	1.00	1.01
alpha[2]	1.00	1.00
alpha[3]	1.00	1.00
alpha[4]	1.00	1.00
alpha[5]	1.00	1.01
alpha[6]	1.00	1.01
alpha[7]	1.00	1.00
alpha[8]	1.00	1.00
alpha[9]	1.00	1.00
deviance	1.01	1.03
intercept	1.00	1.00
overdispersion	1.00	1.01
sigma_year	1.00	1.01
slope[1]	1.00	1.01
slope[2]	1.00	1.00
slope[3]	1.01	1.03

Multivariate psrf

1.02

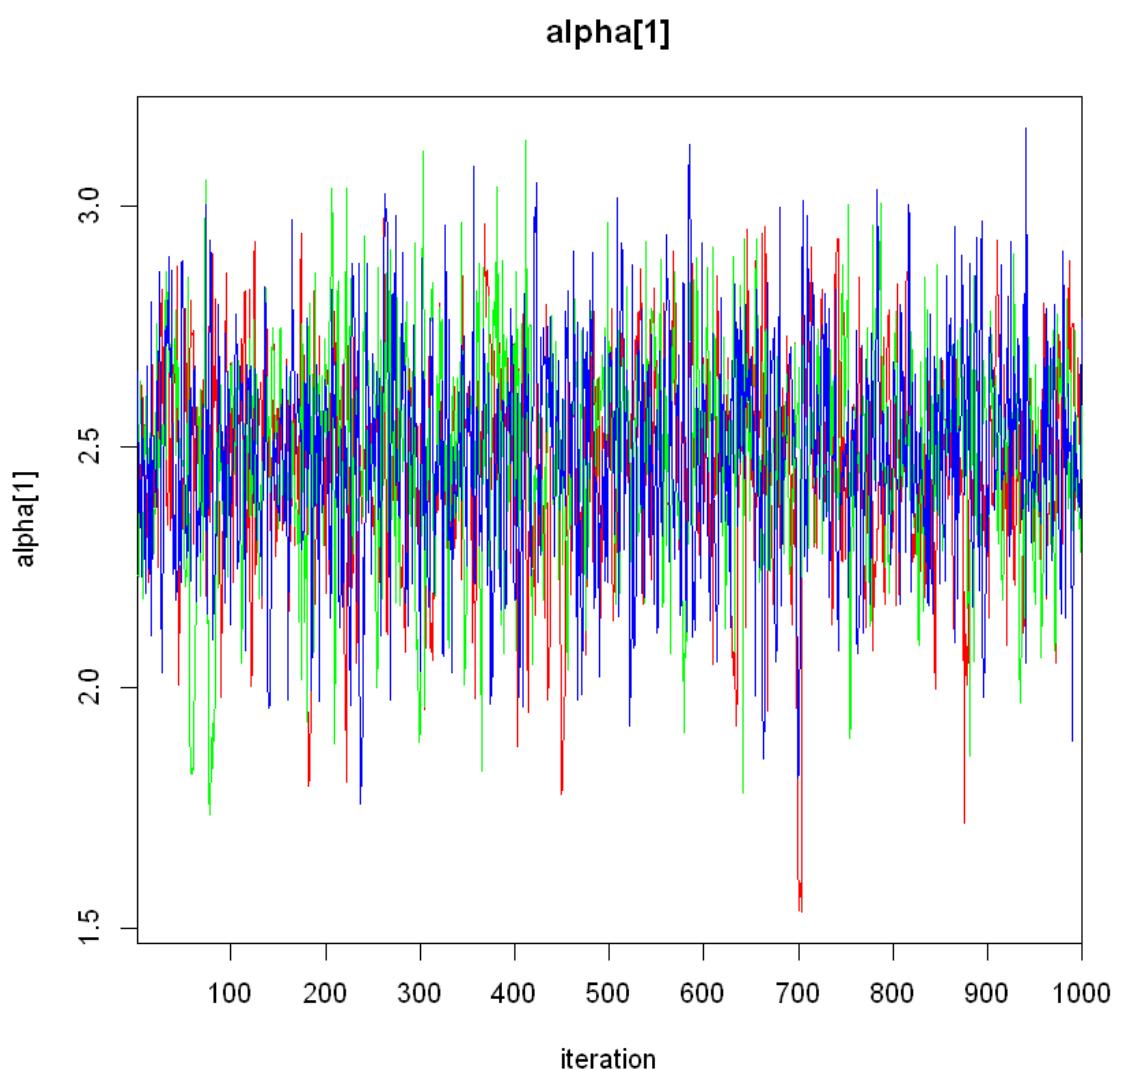


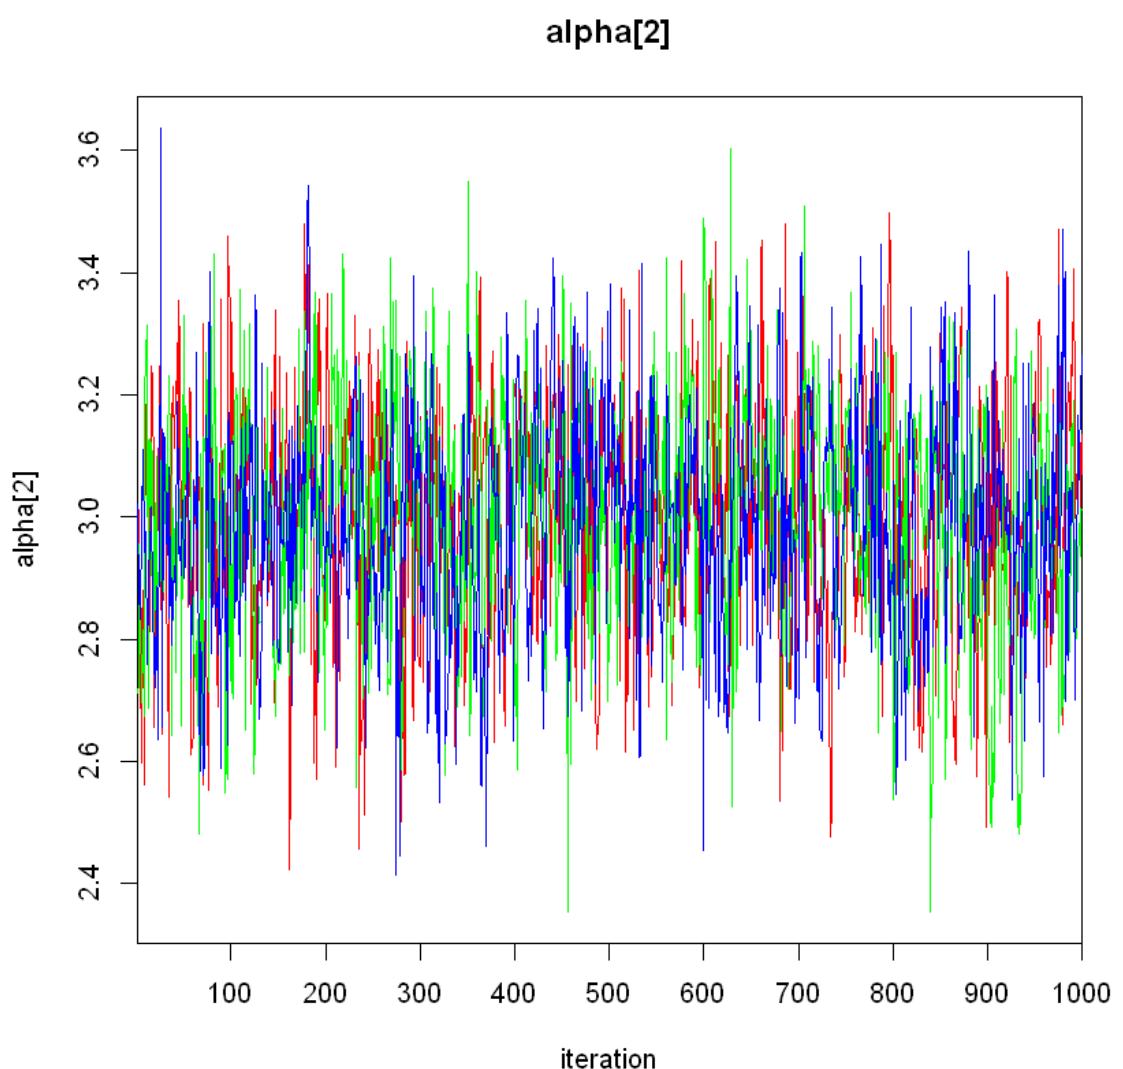


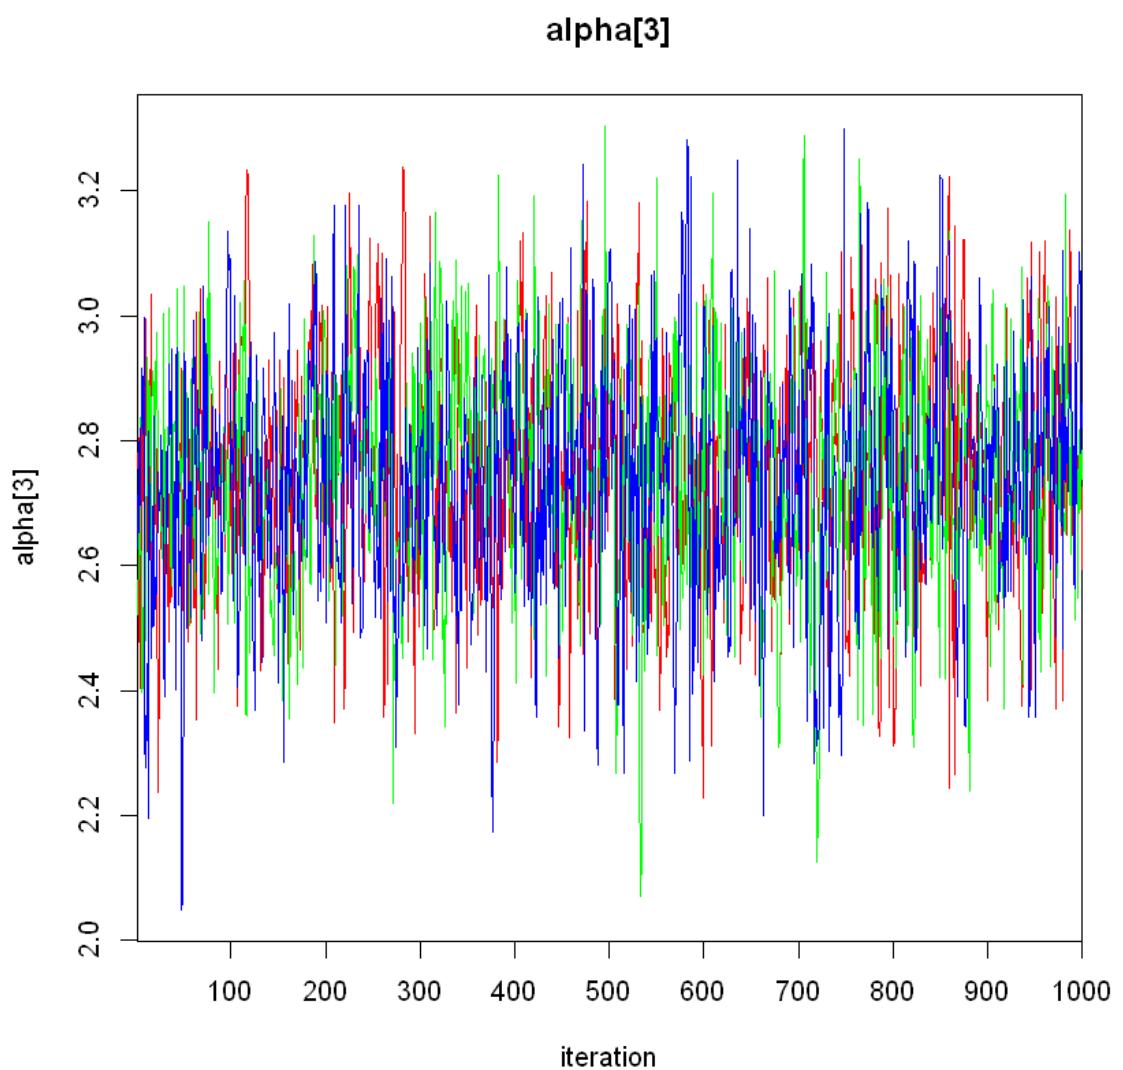


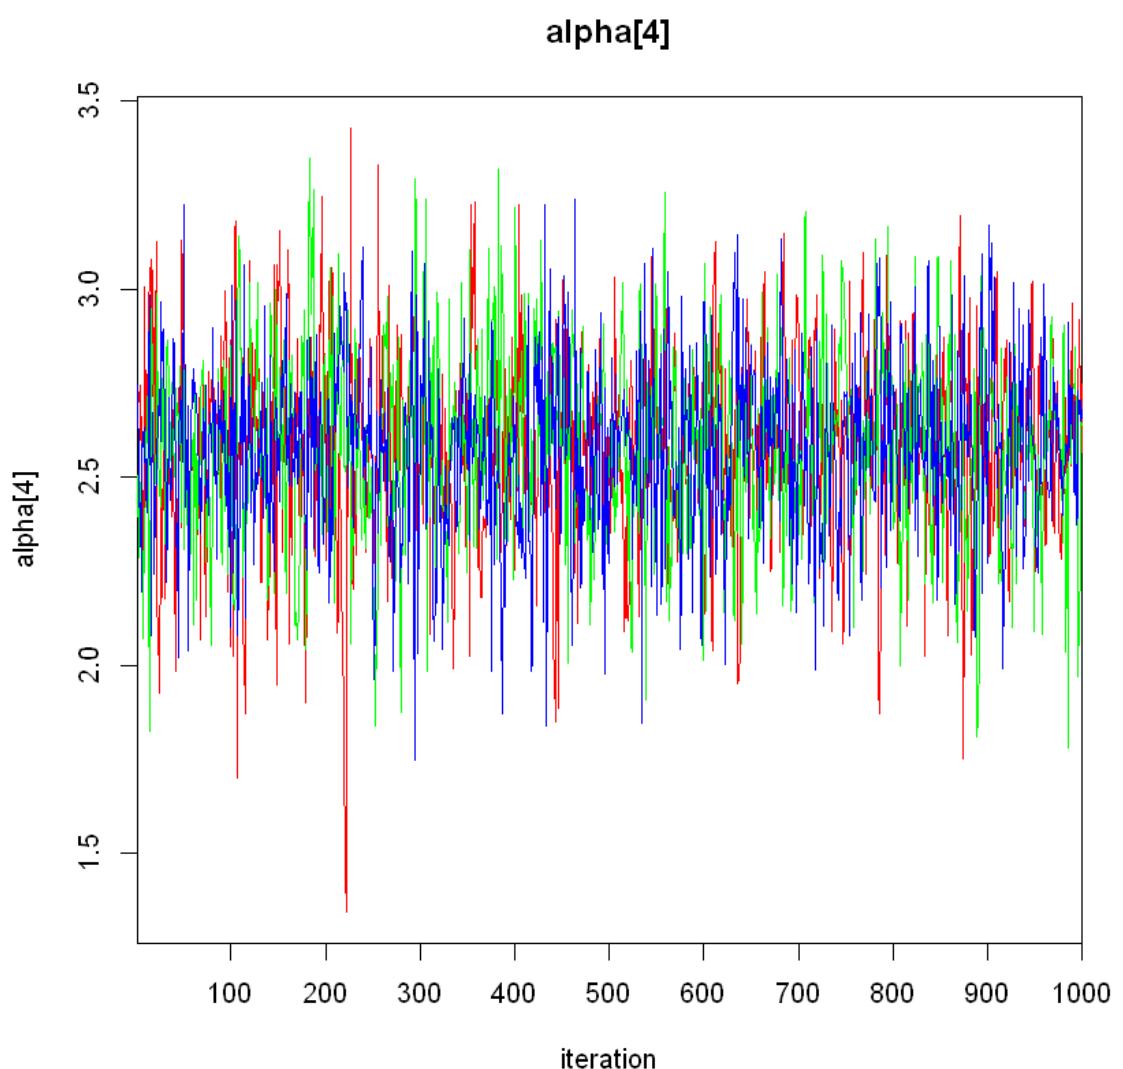
et leur trace

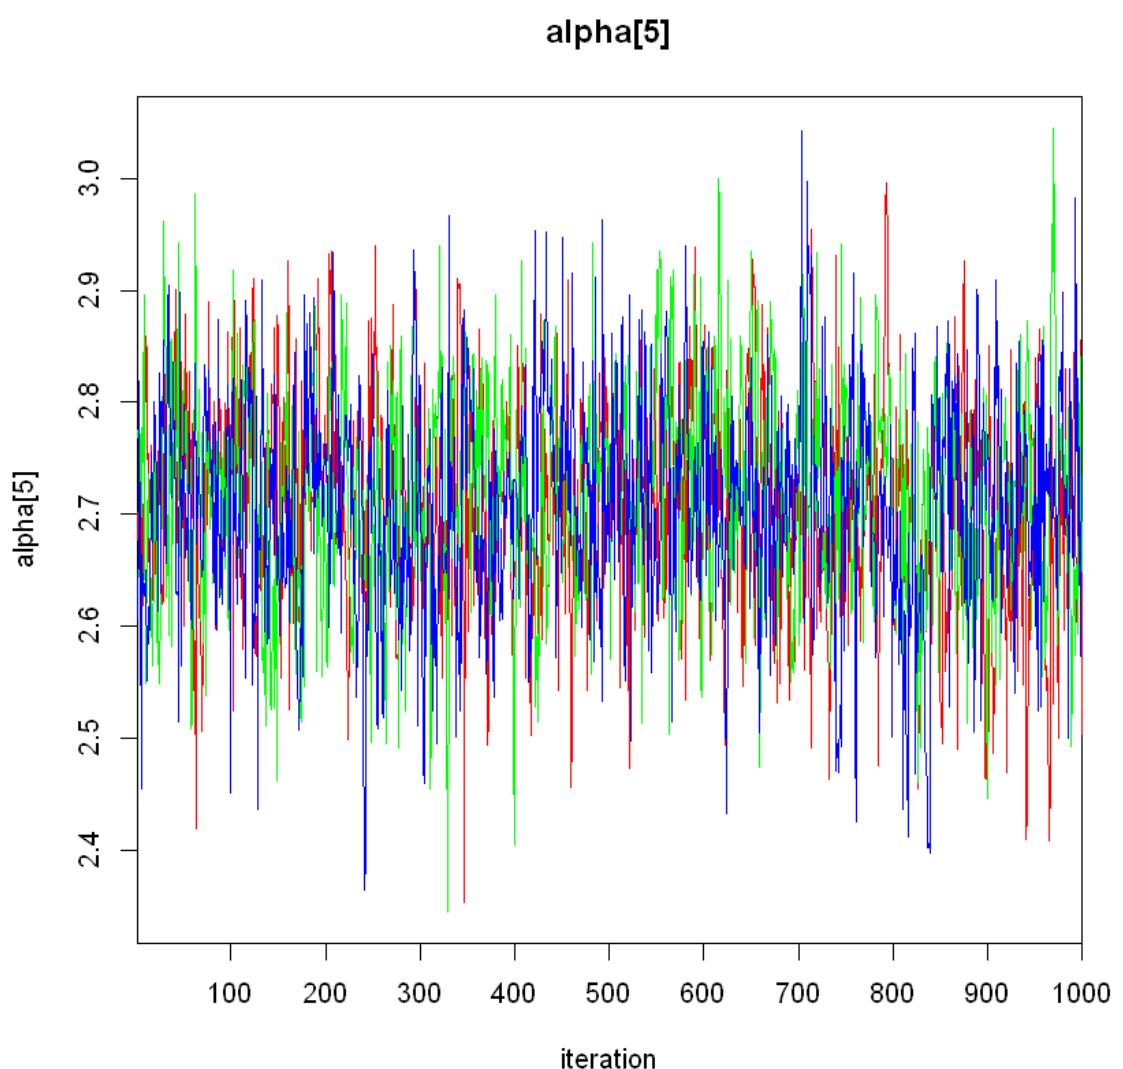
In [29]: `traceplot(out4)`

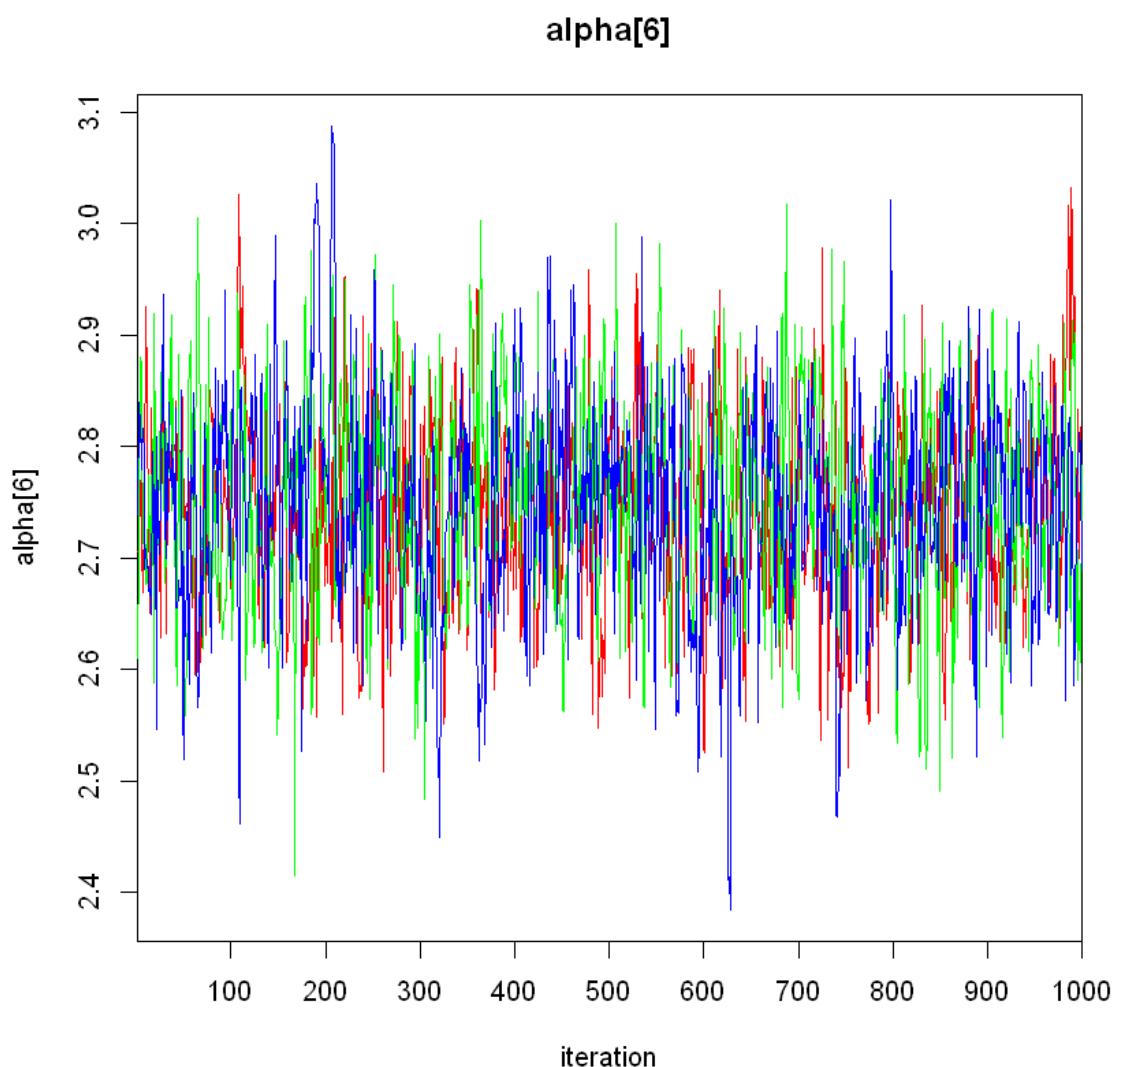


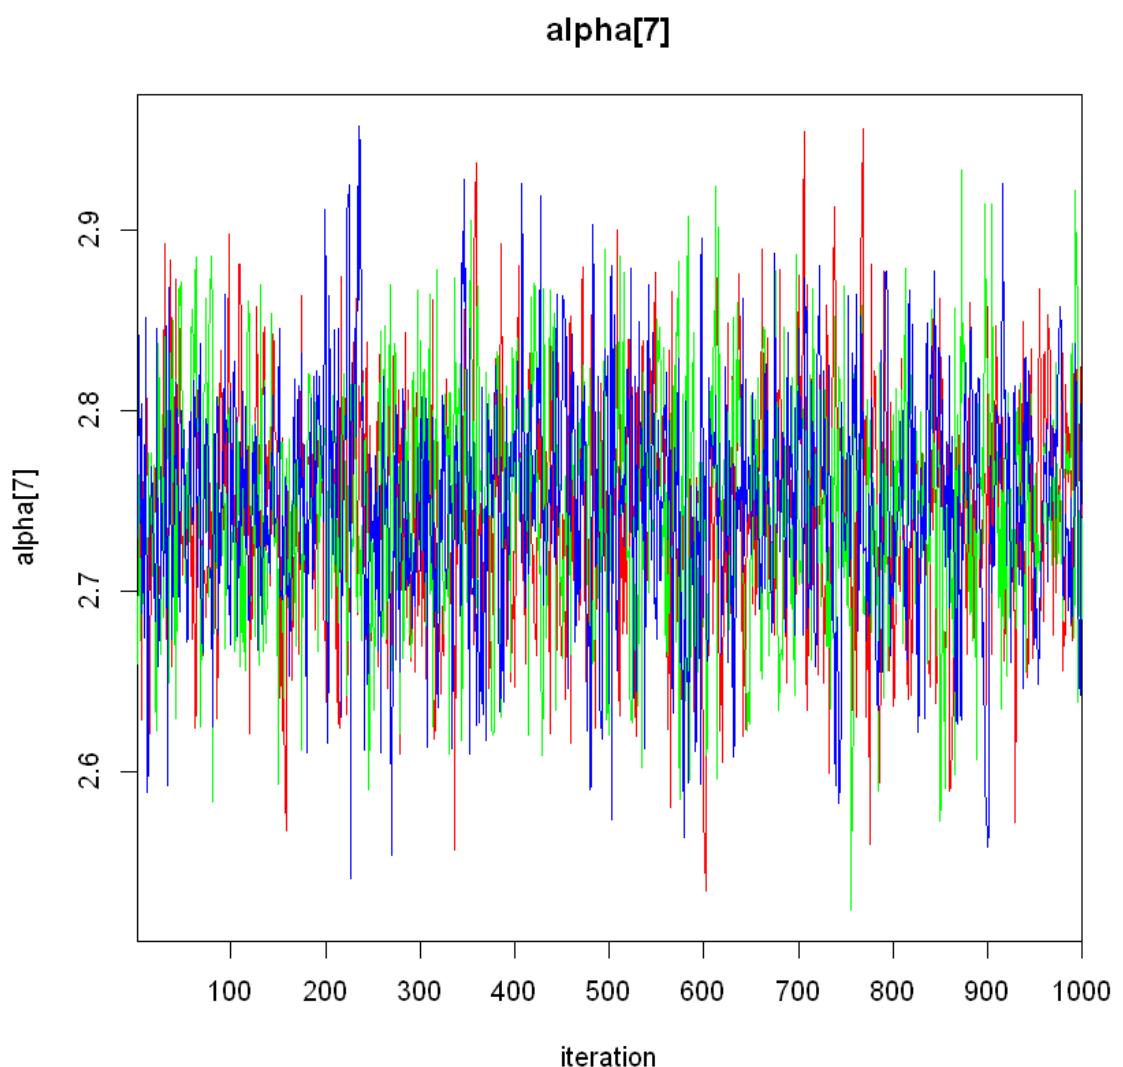


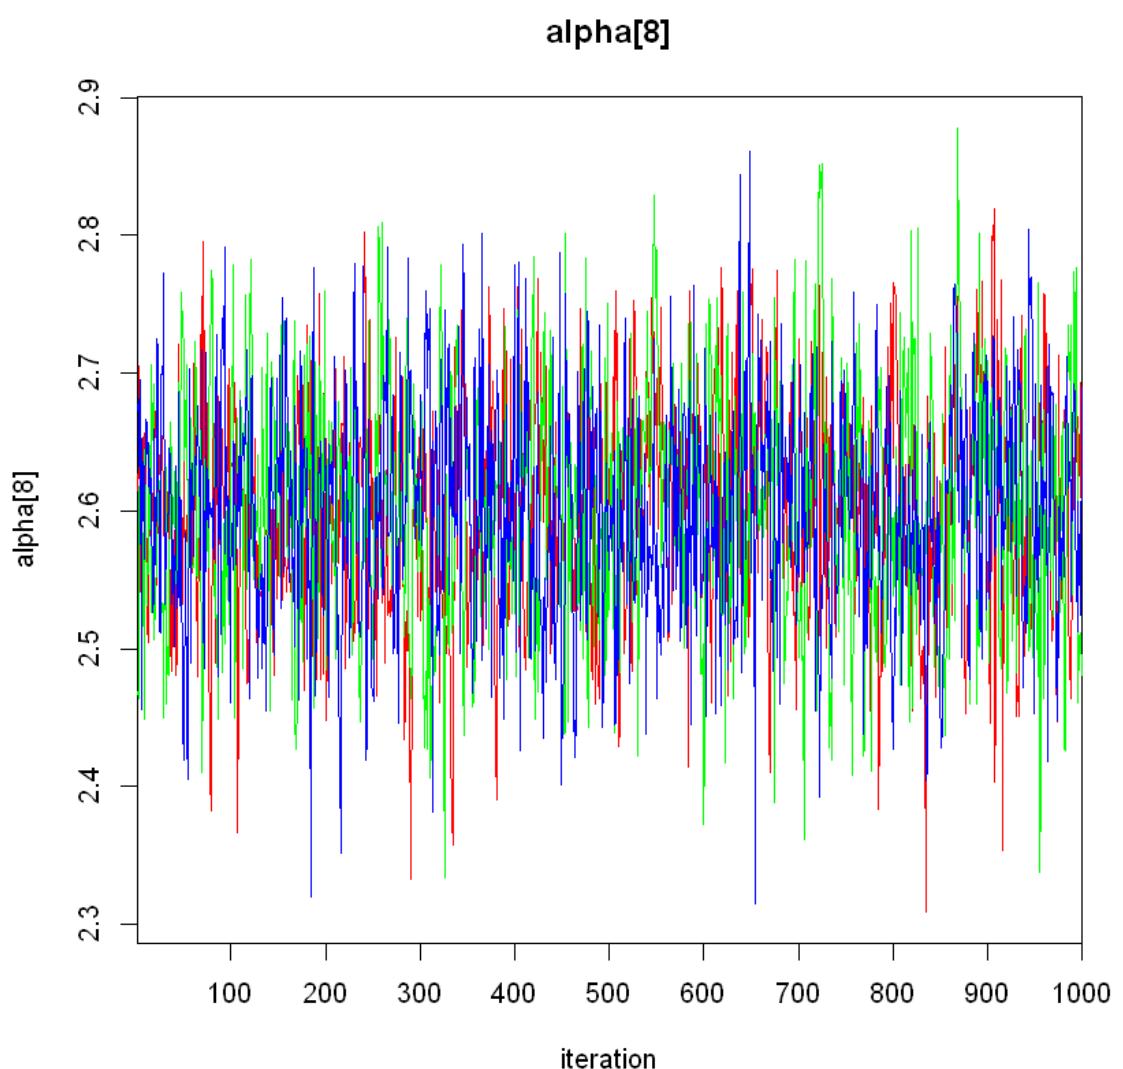


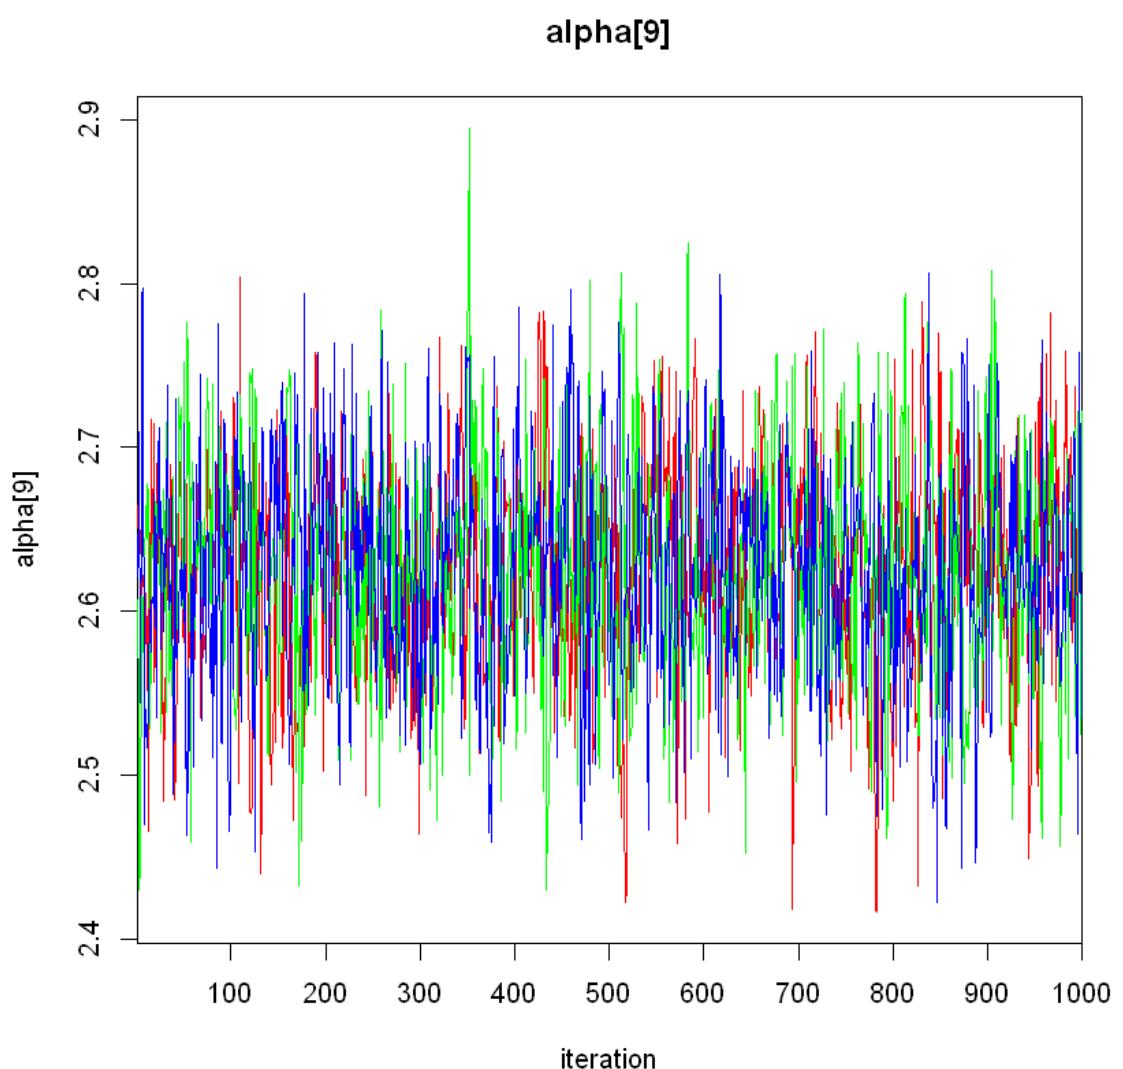


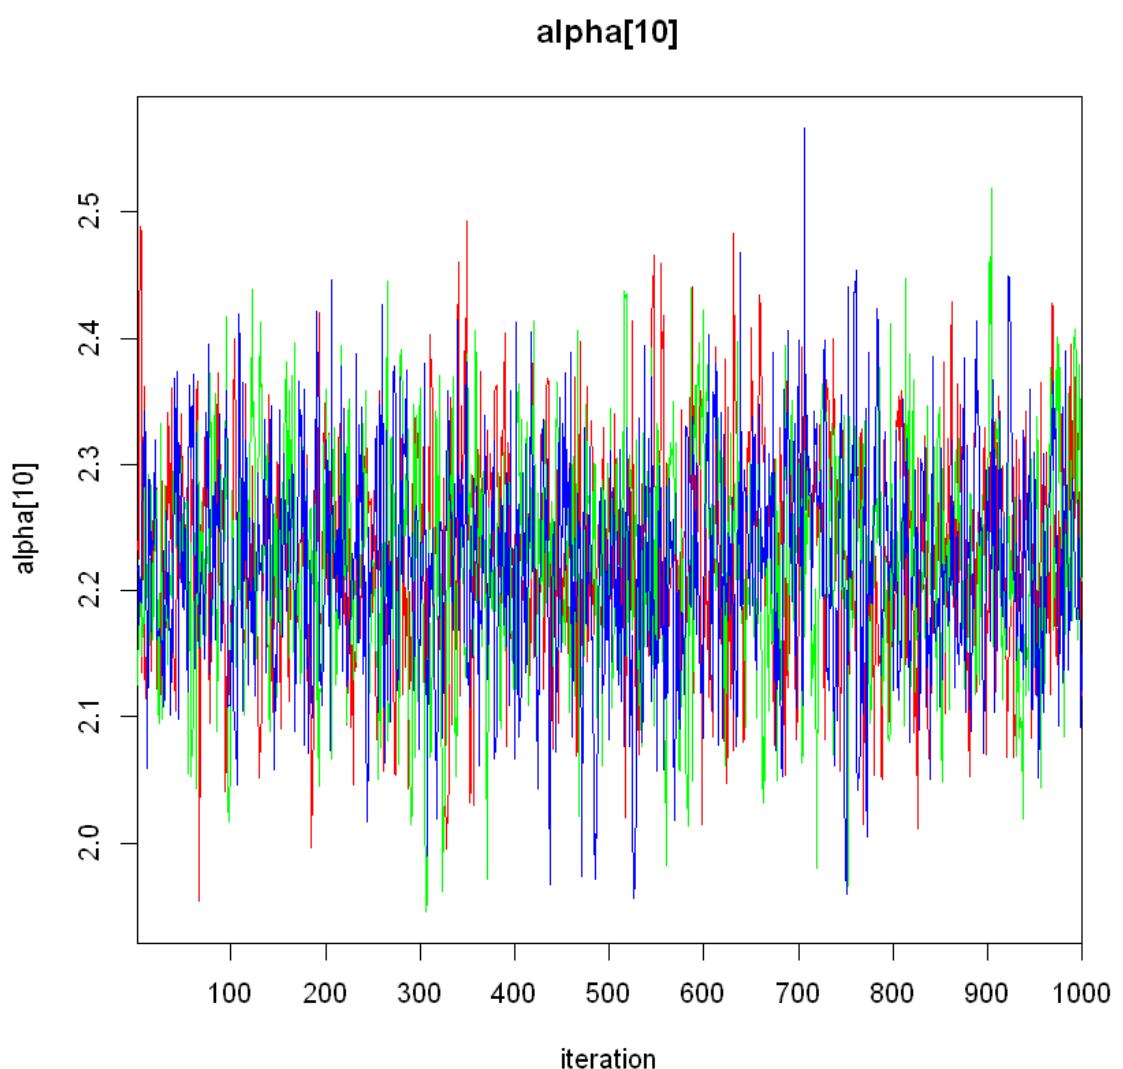


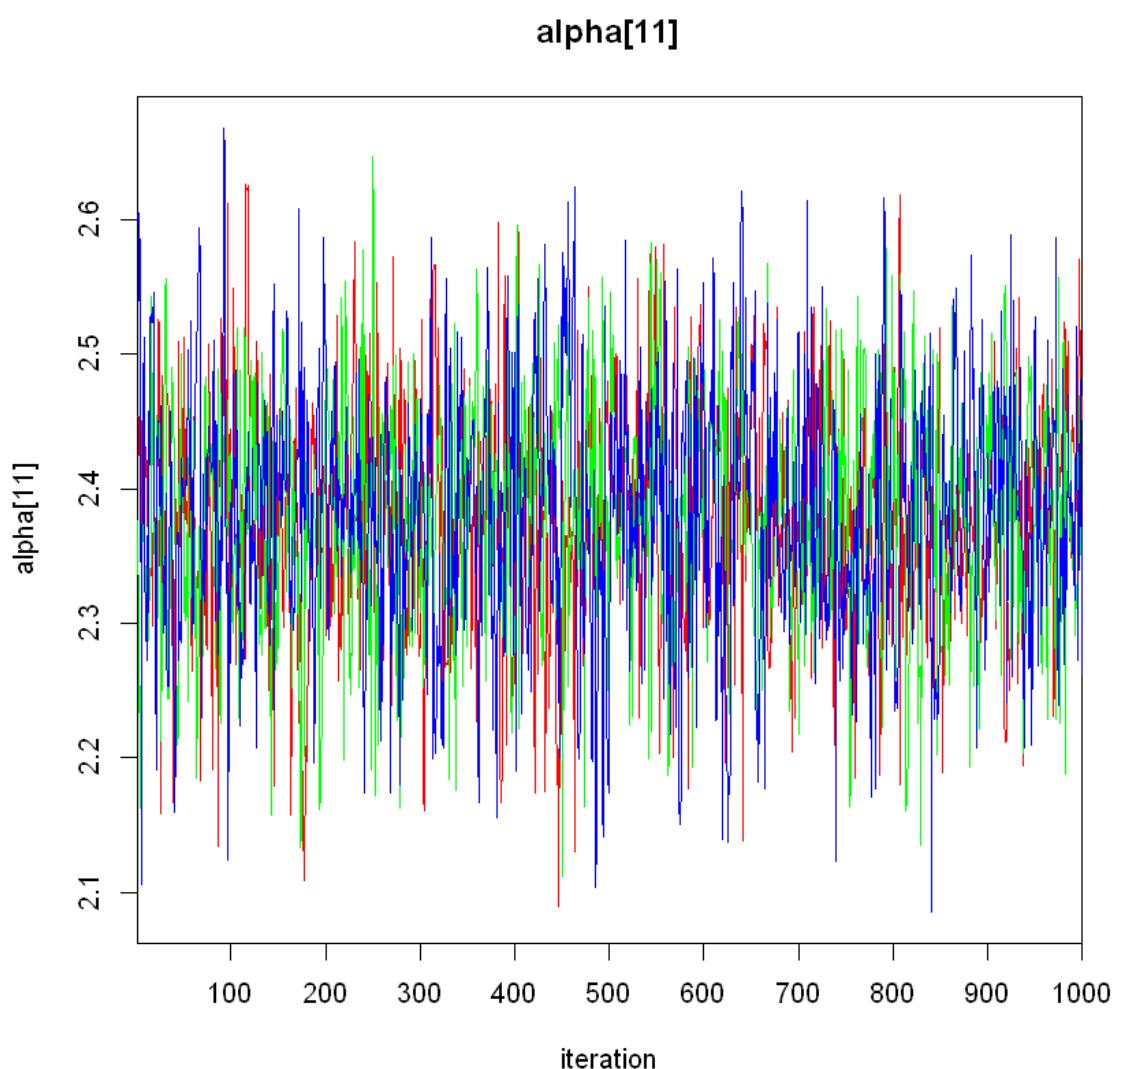


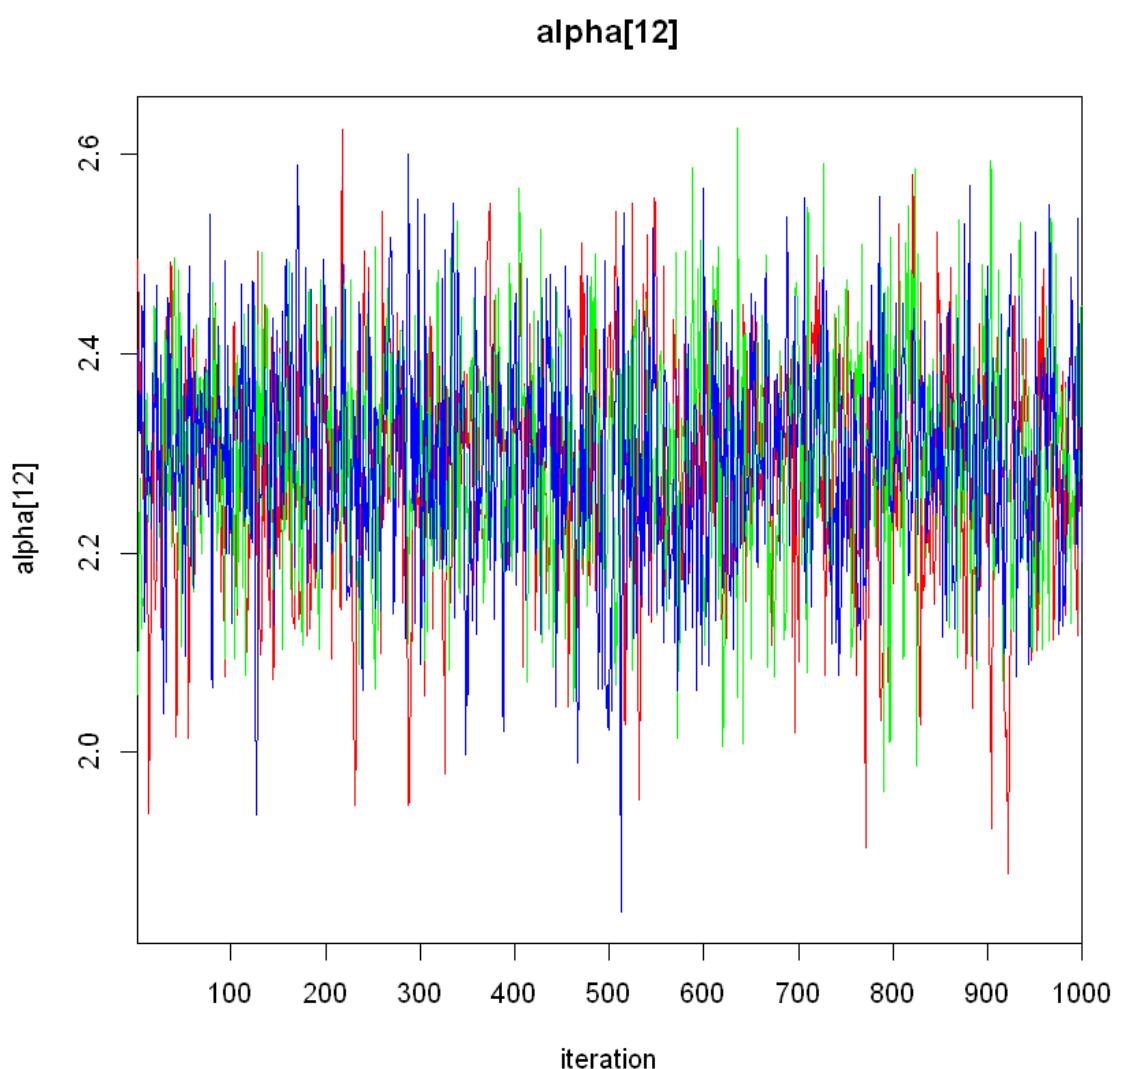


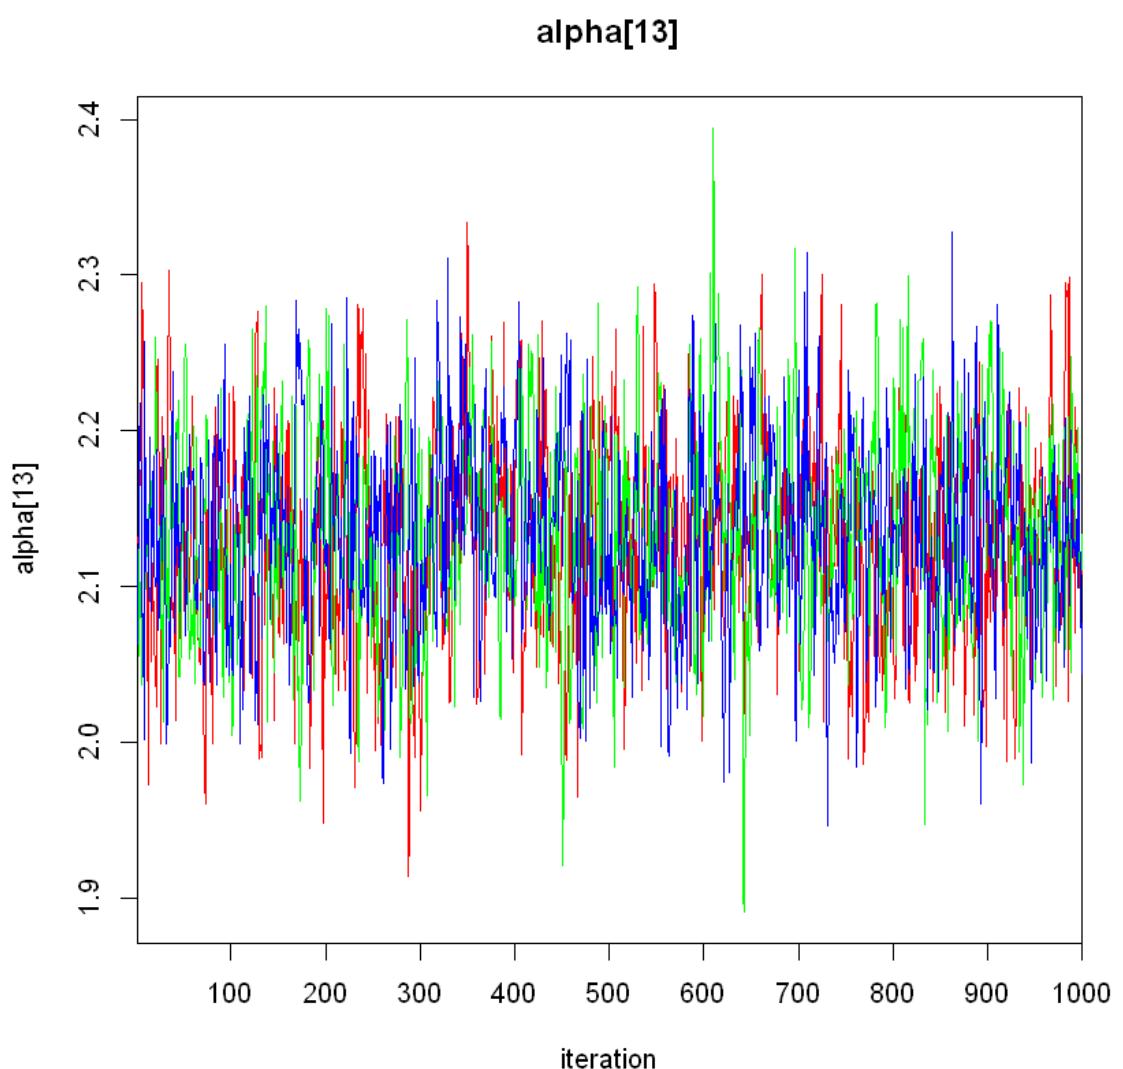


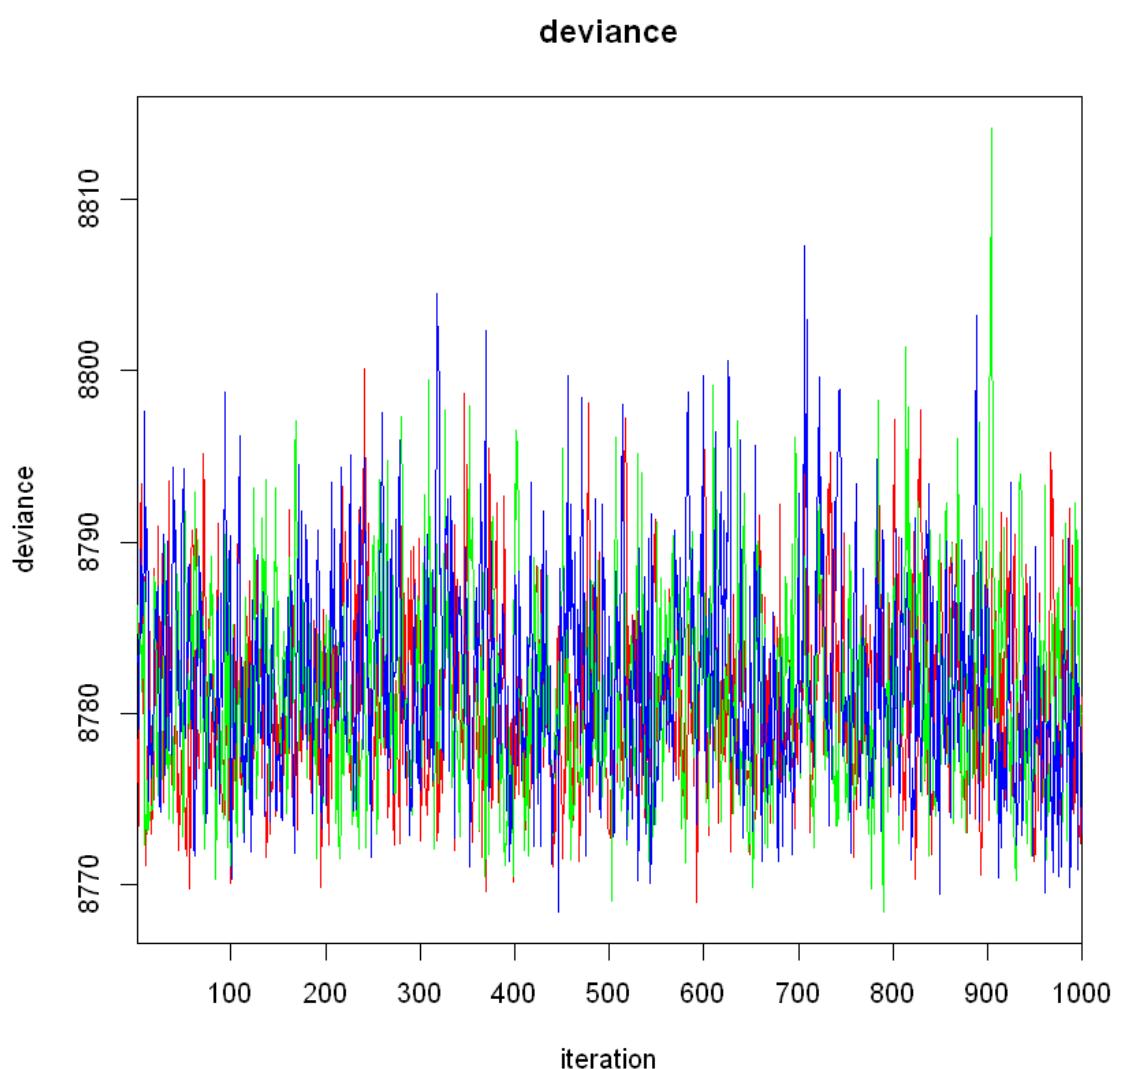


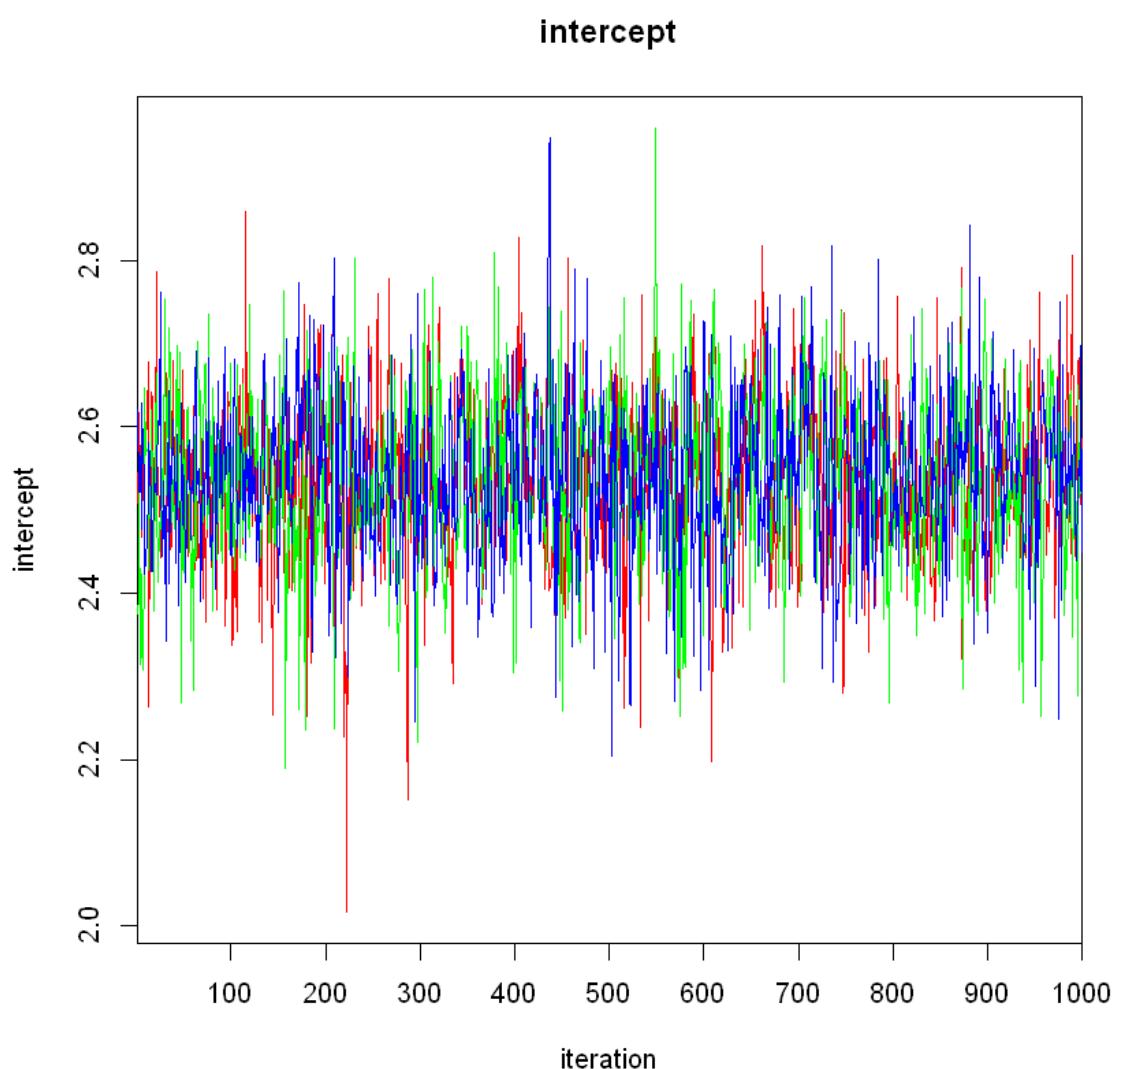




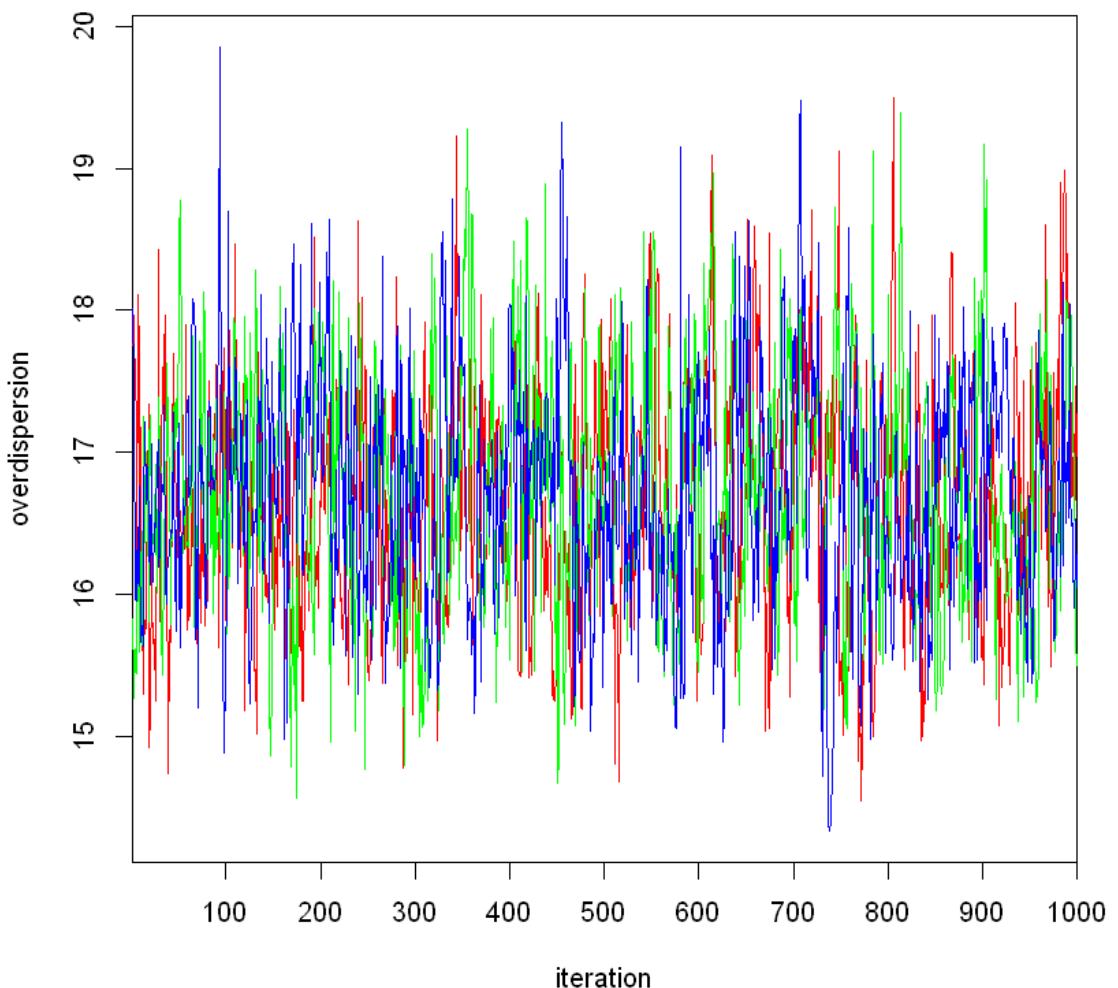


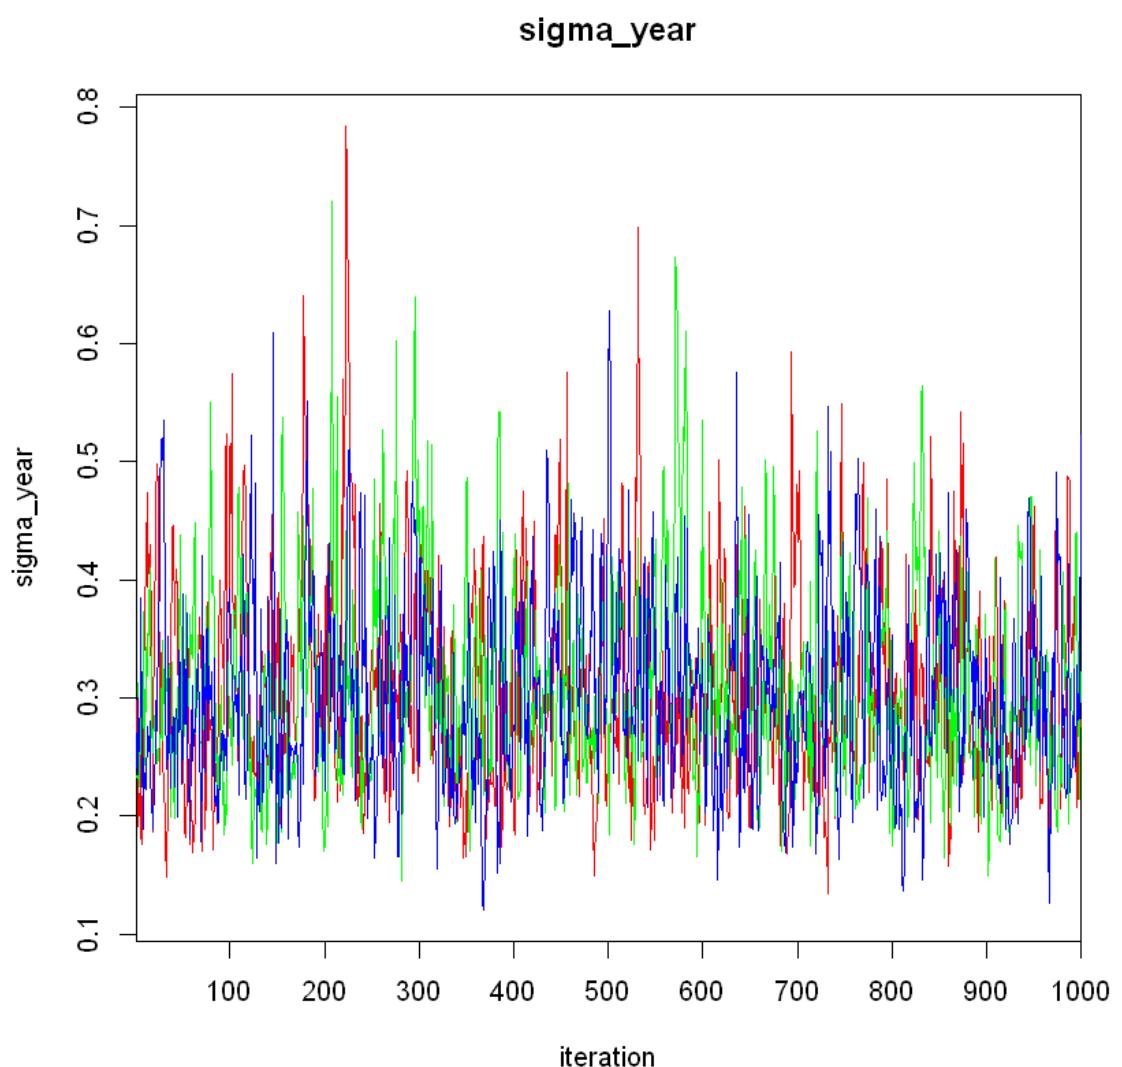


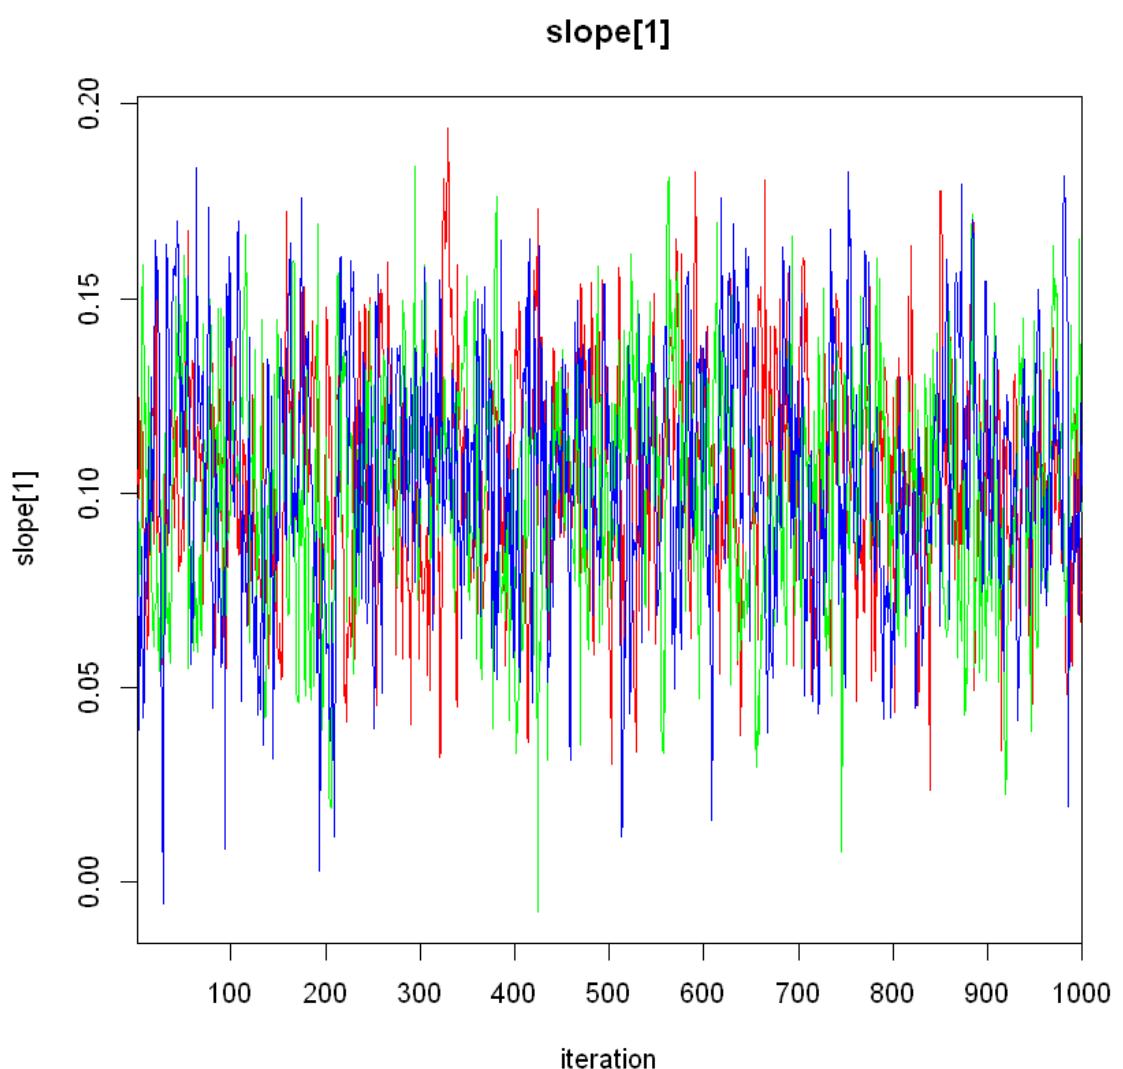


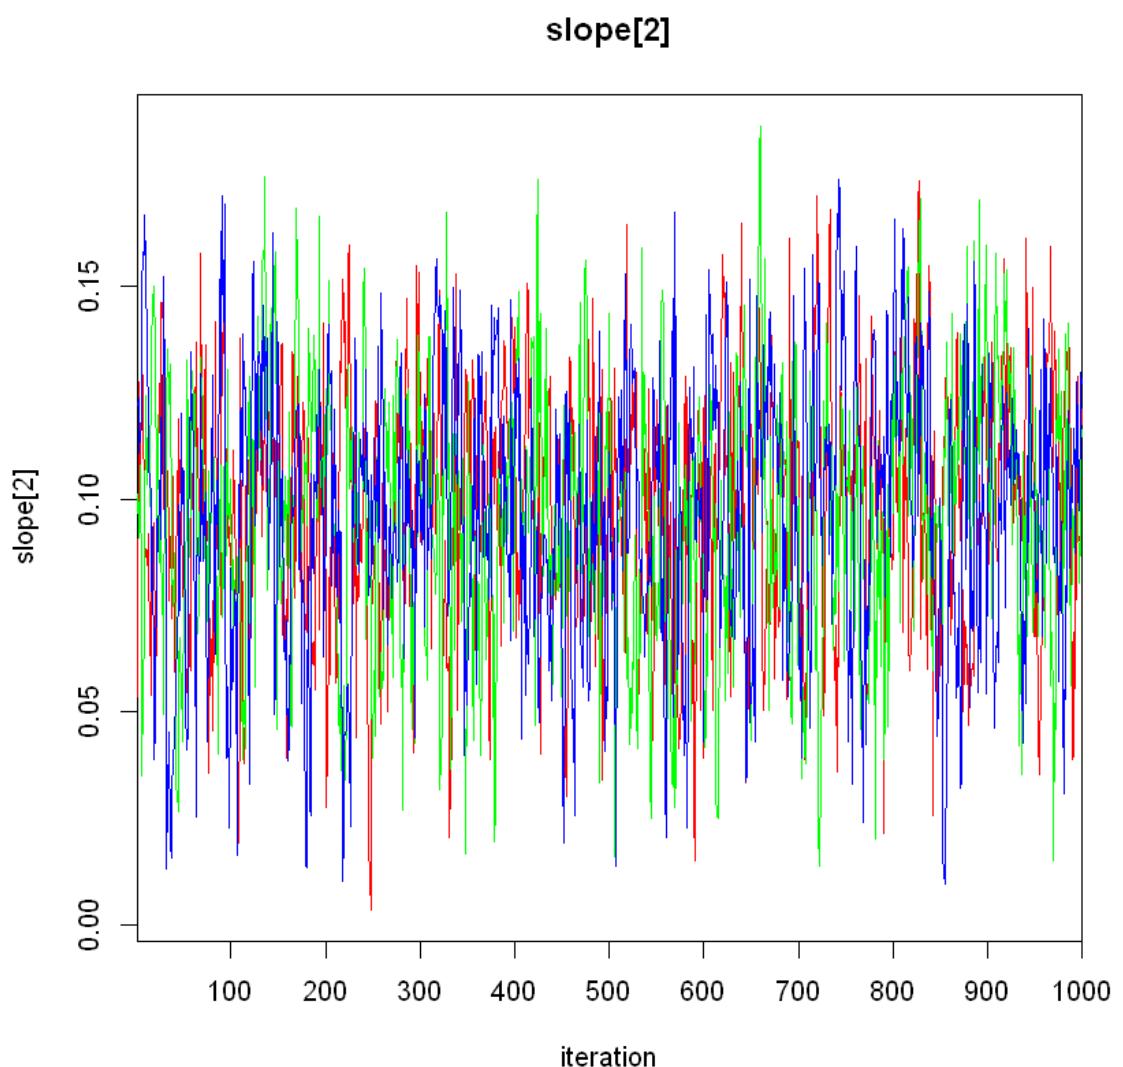


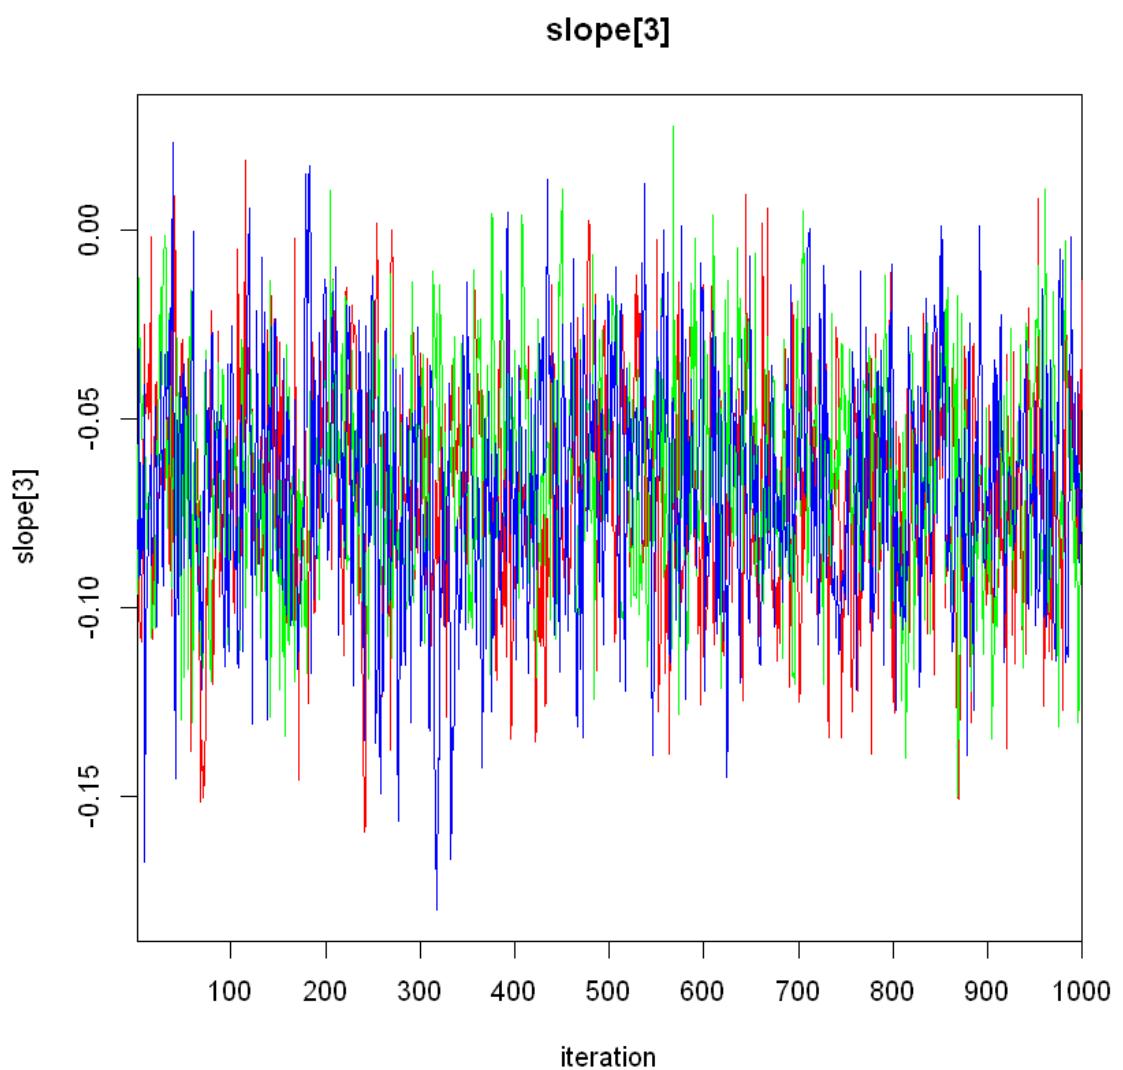
overdispersion











WAIC

On peut calculer le WAIC, du point de vue de ce critère le model est il meilleur que les précédents?

```
In [30]: ### calcul du WAIC
## besoin de calculer la log vraisemblance sous le modele
y_rep_4 <- log_li4 <- array(NA, dim = c(nc * (ni - nb)/nt, nrow(obs)))

for(i in 1:nrow(obs)) {
  overdispersion <- drop(out4$sims.list$overdispersion)
  linpred <- out4$sims.list$slope[, 1] * data.jags$X1[i] +
    out4$sims.list$slope[, 2] * data.jags$X2[i] +
    out4$sims.list$slope[, 3] * data.jags$X3[i] +
    out4$sims.list$alpha[, data.jags$YEAR[i]]
  log_li4[, i] <- dnbinom(data.jags$Y[i],
                            prob = 1 / overdispersion,
                            size = exp(linpred) / (overdispersion - 1),
                            log = TRUE
                            )
  y_rep_4[, i] <- rnbinom(nrow(y_rep_4),
                           prob = 1 / overdispersion,
                           size = exp(linpred) / (overdispersion - 1)
                           ) + 1
}; rm(i, linpred, overdispersion)

loo::waic(log_li4)
loo::loo(log_li4)
```

Warning message:
 "1 (0.1%) p_waic estimates greater than 0.4. We recommend trying loo instead."
 Warning message:
 "1 (0.1%) p_waic estimates greater than 0.4. We recommend trying loo instead."

Computed from 3000 by 1269 log-likelihood matrix

	Estimate	SE
elpd_waic	-4398.3	56.6
p_waic	14.8	1.2
waic	8796.6	113.2

Warning message:
 "Relative effective sample sizes ('r_eff' argument) not specified.
 For models fit with MCMC, the reported PSIS effective sample sizes and
 MCSE estimates will be over-optimistic."

Computed from 3000 by 1269 log-likelihood matrix

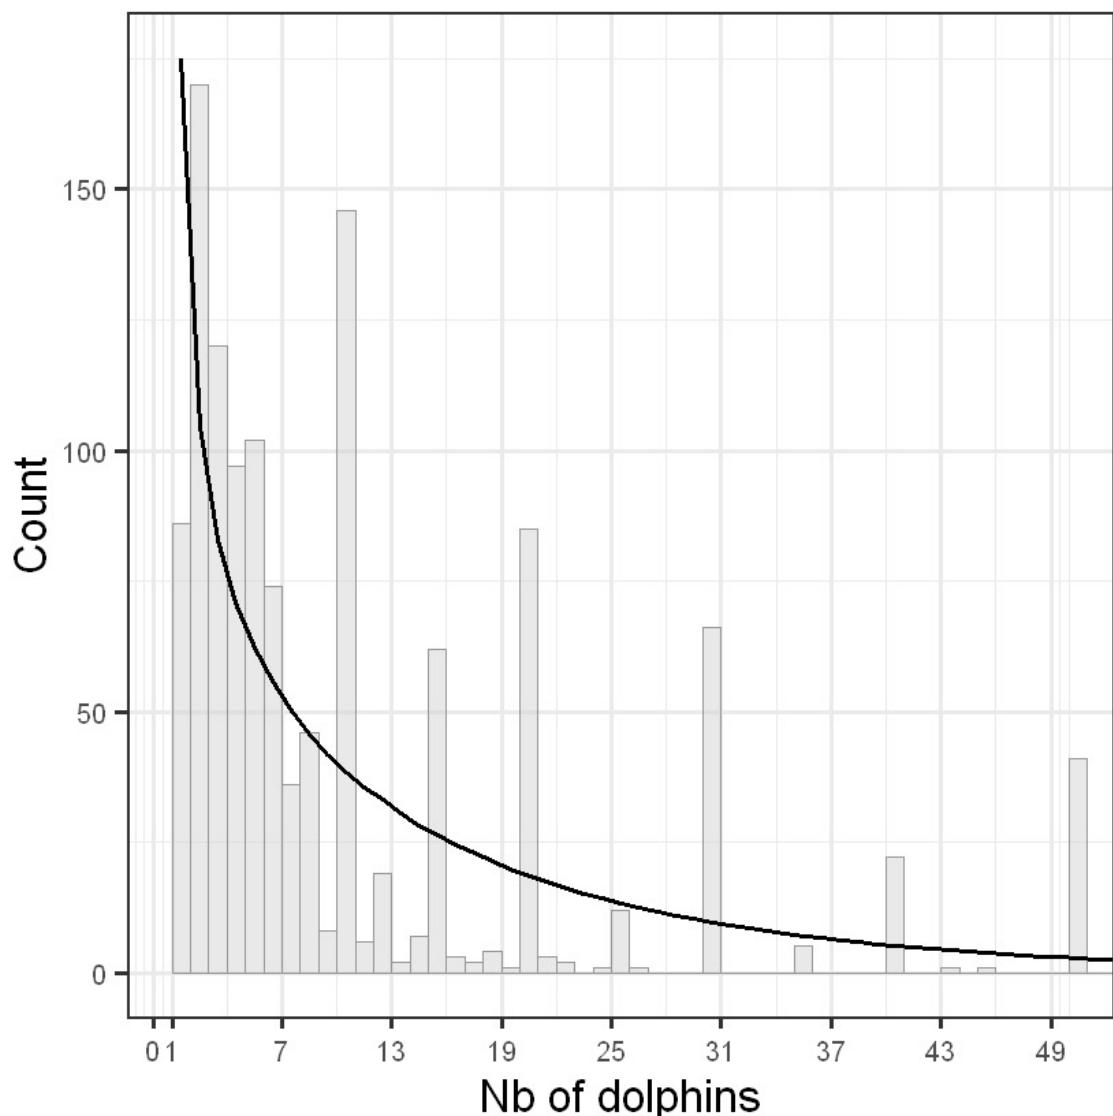
	Estimate	SE
elpd_loo	-4398.4	56.6
p_loo	14.9	1.2
looic	8796.7	113.2

Monte Carlo SE of elpd_loo	is 0.1.	

All Pareto k estimates are good (k < 0.5).
 See help('pareto-k-diagnostic') for details.

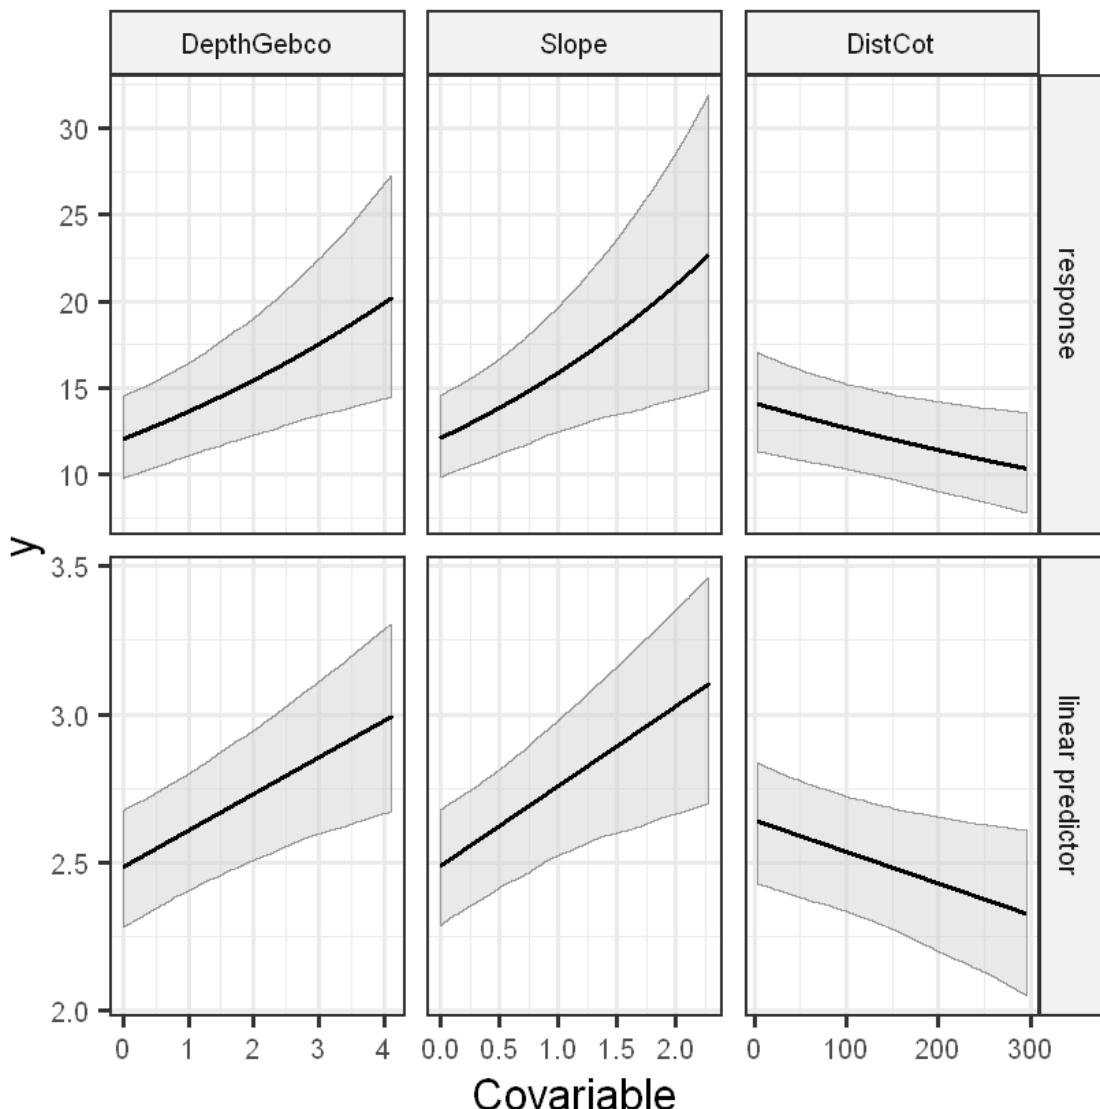
L'histogramme des donnees se compare-t-il à l'histogramme attendu sous le modèle?

```
In [31]: ## regarder l'histogramme des donnees et le comparer a l'histogramme attendu sous le modele
rootogram_model_4 <- rootogram(countdata = obs$nombre, y_rep = y_rep_4)
rootogram_model_4 +
  coord_cartesian(xlim = c(1, 50))
```



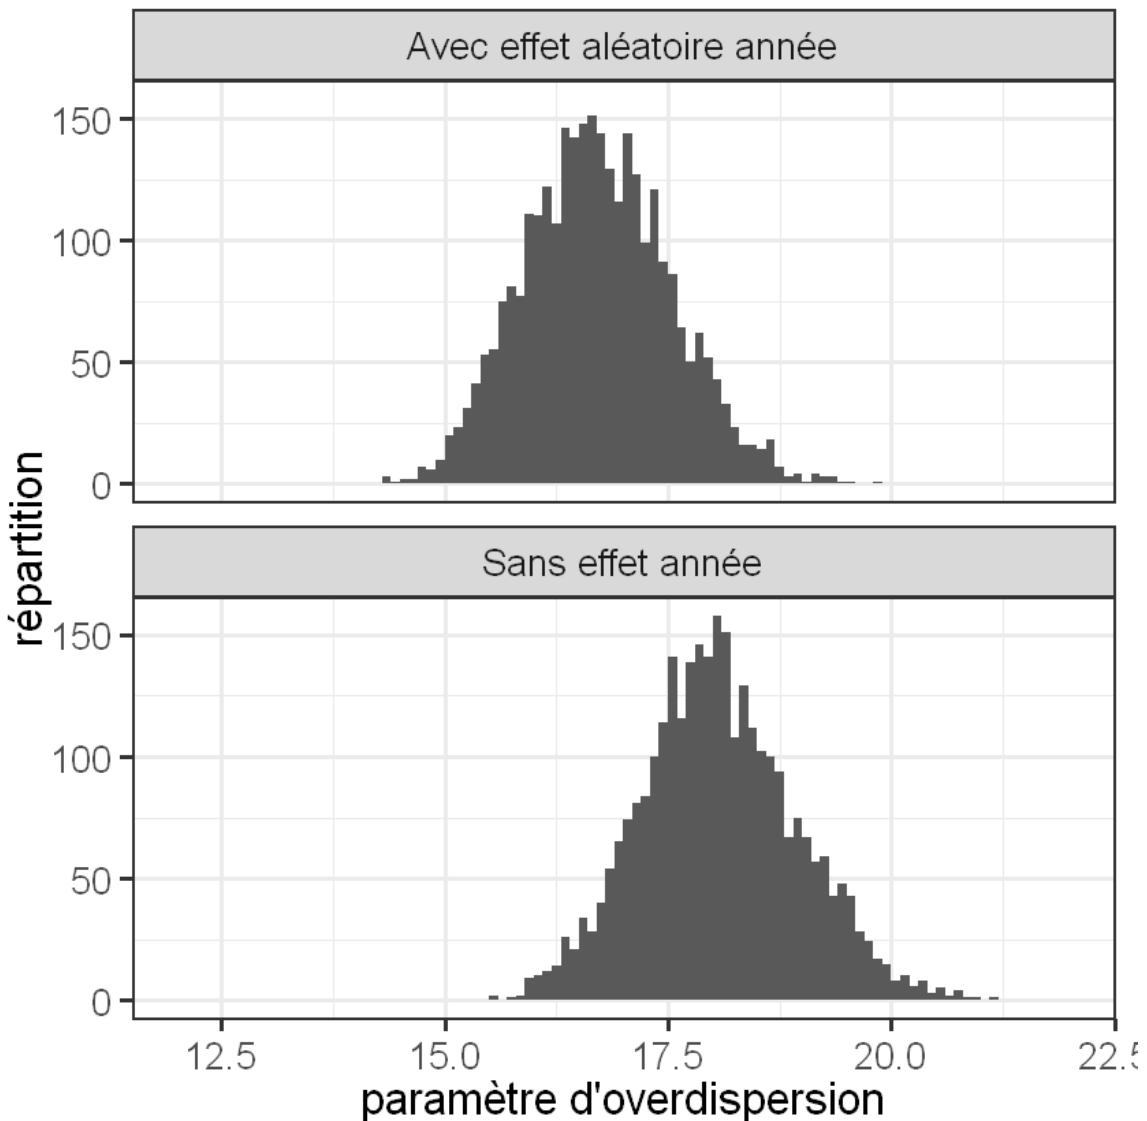
Un ajustement des effets avec des incertitudes plus réalistes

```
In [32]: ### un peu mieux que le modèle précédent...
plot_relationships(data_df = obs, jagsfit = out4, cov_name = c("DepthGebco", "Slope", "DistCot"))
```



On va regarder ce que ce modèle avec effets aléatoires change au niveau de l'estimation du paramètre de surdispersion:

```
In [33]: ggplot(data = data.frame(x = c(out3$sims.list$overdispersion,
                                         out4$sims.list$overdispersion
                                         ),
                                         distribution = rep(c("Sans effet année", "Avec effet aléatoire année"), each=length(out3$sims.list$overdispersion) )
                                         ),
                                         aes(x = x, group = distribution)
                                         ) +
geom_histogram(breaks = seq(10, 25, 0.1)) +
facet_wrap(~distribution, ncol = 1) +
coord_cartesian(xlim = c(12, 22))+labs(x="paramètre d'overdispersion", y="répartition")
```



Une partie de la surdispersion est absorbée par l'effet année mais il reste une grande part qui n'est pas expliquée :

```
In [34]: 1 - round(mean(out4$sims.list$overdispersion /
                           out3$sims.list$overdispersion
                           ), 2
                           )
```

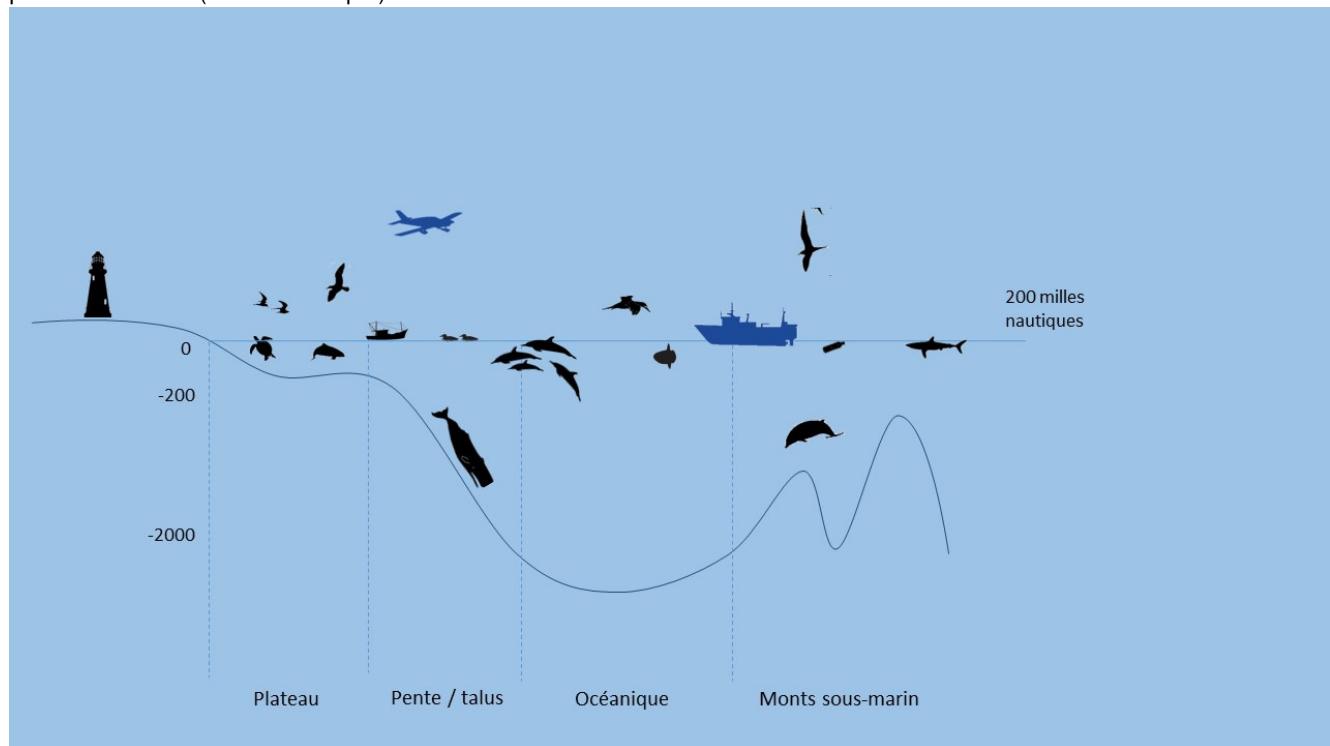
0.07

Une dernière option ici est de tenir compte d'un effet spatial avec un modèle de type Conditional Auto-Regressive (CAR). Ce modèle est facile à ajuster avec Stan (https://mc-stan.org/users/documentation/case-studies/icar_stan.html) (https://mc-stan.org/users/documentation/case-studies/icar_stan.html). Il faut cependant utiliser un nouveau bloc pour y définir une nouvelle distribution : la distribution CAR pour l'effet spatial. L'avantage de Stan ici est de pouvoir utiliser une paramétrisation qui va éviter des calculs coûteux. Ce modèle est ajustable dans un script supplémentaire mais ne sera pas couvert dans le TD.

On va donc ici considérer que notre meilleur modèle est le modèle surdispersé avec effet aléatoire de l'année . Les relations estimées avec l'environnement nous donnent la crédibilité de ces différentes variables environnementales sur la réponse conditionnellement à cette construction.

Conclusion

Nous avons ajuster une série de modèle à la complexité croissante pour estimer le nombre de dauphins dans le Golfe de Gascogne en fonction de diverses covariables environnementales. On peut voir ici qu'il y a plus de dauphins dans des zones de grandes profondeurs, loin des côtes et aussi des zones où la bathymétrie changent très rapidement sur de petites distances (talus océanique).



Néanmoins, le modèle sélectionné reste mauvais car il ignore un aspect important des données : les observateurs qui font les relevés sur le terrain ont tendance à arrondir les chiffres au delà d'une certaine abondance d'animaux, et cela induit des pics à des multiples de 5 ou 10. Il faudrait donc tenir compte du comportement des observateurs car celui-ci induit une source d'erreur de mesure qui n'est pas anodine, et qui contribue à générer de la surdispersion.

In []: