

# Μπεϋζιανή Στατιστική

Βασίλης Κατσιάνος

Αύγουστος 2023

## Περιεχόμενα

<b>1 Κανονική Πιθανοφάνεια</b>	<b>1</b>
1.1 Μονοδιάστατη Κανονική Κατανομή . . . . .	1
1.2 Γενικευμένη Κατανομή Student's t . . . . .	7
1.3 Μοντέλο Ανάλυσης Διασποράς με Έναν Παράγοντα . . . . .	12
1.4 Γραμμικό Μοντέλο με Student's t Σφάλματα . . . . .	15
1.5 Πολυδιάστατη Κανονική Κατανομή . . . . .	20
1.6 Πολυδιάστατη Κατανομή Student's t . . . . .	31
<b>2 Γενικευμένα Γραμμικά Μοντέλα</b>	<b>35</b>
2.1 Λογιστικό Μοντέλο . . . . .	35
2.2 Μοντέλο Πιθανομονάδας . . . . .	36
2.3 Λογαριθμικό Μοντέλο Poisson . . . . .	39
2.4 Μηδενικά Διογκωμένο Μοντέλο Poisson . . . . .	41
<b>3 Λύσεις Θεμάτων Εξετάσεων</b>	<b>45</b>
3.1 Οκτώβριος 2011 . . . . .	45
3.2 Φεβρουάριος 2009 . . . . .	49

## 1 Κανονική Πιθανοφάνεια

### 1.1 Μονοδιάστατη Κανονική Κατανομή

Έστω τυχαίο δείγμα  $y_1, \dots, y_n$  από την κανονική κατανομή  $\mathcal{N}(\mu, \tau^{-1})$ .

α. Θεωρούμε prior ανεξαρτησία με κατανομές  $\mu \sim \mathcal{N}(a, c^{-1})$  και  $\tau \sim \text{Gamma}(p, q)$ . Να υπολογιστούν οι δεσμευμένες posterior κατανομές των παραμέτρων  $\mu$  και  $\tau$ .

β. Θεωρούμε τη συζυγή prior κατανομή  $\mu \mid \tau \sim \mathcal{N}(a, c^{-1}\tau^{-1})$ ,  $\tau \sim \text{Gamma}(p, q)$ . Να υπολογιστούν οι δεσμευμένες και οι περιθώριες posterior κατανομές των παραμέτρων  $\mu$  και  $\tau$ .

Λύση.

α. Η από κοινού prior κατανομή μπορεί να γραφτεί ως:

$$\begin{aligned}
\pi(\mu, \tau) &= \pi(\mu) \cdot \pi(\tau) \\
&= \sqrt{\frac{c}{2\pi}} \exp\left\{-\frac{c(\mu - a)^2}{2}\right\} \cdot \frac{q^p}{\Gamma(p)} \tau^{p-1} e^{-q\tau} \\
&\propto \exp\left\{-c\frac{\mu^2 - 2\mu a + a^2}{2}\right\} \cdot \tau^{p-1} e^{-q\tau} \\
&\propto \exp\left\{-\frac{1}{2}c\mu^2 + ca\mu\right\} \cdot \tau^{p-1} e^{-q\tau}.
\end{aligned}$$

Η πιθανοφάνεια ολόκληρου του δείγματος δίνεται από τη σχέση:

$$\begin{aligned}
f(y | \mu, \tau) &= \prod_{i=1}^n f(y_i | \mu, \tau) \\
&= \prod_{i=1}^n \sqrt{\frac{\tau}{2\pi}} \exp\left\{-\frac{\tau(y_i - \mu)^2}{2}\right\} \\
&\propto \tau^{\frac{n}{2}} \exp\left\{-\frac{1}{2} \sum_{i=1}^n (y_i - \mu)^2 \tau\right\} \\
&= \tau^{\frac{n}{2}} \exp\left\{-\sum_{i=1}^n \frac{y_i^2 - 2y_i\mu + \mu^2}{2} \tau\right\} \\
&= \exp\left\{-\frac{1}{2}n\tau\mu^2 + n\tau\bar{y}\mu\right\} \cdot \tau^{\frac{n}{2}} \exp\left\{-\frac{1}{2} \sum_{i=1}^n y_i^2 \tau\right\}.
\end{aligned}$$

Επομένως, παίρνουμε τις δεσμευμένες posterior κατανομές των  $\mu$  και  $\tau$  ως εξής:

$$\begin{aligned}
\pi(\mu | \tau, y) &\propto \pi(\mu, \tau | y) \\
&\propto \pi(\mu, \tau) \cdot f(y | \mu, \tau) \\
&\propto \exp\left\{-\frac{c}{2}\mu^2 + ca\mu\right\} \cdot \exp\left\{-\frac{n\tau}{2}\mu^2 + n\tau\bar{y}\mu\right\} \\
&= \exp\left\{-\frac{1}{2} \underbrace{(c + n\tau)}_{c_n} \mu^2 + (ca + n\tau\bar{y}) \mu\right\} \\
&= \exp\left\{-\frac{c + n\tau}{2} \mu^2 + \underbrace{(c + n\tau)}_{c_n} \underbrace{\frac{ca + n\tau\bar{y}}{c + n\tau}}_{a_n} \mu\right\},
\end{aligned}$$

$$\begin{aligned}
\pi(\tau | \mu, y) &\propto \pi(\mu, \tau) \cdot f(y | \mu, \tau) \\
&\propto \tau^{p-1} e^{-q\tau} \cdot \tau^{\frac{n}{2}} \exp\left\{-\frac{1}{2} \sum_{i=1}^n (y_i - \mu)^2 \tau\right\} \\
&= \tau^{p+\frac{n}{2}-1} \exp\left\{-\left[q + \frac{1}{2} \sum_{i=1}^n (y_i - \mu)^2\right] \tau\right\}.
\end{aligned}$$

Δηλαδή,

$$\mu \mid \tau, y \sim \mathcal{N}\left(\frac{ca + n\tau\bar{y}}{c + n\tau}, \frac{1}{c + n\tau}\right), \quad \tau \mid \mu, y \sim \text{Gamma}\left(p + \frac{n}{2}, q + \frac{1}{2} \sum_{i=1}^n (y_i - \mu)^2\right).$$


Μπορούμε να υπολογίσουμε την prior του Jeffreys για τη μονοδιάστατη κανονική κατανομή ως εξής:

$$\begin{aligned} \log f(y \mid \mu, \tau) &= \frac{1}{2} \log \tau - \frac{1}{2} \log(2\pi) - \frac{\tau(y - \mu)^2}{2}, \\ \frac{\partial \log f(y \mid \mu, \tau)}{\partial \mu} &= \tau(y - \mu), \quad \frac{\partial \log f(y \mid \mu, \tau)}{\partial \tau} = \frac{1}{2\tau} - \frac{(y - \mu)^2}{2}, \\ \frac{\partial^2 \log f(y \mid \mu, \tau)}{\partial \mu^2} &= -\tau, \quad \frac{\partial^2 \log f(y \mid \mu, \tau)}{\partial \tau^2} = -\frac{1}{2\tau^2}, \quad \frac{\partial^2 \log f(y \mid \mu, \tau)}{\partial \mu \partial \tau} = y - \mu, \\ \mathcal{J}(\mu, \tau) &= -\mathbb{E}\left[\frac{\partial \log f(y \mid \mu, \tau)}{\partial(\mu, \tau)\partial(\mu, \tau)}\right] = \begin{bmatrix} \tau & 0 \\ 0 & \frac{1}{2\tau^2} \end{bmatrix}, \quad J(\mu, \tau) \propto \sqrt{|\mathcal{J}(\mu, \tau)|} = \sqrt{\frac{1}{2\tau}} \propto \tau^{-0.5}. \end{aligned}$$

Παρατηρούμε ότι η μη-ορθή prior του Jeffreys προκύπτει για  $a = c = q = 0$  και  $p = 0.5$

```
MCMCnorm = function(Y, mu0, tau0, a, c, p, q, niter, nburn) {
  n = length(Y)
  S = sum(Y)
  mu = numeric(niter)
  tau = numeric(niter)
  mu[1] = mu0
  tau[1] = tau0
  for (i in 2:niter) {
    mu[i] = rnorm(1, (c * a + tau[i - 1] * S)/(c + n * tau[i - 1]), (c +
      n * tau[i - 1])^(-0.5))
    tau[i] = rgamma(1, p + n/2, q + sum((Y - mu[i])^2)/2)
  }
  return(list(mu = mu[-(1:nburn)], tau = tau[-(1:nburn)]))
}

n = 1000
mu = 1
tau = 2
Y = rnorm(n, mu, tau^(-0.5))
posterior = MCMCnorm(Y, 0, 1, 0, 0, 0.5, 0, 5000, 1000)
par(mfrow = c(1, 2))
hist(posterior$mu, "FD", freq = FALSE, main = NA, xlab = expression(mu))
abline(v = mu, col = 2, lty = 2)
hist(posterior$tau, "FD", freq = FALSE, main = NA, xlab = expression(tau))
abline(v = tau, col = 2, lty = 2)
```



β. Η από κοινού prior κατανομή μπορεί να γραφτεί ως:

$$\begin{aligned}
 \pi(\mu, \tau) &= \pi(\mu | \tau) \cdot \pi(\tau) \\
 &= \sqrt{\frac{c\tau}{2\pi}} \exp\left\{-\frac{c\tau(\mu - a)^2}{2}\right\} \cdot \frac{q^p}{\Gamma(p)} \tau^{p-1} e^{-q\tau} \\
 &\propto \tau^{p+\frac{1}{2}-1} \exp\left\{-\left[q + \frac{c(\mu - a)^2}{2}\right]\tau\right\} \\
 &= \tau^{\frac{1}{2}} \exp\left\{-c\tau \frac{\mu^2 - 2\mu a + a^2}{2}\right\} \cdot \tau^{p-1} e^{-q\tau} \\
 &= \tau^{\frac{1}{2}} \exp\left\{-\frac{1}{2}c\tau\mu^2 + c\tau a\mu\right\} \cdot \tau^{p-1} \exp\left\{-\left(q + \frac{ca^2}{2}\right)\tau\right\}.
 \end{aligned}$$

Επομένως, παίρνουμε την από κοινού posterior κατανομή των  $\mu$  και  $\tau$  ως εξής:

$$\begin{aligned}
 \pi(\mu, \tau | y) &\propto \pi(\mu, \tau) \cdot f(y | \mu, \tau) \\
 &\propto \tau^{\frac{1}{2}} \exp\left\{-\frac{1}{2}c\tau\mu^2 + c\tau a\mu\right\} \cdot \exp\left\{-\frac{1}{2}n\tau\mu^2 + n\tau\bar{y}\mu\right\} \\
 &\quad \times \tau^{p-1} \exp\left\{-\left(q + \frac{ca^2}{2}\right)\tau\right\} \cdot \tau^{\frac{n}{2}} \exp\left\{-\frac{1}{2}\sum_{i=1}^n y_i^2 \tau\right\} \\
 &= \tau^{\frac{1}{2}} \exp\left\{-\frac{1}{2}\underbrace{(c+n)}_{c_n} \tau\mu^2 + \tau(ca + n\bar{y})\mu\right\} \cdot \tau^{p+\frac{n}{2}-1} \exp\left\{-\left(q + \frac{ca^2}{2} + \frac{1}{2}\sum_{i=1}^n y_i^2\right)\tau\right\} \\
 &= \tau^{\frac{1}{2}} \exp\left\{-\frac{c+n}{2}\tau\mu^2 + \underbrace{(c+n)}_{c_n} \tau \frac{ca + n\bar{y}}{c+n} \mu\right\} \cdot \tau^{p+\frac{n}{2}-1} \exp\left\{-\left(q + \frac{ca^2}{2} + \frac{1}{2}\sum_{i=1}^n y_i^2\right)\tau\right\} \\
 &= \tau^{\frac{1}{2}} \exp\left\{-\frac{1}{2}c_n\tau\mu^2 + c_n\tau a_n\mu - \frac{1}{2}c_n\tau a_n^2 + \frac{1}{2}c_n\tau a_n^2\right\} \\
 &\quad \times \tau^{p+\frac{n}{2}-1} \exp\left\{-\left(q + \frac{ca^2}{2} + \frac{1}{2}\sum_{i=1}^n y_i^2\right)\tau\right\}
 \end{aligned}$$

$$= \tau^{\frac{1}{2}} \exp \left\{ -\frac{c_n \tau (\mu - a_n)^2}{2} \right\} \cdot \tau^{p+\frac{n}{2}-1} \exp \left\{ -\left( q + \frac{ca^2}{2} + \frac{1}{2} \sum_{i=1}^n y_i^2 - \frac{c_n a_n^2}{2} \right) \tau \right\}.$$

Υπολογίζουμε ότι:

$$c_n a_n^2 = (c+n) \left( \frac{ca + n\bar{y}}{c+n} \right)^2 = \frac{(ca + n\bar{y})^2}{c+n}.$$

Δηλαδή,

$$\mu | \tau, y \sim \mathcal{N} \left( \frac{ca + n\bar{y}}{c+n}, \frac{\tau^{-1}}{c+n} \right), \quad \tau | y \sim \text{Gamma} \left( p + \frac{n}{2}, q + \frac{ca^2}{2} + \frac{1}{2} \sum_{i=1}^n y_i^2 - \frac{(ca + n\bar{y})^2}{2(c+n)} \right).$$

Επιπλέον, παίρνουμε τη δεσμευμένη posterior κατανομή του  $\tau$  ως εξής:

$$\begin{aligned} \pi(\tau | \mu, y) &\propto \pi(\mu, \tau) \cdot f(y | \mu, \tau) \\ &\propto \tau^{p+\frac{1}{2}-1} \exp \left\{ -\left[ q + \frac{c(\mu - a)^2}{2} \right] \tau \right\} \cdot \tau^{\frac{n}{2}} \exp \left\{ -\frac{1}{2} \sum_{i=1}^n (y_i - \mu)^2 \tau \right\} \\ &= \tau^{p+\frac{n+1}{2}-1} \exp \left\{ -\left[ q + \frac{c(\mu - a)^2}{2} + \frac{1}{2} \sum_{i=1}^n (y_i - \mu)^2 \right] \tau \right\}. \end{aligned}$$

Δηλαδή,

$$\tau | \mu, y \sim \text{Gamma} \left( p + \frac{n+1}{2}, q + \frac{c(\mu - a)^2}{2} + \frac{1}{2} \sum_{i=1}^n (y_i - \mu)^2 \right).$$

**Ορισμός 1.1.** Λέμε ότι μία τυχαία μεταβλητή  $X$  ακολουθεί τη γενικευμένη κατανομή Student's t με μέσο  $\mu \in \mathbb{R}$ , διασπορά  $\sigma^2 > 0$ ,  $\nu > 0$  βαθμούς ελευθερίας και γράφουμε  $X \sim t_\nu(\mu, \sigma^2)$ , αν έχει συνάρτηση πυκνότητας πιθανότητας:

$$f_X(x | \mu, \sigma^2, \nu) = \frac{\Gamma(\frac{\nu+1}{2})}{\Gamma(\frac{\nu}{2})} \frac{1}{\sqrt{\nu\pi\sigma^2}} \left[ 1 + \frac{1}{\nu\sigma^2} (x - \mu)^2 \right]^{-\frac{\nu+1}{2}}, \quad x \in \mathbb{R}.$$

Τέλος, ορίζουμε:

$$p_n = p + \frac{n}{2}, \quad q_n = q + \frac{ca^2}{2} + \frac{1}{2} \sum_{i=1}^n y_i^2 - \frac{c_n a_n^2}{2}.$$

Τότε, υπολογίζουμε την περιθώρια posterior κατανομή του  $\mu$  ως εξής:

$$\begin{aligned} \pi(\mu | y) &= \int \pi(\mu, \tau | y) d\tau \\ &\propto \int \tau^{p+\frac{n+1}{2}-1} \exp \left\{ -\left[ q + \frac{c(\mu - a)^2}{2} + \frac{1}{2} \sum_{i=1}^n (y_i - \mu)^2 \right] \tau \right\} d\tau \\ &\propto \left[ q + \frac{c(\mu - a)^2}{2} + \frac{1}{2} \sum_{i=1}^n (y_i - \mu)^2 \right]^{-(p+\frac{n+1}{2})} \\ &= \left[ q + \frac{ca^2}{2} + \frac{1}{2} \sum_{i=1}^n y_i^2 + \frac{c+n}{2} \mu^2 - (ca + n\bar{y}) \mu \right]^{-p_n - \frac{1}{2}} \end{aligned}$$

$$\begin{aligned}
&= \left[ q + \frac{ca^2}{2} + \frac{1}{2} \sum_{i=1}^n y_i^2 - \frac{c_n a_n^2}{2} + \frac{c_n (\mu - a_n)^2}{2} \right]^{-\frac{2p_n+1}{2}} \\
&\propto \left[ 1 + \frac{c_n (\mu - a_n)^2}{2q_n} \right]^{-\frac{2p_n+1}{2}} \\
&= \left[ 1 + \frac{1}{2p_n} \frac{(\mu - a_n)^2}{\frac{q_n}{c_n p_n}} \right]^{-\frac{2p_n+1}{2}}.
\end{aligned}$$

Δηλαδή,

$$\mu | y \sim t_{2p_n} \left( a_n, \frac{q_n}{c_n p_n} \right).$$

Πρώτα θα υλοποιήσουμε έναν δειγματολήπτη Gibbs που προσομοιώνει εναλλάξ από τις δεσμευμένες posterior κατανομές των παραμέτρων  $\mu$  και  $\tau$ .

```



MCMCnorm = function(Y, mu0, tau0, a, c, p, q, niter, nburn) {
  n = length(Y)
  S = sum(Y)
  cn = c + n
  an = (c * a + S)/cn
  mu = numeric(niter)
  tau = numeric(niter)
  mu[1] = mu0
  tau[1] = tau0
  for (i in 2:niter) {
    mu[i] = rnorm(1, an, (cn * tau[i - 1])^(-0.5))
    tau[i] = rgamma(1, p + (n + 1)/2, q + c * (mu[i] - a)^2/2 + sum((Y -
      mu[i])^2)/2)
  }
  return(list(mu = mu[-(1:nburn)], tau = tau[-(1:nburn)]))
}

```

```

posterior = MCMCnorm(Y, 0, 1, 0, 0, 0.5, 0, 5000, 1000)
par(mfrow = c(1, 2))
hist(posterior$mu, "FD", freq = FALSE, main = NA, xlab = expression(mu))
abline(v = mu, col = 2, lty = 2)
hist(posterior$tau, "FD", freq = FALSE, main = NA, xlab = expression(tau))
abline(v = tau, col = 2, lty = 2)


```



Έπειτα, θα υλοποιήσουμε τη μέθοδο της σύνθεσης που προσομοιώνει πρώτα από την περιθώρια posterior κατανομή της παραμέτρου  $\tau$  και στη συνέχεια από τη δεσμευμένη posterior κατανομή της παραμέτρου  $\mu$ .

```
CMnorm = function(Y, a, c, p, q, niter) {
  n = length(Y)
  S = sum(Y)
  cn = c + n
  an = (c * a + S)/cn
  pn = p + n/2
  qn = q + c * a^2/2 + sum(Y^2)/2 - cn * an^2/2
  mu = numeric(niter)
  tau = numeric(niter)
  for (i in 1:niter) {
    tau[i] = rgamma(1, pn, qn)
    mu[i] = rnorm(1, an, (cn * tau[i])^(-0.5))
  }
  return(list(mu = mu, tau = tau))
}

posterior = CMnorm(Y, 0, 0, 0.5, 0, 4000)
par(mfrow = c(1, 2))
hist(posterior$mu, "FD", freq = FALSE, main = NA, xlab = expression(mu))
abline(v = mu, col = 2, lty = 2)
hist(posterior$tau, "FD", freq = FALSE, main = NA, xlab = expression(tau))
abline(v = tau, col = 2, lty = 2)
```



## 1.2 Γενικευμένη Κατανομή Student's t

Έστω τυχαίο δείγμα  $y_1, \dots, y_n$  από τη γενικευμένη κατανομή Student's t με μέσο  $\mu \in \mathbb{R}$ , ακρίβεια  $\tau > 0$  και  $\nu > 0$  βαθμούς ελευθερίας, δηλαδή:

$$f(y_i | \mu, \tau, \nu) = \frac{\Gamma(\frac{\nu+1}{2})}{\Gamma(\frac{\nu}{2})} \sqrt{\frac{\tau}{\nu\pi}} \left[ 1 + \frac{1}{\nu} \tau (y_i - \mu)^2 \right]^{-\frac{\nu+1}{2}}, \quad y_i \in \mathbb{R}.$$

Θεωρούμε τις τυχαίες μεταβλητές  $W_i \sim \mathcal{N}(0, \tau^{-1})$  και  $V_i \sim \chi_\nu^2 \equiv \text{Gamma}(\frac{\nu}{2}, \frac{1}{2})$ . Τότε, παρατηρούμε ότι:

$$Y_i \stackrel{d}{=} \frac{W_i}{\sqrt{\frac{V_i}{\nu}}} + \mu.$$

Θέτουμε  $Z_i = \frac{V_i}{\nu}$ . Τότε,  $Z_i \sim \text{Gamma}(\frac{\nu}{2}, \frac{\nu}{2})$ . Παρατηρούμε ότι:

$$Y_i | z_i \stackrel{d}{=} \frac{W_i}{\sqrt{z_i}} + \mu \sim \mathcal{N}(\mu, \tau^{-1} z_i^{-1}).$$

Θεωρούμε γνωστούς τους βαθμούς ελευθερίας  $\nu$  και prior ανεξαρτησία για τις παραμέτρους  $\mu, \tau$  με κατανομές  $\mu \sim \mathcal{N}(a, c^{-1})$ ,  $\tau \sim \text{Gamma}(p, q)$ . Να υπολογιστούν οι δεσμευμένες posterior κατανομές των παραμέτρων  $\mu, \tau$  και των λανθανουσών μεταβλητών  $z_i$ .

Λύση.

Η από κοινού prior κατανομή μπορεί να γραφτεί ως:

$$\begin{aligned} \pi(\mu, \tau) &= \pi(\mu) \cdot \pi(\tau) \\ &= \sqrt{\frac{c}{2\pi}} \exp\left\{-\frac{c(\mu - a)^2}{2}\right\} \cdot \frac{q^p}{\Gamma(p)} \tau^{p-1} e^{-q\tau} \\ &\propto \exp\left\{-c \frac{\mu^2 - 2\mu a + a^2}{2}\right\} \cdot \tau^{p-1} e^{-q\tau} \end{aligned}$$



$$\propto \exp \left\{ -\frac{1}{2}c\mu^2 + ca\mu \right\} \cdot \tau^{p-1} e^{-q\tau}.$$

Ορίζουμε:

$$\bar{z}y = \frac{1}{n} \sum_{i=1}^n z_i y_i.$$

Η πλήρης πιθανοφάνεια, δηλαδή η από κοινού πιθανοφάνεια των παρατηρούμενων μεταβλητών  $y_i$  και των λανθανουσών μεταβλητών  $z_i$ , δίνεται από τη σχέση:

$$\begin{aligned} f(y, z | \mu, \tau) &= \prod_{i=1}^n f(y_i, z_i | \mu, \tau) \\ &= \prod_{i=1}^n f(z_i) f(y_i | z_i, \mu, \tau) \\ &= \prod_{i=1}^n \frac{\left(\frac{\nu}{2}\right)^{\frac{\nu}{2}}}{\Gamma\left(\frac{\nu}{2}\right)} z_i^{\frac{\nu}{2}-1} e^{-\frac{\nu}{2}z_i} \sqrt{\frac{\tau z_i}{2\pi}} \exp \left\{ -\frac{\tau z_i (y_i - \mu)^2}{2} \right\} \\ &\propto \tau^{\frac{n}{2}} \cdot \prod_{i=1}^n z_i^{\frac{\nu+1}{2}-1} \exp \left\{ -\sum_{i=1}^n \frac{\nu + \tau(y_i - \mu)^2}{2} z_i \right\} \\ &= \tau^{\frac{n}{2}} \exp \left\{ -\frac{1}{2} \sum_{i=1}^n z_i (y_i - \mu)^2 \tau \right\} \cdot \prod_{i=1}^n z_i^{\frac{\nu+1}{2}-1} \exp \left\{ -\frac{\nu}{2} \sum_{i=1}^n z_i \right\} \\ &= \tau^{\frac{n}{2}} \exp \left\{ -\sum_{i=1}^n \frac{y_i^2 - 2y_i\mu + \mu^2}{2} z_i \tau \right\} \cdot \prod_{i=1}^n z_i^{\frac{\nu+1}{2}-1} \exp \left\{ -\frac{\nu}{2} \sum_{i=1}^n z_i \right\} \\ &= \exp \left\{ -\frac{1}{2} n\tau \bar{z} \mu^2 + n\tau \bar{z} y \mu \right\} \cdot \tau^{\frac{n}{2}} \exp \left\{ -\frac{1}{2} \sum_{i=1}^n z_i y_i^2 \tau \right\} \cdot \prod_{i=1}^n z_i^{\frac{\nu+1}{2}-1} \exp \left\{ -\frac{\nu}{2} \sum_{i=1}^n z_i \right\}. \end{aligned}$$

Επομένως, παίρνουμε τις δεσμευμένες posterior κατανομές των παραμέτρων  $\mu$  και  $\tau$  ως εξής:

$$\begin{aligned} \pi(\mu | \tau, z, y) &\propto \pi(\mu, \tau, z | y) \\ &\propto \pi(\mu, \tau) \cdot f(y, z | \mu, \tau) \\ &\propto \exp \left\{ -\frac{1}{2}c\mu^2 + ca\mu \right\} \cdot \exp \left\{ -\frac{1}{2}n\tau \bar{z} \mu^2 + n\tau \bar{z} y \mu \right\} \\ &= \exp \left\{ -\frac{1}{2} \underbrace{(c + n\tau \bar{z})}_{c_n} \mu^2 + (ca + n\tau \bar{z} y) \mu \right\} \\ &= \exp \left\{ -\frac{c + n\tau \bar{z}}{2} \mu^2 + \underbrace{(c + n\tau \bar{z})}_{c_n} \underbrace{\frac{ca + n\tau \bar{z} y}{c + n\tau \bar{z}}}_{a_n} \mu \right\}, \end{aligned}$$

$$\begin{aligned} \pi(\tau | \mu, z, y) &\propto \pi(\mu, \tau) \cdot f(y, z | \mu, \tau) \\ &\propto \tau^{p-1} e^{-q\tau} \cdot \tau^{\frac{n}{2}} \exp \left\{ -\frac{1}{2} \sum_{i=1}^n z_i (y_i - \mu)^2 \tau \right\} \end{aligned}$$

$$= \tau^{p+\frac{n}{2}-1} \exp \left\{ - \left[ q + \frac{1}{2} \sum_{i=1}^n z_i (y_i - \mu)^2 \right] \tau \right\}.$$

Επιπλέον, παίρνουμε τη δεσμευμένη posterior κατανομή των λανθανουσών μεταβλητών  $z_i$  ως εξής:

$$f(z_i | y_i, \mu, \tau) \propto f(y_i, z_i | \mu, \tau) \propto z_i^{\frac{\nu+1}{2}-1} \exp \left\{ - \frac{\nu + \tau(y_i - \mu)^2}{2} z_i \right\}.$$

Δηλαδή,


$$\mu | \tau, z, y \sim \mathcal{N} \left( \frac{ca + n\tau\bar{z}\bar{y}}{c + n\tau\bar{z}}, \frac{1}{c + n\tau\bar{z}} \right), \quad \tau | \mu, z, y \sim \text{Gamma} \left( p + \frac{n}{2}, q + \frac{1}{2} \sum_{i=1}^n z_i (y_i - \mu)^2 \right),$$

$$z_i | y_i, \mu, \tau \sim \text{Gamma} \left( \frac{\nu + 1}{2}, \frac{\nu + \tau(y_i - \mu)^2}{2} \right).$$

```
MCMCt = function(Y, mu0, tau0, nu, a, c, p, q, niter, nburn) {
  n = length(Y)
  mu = numeric(niter)
  tau = numeric(niter)
  Z = matrix(0, niter, n)
  mu[1] = mu0
  tau[1] = tau0
  Z[1, ] = rgamma(n, (nu + 1)/2, (nu + tau[1] * (Y - mu[1])^2)/2)
  for (i in 2:niter) {
    mu[i] = rnorm(1, (c * a + tau[i - 1] * sum(Z[i - 1, ] * Y))/(c + tau[i - 1] * sum(Z[i - 1, ])), (c + n * tau[i - 1])^(-0.5))
    tau[i] = rgamma(1, p + n/2, q + sum(Z[i - 1, ] * (Y - mu[i])^2)/2)
    Z[i, ] = rgamma(n, (nu + 1)/2, (nu + tau[i] * (Y - mu[i])^2)/2)
  }
  return(list(mu = mu[-(1:nburn)], tau = tau[-(1:nburn)], Z = Z[-(1:nburn), ]))
}
```

```
library(mvtnorm)
n = 1000
mu = 1
tau = 2
nu = 10
Y = rmvt(n, matrix(tau^(-1)), nu, mu)
posterior = MCMCt(Y, 0, 1, nu, 0, 0, 0.5, 0, 5000, 1000)
par(mfrow = c(1, 2))
hist(posterior$mu, "FD", freq = FALSE, main = NA, xlab = expression(mu))
abline(v = mu, col = 2, lty = 2)
```

```
hist(posterior$tau, "FD", freq = FALSE, main = NA, xlab = expression(tau))
abline(v = tau, col = 2, lty = 2)
```



Εναλλακτικά, μπορούμε να σχεδιάσουμε έναν αλγόριθμο Random Walk Metropolis-Hastings. Για την παράμετρο  $\mu \in \mathbb{R}$  θεωρούμε την προτείνουσα τυχαία μεταβλητή  $\mu^* | \mu_{\ell-1} \sim \mathcal{N}(\mu_{\ell-1}, \sigma_\mu^2)$  με πιθανότητα αποδοχής:

$$A(\mu_{\ell-1}, \mu^*) = \min \left\{ \frac{\pi(\mu^*)}{\pi(\mu_{\ell-1})} \frac{f(y | \mu^*, \tau_{\ell-1})}{f(y | \mu_{\ell-1}, \tau_{\ell-1})}, 1 \right\}.$$

Για την παράμετρο  $\tau > 0$  θεωρούμε την προτείνουσα τυχαία μεταβλητή  $\tau^* | \tau_{\ell-1} \sim \text{Lognormal}(\log \tau_{\ell-1}, \sigma_\tau^2)$  με δεσμευμένη συνάρτηση πυκνότητας πιθανότητας:

$$f(\tau^* | \tau_{\ell-1}) = \frac{1}{\sqrt{2\pi\sigma_\tau^2\tau_{\ell-1}^2}} \exp \left\{ -\frac{(\log \tau^* - \log \tau_{\ell-1})^2}{2\sigma_\tau^2} \right\}.$$

Τότε, η πιθανότητα αποδοχής της τιμής  $\tau^*$  δίνεται από τη σχέση:

$$A(\tau_{\ell-1}, \tau^*) = \min \left\{ \frac{\pi(\tau^*)}{\pi(\tau_{\ell-1})} \frac{f(y | \mu_\ell, \tau^*)}{f(y | \mu_\ell, \tau_{\ell-1})} \frac{\tau^*}{\tau_{\ell-1}}, 1 \right\}.$$

Αν  $Z \sim \mathcal{N}(0, \sigma_\tau^2)$ , τότε γνωρίζουμε ότι  $\tau^* | \tau_{\ell-1} \sim \tau_{\ell-1} e^Z$ . Επομένως, η συγκεκριμένη προτείνουσα καλείται πολλαπλασιαστικός τυχαίος περίπατος και μπορεί να γραφτεί ισοδύναμα ως τυχαίος περίπατος σε λογαριθμική κλίμακα με τον ακόλουθο τρόπο:  $\log \tau^* | \tau_{\ell-1} \sim \mathcal{N}(\log \tau_{\ell-1}, \sigma_\tau^2)$ .

```
RWMHt = function(Y, mu0, tau0, nu, musd, tausd, niter, nburn) {
  library(mvtnorm)
  mu = numeric(niter)
  tau = numeric(niter)
  mu[1] = mu0
  tau[1] = tau0
  for (i in 2:niter) {
    mustar = rnorm(1, mu[i - 1], musd)
```

```


logA = sum(dmvt(Y, mustar, matrix(tau[i - 1]^(-1)), nu) - dmvt(Y, mu[i -
  1], matrix(tau[i - 1]^(-1)), nu))
mu[i] = ifelse(log(runif(1)) < logA, mustar, mu[i - 1])
taustar = tau[i - 1] * exp(rnorm(1, sd = tausd))
logA = log(taustar/tau[i - 1])/2 + sum(dmvt(Y, mu[i], matrix(taustar^(-1)),
  nu) - dmvt(Y, mu[i], matrix(tau[i - 1]^(-1)), nu))
tau[i] = ifelse(log(runif(1)) < logA, taustar, tau[i - 1])
}
return(list(mu = mu[-(1:nburn)], tau = tau[-(1:nburn)]))
}

```

```

posterior = RWMHt(Y, 0, 1, nu, 0.05, 0.1, 5000, 1000)
par(mfrow = c(1, 2))
plot(posterior$mu, type = "l", ylab = expression(mu))
abline(h = mu, col = 2, lty = 2)
plot(posterior$tau, type = "l", ylab = expression(tau))
abline(h = tau, col = 2, lty = 2)


```



```

hist(posterior$mu, "FD", freq = FALSE, main = NA, xlab = expression(mu))
abline(v = mu, col = 2, lty = 2)
hist(posterior$tau, "FD", freq = FALSE, main = NA, xlab = expression(tau))
abline(v = tau, col = 2, lty = 2)

```



### 1.3 Μοντέλο Ανάλυσης Διασποράς με Έναν Παράγοντα

Θεωρούμε το μοντέλο ανάλυσης διασποράς  $y_{ij} = \mu_i + \varepsilon_{ij}$ , όπου  $\varepsilon_i \sim \mathcal{N}(0, \tau^{-1})$  για  $i = 1, 2, \dots, m$  και  $j = 1, 2, \dots, n_i$ . Θεωρούμε prior ανεξαρτησία με κατανομές  $\mu_i \sim \mathcal{N}(a, c^{-1})$  και  $\tau \sim \text{Gamma}(p, q)$ . Να υπολογιστούν οι δεσμευμένες posterior κατανομές των παραμέτρων  $\mu_i$  και  $\tau$ .

Λύση.

Η από κοινού prior κατανομή μπορεί να γραφτεί ως:

$$\begin{aligned}
 \pi(\mu, \tau) &= \pi(\tau) \cdot \prod_{i=1}^m \pi(\mu_i) \\
 &= \frac{q^p}{\Gamma(p)} \tau^{p-1} e^{-q\tau} \cdot \prod_{i=1}^m \sqrt{\frac{c}{2\pi}} \exp\left\{-\frac{c(\mu_i - a)^2}{2}\right\} \\
 &\propto \exp\left\{-c \sum_{i=1}^m \frac{\mu_i^2 - 2a\mu_i + a^2}{2}\right\} \cdot \tau^{p-1} e^{-q\tau} \\
 &\propto \exp\left\{-\frac{c}{2} \sum_{i=1}^m \mu_i^2 + ca \sum_{i=1}^m \mu_i\right\} \cdot \tau^{p-1} e^{-q\tau}.
 \end{aligned}$$

Ορίζουμε:

$$n = \sum_{i=1}^m N_i, \quad \bar{y}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} y_{ij}.$$

Τότε, η πιθανοφάνεια ολόκληρου του δείγματος δίνεται από τη σχέση:

$$\begin{aligned}
 f(y | \mu, \tau) &= \prod_{i=1}^m \prod_{j=1}^{n_i} f(y_{ij} | \mu, \tau) \\
 &= \prod_{i=1}^m \prod_{j=1}^{n_i} \sqrt{\frac{\tau}{2\pi}} \exp\left\{-\frac{\tau(y_{ij} - \mu_i)^2}{2}\right\}
 \end{aligned}$$

$$\begin{aligned}
&\propto \tau^{\frac{n}{2}} \exp \left\{ -\frac{1}{2} \sum_{i=1}^m \sum_{j=1}^{n_i} (y_{ij} - \mu_i)^2 \tau \right\} \\
&= \tau^{\frac{n}{2}} \exp \left\{ -\sum_{i=1}^m \sum_{j=1}^{n_i} \frac{y_{ij}^2 - 2y_{ij}\mu_i + \mu_i^2}{2} \tau \right\} \\
&= \exp \left\{ -\frac{1}{2} \tau \sum_{i=1}^m N_i \mu_i^2 + \tau \sum_{i=1}^m N_i \bar{y}_i \mu_i \right\} \cdot \tau^{\frac{n}{2}} \exp \left\{ -\frac{1}{2} \sum_{i=1}^m \sum_{j=1}^{n_i} y_{ij}^2 \tau \right\}.
\end{aligned}$$

Επομένως, παίρνουμε τις δεσμευμένες posterior κατανομές των  $\mu_i$  και  $\tau$  ως εξής:

$$\begin{aligned}
\pi(\mu_i | \tau, y) &\propto \pi(\mu, \tau | y) \\
&\propto \pi(\mu, \tau) \cdot f(y | \mu, \tau) \\
&\propto \exp \left\{ -\frac{c}{2} \mu_i^2 + ca \mu_i \right\} \cdot \exp \left\{ -\frac{1}{2} n_i \tau \mu_i^2 + n_i \tau \bar{y}_i \mu_i \right\} \\
&= \exp \left\{ -\frac{1}{2} \underbrace{(c + n_i \tau)}_{c_n} \mu_i^2 + (ca + n_i \tau \bar{y}_i) \mu_i \right\} \\
&= \exp \left\{ -\frac{c + n_i \tau}{2} \mu_i^2 + \underbrace{(c + n_i \tau)}_{c_n} \underbrace{\frac{ca + n_i \tau \bar{y}_i}{c + n_i \tau}}_{a_n} \mu_i \right\},
\end{aligned}$$

$$\begin{aligned}
\pi(\tau | \mu, y) &\propto \pi(\mu, \tau) \cdot f(y | \mu, \tau) \\
&\propto \tau^{p-1} e^{-q\tau} \cdot \tau^{\frac{n}{2}} \exp \left\{ -\frac{1}{2} \sum_{i=1}^m \sum_{j=1}^{n_i} (y_{ij} - \mu_i)^2 \tau \right\} \\
&= \tau^{p+\frac{n}{2}-1} \exp \left\{ -\left[ q + \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^{n_i} (y_{ij} - \mu_i)^2 \right] \tau \right\}.
\end{aligned}$$

Δηλαδή,

$$\mu_i | \tau, y \sim \mathcal{N} \left( \frac{ca + n_i \tau \bar{y}_i}{c + n_i \tau}, \frac{1}{c + n_i \tau} \right), \quad \tau | \mu, y \sim \text{Gamma} \left( p + \frac{n}{2}, q + \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^{n_i} (y_{ij} - \mu_i)^2 \right).$$

```

MCMCAnova = function(Y, X, mu0, tau0, a, c, p, q, niter, nburn) {
  n = length(Y)
  m = length(levels(X))
  N = table(X)
  S = aggregate(Y ~ X, FUN = sum)[, 2]
  mu = matrix(0, niter, m)
  tau = numeric(niter)
  mu[1, ] = mu0
  tau[1] = tau0
  for (i in 2:niter) {
    mu[i, ] = rnorm(m, (c * a + tau[i - 1] * S)/(c + N * tau[i - 1]), (c +


```

```

      N * tau[i - 1])^(-0.5))
    tau[i] = rgamma(1, p + n/2, q + sum((Y - mu[i, X])^2)/2)
  }
  return(list(tau = tau[-(1:nburn)], mu = mu[-(1:nburn), ]))
}

n = 1000
m = 2
tau = 3
mu = c(1, 4)
X = factor(sample(m, n, replace = TRUE), levels = 1:m)
Y = rnorm(n, mu[X], tau^(-0.5))
posterior = MCMCanova(Y, X, numeric(m), 1, 0, 0, 0.5, 0, 5000, 1000)
par(mfrow = c(1, 3))
hist(posterior$mu[, 1], "FD", freq = FALSE, main = NA, xlab = expression(mu[1]))
abline(v = mu[1], col = 2, lty = 2)
hist(posterior$mu[, 2], "FD", freq = FALSE, main = NA, xlab = expression(mu[2]))
abline(v = mu[2], col = 2, lty = 2)
hist(posterior$tau, "FD", freq = FALSE, main = NA, xlab = expression(tau))
abline(v = tau, col = 2, lty = 2)

```



#### 1.4 Γραμμικό Μοντέλο με Student's t Σφάλματα

Θεωρούμε το γραμμικό μοντέλο  $y_i = x_i^T \beta + \varepsilon_i$ , όπου  $\beta \in \mathbb{R}^k$  και τα τυχαία σφάλματα  $\varepsilon_i$  ακολουθούν τη γενικευμένη κατανομή Student's t με μέσο 0, ακρίβεια  $\tau > 0$  και  $\nu > 0$  βαθμούς ελευθερίας, δηλαδή:

$$f(y_i | \beta, \tau, \nu) = \frac{\Gamma(\frac{\nu+1}{2})}{\Gamma(\frac{\nu}{2})} \sqrt{\frac{\tau}{\nu\pi}} \left[ 1 + \frac{1}{\nu} \tau (y_i - x_i^T \beta)^2 \right]^{-\frac{\nu+1}{2}}, \quad y_i \in \mathbb{R}.$$

Θεωρούμε τις τυχαίες μεταβλητές  $W_i \sim \mathcal{N}(0, \tau^{-1})$  και  $V_i \sim \chi_\nu^2 \equiv \text{Gamma}(\frac{\nu}{2}, \frac{1}{2})$ . Τότε, παρατηρούμε ότι:

$$Y_i \stackrel{d}{=} \frac{W_i}{\sqrt{\frac{V_i}{\nu}}} + x_i^T \beta.$$

Θέτουμε  $Z_i = \frac{V_i}{\nu}$ . Τότε,  $Z_i \sim \text{Gamma}(\frac{\nu}{2}, \frac{\nu}{2})$ . Παρατηρούμε ότι:

$$Y_i | z_i \stackrel{d}{=} \frac{W_i}{\sqrt{z_i}} + x_i^T \beta \sim \mathcal{N}(x_i^T \beta, \tau^{-1} z_i^{-1}).$$

Θεωρούμε γνωστή την παράμετρο  $\nu$  και τη δεσμευμένα συζυγή prior κατανομή  $\beta | \tau \sim \mathcal{N}_k(a, \tau^{-1} C^{-1})$ ,  $\tau \sim \text{Gamma}(p, q)$ . Να υπολογιστούν οι δεσμευμένες posterior κατανομές  $\pi(\beta, \tau | z, y)$ ,  $\pi(\tau | \beta, z, y)$  και  $f(z_i | y_i, \beta, \tau)$ .

Λύση.

Η από κοινού prior κατανομή μπορεί να γραφτεί ως:

$$\begin{aligned} \pi(\beta, \tau) &= \pi(\beta | \tau) \cdot \pi(\tau) \\ &= (2\pi)^{-\frac{k}{2}} |\tau^{-1} C^{-1}|^{-\frac{1}{2}} \exp \left\{ -\frac{\tau(\beta - a)^T C (\beta - a)}{2} \right\} \cdot \frac{q^p}{\Gamma(p)} \tau^{p-1} e^{-q\tau} \\ &\propto \tau^{p+\frac{k}{2}-1} \exp \left\{ -\left[ q + \frac{(\beta - a)^T C (\beta - a)}{2} \right] \tau \right\} \\ &= \tau^{\frac{k}{2}} \exp \left\{ -\tau \frac{\beta^T C \beta - 2\beta^T C a + a^T C a}{2} \right\} \cdot \tau^{p-1} e^{-q\tau} \\ &= \tau^{\frac{k}{2}} \exp \left\{ -\frac{\beta^T \tau C \beta}{2} + \beta^T \tau C a \right\} \cdot \tau^{p-1} \exp \left\{ -\left( q + \frac{a^T C a}{2} \right) \tau \right\}. \end{aligned}$$

Η πλήρης πιθανοφάνεια, δηλαδή η από κοινού πιθανοφάνεια των παρατηρούμενων μεταβλητών  $y_i$  και των λανθανουσών μεταβλητών  $z_i$ , δίνεται από τη σχέση:

$$\begin{aligned} f(y, z | \beta, \tau) &= \prod_{i=1}^n f(y_i, z_i | \beta, \tau) \\ &= \prod_{i=1}^n f(z_i) f(y_i | z_i, \beta, \tau) \\ &= \prod_{i=1}^n \frac{(\frac{\nu}{2})^{\frac{\nu}{2}}}{\Gamma(\frac{\nu}{2})} z_i^{\frac{\nu}{2}-1} e^{-\frac{\nu}{2} z_i} \sqrt{\frac{\tau z_i}{2\pi}} \exp \left\{ -\frac{\tau z_i (y_i - x_i^T \beta)^2}{2} \right\} \\ &\propto \tau^{\frac{n}{2}} \cdot \prod_{i=1}^n z_i^{\frac{\nu+1}{2}-1} \exp \left\{ -\sum_{i=1}^n \frac{\nu + \tau (y_i - x_i^T \beta)^2}{2} z_i \right\}. \end{aligned}$$

Ορίζουμε  $y = (y_1, \dots, y_n)^T \in \mathbb{R}^n$ , τον πίνακα σχεδιασμού  $X = (x_1, \dots, x_n)^T \in \mathbb{R}^{n \times k}$  και τον διαγώνιο πίνακα βαρών  $Z = \text{diag}(z_1, \dots, z_n) \in \mathbb{R}^{n \times n}$ . Τότε, παρατηρούμε ότι  $y | z \sim N_n(X\beta, \tau^{-1} Z^{-1})$ . Δηλαδή, η πλήρης



πιθανοφάνεια ολόκληρου του δείγματος δίνεται από τη σχέση:

$$\begin{aligned}
f(y, z | \beta, \tau) &= f(z) \cdot f(y | z, \beta, \tau) \\
&= f(y | z, \beta, \tau) \cdot \prod_{i=1}^n f(z_i) \\
&= (2\pi)^{-\frac{n}{2}} |\tau^{-1} Z^{-1}|^{-\frac{1}{2}} \exp \left\{ -\frac{\tau(y - X\beta)^T Z (y - X\beta)}{2} \right\} \cdot \prod_{i=1}^n \frac{(\frac{\nu}{2})^{\frac{\nu}{2}}}{\Gamma(\frac{\nu}{2})} z_i^{\frac{\nu}{2}-1} e^{-\frac{\nu}{2} z_i} \\
&\propto \tau^{\frac{n}{2}} \exp \left\{ -\frac{(y - X\beta)^T Z (y - X\beta)}{2} \tau \right\} \cdot |Z|^{\frac{1}{2}} \prod_{i=1}^n z_i^{\frac{\nu}{2}-1} \exp \left\{ -\frac{\nu}{2} \sum_{i=1}^n z_i \right\} \\
&= \tau^{\frac{n}{2}} \exp \left\{ -\frac{y^T Z y - 2\beta^T X^T Z y + \beta^T X^T Z X \beta}{2} \tau \right\} \cdot \prod_{i=1}^n z_i^{\frac{1}{2}} \prod_{i=1}^n z_i^{\frac{\nu}{2}-1} \exp \left\{ -\frac{\nu}{2} \sum_{i=1}^n z_i \right\} \\
&= \exp \left\{ -\frac{\beta^T \tau X^T Z X \beta}{2} + \beta^T \tau X^T Z y \right\} \cdot \tau^{\frac{n}{2}} \exp \left\{ -\frac{y^T Z y}{2} \tau \right\} \\
&\quad \times \prod_{i=1}^n z_i^{\frac{\nu+1}{2}-1} \exp \left\{ -\frac{\nu}{2} \sum_{i=1}^n z_i \right\}.
\end{aligned}$$

Επομένως, παίρνουμε την από κοινού δεσμευμένη posterior κατανομή των  $\beta$  και  $\tau$  ως εξής:

$$\begin{aligned}
\pi(\beta, \tau | z, y) &\propto \pi(\beta, \tau, z | y) \\
&\propto \pi(\beta, \tau) \cdot f(y, z | \beta, \tau) \\
&\propto \tau^{\frac{k}{2}} \exp \left\{ -\frac{\beta^T \tau C \beta}{2} + \beta^T \tau C a \right\} \cdot \tau^{p-1} \exp \left\{ -\left( q + \frac{a^T C a}{2} \right) \tau \right\} \\
&\quad \times \exp \left\{ -\frac{\beta^T \tau X^T Z X \beta}{2} + \beta^T \tau X^T Z y \right\} \cdot \tau^{\frac{n}{2}} \exp \left\{ -\frac{y^T Z y}{2} \tau \right\} \\
&= \tau^{\frac{k}{2}} \exp \left\{ -\frac{1}{2} \beta^T \tau \underbrace{(C + X^T Z X)}_{C_n} \beta + \beta^T \tau (C a + X^T Z y) \right\} \\
&\quad \times \tau^{p+\frac{n}{2}-1} \exp \left\{ -\left( q + \frac{a^T C a + y^T Z y}{2} \right) \tau \right\} \\
&= \tau^{\frac{k}{2}} \exp \left\{ -\frac{\beta^T \tau C_n \beta}{2} + \beta^T \tau \underbrace{(C + X^T Z X)}_{C_n} \underbrace{(C a + X^T Z y)}_{a_n} \right\} \\
&\quad \times \tau^{p+\frac{n}{2}-1} \exp \left\{ -\left( q + \frac{a^T C a + y^T Z y}{2} \right) \tau \right\} \\
&= \tau^{\frac{k}{2}} \exp \left\{ -\frac{\beta^T \tau C_n \beta}{2} + \beta^T \tau C_n a_n - \frac{a_n^T \tau C_n a_n}{2} + \frac{a_n^T \tau C_n a_n}{2} \right\} \\
&\quad \times \tau^{p+\frac{n}{2}-1} \exp \left\{ -\left( q + \frac{a^T C a + y^T Z y}{2} \right) \tau \right\} \\
&= \tau^{\frac{k}{2}} \exp \left\{ -\frac{\tau(\beta - a_n)^T C_n (\beta - a_n)}{2} \right\} \\
&\quad \times \tau^{p+\frac{n}{2}-1} \exp \left\{ -\left( q + \frac{a^T C a + y^T Z y - a_n^T C_n a_n}{2} \right) \tau \right\}.
\end{aligned}$$

Υπολογίζουμε ότι:

$$a_n^T C_n a_n = (Ca + X^T Z y)^T (C + X^T Z X)^{-1} (Ca + X^T Z y).$$

Δηλαδή,

$$\beta \mid \tau, z, y \sim \mathcal{N}_k \left( (C + X^T Z X)^{-1} (Ca + X^T Z y), \tau^{-1} (C + X^T Z X)^{-1} \right),$$

$$\tau \mid z, y \sim \text{Gamma} \left( p + \frac{n}{2}, q + \frac{a^T C a + y^T Z y - a_n^T C_n a_n}{2} \right).$$

Επιπλέον, παίρνουμε τη δεσμευμένη posterior κατανομή του  $\tau$  ως εξής:

$$\begin{aligned} \pi(\tau \mid \beta, z, y) &\propto \pi(\beta, \tau) \cdot f(y, z \mid \beta, \tau) \\ &\propto \tau^{p + \frac{k}{2} - 1} \exp \left\{ - \left[ q + \frac{(\beta - a)^T C (\beta - a)}{2} \right] \tau \right\} \cdot \tau^{\frac{n}{2}} \exp \left\{ - \frac{(y - X\beta)^T Z (y - X\beta)}{2} \tau \right\} \\ &= \tau^{p + \frac{n+k}{2} - 1} \exp \left\{ - \left[ q + \frac{(\beta - a)^T C (\beta - a) + (y - X\beta)^T Z (y - X\beta)}{2} \right] \tau \right\}. \end{aligned}$$

Δηλαδή,

$$\tau \mid \beta, z, y \sim \text{Gamma} \left( p + \frac{n+k}{2}, q + \frac{(\beta - a)^T C (\beta - a) + (y - X\beta)^T Z (y - X\beta)}{2} \right).$$

Τέλος, παίρνουμε τη δεσμευμένη posterior κατανομή των λανθανουσών μεταβλητών  $z_i$  ως εξής:

$$f(z_i \mid y_i, \beta, \tau) \propto f(y_i, z_i \mid \beta, \tau) \propto z_i^{\frac{\nu+1}{2}-1} \exp \left\{ - \frac{\nu + \tau (y_i - x_i^T \beta)^2}{2} z_i \right\}.$$

Δηλαδή,

$$z_i \mid y_i, \beta, \tau \sim \text{Gamma} \left( \frac{\nu+1}{2}, \frac{\nu + \tau (y_i - x_i^T \beta)^2}{2} \right).$$

Πρώτα θα υλοποιήσουμε έναν δειγματολήπτη Gibbs που προσομοιώνει διαδοχικά από τις δεσμευμένες posterior κατανομές των παραμέτρων  $\beta, \tau$  και των λανθανουσών μεταβλητών  $z_i$ .


```
MCMCt1m = function(Y, X, beta0, tau0, nu, a, C, p, q, niter, nburn) {
  library(MASS)
  n = length(Y)
  k = dim(X)[2]
  beta = matrix(0, niter, k)
  tau = numeric(niter)
  Z = matrix(0, niter, n)
  beta[1, ] = beta0
  tau[1] = tau0
  Z[1, ] = rgamma(n, (nu + 1)/2, (nu + tau[1] * (Y - X %*% beta[1, ])^2)/2)
  for (i in 2:niter) {
    Cn = C + crossprod(X, Z[i - 1, ] * X)
    an = solve(Cn, C %*% a + crossprod(X, Z[i - 1, ] * Y))
    beta[i, ] = mvrnorm(1, an, solve(Cn)/tau[i - 1])
  }
}
```

```

    tau[i] = rgamma(1, p + (n + k)/2, q + (crossprod(beta[i, ] - a, C %%%
      (beta[i, ] - a)) + crossprod(Y - X %%% beta[i, ], Z[i - 1, ] * (Y -
      X %%% beta[i, ])))/2)
    Z[i, ] = rgamma(n, (nu + 1)/2, (nu + tau[i] * (Y - X %%% beta[i, ])^2)/2)
  }
  return(list(beta = beta[-(1:nburn), ], tau = tau[-(1:nburn)], Z = Z[-(1:nburn),
    ]))
}

library(mvtnorm)
n = 1000
k = 2
beta = c(1, 3)
tau = 2
nu = 10
X = cbind(1, rnorm(n))
Y = X %%% beta + rmvt(n, matrix(tau^(-1)), nu)
posterior = MCMCtM(Y, X, numeric(k), 1, nu, numeric(k), matrix(0, k, k), 0.5,
  0, 5000, 1000)
par(mfrow = c(1, 3))
hist(posterior$beta[, 1], "FD", freq = FALSE, main = NA, xlab = expression(beta[0]))
abline(v = beta[1], col = 2, lty = 2)
hist(posterior$beta[, 2], "FD", freq = FALSE, main = NA, xlab = expression(beta[1]))
abline(v = beta[2], col = 2, lty = 2)
hist(posterior$tau, "FD", freq = FALSE, main = NA, xlab = expression(tau))
abline(v = tau, col = 2, lty = 2)


```



Έπειτα, θα υλοποιήσουμε έναν αλγόριθμο Gibbs που προσομοιώνει εναλλάξ από τις δεσμευμένες posterior κατανομές της παραμέτρου  $(\beta, \tau)$  και των λανθανουσών μεταβλητών  $z_i$ .

```
MCMCt1m = function(Y, X, beta0, tau0, nu, a, C, p, q, niter, nburn) {
  library(MASS)
  n = length(Y)
  k = dim(X)[2]
  beta = matrix(0, niter, k)
  tau = numeric(niter)
  Z = matrix(0, niter, n)
  beta[1, ] = beta0
  tau[1] = tau0
  Z[1, ] = rgamma(n, (nu + 1)/2, (nu + tau[1] * (Y - X %*% beta[1, ])^2)/2)
  for (i in 2:niter) {
    Cn = C + crossprod(X, Z[i - 1, ] * X)
    an = solve(Cn, C %*% a + crossprod(X, Z[i - 1, ] * Y))
    qn = q + (crossprod(a, C %*% a) + crossprod(Y, Z[i - 1, ] * Y) - crossprod(C %*%
      a + crossprod(X, Z[i - 1, ] * Y), an))/2
    tau[i] = rgamma(1, p + n/2, qn)
    beta[i, ] = mvrnorm(1, an, solve(Cn)/tau[i])
    Z[i, ] = rgamma(n, (nu + 1)/2, (nu + tau[i] * (Y - X %*% beta[i, ])^2)/2)
  }
  return(list(beta = beta[-(1:nburn), ], tau = tau[-(1:nburn)], Z = Z[-(1:nburn),
    ]))
}

posterior = MCMCt1m(Y, X, numeric(k), 1, nu, numeric(k), matrix(0, k, k), 0.5,
  0, 5000, 1000)
par(mfrow = c(1, 3))
hist(posterior$beta[, 1], "FD", freq = FALSE, main = NA, xlab = expression(beta[0]))
abline(v = beta[1], col = 2, lty = 2)
hist(posterior$beta[, 2], "FD", freq = FALSE, main = NA, xlab = expression(beta[1]))
abline(v = beta[2], col = 2, lty = 2)
hist(posterior$tau, "FD", freq = FALSE, main = NA, xlab = expression(tau))
abline(v = tau, col = 2, lty = 2)
```



## 1.5 Πολυδιάστατη Κανονική Κατανομή

**Ορισμός 1.2.** Ορίζουμε την πολυδιάστατη συνάρτηση Γάμμα ως εξής:

$$\Gamma_k(x) = \pi^{\frac{k(k-1)}{4}} \prod_{j=1}^k \Gamma\left(x + \frac{1-j}{2}\right), \quad x > \frac{k-1}{2}, \quad k \in \mathbb{N}.$$

**Ορισμός 1.3.** Λέμε ότι ένας θετικά ορισμένος τυχαίος πίνακας  $X \in \mathbb{R}^{k \times k}$  ακολουθεί την κατανομή Wishart με θετικά ορισμένο πίνακα κλίμακας  $A \in \mathbb{R}^{k \times k}$ ,  $\nu > 0$  βαθμούς ελευθερίας και γράφουμε  $X \sim \mathcal{W}_k(A, \nu)$ , αν έχει συνάρτηση πυκνότητας πιθανότητας:

$$f_X(x | A, \nu) = \frac{1}{2^{\frac{\nu k}{2}} |A|^{\frac{\nu}{2}} \Gamma_k\left(\frac{\nu}{2}\right)} |x|^{\frac{\nu-k-1}{2}} e^{-\frac{1}{2}\text{tr}(A^{-1}x)}, \quad x \in \mathbb{R}^{k \times k}.$$

Έστω τυχαίο δείγμα  $y_1, \dots, y_n$  από την πολυδιάστατη κανονική κατανομή  $\mathcal{N}_k(\mu, \Sigma)$ .

- α. Θεωρούμε prior ανεξαρτησία με κατανομές  $\mu \sim \mathcal{N}_k(a, C^{-1})$  και  $\Omega \sim \mathcal{W}_k(A^{-1}, d)$ . Να υπολογιστούν οι δεσμευμένες posterior κατανομές των  $\mu$  και  $\Omega$ .
- β. Θεωρούμε τη συζυγή prior κατανομή  $\mu | \Omega \sim \mathcal{N}_k(a, c^{-1}\Omega^{-1})$ ,  $\Omega \sim \mathcal{W}_k(A^{-1}, d)$ . Να υπολογιστούν οι δεσμευμένες και οι περιθώριες posterior κατανομές των παραμέτρων  $\mu$  και  $\Omega$ .

Λύση.

α. Η από κοινού prior κατανομή μπορεί να γραφτεί ως:

$$\begin{aligned}
\pi(\mu, \Omega) &= \pi(\mu) \cdot \pi(\Omega) \\
&= (2\pi)^{-\frac{k}{2}} |C^{-1}|^{-\frac{1}{2}} \exp \left\{ -\frac{(\mu - a)^T C (\mu - a)}{2} \right\} \cdot \frac{|A|^{\frac{d}{2}}}{2^{\frac{dk}{2}} \Gamma_k \left( \frac{d}{2} \right)} |\Omega|^{\frac{d-k-1}{2}} e^{-\frac{1}{2} \text{tr}(A\Omega)} \\
&\propto \exp \left\{ -\frac{\mu^T C \mu - 2\mu^T C a + a^T C a}{2} \right\} \cdot |\Omega|^{\frac{d-k-1}{2}} e^{-\frac{1}{2} \text{tr}(A\Omega)} \\
&\propto \exp \left\{ -\frac{\mu^T C \mu}{2} + \mu^T C a \right\} \cdot |\Omega|^{\frac{d-k-1}{2}} e^{-\frac{1}{2} \text{tr}(A\Omega)}.
\end{aligned}$$

**Λήμμα 1.1.** Έστω  $x \in \mathbb{R}^n$  και  $A \in \mathbb{R}^{n \times n}$ . Τότε,

$$x^T A x = \text{tr}(x^T A x) = \text{tr}(x x^T A).$$

Η πιθανοφάνεια ολόκληρου του δείγματος δίνεται από τη σχέση:

$$\begin{aligned}
f(y | \mu, \Omega) &= \prod_{i=1}^n f(y_i | \mu, \Omega) \\
&= \prod_{i=1}^n (2\pi)^{-\frac{k}{2}} |\Omega^{-1}|^{-\frac{1}{2}} \exp \left\{ -\frac{(y_i - \mu)^T \Omega (y_i - \mu)}{2} \right\} \\
&\propto |\Omega|^{\frac{n}{2}} \exp \left\{ -\frac{1}{2} \text{tr} \left[ \sum_{i=1}^n (y_i - \mu)(y_i - \mu)^T \Omega \right] \right\} \\
&= |\Omega|^{\frac{n}{2}} \exp \left\{ -\sum_{i=1}^n \frac{y_i^T \Omega y_i - 2\mu^T \Omega y_i + \mu^T \Omega \mu}{2} \right\} \\
&= \exp \left\{ -\frac{\mu^T n \Omega \mu}{2} + \mu^T n \Omega \bar{y} \right\} \cdot |\Omega|^{\frac{n}{2}} \exp \left\{ -\frac{1}{2} \text{tr} \left( \sum_{i=1}^n y_i y_i^T \Omega \right) \right\}.
\end{aligned}$$

Επομένως, παίρνουμε τις δεσμευμένες posterior κατανομές των  $\mu$  και  $\Omega$  ως εξής:

$$\begin{aligned}
\pi(\mu | \Omega, y) &\propto \pi(\mu, \Omega | y) \\
&\propto \pi(\mu, \Omega) \cdot f(y | \mu, \Omega) \\
&\propto \exp \left\{ -\frac{\mu^T C \mu}{2} + \mu^T C a \right\} \cdot \exp \left\{ -\frac{\mu^T n \Omega \mu}{2} + \mu^T n \Omega \bar{y} \right\} \\
&= \exp \left\{ -\frac{1}{2} \mu^T \underbrace{(C + n\Omega)}_{C_n} \mu + \mu^T (C a + n\Omega \bar{y}) \right\} \\
&= \exp \left\{ -\frac{\mu^T (C + n\Omega) \mu}{2} + \mu^T \underbrace{(C + n\Omega)}_{C_n} \underbrace{(C + n\Omega)^{-1} (C a + n\Omega \bar{y})}_{a_n} \right\},
\end{aligned}$$

$$\begin{aligned}
\pi(\Omega \mid \mu, y) &\propto \pi(\mu, \Omega) \cdot f(y \mid \mu, \Omega) \\
&\propto |\Omega|^{\frac{d-k-1}{2}} e^{-\frac{1}{2}\text{tr}(A\Omega)} \cdot |\Omega|^{\frac{n}{2}} \exp \left\{ -\frac{1}{2} \text{tr} \left[ \sum_{i=1}^n (y_i - \mu)(y_i - \mu)^T \Omega \right] \right\} \\
&= |\Omega|^{\frac{d+n-k-1}{2}} \exp \left\{ -\frac{1}{2} \text{tr} \left[ \left( A + \sum_{i=1}^n (y_i - \mu)(y_i - \mu)^T \right) \Omega \right] \right\}.
\end{aligned}$$

Δηλαδή,

$$\begin{aligned}
\mu \mid \Omega, y &\sim \mathcal{N}_k \left( (C + n\Omega)^{-1} (Ca + n\Omega\bar{y}), (C + n\Omega)^{-1} \right), \\
\Omega \mid \mu, y &\sim \mathcal{W}_k \left( \left( A + \sum_{i=1}^n (y_i - \mu)(y_i - \mu)^T \right)^{-1}, d + n \right).
\end{aligned}$$

**Ορισμός 1.4.** Ορίζουμε το γινόμενο Kronecker δύο πινάκων  $A \in \mathbb{R}^{n \times m}$  και  $B \in \mathbb{R}^{p \times q}$  ως τον πίνακα:

$$C = A \otimes B = \begin{bmatrix} a_{11}B & a_{12}B & \cdots & a_{1m}B \\ a_{21}B & a_{22}B & \cdots & a_{2m}B \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1}B & a_{n2}B & \cdots & a_{nm}B \end{bmatrix} \in \mathbb{R}^{np \times mq}.$$

**Λήμμα 1.2.** Έστω  $A \in \mathbb{R}^{n \times n}$  θετικά ορισμένος πίνακας,  $x, a \in \mathbb{R}^n$  και  $c \in \mathbb{R}$ . Τότε, ισχύει ότι:

$$\begin{aligned}
\frac{\partial c}{\partial x} &= \mathbf{0}_n, & \frac{\partial a}{\partial x} &= \mathbf{0}_{n \times n}, & \frac{\partial Ax}{\partial x} &= A, & \frac{\partial a^T x}{\partial x} &= a, & \frac{\partial x^T Ax}{\partial x} &= 2Ax, \\
\frac{\partial aa^T}{\partial x} &= \mathbf{0}_{n^2 \times n}, & \frac{\partial ax^T}{\partial x} &= \frac{\partial xa^T}{\partial x} = a \otimes I_n, & \frac{\partial xx^T}{\partial x} &= x \otimes I_n + I_n \otimes x, \\
\frac{\partial x^T Ax}{\partial A} &= xx^T, & \frac{\partial \log |A|}{\partial A} &= A^{-1}, & \frac{\partial A^{-1}}{\partial A} &= -A^{-1} \otimes A^{-1}, & \frac{\partial Ax}{\partial A} &= x^T \otimes I_n.
\end{aligned}$$

**Λήμμα 1.3.** Έστω  $X \in \mathbb{R}^k$  τυχαίο διάνυσμα και  $A \in \mathbb{R}^{n \times m}$  σταθερός πίνακας. Τότε, ισχύει ότι:

$$\mathbb{E}(A \otimes X) = A \otimes \mathbb{E}(X), \quad \mathbb{E}(X \otimes A) = \mathbb{E}(X) \otimes A.$$

**Λήμμα 1.4.** Έστω  $A \in \mathbb{R}^{n \times n}$  και  $B \in \mathbb{R}^{m \times m}$ . Τότε, ισχύει ότι:

$$|A \otimes B| = |A|^m |B|^n.$$

Μπορούμε να υπολογίσουμε την prior του Jeffreys για την πολυδιάστατη κανονική κατανομή ως εξής:

$$\begin{aligned}
\log f(y \mid \mu, \Omega) &= \frac{1}{2} \log |\Omega| - \frac{k}{2} \log(2\pi) - \frac{(y - \mu)^T \Omega (y - \mu)}{2}, \\
\frac{\partial \log f(y \mid \mu, \Omega)}{\partial \mu} &= \Omega(y - \mu) \in \mathbb{R}^k, & \frac{\partial \log f(y \mid \mu, \Omega)}{\partial \Omega} &= \frac{1}{2} \Omega^{-1} - \frac{(y - \mu)(y - \mu)^T}{2} \in \mathbb{R}^{k \times k}, \\
\frac{\partial^2 \log f(y \mid \mu, \Omega)}{\partial \mu \partial \mu} &= -\Omega \in \mathbb{R}^{k \times k}, & \frac{\partial^2 \log f(y \mid \mu, \Omega)}{\partial \Omega \partial \Omega} &= -\frac{1}{2} \Omega^{-1} \otimes \Omega^{-1} \in \mathbb{R}^{k^2 \times k^2},
\end{aligned}$$

$$\frac{\partial^2 \log f(y | \mu, \Omega)}{\partial \Omega \partial \mu} = (y - \mu)^\top \otimes I_k \in \mathbb{R}^{k \times k^2}, \quad \frac{\partial^2 \log f(y | \mu, \Omega)}{\partial \mu \partial \Omega} = \frac{(y - \mu) \otimes I_k + I_k \otimes (y - \mu)}{2} \in \mathbb{R}^{k^2 \times k},$$

$$\mathcal{J}(\mu, \Omega) = \mathbb{E} \left[ -\frac{\partial^2 \log f(y | \mu, \Omega)}{\partial(\mu, \Omega) \partial(\mu, \Omega)} \right] = \begin{bmatrix} \Omega & \mathbf{0}_{k \times k^2} \\ \mathbf{0}_{k^2 \times k} & \frac{1}{2} \Omega^{-1} \otimes \Omega^{-1} \end{bmatrix},$$



$$J(\mu, \Omega) \propto \sqrt{|\mathcal{J}(\mu, \Omega)|} = \sqrt{|\Omega| \left| \frac{1}{2} \Omega^{-1} \otimes \Omega^{-1} \right|} \propto \sqrt{|\Omega| |\Omega|^{-k} |\Omega|^{-k}} = |\Omega|^{\frac{1-2k}{2}}.$$

Παρατηρούμε ότι η μη-ορθή prior του Jeffreys προκύπτει για  $a = \mathbf{0}_k$ ,  $C = A = \mathbf{0}_{k \times k}$  και  $d = 2 - k$

```
MCMCmnorm = function(Y, mu0, Omega0, a, C, A, d, niter, nburn) {
  library(MASS)
  n = dim(Y)[1]
  k = dim(Y)[2]
  S = colSums(Y)
  mu = matrix(0, niter, k)
  Omega = array(0, c(k, k, niter))
  mu[1, ] = mu0
  Omega[, , 1] = Omega0
  for (i in 2:niter) {
    Cn = C + n * Omega[, , i - 1]
    an = solve(Cn, C %*% a + Omega[, , i - 1] %*% S)
    mu[i, ] = mvrnorm(1, an, solve(Cn))
    Omega[, , i] = rWishart(1, d + n, solve(A + tcrossprod(t(Y) - mu[i,
      ])))
  }
  return(list(mu = mu[-(1:nburn), ], Omega = Omega[, , -(1:nburn)]))
}

library(MASS)
n = 1000
k = 2
mu = c(4, 5)
Omega = matrix(c(2, 1, 1, 3), k)
Y = mvrnorm(n, mu, solve(Omega))
posterior = MCMCmnorm(Y, numeric(k), diag(k), numeric(k), matrix(0, k, k),
  matrix(0, k, k), 2 - k, 5000, 1000)
par(mfrow = c(1, 2))
hist(posterior$mu[, 1], "FD", freq = FALSE, main = NA, xlab = expression(mu[1]))
abline(v = mu[1], col = 2, lty = 2)
hist(posterior$mu[, 2], "FD", freq = FALSE, main = NA, xlab = expression(mu[2]))
abline(v = mu[2], col = 2, lty = 2)
```


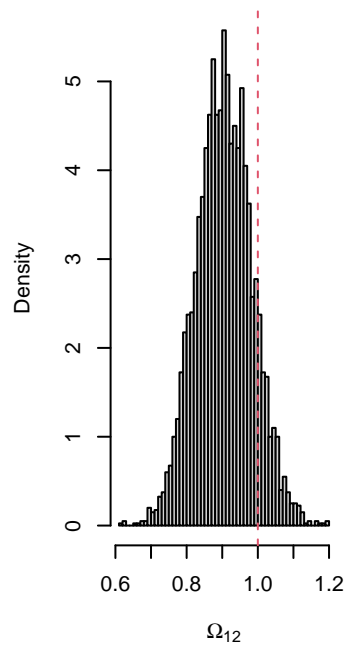





```

par(mfrow = c(1, 3))
hist(posterior$Omega[1, 1, ], "FD", freq = FALSE, main = NA, xlab = expression(Omega[11]))
abline(v = Omega[1, 1], col = 2, lty = 2)
hist(posterior$Omega[1, 2, ], "FD", freq = FALSE, main = NA, xlab = expression(Omega[12]))
abline(v = Omega[1, 2], col = 2, lty = 2)
hist(posterior$Omega[2, 2, ], "FD", freq = FALSE, main = NA, xlab = expression(Omega[22]))
abline(v = Omega[2, 2], col = 2, lty = 2)

```



β. Η από κοινού prior κατανομή μπορεί να γραφτεί ως:

$$\begin{aligned}
\pi(\mu, \Omega) &= \pi(\mu | \Omega) \cdot \pi(\Omega) \\
&= (2\pi)^{-\frac{k}{2}} |c^{-1}\Omega^{-1}|^{-\frac{1}{2}} \exp \left\{ -\frac{c(\mu - a)^T \Omega (\mu - a)}{2} \right\} \cdot \frac{|A|^{\frac{d}{2}}}{2^{\frac{dk}{2}} \Gamma_k \left(\frac{d}{2}\right)} |\Omega|^{\frac{d-k-1}{2}} e^{-\frac{1}{2} \text{tr}(A\Omega)} \\
&\propto |\Omega|^{\frac{d+1-k-1}{2}} \exp \left\{ -\frac{1}{2} \text{tr} [(A + c(\mu - a)(\mu - a)^T) \Omega] \right\} \\
&= |\Omega|^{\frac{1}{2}} \exp \left\{ -c \frac{\mu^T \Omega \mu - 2\mu^T \Omega a + a^T \Omega a}{2} \right\} \cdot |\Omega|^{\frac{d-k-1}{2}} e^{-\frac{1}{2} \text{tr}(A\Omega)} \\
&= |\Omega|^{\frac{1}{2}} \exp \left\{ -\frac{\mu^T c \Omega \mu}{2} + \mu^T c \Omega a \right\} \cdot |\Omega|^{\frac{d-k-1}{2}} \exp \left\{ -\frac{1}{2} \text{tr} [(A + caa^T) \Omega] \right\}.
\end{aligned}$$

Επομένως, παίρνουμε την από κοινού posterior κατανομή των  $\mu$  και  $\Omega$  ως εξής:

$$\begin{aligned}
\pi(\mu, \Omega | y) &\propto \pi(\mu, \Omega) \cdot f(y | \mu, \Omega) \\
&\propto |\Omega|^{\frac{1}{2}} \exp \left\{ -\frac{\mu^T c \Omega \mu}{2} + \mu^T c \Omega a \right\} \cdot |\Omega|^{\frac{d-k-1}{2}} \exp \left\{ -\frac{1}{2} \text{tr} [(A + caa^T) \Omega] \right\} \\
&\quad \times \exp \left\{ -\frac{\mu^T n \Omega \mu}{2} + \mu^T n \Omega \bar{y} \right\} \cdot |\Omega|^{\frac{n}{2}} \exp \left\{ -\frac{1}{2} \text{tr} \left( \sum_{i=1}^n y_i y_i^T \Omega \right) \right\} \\
&= |\Omega|^{\frac{1}{2}} \exp \left\{ -\frac{1}{2} \mu^T \underbrace{(c + n)}_{c_n} \Omega \mu + \mu^T \Omega (ca + n\bar{y}) \right\} \\
&\quad \times |\Omega|^{\frac{d+n-k-1}{2}} \exp \left\{ -\frac{1}{2} \text{tr} \left[ \left( A + caa^T + \sum_{i=1}^n y_i y_i^T \right) \Omega \right] \right\} \\
&= |\Omega|^{\frac{1}{2}} \exp \left\{ -\frac{\mu^T (c + n) \Omega \mu}{2} + \mu^T \underbrace{(c + n)}_{c_n} \Omega \underbrace{\frac{ca + n\bar{y}}{c + n}}_{a_n} \right\} \\
&\quad \times |\Omega|^{\frac{d+n-k-1}{2}} \exp \left\{ -\frac{1}{2} \text{tr} \left[ \left( A + caa^T + \sum_{i=1}^n y_i y_i^T \right) \Omega \right] \right\} \\
&= |\Omega|^{\frac{1}{2}} \exp \left\{ -\frac{\mu^T c_n \Omega \mu}{2} + \mu^T c_n \Omega a_n - \frac{a_n^T c_n \Omega a_n}{2} + \frac{a_n^T c_n \Omega a_n}{2} \right\} \\
&\quad \times |\Omega|^{\frac{d+n-k-1}{2}} \exp \left\{ -\frac{1}{2} \text{tr} \left[ \left( A + caa^T + \sum_{i=1}^n y_i y_i^T \right) \Omega \right] \right\} \\
&= |\Omega|^{\frac{1}{2}} \exp \left\{ -\frac{c_n (\mu - a_n)^T \Omega (\mu - a_n)}{2} \right\} \\
&\quad \times |\Omega|^{\frac{d+n-k-1}{2}} \exp \left\{ -\frac{1}{2} \text{tr} \left[ \left( A + caa^T + \sum_{i=1}^n y_i y_i^T - c_n a_n a_n^T \right) \Omega \right] \right\}.
\end{aligned}$$

Υπολογίζουμε ότι:

$$c_n a_n a_n^T = \frac{(ca + n\bar{y})(ca + n\bar{y})^T}{c + n}.$$

Δηλαδή,

$$\mu \mid \Omega, y \sim \mathcal{N}_k \left( \frac{ca + n\bar{y}}{c + n}, \frac{1}{c + n} \Omega^{-1} \right),$$

$$\Omega \mid y \sim \mathcal{W}_k \left( \left( A + caa^T + \sum_{i=1}^n y_i y_i^T - \frac{(ca + n\bar{y})(ca + n\bar{y})^T}{c + n} \right)^{-1}, d + n \right).$$

Επιπλέον, παίρνουμε τη δεσμευμένη posterior κατανομή του  $\Omega$  ως εξής:

$$\begin{aligned} \pi(\Omega \mid \mu, y) &\propto \pi(\mu, \Omega) \cdot f(y \mid \mu, \Omega) \\ &\propto |\Omega|^{\frac{d+1-k-1}{2}} \exp \left\{ -\frac{1}{2} \text{tr} \left[ (A + c(\mu - a)(\mu - a)^T) \Omega \right] \right\} \\ &\quad \times |\Omega|^{\frac{n}{2}} \exp \left\{ -\frac{1}{2} \text{tr} \left[ \sum_{i=1}^n (y_i - \mu)(y_i - \mu)^T \Omega \right] \right\} \\ &= |\Omega|^{\frac{d+n+1-k-1}{2}} \exp \left\{ -\frac{1}{2} \text{tr} \left[ \left( A + c(\mu - a)(\mu - a)^T + \sum_{i=1}^n (y_i - \mu)(y_i - \mu)^T \right) \Omega \right] \right\}. \end{aligned}$$

Δηλαδή,

$$\Omega \mid \mu, y \sim \mathcal{W}_k \left( \left( A + c(\mu - a)(\mu - a)^T + \sum_{i=1}^n (y_i - \mu)(y_i - \mu)^T \right)^{-1}, d + n + 1 \right).$$

**Ορισμός 1.5.** Λέμε ότι ένα τυχαίο διάνυσμα  $X \in \mathbb{R}^k$  ακολουθεί την πολυδιάστατη κατανομή Student's t με μέσο  $\mu \in \mathbb{R}^k$ , θετικά ορισμένο πίνακα συνδιακύμανσης  $\Sigma \in \mathbb{R}^{k \times k}$ ,  $\nu > 0$  βαθμούς ελευθερίας και γράφουμε  $X \sim t_\nu(\mu, \Sigma)$ , αν έχει συνάρτηση πυκνότητας πιθανότητας:

$$f_X(x \mid \mu, \Sigma, \nu) = \frac{\Gamma(\frac{\nu+k}{2})}{\Gamma(\frac{\nu}{2})} \frac{1}{(\nu\pi)^{\frac{k}{2}} |\Sigma|^{\frac{1}{2}}} \left[ 1 + \frac{1}{\nu} (x - \mu)^T \Sigma^{-1} (x - \mu) \right]^{-\frac{\nu+k}{2}}, \quad x \in \mathbb{R}^k.$$

**Λήμμα 1.5.** Έστω  $x, y \in \mathbb{R}^n$  και  $A \in \mathbb{R}^{n \times n}$  αντιστρέψιμος πίνακας. Τότε,

$$|A + xy^T| = |A| (1 + y^T A^{-1} x).$$

Τέλος, ορίζουμε:

$$d_n = d + n - k + 1, \quad A_n = A + caa^T + \sum_{i=1}^n y_i y_i^T - c_n a_n a_n^T.$$

Τότε, υπολογίζουμε την περιθώρια posterior κατανομή του  $\mu$  ως εξής:

$$\begin{aligned} \pi(\mu \mid y) &= \int \pi(\mu, \Omega \mid y) d\Omega \\ &\propto \int |\Omega|^{\frac{d+n+1-k-1}{2}} \exp \left\{ -\frac{1}{2} \text{tr} \left[ \left( A + c(\mu - a)(\mu - a)^T + \sum_{i=1}^n (y_i - \mu)(y_i - \mu)^T \right) \Omega \right] \right\} d\Omega \\ &\propto \left| A + c(\mu - a)(\mu - a)^T + \sum_{i=1}^n (y_i - \mu)(y_i - \mu)^T \right|^{-\frac{d+n+1}{2}} \end{aligned}$$

$$\begin{aligned}
&= \left| A + caa^T + \sum_{i=1}^n y_i y_i^T + (c+n)\mu\mu^T - (ca+n\bar{y})\mu^T - \mu(ca+n\bar{y})^T \right|^{-\frac{d+n-k+1+k}{2}} \\
&= \left| A + caa^T + \sum_{i=1}^n y_i y_i^T - c_n a_n a_n^T + c_n (\mu - a_n) (\mu - a_n)^T \right|^{-\frac{d_n+k}{2}} \\
&\propto \left[ 1 + c_n (\mu - a_n)^T A_n^{-1} (\mu - a_n) \right]^{-\frac{d_n+k}{2}} \\
&= \left[ 1 + \frac{1}{d_n} (\mu - a_n)^T c_n d_n A_n^{-1} (\mu - a_n) \right]^{-\frac{d_n+k}{2}}.
\end{aligned}$$

Δηλαδή,

$$\mu | y \sim t_{d_n} \left( a_n, \frac{1}{c_n d_n} A_n \right).$$



Πρώτα θα υλοποιήσουμε έναν δειγματολήπτη Gibbs που προσομοιώνει εναλλάξ από τις δεσμευμένες posterior κατανομές των παραμέτρων  $\mu$  και  $\Omega$ .

```

MCMCmnorm = function(Y, mu0, Omega0, a, c, A, d, niter, nburn) {
  library(MASS)
  n = dim(Y)[1]
  k = dim(Y)[2]
  S = colSums(Y)
  cn = c + n
  an = (c * a + S)/cn
  mu = matrix(0, niter, k)
  Omega = array(0, c(k, k, niter))
  mu[1, ] = mu0
  Omega[, , 1] = Omega0
  for (i in 2:niter) {
    mu[i, ] = mvrnorm(1, an, solve(Omega[, , i - 1])/cn)
    Omega[, , i] = rWishart(1, d + n + 1, solve(A + c * tcrossprod(mu[i, ] - a) + tcrossprod(t(Y) - mu[i, ])))
  }
  return(list(mu = mu[-(1:nburn), ], Omega = Omega[, , -(1:nburn)]))
}

posterior = MCMCmnorm(Y, numeric(k), diag(k), numeric(k), 0, matrix(0, k, k),
  2 - k, 5000, 1000)
par(mfrow = c(1, 2))
hist(posterior$mu[, 1], "FD", freq = FALSE, main = NA, xlab = expression(mu[1]))
abline(v = mu[1], col = 2, lty = 2)
hist(posterior$mu[, 2], "FD", freq = FALSE, main = NA, xlab = expression(mu[2]))
abline(v = mu[2], col = 2, lty = 2)




```



```

par(mfrow = c(1, 3))
hist(posterior$Omega[1, 1, ], "FD", freq = FALSE, main = NA, xlab = expression(Omega[11]))
abline(v = Omega[1, 1], col = 2, lty = 2)
hist(posterior$Omega[1, 2, ], "FD", freq = FALSE, main = NA, xlab = expression(Omega[12]))
abline(v = Omega[1, 2], col = 2, lty = 2)
hist(posterior$Omega[2, 2, ], "FD", freq = FALSE, main = NA, xlab = expression(Omega[22]))
abline(v = Omega[2, 2], col = 2, lty = 2)

```



Έπειτα, θα υλοποιήσουμε τη μέθοδο της σύνθεσης που προσομοιώνει πρώτα από την περιθώρια posterior κατανομή της παραμέτρου  $\Omega$  και στη συνέχεια από τη δεσμευμένη posterior κατανομή της παραμέτρου  $\mu$ .

```

CMmvnorm = function(Y, mu0, Omega0, a, c, A, d, niter, nburn) {
  library(MASS)
  n = dim(Y)[1]


```

```

k = dim(Y)[2]
S = colSums(Y)
cn = c + n
an = (c * a + S)/cn
An = solve(A + c * tcrossprod(a) + crossprod(Y) - cn * tcrossprod(an))
mu = matrix(0, niter, k)
Omega = array(0, c(k, k, niter))
mu[1, ] = mu0
Omega[, , 1] = Omega0
for (i in 2:niter) {
  Omega[, , i] = rWishart(1, d + n, An)
  mu[i, ] = mvrnorm(1, an, solve(Omega[, , i])/cn)
}
return(list(mu = mu[-(1:nburn), ], Omega = Omega[, , -(1:nburn)]))
}

posterior = CMmvnorm(Y, numeric(k), diag(k), numeric(k), 0, matrix(0, k, k),
  2 - k, 5000, 1000)
par(mfrow = c(1, 2))
hist(posterior$mu[, 1], "FD", freq = FALSE, main = NA, xlab = expression(mu[1]))
abline(v = mu[1], col = 2, lty = 2)
hist(posterior$mu[, 2], "FD", freq = FALSE, main = NA, xlab = expression(mu[2]))
abline(v = mu[2], col = 2, lty = 2)

```

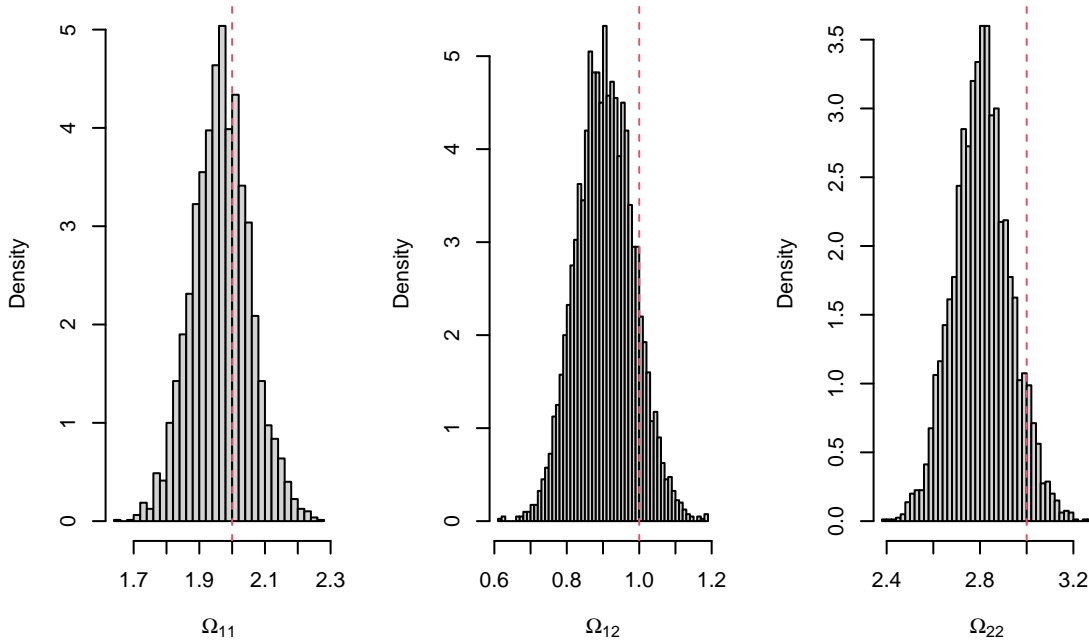


```

par(mfrow = c(1, 3))
hist(posterior$Omega[1, 1, ], "FD", freq = FALSE, main = NA, xlab = expression(Omega[11]))
abline(v = Omega[1, 1], col = 2, lty = 2)
hist(posterior$Omega[1, 2, ], "FD", freq = FALSE, main = NA, xlab = expression(Omega[12]))
abline(v = Omega[1, 2], col = 2, lty = 2)

```

```
hist(posterior$Omega[2, 2, ], "FD", freq = FALSE, main = NA, xlab = expression(Omega[22]))
abline(v = Omega[2, 2], col = 2, lty = 2)
```



## 1.6 Πολυδιάστατη Κατανομή Student's t

Έστω τυχαίο δείγμα  $y_1, \dots, y_n$  από την πολυδιάστατη κατανομή Student's t με μέσο  $\mu \in \mathbb{R}^k$ , θετικά ορισμένο πίνακα ακρίβειας  $\Omega \in \mathbb{R}^{k \times k}$  και  $\nu > 0$  βαθμούς ελευθερίας, δηλαδή:

$$f(y_i | \mu, \Omega, \nu) = \frac{\Gamma(\frac{\nu+k}{2})}{\Gamma(\frac{\nu}{2})} (\nu\pi)^{-\frac{k}{2}} |\Omega|^{\frac{1}{2}} \left[ 1 + \frac{1}{\nu} (y_i - \mu)^T \Omega (y_i - \mu) \right]^{-\frac{\nu+k}{2}}, \quad y_i \in \mathbb{R}^k.$$

Θεωρούμε τις τυχαίες μεταβλητές  $W_i \sim \mathcal{N}_k(0, \Omega^{-1})$  και  $V_i \sim \chi_\nu^2 \equiv \text{Gamma}(\frac{\nu}{2}, \frac{1}{2})$ . Τότε, παρατηρούμε ότι:

$$Y_i \stackrel{d}{=} \frac{W_i}{\sqrt{\frac{V_i}{\nu}}} + \mu.$$

Θέτουμε  $Z_i = \frac{V_i}{\nu}$ . Τότε,  $Z_i \sim \text{Gamma}(\frac{\nu}{2}, \frac{\nu}{2})$ . Παρατηρούμε ότι:

$$Y_i | z_i \stackrel{d}{=} \frac{W_i}{\sqrt{z_i}} + \mu \sim \mathcal{N}_k(\mu, z_i^{-1} \Omega^{-1}).$$

Θεωρούμε γνωστούς τους βαθμούς ελευθερίας  $\nu$  και prior ανεξαρτησία για τις παραμέτρους  $\mu, \Omega$  με κατανομές  $\mu \sim \mathcal{N}_k(a, C^{-1})$  και  $\Omega \sim \mathcal{W}_k(A^{-1}, d)$ . Να υπολογιστούν οι δεσμευμένες posterior κατανομές των παραμέτρων  $\mu, \Omega$  και των λανθανουσών μεταβλητών  $z_i$ .

Λύση.

Η από κοινού prior κατανομή μπορεί να γραφτεί ως:

$$\begin{aligned}
\pi(\mu, \Omega) &= \pi(\mu) \cdot \pi(\Omega) \\
&= (2\pi)^{-\frac{k}{2}} |C^{-1}|^{-\frac{1}{2}} \exp \left\{ -\frac{(\mu - a)^T C (\mu - a)}{2} \right\} \cdot \frac{|A|^{\frac{d}{2}}}{2^{\frac{dk}{2}} \Gamma_k \left( \frac{d}{2} \right)} |\Omega|^{\frac{d-k-1}{2}} e^{-\frac{1}{2} \text{tr}(A\Omega)} \\
&\propto \exp \left\{ -\frac{\mu^T C \mu - 2\mu^T C a + a^T C a}{2} \right\} \cdot |\Omega|^{\frac{d-k-1}{2}} e^{-\frac{1}{2} \text{tr}(A\Omega)} \\
&\propto \exp \left\{ -\frac{\mu^T C \mu}{2} + \mu^T C a \right\} \cdot |\Omega|^{\frac{d-k-1}{2}} e^{-\frac{1}{2} \text{tr}(A\Omega)}.
\end{aligned}$$

Ορίζουμε:

$$\bar{zy} = \frac{1}{n} \sum_{i=1}^n z_i y_i.$$

Η πλήρης πιθανοφάνεια, δηλαδή η από κοινού πιθανοφάνεια των παρατηρούμενων μεταβλητών  $y_i$  και των λανθανουσών μεταβλητών  $z_i$ , δίνεται από τη σχέση:

$$\begin{aligned}
f(y, z | \mu, \Omega) &= \prod_{i=1}^n f(y_i, z_i | \mu, \Omega) \\
&= \prod_{i=1}^n f(z_i) f(y_i | z_i, \mu, \Omega) \\
&= \prod_{i=1}^n \left( \frac{\nu}{2} \right)^{\frac{\nu}{2}} z_i^{\frac{\nu}{2}-1} e^{-\frac{\nu}{2} z_i} (2\pi)^{-\frac{k}{2}} |z_i^{-1} \Omega^{-1}|^{-\frac{1}{2}} \exp \left\{ -\frac{z_i (y_i - \mu)^T \Omega (y_i - \mu)}{2} \right\} \\
&\propto |\Omega|^{\frac{n}{2}} \cdot \prod_{i=1}^n z_i^{\frac{\nu+k}{2}-1} \exp \left\{ -\sum_{i=1}^n \frac{\nu + (y_i - \mu)^T \Omega (y_i - \mu)}{2} z_i \right\} \\
&= |\Omega|^{\frac{n}{2}} \exp \left\{ -\frac{1}{2} \text{tr} \left[ \sum_{i=1}^n z_i (y_i - \mu) (y_i - \mu)^T \Omega \right] \right\} \cdot \prod_{i=1}^n z_i^{\frac{\nu+k}{2}-1} \exp \left\{ -\frac{\nu}{2} \sum_{i=1}^n z_i \right\} \\
&= |\Omega|^{\frac{n}{2}} \exp \left\{ -\sum_{i=1}^n \frac{y_i^T \Omega y_i - 2\mu^T \Omega y_i + \mu^T \Omega \mu}{2} z_i \right\} \cdot \prod_{i=1}^n z_i^{\frac{\nu+k}{2}-1} \exp \left\{ -\frac{\nu}{2} \sum_{i=1}^n z_i \right\} \\
&= \exp \left\{ -\frac{\mu^T n \bar{z} \Omega \mu}{2} + \mu^T n \Omega \bar{zy} \right\} \cdot |\Omega|^{\frac{n}{2}} \exp \left\{ -\frac{1}{2} \text{tr} \left( \sum_{i=1}^n z_i y_i y_i^T \Omega \right) \right\} \\
&\quad \times \prod_{i=1}^n z_i^{\frac{\nu+k}{2}-1} \exp \left\{ -\frac{\nu}{2} \sum_{i=1}^n z_i \right\}.
\end{aligned}$$

Επομένως, παίρνουμε τις δεσμευμένες posterior κατανομές των παραμέτρων  $\mu$  και  $\Omega$  ως εξής:

$$\begin{aligned}
\pi(\mu | \Omega, z, y) &\propto \pi(\mu, \Omega, z | y) \\
&\propto \pi(\mu, \Omega) \cdot f(y, z | \mu, \Omega) \\
&\propto \exp \left\{ -\frac{\mu^T C \mu}{2} + \mu^T C a \right\} \cdot \exp \left\{ -\frac{\mu^T n \bar{z} \Omega \mu}{2} + \mu^T n \Omega \bar{zy} \right\}
\end{aligned}$$



$$\begin{aligned}
&= \exp \left\{ -\frac{1}{2} \mu^T \underbrace{(C + n\bar{z}\Omega)}_{C_n} \mu + \mu^T (Ca + n\Omega\bar{z}y) \right\} \\
&= \exp \left\{ -\frac{\mu^T C_n \mu}{2} + \mu^T \underbrace{(C + n\bar{z}\Omega)}_{C_n} \underbrace{(C + n\bar{z}\Omega)^{-1}}_{a_n} (Ca + n\Omega\bar{z}y) \right\},
\end{aligned}$$

$$\begin{aligned}
\pi(\Omega \mid \mu, z, y) &\propto \pi(\mu, \Omega) \cdot f(y, z \mid \mu, \Omega) \\
&\propto |\Omega|^{\frac{d-k-1}{2}} e^{-\frac{1}{2}\text{tr}(A\Omega)} \cdot |\Omega|^{\frac{n}{2}} \exp \left\{ -\frac{1}{2} \text{tr} \left[ \sum_{i=1}^n z_i (y_i - \mu)(y_i - \mu)^T \Omega \right] \right\} \\
&= |\Omega|^{\frac{d+n-k-1}{2}} \exp \left\{ -\frac{1}{2} \text{tr} \left[ \left( A + \sum_{i=1}^n z_i (y_i - \mu)(y_i - \mu)^T \right) \Omega \right] \right\}.
\end{aligned}$$

Επιπλέον, παίρνουμε τη δεσμευμένη posterior κατανομή των λανθανουσών μεταβλητών  $z_i$  ως εξής:

$$f(z_i \mid y_i, \mu, \Omega) \propto f(y_i, z_i \mid \mu, \Omega) \propto z_i^{\frac{\nu+k}{2}-1} \exp \left\{ -\frac{\nu + (y_i - \mu)^T \Omega (y_i - \mu)}{2} z_i \right\}.$$

Δηλαδή,

$$\begin{aligned}
\mu \mid \Omega, z, y &\sim \mathcal{N}_k \left( (C + n\bar{z}\Omega)^{-1} (Ca + n\Omega\bar{z}y), (C + n\bar{z}\Omega)^{-1} \right), \\
\Omega \mid \mu, z, y &\sim \mathcal{W}_k \left( \left( A + \sum_{i=1}^n z_i (y_i - \mu)(y_i - \mu)^T \right)^{-1}, d + n \right), \\
z_i \mid y_i, \mu, \Omega &\sim \text{Gamma} \left( \frac{\nu + k}{2}, \frac{\nu + (y_i - \mu)^T \Omega (y_i - \mu)}{2} \right).
\end{aligned}$$

```

MCMCmvt = function(Y, mu0, Omega0, nu, a, C, A, d, niter, nburn) {
  library(MASS)
  n = dim(Y)[1]
  k = dim(Y)[2]
  mu = matrix(0, niter, k)
  Omega = array(0, c(k, k, niter))
  Z = matrix(0, niter, n)
  mu[1, ] = mu0
  Omega[, , 1] = Omega0
  Z[1, ] = rgamma(n, (nu + k)/2, (nu + colSums((t(Y) - mu[1, ]) * Omega[, , 1] %*% (t(Y) - mu[1, ])))/2)
  for (i in 2:niter) {
    Cn = C + sum(Z[i - 1, ]) * Omega[, , i - 1]
    an = solve(Cn, C %*% a + Omega[, , i - 1] %*% colSums(Z[i - 1, ] * Y))
    mu[i, ] = mvrnorm(1, an, solve(Cn))
    Omega[, , i] = rWishart(1, d + n, solve(A + crossprod(sqrt(Z[i - 1, ]) * t(t(Y) - mu[i, ]))))
    Z[i, ] = rgamma(n, (nu + k)/2, (nu + colSums((t(Y) - mu[i, ]) * Omega[, , i] %*% (t(Y) - mu[i, ])))/2)
  }
}


```

```

}
return(list(mu = mu[-(1:nburn)], ], Omega = Omega[, , -(1:nburn)]))
}

library(mvtnorm)
n = 1000
k = 2
mu = c(4, 5)
Omega = matrix(c(2, 1, 1, 3), k)
nu = 10
Y = rmvt(n, solve(Omega), nu, mu)
posterior = MCMCmvt(Y, numeric(k), diag(k), nu, numeric(k), matrix(0, k, k),
matrix(0, k, k), 2 - k, 5000, 1000)
par(mfrow = c(1, 2))
hist(posterior$mu[, 1], "FD", freq = FALSE, main = NA, xlab = expression(mu[1]))
abline(v = mu[1], col = 2, lty = 2)
hist(posterior$mu[, 2], "FD", freq = FALSE, main = NA, xlab = expression(mu[2]))
abline(v = mu[2], col = 2, lty = 2)



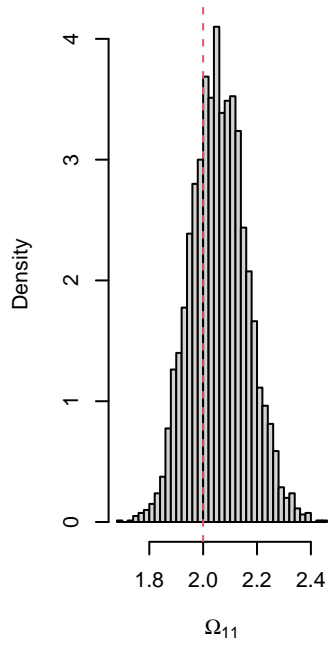
```



```

par(mfrow = c(1, 3))
hist(posterior$Omega[1, 1, ], "FD", freq = FALSE, main = NA, xlab = expression(Omega[11]))
abline(v = Omega[1, 1], col = 2, lty = 2)
hist(posterior$Omega[1, 2, ], "FD", freq = FALSE, main = NA, xlab = expression(Omega[12]))
abline(v = Omega[1, 2], col = 2, lty = 2)
hist(posterior$Omega[2, 2, ], "FD", freq = FALSE, main = NA, xlab = expression(Omega[22]))
abline(v = Omega[2, 2], col = 2, lty = 2)

```




## 2 Γενικευμένα Γραμμικά Μοντέλα

### 2.1 Λογιστικό Μοντέλο

Θεωρούμε το λογιστικό μοντέλο παλινδρόμησης  $y_i \sim \text{Bernoulli}(p_i)$ , όπου  $\text{logit } p_i = \log \frac{p_i}{1-p_i} = \beta_0 + \beta_1 x_i$ , δηλαδή  $p_i = \frac{1}{1+e^{-\beta_0-\beta_1 x_i}}$ . Θεωρούμε prior ανεξαρτησία με μη-ορθές κατανομές  $\pi(\beta_0) \propto 1$  και  $\pi(\beta_1) \propto 1$ . Μπορούμε να υλοποιήσουμε έναν αλγόριθμο Random Walk Metropolis-Hastings με προτεινόμενες τυχαίες μεταβλητές  $\beta_0^* | \beta_0^{(\ell-1)} \sim \mathcal{N}(\beta_0^{(\ell-1)}, \sigma_0^2)$  και  $\beta_1^* | \beta_1^{(\ell-1)} \sim \mathcal{N}(\beta_1^{(\ell-1)}, \sigma_1^2)$ .

```
RWMHlogistic = function(Y, X, beta00, beta10, beta0sd, beta1sd, niter, nburn) {
  beta0 = numeric(niter)
  beta1 = numeric(niter)
  beta0[1] = beta00
  beta1[1] = beta10
  for (i in 2:niter) {
    beta0star = rnorm(1, beta0[i - 1], beta0sd)
    logA = sum(dbinom(Y, 1, (1 + exp(-beta0star - beta1[i - 1] * X))^(-1),
      log = TRUE) - dbinom(Y, 1, (1 + exp(-beta0[i - 1] - beta1[i - 1] *
      X))^(-1), log = TRUE))
    beta0[i] = ifelse(log(runif(1)) < logA, beta0star, beta0[i - 1])
    beta1star = rnorm(1, beta1[i - 1], beta1sd)
    logA = sum(dbinom(Y, 1, (1 + exp(-beta0[i] - beta1star * X))^(-1), log = TRUE) -
      dbinom(Y, 1, (1 + exp(-beta0[i] - beta1[i - 1] * X))^(-1), log = TRUE))
    beta1[i] = ifelse(log(runif(1)) < logA, beta1star, beta1[i - 1])
  }
  return(list(beta0 = beta0[-(1:nburn)], beta1 = beta1[-(1:nburn)]))
}


n = 1000
beta0 = 1
beta1 = 2
X = rnorm(n)
Y = rbinom(n, 1, (1 + exp(-beta0 - beta1 * X))^(-1))
posterior = RWMHlogistic(Y, X, 0, 0, 0.15, 0.25, 5000, 1000)
par(mfrow = c(1, 2))
plot(posterior$beta0, type = "l", ylab = expression(beta[0]))
abline(h = beta0, col = 2, lty = 2)
plot(posterior$beta1, type = "l", ylab = expression(beta[1]))
abline(h = beta1, col = 2, lty = 2)
```



```

hist(posterior$beta0, "FD", freq = FALSE, main = NA, xlab = expression(beta[0]))
abline(v = beta0, col = 2, lty = 2)
hist(posterior$beta1, "FD", freq = FALSE, main = NA, xlab = expression(beta[1]))
abline(v = beta1, col = 2, lty = 2)

```



## 2.2 Μοντέλο Πιθανομονάδας

Θεωρούμε το μοντέλο πιθανομονάδας  $y_i \sim \text{Bernoulli}(p_i)$ , όπου  $p_i = \Phi(x_i^T \beta)$  και  $\beta \in \mathbb{R}^k$ . Θεωρούμε τις ανεξάρτητες τυχαίες μεταβλητές  $z_i = x_i^T \beta + \varepsilon_i$ , όπου  $\varepsilon_i \sim \mathcal{N}(0, 1)$ . Τότε, παρατηρούμε ότι:

$$p_i = \mathbb{P}(Y_i = 1) = \Phi(x_i^T \beta) = \mathbb{P}(\varepsilon_i \leq x_i^T \beta) = \mathbb{P}(\varepsilon_i \geq -x_i^T \beta) = \mathbb{P}(Z_i \geq 0).$$

Δηλαδή,  $y_i | z_i \stackrel{d}{=} \mathbb{1}_{\{z_i \geq 0\}}$ . Θεωρούμε την prior κατανομή  $\beta \sim \mathcal{N}_k(a, C^{-1})$ . Να υπολογιστούν οι δεσμευμένες posterior κατανομές της παραμέτρου  $\beta$  και των λανθανουσών μεταβλητών  $z_i$ .

Λύση.

Η prior κατανομή μπορεί να γραφτεί ως:

$$\begin{aligned}\pi(\beta) &= (2\pi)^{-\frac{k}{2}} |C^{-1}|^{-\frac{1}{2}} \exp \left\{ -\frac{(\beta - a)^T C (\beta - a)}{2} \right\} \\ &\propto \exp \left\{ -\frac{\beta^T C \beta - 2\beta^T C a + a^T C a}{2} \right\} \\ &\propto \exp \left\{ -\frac{\beta^T C \beta}{2} + \beta^T C a \right\}.\end{aligned}$$

Η πλήρης πιθανοφάνεια, δηλαδή η από κοινού πιθανοφάνεια των παρατηρούμενων μεταβλητών  $y_i$  και των λανθανουσών μεταβλητών  $z_i$ , δίνεται από τη σχέση:

$$\begin{aligned}f(y, z | \beta) &= \prod_{i=1}^n f(y_i, z_i | \beta) \\ &= \prod_{i=1}^n f(z_i | \beta) f(y_i | z_i) \\ &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi}} \exp \left\{ -\frac{(z_i - x_i^T \beta)^2}{2} \right\} \mathbf{1}_{\{z_i \geq 0\}} \mathbf{1}_{\{z_i < 0\}}^{1-y_i}.\end{aligned}$$

Ορίζουμε  $z = (z_1, \dots, z_n)^T \in \mathbb{R}^n$  και τον πίνακα σχεδιασμού  $X = (x_1, \dots, x_n)^T \in \mathbb{R}^{n \times k}$ . Τότε, παρατηρούμε ότι  $z \sim N_n(X\beta, I_n)$ . Δηλαδή, η πλήρης πιθανοφάνεια ολόκληρου του δείγματος δίνεται από τη σχέση:

$$\begin{aligned}f(y, z | \beta) &= f(z | \beta) \cdot f(y | z) \\ &= f(z | \beta) \cdot \prod_{i=1}^n f(y_i | z_i) \\ &= (2\pi)^{-\frac{n}{2}} |I_n|^{-\frac{1}{2}} \exp \left\{ -\frac{(z - X\beta)^T (z - X\beta)}{2} \right\} \cdot \prod_{i=1}^n \mathbf{1}_{\{z_i \geq 0\}}^{y_i} \mathbf{1}_{\{z_i < 0\}}^{1-y_i} \\ &\propto \exp \left\{ -\frac{z^T z - 2\beta^T X^T z + \beta^T X^T X \beta}{2} \right\} \cdot \prod_{i=1}^n \mathbf{1}_{\{z_i \geq 0\}}^{y_i} \mathbf{1}_{\{z_i < 0\}}^{1-y_i} \\ &\propto \exp \left\{ -\frac{\beta^T X^T X \beta}{2} + \beta^T X^T z \right\} \cdot \prod_{i=1}^n \mathbf{1}_{\{z_i \geq 0\}}^{y_i} \mathbf{1}_{\{z_i < 0\}}^{1-y_i}.\end{aligned}$$

Επομένως, παίρνουμε τη δεσμευμένη posterior κατανομή του  $\beta$  ως εξής:

$$\begin{aligned}\pi(\beta | z, y) &\propto \pi(\beta, z | y) \\ &\propto \pi(\beta) \cdot f(y, z | \beta) \\ &\propto \exp \left\{ -\frac{\beta^T C \beta}{2} + \beta^T C a \right\} \cdot \exp \left\{ -\frac{\beta^T X^T X \beta}{2} + \beta^T X^T z \right\} \\ &= \exp \left\{ -\frac{1}{2} \beta^T \underbrace{(C + X^T X)}_{C_n} \beta + \beta^T (C a + X^T z) \right\}\end{aligned}$$

$$= \exp \left\{ -\frac{\beta^T C_n \beta}{2} + \beta^T \underbrace{(C + X^T X)}_{C_n} \underbrace{(C + X^T X)^{-1} (Ca + X^T z)}_{a_n} \right\}.$$

Επιπλέον, παίρνουμε τη δεσμευμένη posterior κατανομή των λανθανουσών μεταβλητών  $z_i$  ως εξής:

$$f(z_i | y_i, \beta) \propto f(y_i, z_i | \beta) \propto \exp \left\{ -\frac{(z_i - x_i^T \beta)^2}{2} \right\} \mathbf{1}_{\{z_i \geq 0\}}^{y_i} \mathbf{1}_{\{z_i < 0\}}^{1-y_i}.$$

Δηλαδή,

$$\beta | z \sim \mathcal{N}_k \left( (C + X^T X)^{-1} (Ca + X^T z), (C + X^T X)^{-1} \right),$$

$$(z_i | y_i = 1, \beta) \sim \mathcal{N}(x_i^T \beta, 1) \mathbf{1}_{\{z_i \geq 0\}}, \quad (z_i | y_i = 0, \beta) \sim \mathcal{N}(x_i^T \beta, 1) \mathbf{1}_{\{z_i < 0\}}.$$

Παρατηρούμε ότι:

$$F_{Z_i | y_i = 1, \beta}(z_i) = \frac{\Phi(z_i - x_i^T \beta) - \Phi(-x_i^T \beta)}{1 - \Phi(-x_i^T \beta)} \mathbf{1}_{\{z_i \geq 0\}}, \quad F_{Z_i | y_i = 0, \beta}(z_i) = \frac{\Phi(z_i - x_i^T \beta)}{\Phi(-x_i^T \beta)} \mathbf{1}_{\{z_i < 0\}}.$$

Αν  $U_1, U_2, \dots, U_n \sim \text{Unif}[0, 1]$ , τότε παίρνουμε ότι:


$$Z_i = \begin{cases} \Phi^{-1} [\Phi(x_i^T \beta) U_i + 1 - \Phi(x_i^T \beta)] + x_i^T \beta, & y_i = 1 \\ \Phi^{-1} [(1 - \Phi(x_i^T \beta)) U_i] + x_i^T \beta, & y_i = 0 \end{cases}.$$

```
MCMCprobit = function(Y, X, beta0, a, C, niter, nburn) {
  library(MASS)
  n = length(Y)
  k = dim(X)[2]
  beta = matrix(0, niter, k)
  Z = matrix(0, niter, n)
  beta[1, ] = beta0
  prob = pnorm(X %*% beta[1, ])
  U = runif(n)
  Z[1, ] = X %*% beta[1, ] + ifelse(Y == 1, qnorm(prob * U + 1 - prob), qnorm((1 -
  prob) * U))
  for (i in 2:niter) {
    Cninv = solve(C + crossprod(X))
    an = crossprod(Cninv, C %*% a + crossprod(X, Z[i - 1, ]))
    beta[i, ] = mvrnorm(1, an, Cninv)
    prob = pnorm(X %*% beta[i, ])
    U = runif(n)
    Z[i, ] = X %*% beta[i, ] + ifelse(Y == 1, qnorm(prob * U + 1 - prob),
    qnorm((1 - prob) * U))
  }
  return(list(beta = beta[-(1:nburn), ], Z = Z[-(1:nburn), ]))
}
```

```

n = 1000
k = 2
beta = c(1, 2)
X = cbind(1, rnorm(n))
Y = rbinom(n, 1, pnorm(X %*% beta))
posterior = MCMCprobit(Y, X, numeric(k), numeric(k), matrix(0, k, k), 5000,
  1000)
par(mfrow = c(1, 2))
hist(posterior$beta[, 1], "FD", freq = FALSE, main = NA, xlab = expression(beta[0]))
abline(v = beta[1], col = 2, lty = 2)
hist(posterior$beta[, 2], "FD", freq = FALSE, main = NA, xlab = expression(beta[1]))
abline(v = beta[2], col = 2, lty = 2)

```



### 2.3 Λογαριθμικό Μοντέλο Poisson

Θεωρούμε το μοντέλο  $y_i \sim \text{Poisson}(\lambda_i)$ , όπου  $\log \lambda_i = \beta_0 + \beta_1 x_i$ , δηλαδή  $\lambda_i = e^{\beta_0 + \beta_1 x_i}$ . Θεωρούμε prior ανεξαρτησία με μη-ορθές κατανομές  $\pi(\beta_0) \propto 1$  και  $\pi(\beta_1) \propto 1$ . Μπορούμε να υλοποιήσουμε έναν αλγόριθμο Random Walk Metropolis-Hastings με προτεινόμενες τυχαίες μεταβλητές  $\beta_0^* | \beta_0^{(\ell-1)} \sim \mathcal{N}(\beta_0^{(\ell-1)}, \sigma_0^2)$  και  $\beta_1^* | \beta_1^{(\ell-1)} \sim \mathcal{N}(\beta_1^{(\ell-1)}, \sigma_1^2)$ .

```

RWMHpois = function(Y, X, beta00, beta10, beta0sd, beta1sd, niter, nburn) {
  beta0 = numeric(niter)
  beta1 = numeric(niter)
  beta0[1] = beta00
  beta1[1] = beta10
  for (i in 2:niter) {
    beta0star = rnorm(1, beta0[i - 1], beta0sd)
    logA = sum(dpois(Y, exp(beta0star + beta1[i - 1] * X), log = TRUE) -
      dpois(Y, exp(beta0[i - 1] + beta1[i - 1] * X), log = TRUE))

```




```


    beta0[i] = ifelse(log(runif(1)) < logA, beta0star, beta0[i - 1])
    beta1star = rnorm(1, beta1[i - 1], beta1sd)
    logA = sum(dpois(Y, exp(beta0[i] + beta1star * X), log = TRUE) - dpois(Y,
        exp(beta0[i] + beta1[i - 1] * X), log = TRUE))
    beta1[i] = ifelse(log(runif(1)) < logA, beta1star, beta1[i - 1])
  }
  return(list(beta0 = beta0[-(1:nburn)], beta1 = beta1[-(1:nburn)]))
}

n = 1000
beta0 = 1
beta1 = 2
X = rnorm(n)
Y = rpois(n, exp(beta0 + beta1 * X))
posterior = RWMHpois(Y, X, 0, 0, 0.015, 0.0075, 5000, 1000)
par(mfrow = c(1, 2))
plot(posterior$beta0, type = "l", ylab = expression(beta[0]))
abline(h = beta0, col = 2, lty = 2)
plot(posterior$beta1, type = "l", ylab = expression(beta[1]))
abline(h = beta1, col = 2, lty = 2)

```



Index




Index

```

hist(posterior$beta0, "FD", freq = FALSE, main = NA, xlab = expression(beta[0]))
abline(v = beta0, col = 2, lty = 2)
hist(posterior$beta1, "FD", freq = FALSE, main = NA, xlab = expression(beta[1]))
abline(v = beta1, col = 2, lty = 2)

```



## 2.4 Μηδενικά Διογκωμένο Μοντέλο Poisson

Θεωρούμε το μηδενικά διογκωμένο μοντέλο παλινδρόμησης:

$$\mathbb{P}(Y_i = k) = \begin{cases} 1 - p + pe^{-\lambda}, & k = 0 \\ pe^{-\lambda} \frac{\lambda^k}{k!}, & k = 1, 2, \dots \end{cases}$$

Θεωρούμε τις ανεξάρτητες τυχαίες μεταβλητές  $z_i \sim \text{Bernoulli}(p)$ . Για  $k = 0, 1, \dots$ , παρατηρούμε ότι:

$$\mathbb{P}(Y_i = k | Z_i = 1) = e^{-\lambda} \frac{\lambda^k}{k!}, \quad \mathbb{P}(Y_i = 0 | Z_i = 0) = 1.$$

Δηλαδή, ισχύει ότι  $(y_i | z_i = 1) \sim \text{Poisson}(\lambda)$  και  $(y_i | z_i = 0) \stackrel{d}{=} 0$ . Θεωρούμε prior ανεξαρτησία με κατανομές  $p \sim \text{Beta}(a, c)$  και  $\lambda \sim \text{Gamma}(d, q)$ . Να υπολογιστούν οι δεσμευμένες posterior κατανομές των παραμέτρων  $p, \lambda$  και των λανθανουσών μεταβλητών  $z_i$ .

Λύση.

Η από κοινού prior κατανομή μπορεί να γραφτεί ως:

$$\begin{aligned} \pi(p, \lambda) &= \pi(p)\pi(\lambda) \\ &= \frac{\Gamma(a+c)}{\Gamma(a)\Gamma(c)} p^{a-1}(1-p)^{c-1} \cdot \frac{q^d}{\Gamma(d)} \lambda^{d-1} e^{-q\lambda} \\ &\propto p^{a-1}(1-p)^{c-1} \cdot \lambda^{d-1} e^{-q\lambda}. \end{aligned}$$

Η πλήρης πιθανοφάνεια, δηλαδή η από κοινού πιθανοφάνεια των παρατηρούμενων μεταβλητών  $y_i$  και των λανθανουσών μεταβλητών  $z_i$ , δίνεται από τη σχέση:

$$f(y, z | p, \lambda) = \prod_{i=1}^n f(y_i, z_i | p, \lambda)$$

$$\begin{aligned}
&= \prod_{i=1}^n f(z_i | p) f(y_i | z_i, \lambda) \\
&= \prod_{i=1}^n p^{z_i} (1-p)^{1-z_i} \left( e^{-\lambda} \frac{\lambda^{y_i}}{y_i!} \right)^{z_i} \mathbb{1}_{\{y_i=0\}}^{1-z_i} \\
&\propto \prod_{i=1}^n p^{z_i} (1-p)^{1-z_i} e^{-\lambda z_i} \lambda^{y_i} \mathbb{1}_{\{y_i=0\}}^{1-z_i} \\
&\propto p^{n\bar{z}} (1-p)^{n-n\bar{z}} \cdot \lambda^{n\bar{y}} e^{-n\lambda\bar{z}} \cdot \prod_{i=1}^n \mathbb{1}_{\{y_i=0\}}^{1-z_i}.
\end{aligned}$$

Επομένως, παίρνουμε τις δεσμευμένες posterior κατανομές των  $p$  και  $\lambda$  ως εξής:

$$\begin{aligned}
\pi(p | \lambda, z, y) &\propto \pi(p, \lambda, z | y) \\
&\propto \pi(p) \cdot f(y, z | p, \lambda) \\
&\propto p^{a-1} (1-p)^{c-1} \cdot p^{n\bar{z}} (1-p)^{n-n\bar{z}} \\
&= p^{a+n\bar{z}-1} (1-p)^{c+n-n\bar{z}-1},
\end{aligned}$$

$$\begin{aligned}
\pi(\lambda | p, z, y) &\propto \pi(\lambda) \cdot f(y, z | p, \lambda) \\
&\propto \lambda^{d-1} e^{-q\lambda} \cdot \lambda^{n\bar{y}} e^{-n\lambda\bar{z}} \\
&= \lambda^{d+n\bar{y}-1} e^{-(q+n\bar{z})\lambda}.
\end{aligned}$$

Επιπλέον, παίρνουμε τη δεσμευμένη posterior κατανομή των λανθανουσών μεταβλητών  $z_i$  ως εξής:

$$f(z_i | y_i, p, \lambda) \propto f(y_i, z_i | p, \lambda) \propto p^{z_i} (1-p)^{1-z_i} e^{-\lambda z_i} \mathbb{1}_{\{y_i=0\}}^{1-z_i} = (pe^{-\lambda})^{z_i} (1-p)^{1-z_i} \mathbb{1}_{\{y_i=0\}}^{1-z_i}.$$

Δηλαδή,

$$p | z, y \sim \text{Beta}(a + n\bar{z}, c + n - n\bar{z}), \quad \lambda | z, y \sim \text{Gamma}(d + n\bar{y}, q + n\bar{z}),$$

$$(z_i | y_i = 0, p, \lambda) \sim \text{Bernoulli}\left(\frac{pe^{-\lambda}}{pe^{-\lambda} + 1 - p}\right), \quad (z_i | y_i > 0, p, \lambda) \stackrel{d}{=} 1.$$

```

MCMCzip = function(Y, p0, lambda0, a, c, p, q, niter, nburn) {
  n = length(Y)
  SY = sum(Y)
  p = numeric(niter)
  lambda = numeric(niter)
  Z = matrix(0, niter, n)
  p[1] = p0
  lambda[1] = lambda0
  Z[1, ] = ifelse(Y == 0, rbinom(n, 1, p[1] * exp(-lambda[1]) / (p[1] * exp(-lambda[1]) +
    1 - p[1])), 1)
  for (i in 2:niter) {
    SZ = sum(Z[i - 1, ])
    p[i] = rbeta(1, a + SZ, c + n - SZ)
    lambda[i] = rgamma(1, p + SY, q + SZ)
  }
}

```

```

    Z[i, ] = ifelse(Y == 0, rbinom(n, 1, p[i] * exp(-lambda[i])/(p[i] *
      exp(-lambda[i]) + 1 - p[i])), 1)
  }
  return(list(p = p[-(1:nburn)], lambda = lambda[-(1:nburn)], Z = Z[-(1:nburn),
    ]))
}

```

```
n = 1000
```


```
p = 0.75
```

```
lambda = 2
```

```
Y = ifelse(rbinom(n, 1, p) == 1, rpois(n, lambda), 0)
```

```
barplot(table(factor(Y, levels = 0:max(Y)))/n, space = 0)
```

```
lines(0:max(Y) + 0.5, c(1 - p, numeric(max(Y))) + p * dpois(0:max(Y), lambda),
  col = 2, lwd = 2)
```



```
posterior = MCMCzip(Y, 0.5, 1, 0.5, 0.5, 0.5, 0, 5000, 1000)
```



```
par(mfrow = c(1, 2))
```

```
hist(posterior$p, "FD", freq = FALSE, main = NA, xlab = "p")
```

```
abline(v = p, col = 2, lty = 2)
```

```
hist(posterior$lambda, "FD", freq = FALSE, main = NA, xlab = expression(lambda))
```

```
abline(v = lambda, col = 2, lty = 2)
```



### 3 Λύσεις Θεμάτων Εξετάσεων

#### 3.1 Οκτώβριος 2011

Θεωρούμε το ακόλουθο μοντέλο:

- Για  $i = 1, 2, \dots, t$ , η παρατήρηση  $x_i$  είναι μία ανεξάρτητη πραγματοποίηση μίας τυχαίας μεταβλητής Poisson με μέση τιμή  $\theta_1$ .
- Για  $i = t + 1, t + 2, \dots, n$ , η παρατήρηση  $x_i$  είναι μία ανεξάρτητη πραγματοποίηση μίας τυχαίας μεταβλητής Poisson με μέση τιμή  $\theta_2$ .

Υποθέτουμε τις prior  $\theta_1 \sim \text{Gamma}(p_1, q_1)$ ,  $\theta_2 \sim \text{Gamma}(p_2, q_2)$  και  $t \sim U\{1, 2, \dots, n - 1\}$ .

α. Γράψτε ως μία σταθερά κανονικοποίησης τις δεσμευμένες posterior κατανομές των παραμέτρων του μοντέλου. Είναι αυτές γνωστές κατανομές; Επίσης βρείτε την περιθώρια posterior κατανομή του  $t$ . Είναι αυτή γνωστή κατανομή;

β. Γράψτε έναν αλγόριθμο MCMC που να προσομοιώνει δείγμα από την από κοινού posterior κατανομή των παραμέτρων του μοντέλου. Εξηγήστε πώς θα πραγματοποιηθεί η προσομοίωση του  $t$ .

Λύση.

α. Η από κοινού prior κατανομή των  $\theta_1$ ,  $\theta_2$  και  $t$  μπορεί να γραφτεί ως:

$$\begin{aligned}\pi(\theta_1, \theta_2, t) &= \pi(\theta_1) \cdot \pi(\theta_2) \cdot \pi(t) \\ &= \frac{q_1^{p_1}}{\Gamma(p_1)} \theta_1^{p_1-1} e^{-q_1 \theta_1} \cdot \frac{q_2^{p_2}}{\Gamma(p_2)} \theta_2^{p_2-1} e^{-q_2 \theta_2} \cdot \frac{1}{n-1} \\ &\propto \theta_1^{p_1-1} e^{-q_1 \theta_1} \cdot \theta_2^{p_2-1} e^{-q_2 \theta_2}.\end{aligned}$$

Ορίζουμε:

$$S_t = \sum_{i=1}^t x_i.$$

Τότε, παρατηρούμε ότι:

$$S_n - S_t = \sum_{i=1}^n x_i - \sum_{i=1}^t x_i = \sum_{i=t+1}^n x_i.$$

Η πιθανοφάνεια ολόκληρου του δείγματος δίνεται από τη σχέση:

$$\begin{aligned}f(x | \theta_1, \theta_2, t) &= \prod_{i=1}^t f(x_i | \theta_1) \cdot \prod_{i=t+1}^n f(x_i | \theta_2) \\ &= \prod_{i=1}^t e^{-\theta_1} \frac{\theta_1^{x_i}}{x_i!} \cdot \prod_{i=t+1}^n e^{-\theta_2} \frac{\theta_2^{x_i}}{x_i!} \\ &= e^{-t\theta_1} \theta_1^{S_t} \cdot e^{-(n-t)\theta_2} \theta_2^{S_n - S_t} \cdot \prod_{i=1}^n \frac{1}{x_i!} \\ &\propto e^{-t\theta_1} \theta_1^{S_t} \cdot e^{-(n-t)\theta_2} \theta_2^{S_n - S_t}.\end{aligned}$$

Επομένως, παίρνουμε τις δεσμευμένες posterior κατανομές των  $\theta_1$ ,  $\theta_2$  και  $t$  ως εξής:

$$\begin{aligned}\pi(\theta_1 | \theta_2, t, x) &\propto \pi(\theta_1, \theta_2, t | x) \\ &\propto \pi(\theta_1, \theta_2, t) \cdot f(x | \theta_1, \theta_2, t) \\ &\propto \theta_1^{p_1-1} e^{-q_1 \theta_1} \cdot e^{-t \theta_1} \theta_1^{S_t} \\ &= \theta_1^{p_1+S_t-1} e^{-(q_1+t)\theta_1},\end{aligned}$$

$$\begin{aligned}\pi(\theta_2 | \theta_1, t, x) &\propto \pi(\theta_1, \theta_2, t) \cdot f(x | \theta_1, \theta_2, t) \\ &\propto \theta_2^{p_2-1} e^{-q_2 \theta_2} \cdot e^{-(n-t)\theta_2} \theta_2^{S_n-S_t} \\ &= \theta_2^{p_2+S_n-S_t-1} e^{-(q_2+n-t)\theta_2},\end{aligned}$$

$$\begin{aligned}\pi(t | \theta_1, \theta_2, x) &\propto \pi(\theta_1, \theta_2, t) \cdot f(x | \theta_1, \theta_2, t) \\ &\propto e^{-t \theta_1} \theta_1^{S_t} \cdot e^{-(n-t)\theta_2} \theta_2^{S_n-S_t} \\ &\propto e^{-t \theta_1} \theta_1^{S_t} \cdot e^{t \theta_2} \theta_2^{-S_t} \\ &= e^{-(\theta_1-\theta_2)t} \left( \frac{\theta_1}{\theta_2} \right)^{S_t}.\end{aligned}$$

Παρατηρούμε ότι οι παράμετροι  $\theta_1$  και  $\theta_2$  είναι a posteriori ανεξάρτητες δεδομένου του  $t$ , δηλαδή:

$$\theta_1 | t, x \sim \text{Gamma}(p_1 + S_t, q_1 + t), \quad \theta_2 | t, x \sim \text{Gamma}(p_2 + S_n - S_t, q_2 + n - t).$$

Η δεσμευμένη posterior κατανομή του  $t$  είναι μία διακριτή κατανομή  $\pi(t | \theta_1, \theta_2, x)$  με πεπερασμένο στήριγμα  $\{1, 2, \dots, n-1\}$ . Για τον υπολογισμό του διανύσματος πιθανοτήτων  $\pi(t | \theta_1, \theta_2, x)$  χρησιμοποιούμε το λεγόμενο κόλπο Log-Sum-Exp. Δηλαδή, ορίζουμε:

$$v_i = -(\theta_1 - \theta_2)i + S_i \log \frac{\theta_1}{\theta_2}, \quad m = \max_{i \in \{1, \dots, n-1\}} v_i.$$

Τότε, παίρνουμε ότι:

$$\pi(t | \theta_1, \theta_2, x) = \frac{e^{v_t - m}}{\sum_{i=1}^{n-1} e^{v_i - m}}.$$

Επιπλέον, παίρνουμε την περιθώρια posterior κατανομή του  $t$  ως εξής:

$$\begin{aligned}\pi(t | x) &= \int_0^\infty \int_0^\infty \pi(\theta_1, \theta_2, t | x) d\theta_1 d\theta_2 \\ &\propto \int_0^\infty \int_0^\infty \pi(\theta_1, \theta_2, t) f(x | \theta_1, \theta_2, t) d\theta_1 d\theta_2 \\ &\propto \int_0^\infty \int_0^\infty \theta_1^{p_1-1} e^{-q_1 \theta_1} \cdot \theta_2^{p_2-1} e^{-q_2 \theta_2} \cdot e^{-t \theta_1} \theta_1^{S_t} \cdot e^{-(n-t)\theta_2} \theta_2^{S_n-S_t} d\theta_1 d\theta_2 \\ &= \int_0^\infty \theta_1^{p_1+S_t-1} e^{-(q_1+t)\theta_1} d\theta_1 \cdot \int_0^\infty \theta_2^{p_2+S_n-S_t-1} e^{-(q_2+n-t)\theta_2} d\theta_2\end{aligned}$$

$$= \frac{\Gamma(p_1 + S_t)}{(q_1 + t)^{p_1 + S_t}} \cdot \frac{\Gamma(p_2 + S_n - S_t)}{(q_2 + n - t)^{p_2 + S_n - S_t}}.$$

β. Για να πάρουμε δείγμα από αυτήν την από κοινού posterior κατανομή, χρησιμοποιούμε τον δειγματολήπτη Gibbs που φαίνεται στην επόμενη σελίδα.

---

**Algorithm 3.1** Δειγματολήπτης Gibbs

---

Ξεκινάμε με αρχικές τιμές  $\theta_1^{(0)}, \theta_2^{(0)}, t^{(0)}$ .

Επαναλαμβάνουμε τα παρακάτω βήματα:


- 1: Προσομοιώνουμε  $\theta_1^{(k)} \sim \text{Gamma}(p_1 + S_{t^{(k-1)}}, q_1 + t^{(k-1)})$ .
  - 2: Προσομοιώνουμε  $\theta_2^{(k)} \sim \text{Gamma}(p_2 + S_n - S_{t^{(k-1)}}, q_2 + n - t^{(k-1)})$ .
  - 3: Υπολογίζουμε το διάνυσμα πιθανοτήτων  $\pi(t | \theta_1^{(k)}, \theta_2^{(k)}, x)$ . Προσομοιώνουμε μία τιμή  $t^{(k)}$  από το σύνολο  $\{1, 2, \dots, n - 1\}$  σύμφωνα με αυτό το διάνυσμα πιθανοτήτων.
- 

```
MCMCchangept = function(Y, theta10, theta20, p1, q1, p2, q2, niter, nburn) {
  n = length(Y)
  S = cumsum(Y)
  theta1 = numeric(niter)
  theta2 = numeric(niter)
  t = numeric(niter)
  theta1[1] = theta10
  theta2[1] = theta20
  logprob = S[-n] * log(theta1[1]/theta2[1]) - (theta1[1] - theta2[1]) * (1:(n -
    1))
  t[1] = sample(n - 1, 1, prob = exp(logprob - max(logprob)))
  for (i in 2:niter) {
    theta1[i] = rgamma(1, p1 + S[t[i - 1]], q1 + t[i - 1])
    theta2[i] = rgamma(1, p2 + S[n] - S[t[i - 1]], q2 + n - t[i - 1])
    logprob = S[-n] * log(theta1[i]/theta2[i]) - (theta1[i] - theta2[i]) *
      (1:(n - 1))
    t[i] = sample(n - 1, 1, prob = exp(logprob - max(logprob)))
  }
  return(list(theta1 = theta1[-(1:nburn)], theta2 = theta2[-(1:nburn)], t = t[-(1:nburn)]))
}


n = 100
theta1 = 2
theta2 = 4
t = 75
Y = c(rpois(t, theta1), rpois(n - t, theta2))
plot(Y, type = "b", pch = 16, lwd = 2)
abline(h = theta1, col = 4, lty = 2)
```



```
abline(h = theta2, col = 4, lty = 2)
abline(v = t, col = 2, lty = 2)
```



```
posterior = MCMCchangepoint(Y, 1, 1, 0.5, 0, 0.5, 0, 5000, 1000)
par(mfrow = c(1, 3))
hist(posterior$theta1, "FD", freq = FALSE, main = NA, xlab = expression(theta[1]))
abline(v = theta1, col = 2, lty = 2)
hist(posterior$theta2, "FD", freq = FALSE, main = NA, xlab = expression(theta[2]))
abline(v = theta2, col = 2, lty = 2)
barplot(table(factor(posterior$t, levels = min(posterior$t):max(posterior$t)))/4000,
        space = 0)
abline(v = t - min(posterior$t) + 0.5, col = 2, lty = 2)
```



### 3.2 Φεβρουάριος 2009

Έστω τυχαίο δείγμα  $y_1, \dots, y_n$  από την εξής μίξη κατανομών Poisson:

$$f(y_i | \alpha, \beta, \gamma) = \gamma f_{\text{Poisson}}(y_i | \alpha) + (1 - \gamma) f_{\text{Poisson}}(y_i | \alpha e^{\beta x_i}),$$

όπου με  $f_{\text{Poisson}}(y_i | \theta)$  συμβολίζουμε τη συνάρτηση πιθανότητας της κατανομής Poisson( $\theta$ ) και  $x_i$  είναι μία επεξηγηματική μεταβλητή για την  $i$ -οστή παρατήρηση. Θεωρούμε prior ανεξαρτησία ανάμεσα στα  $\alpha, \beta, \gamma$  με κατανομές  $\alpha \sim \text{Gamma}(2, 1)$ ,  $\beta \sim \mathcal{N}(0, 1)$  και  $\gamma \sim U(0, 1) \equiv \text{Beta}(1, 1)$ .

- α. Γράψτε ως μία σταθερά κανονικοποίησης την από κοινού posterior κατανομή των παραμέτρων  $\alpha, \beta, \gamma$ . Για να πάρετε δείγμα από αυτήν την posterior κατανομή, κατασκευάστε έναν αλγόριθμο MCMC με βήματα Metropolis-Hastings για την ανανέωση καθεμιάς από τις παραμέτρους. Για τις παραμέτρους  $\alpha, \gamma$  να χρησιμοποιηθούν ως ανεξάρτητες γεννήτριες προτεινόμενων τιμών οι αντίστοιχες prior κατανομές των παραμέτρων, ενώ για το  $\beta$  να χρησιμοποιηθεί Random Walk Metropolis-Hastings. Για το τελευταίο βήμα πώς θα επιλεγεί η διασπορά της γεννήτριας προτεινόμενων τιμών;
- β. Θεωρούμε τώρα την παρακάτω τεχνική αύξησης δεδομένων. Για κάθε  $y_i$  εισάγουμε μία δίτιμη τυχαία μεταβλητή  $z_i$  τέτοια, ώστε:

$$P(Z_i = 1 | \gamma) = 1 - P(Z_i = 0 | \gamma) = \gamma.$$

Τότε, η δεσμευμένη συνάρτηση πιθανότητας της  $y_i$  δεδομένου του  $z_i$  θα είναι:

$$f(y_i | z_i, \alpha, \beta) = \begin{cases} f_{\text{Poisson}}(y_i | \alpha), & z_i = 1 \\ f_{\text{Poisson}}(y_i | \alpha e^{\beta x_i}), & z_i = 0 \end{cases}.$$

Βρείτε τις δεσμευμένες posterior κατανομές όλων των αγνώστων ποσοτήτων. Είναι αυτές γνωστές κατανομές; Γράψτε έναν αλγόριθμο MCMC που να προσομοιώνει αυτές τις ποσότητες. Πώς θα προσομοιώσετε καθένα από τα  $z_i$ ;

Λύση.

- α. Η από κοινού prior κατανομή των  $\alpha, \beta$  και  $\gamma$  μπορεί να γραφτεί ως:

$$\begin{aligned} \pi(\alpha, \beta, \gamma) &= \pi(\alpha) \cdot \pi(\beta) \cdot \pi(\gamma) \\ &= \alpha e^{-\alpha} \cdot \frac{1}{\sqrt{2\pi}} e^{-\beta^2/2} \cdot 1 \\ &\propto \alpha e^{-\alpha} \cdot e^{-\beta^2/2}. \end{aligned}$$

Η πιθανοφάνεια ολόκληρου του δείγματος δίνεται από τη σχέση:

$$\begin{aligned} f(y | \alpha, \beta, \gamma) &= \prod_{i=1}^n f(y_i | \alpha, \beta, \gamma) \\ &= \prod_{i=1}^n [\gamma f_{\text{Poisson}}(y_i | \alpha) + (1 - \gamma) f_{\text{Poisson}}(y_i | \alpha e^{\beta x_i})] \end{aligned}$$

$$\begin{aligned}
&= \prod_{i=1}^n \left[ \gamma e^{-\alpha} \frac{\alpha^{y_i}}{y_i!} + (1-\gamma) e^{-\alpha e^{\beta x_i}} \frac{\alpha^{y_i} e^{\beta x_i y_i}}{y_i!} \right] \\
&= \prod_{i=1}^n \frac{\alpha^{y_i}}{y_i!} \left[ \gamma e^{-\alpha} + (1-\gamma) e^{\beta x_i y_i - \alpha e^{\beta x_i}} \right] \\
&\propto \alpha^{n\bar{y}} \prod_{i=1}^n \left[ \gamma e^{-\alpha} + (1-\gamma) e^{\beta x_i y_i - \alpha e^{\beta x_i}} \right].
\end{aligned}$$

Για τον υπολογισμό της πιθανοφάνειας χρησιμοποιούμε πάλι το κόλπο Log-Sum-Exp. Δηλαδή, ορίζουμε:

$$v_{i1} = \log \gamma + \log f_{\text{Poisson}}(y_i | \alpha), \quad v_{i2} = \log(1-\gamma) + \log f_{\text{Poisson}}(y_i | \alpha e^{\beta x_i}), \quad m_i = \max\{v_{i1}, v_{i2}\}.$$

Τότε, παίρνουμε ότι:

$$\log f(y | \alpha, \beta, \gamma) = \sum_{i=1}^n [m_i + \log(e^{v_{i1}-m_i} + e^{v_{i2}-m_i})].$$

Επομένως, παίρνουμε την από κοινού posterior κατανομή των  $\alpha$ ,  $\beta$  και  $\gamma$  ως εξής:

$$\begin{aligned}
\pi(\alpha, \beta, \gamma | y) &\propto \pi(\alpha, \beta, \gamma) \cdot f(y | \alpha, \beta, \gamma) \\
&\propto \alpha e^{-\alpha} \cdot e^{-\beta^2/2} \cdot \alpha^{n\bar{y}} \prod_{i=1}^n \left[ \gamma e^{-\alpha} + (1-\gamma) e^{\beta x_i y_i - \alpha e^{\beta x_i}} \right] \\
&= \alpha^{n\bar{y}+1} e^{-\alpha} \cdot e^{-\beta^2/2} \cdot \prod_{i=1}^n \left[ \gamma e^{-\alpha} + (1-\gamma) e^{\beta x_i y_i - \alpha e^{\beta x_i}} \right].
\end{aligned}$$

Για να πάρουμε δείγμα από αυτήν την από κοινού posterior κατανομή, χρησιμοποιούμε τον αλγόριθμο Metropolis-Hastings που φαίνεται στην επόμενη σελίδα. Προσαρμόζουμε τη διασπορά  $\sigma_\beta^2$  της γεννήτριας προτεινόμενων τιμών για το  $\beta$  έτσι, ώστε το ποσοστό αποδοχής των προτεινόμενων τιμών του αλγορίθμου για το  $\beta$  να είναι περίπου ίσο με 50%.

---

**Algorithm 3.2** Metropolis-Hastings

---

Ξεκινάμε με αρχικές τιμές  $\alpha^{(0)}, \gamma^{(0)}, \beta^{(0)}$ .

Επαναλαμβάνουμε τα παρακάτω βήματα:

1: Προσομοιώνουμε  $\alpha^* \sim \text{Gamma}(10, 1)$  και  $U_\alpha \sim U(0, 1)$ .

2: Υπολογίζουμε τον λόγο:

$$A_\alpha = \frac{f(y | \alpha^*, \beta^{(\ell-1)}, \gamma^{(\ell-1)})}{f(y | \alpha^{(\ell-1)}, \beta^{(\ell-1)}, \gamma^{(\ell-1)})}.$$

3: Αν  $U_\alpha < A_\alpha$ , τότε θέτουμε  $\alpha^{(\ell)} = \alpha^*$ . Διαφορετικά, θέτουμε  $\alpha^{(\ell)} = \alpha^{(\ell-1)}$ .

4: Προσομοιώνουμε  $\gamma^* \sim U(0, 1)$  και  $U_\gamma \sim U(0, 1)$ .

5: Υπολογίζουμε τον λόγο:

$$A_\gamma = \frac{f(y | \alpha^{(\ell)}, \beta^{(\ell-1)}, \gamma^*)}{f(y | \alpha^{(\ell)}, \beta^{(\ell-1)}, \gamma^{(\ell-1)})}.$$

6: Αν  $U_\gamma < A_\gamma$ , τότε θέτουμε  $\gamma^{(\ell)} = \gamma^*$ . Διαφορετικά, θέτουμε  $\gamma^{(\ell)} = \gamma^{(\ell-1)}$ .

7: Προσομοιώνουμε  $\beta^* \sim \mathcal{N}(\beta^{(\ell-1)}, \sigma_\beta^2)$  και  $U_\beta \sim U(0, 1)$ .

8: Υπολογίζουμε τον λόγο:

$$A_\beta = \frac{\pi(\beta^* | \alpha^{(\ell)}, \gamma^{(\ell)}, y)}{\pi(\beta^{(\ell-1)} | \alpha^{(\ell)}, \gamma^{(\ell)}, y)}.$$

9: Αν  $U_\beta < A_\beta$ , τότε θέτουμε  $\beta^{(\ell)} = \beta^*$ . Διαφορετικά, θέτουμε  $\beta^{(\ell)} = \beta^{(\ell-1)}$ .

---

```
logdpois = function(Y, X, alpha, gamma, beta) {  
  logprob = cbind(log(gamma) + dpois(Y, alpha, log = TRUE), log(1 - gamma) +  
    dpois(Y, alpha * exp(beta * X), log = TRUE))  
  maximum = apply(logprob, 1, max)  
  return(sum(maximum + log(rowSums(exp(logprob - maximum)))))  
}
```


```
MHpois = function(Y, X, alpha0, gamma0, beta0, betasd, niter, nburn) {  
  alpha = numeric(niter)  
  gamma = numeric(niter)  
  beta = numeric(niter)  
  alpha[1] = alpha0  
  gamma[1] = gamma0  
  beta[1] = beta0  
  for (i in 2:niter) {
```

```

    alphastar = rgamma(1, 2)
    logA = logdpois(Y, X, alphastar, gamma[i - 1], beta[i - 1]) - logdpois(Y,
      X, alpha[i - 1], gamma[i - 1], beta[i - 1])
    alpha[i] = ifelse(log(runif(1)) < logA, alphastar, alpha[i - 1])
    gammastar = runif(1)
    logA = logdpois(Y, X, alpha[i], gammastar, beta[i - 1]) - logdpois(Y,
      X, alpha[i], gamma[i - 1], beta[i - 1])
    gamma[i] = ifelse(log(runif(1)) < logA, gammastar, gamma[i - 1])
    betastar = rnorm(1, beta[i - 1], betasd)
    logA = (beta[i - 1]^2 - betastar^2)/2 + logdpois(Y, X, alpha[i], gamma[i],
      betastar) - logdpois(Y, X, alpha[i], gamma[i], beta[i - 1])
    beta[i] = ifelse(log(runif(1)) < logA, betastar, beta[i - 1])
  }
  return(list(alpha = alpha[-(1:nburn)], gamma = gamma[-(1:nburn)], beta = beta[-(1:nburn)]))
}

n = 1000
alpha = 2
gamma = 0.25
beta = 0.5
X = rnorm(n)
Z = rbinom(n, 1, gamma)
Y = ifelse(Z == 1, rpois(n, alpha), rpois(n, alpha * exp(beta * X)))
posterior = MHpois(Y, X, 1, 0.5, 0, 0.05, 5000, 1000)
par(mfrow = c(1, 3))
plot(posterior$alpha, type = "l", ylab = expression(alpha))
abline(h = alpha, col = 2, lty = 2)
plot(posterior$gamma, type = "l", ylab = expression(gamma))
abline(h = gamma, col = 2, lty = 2)
plot(posterior$beta, type = "l", ylab = expression(beta))
abline(h = beta, col = 2, lty = 2)


```



```

hist(posterior$alpha, "FD", freq = FALSE, main = NA, xlab = expression(alpha))
abline(v = alpha, col = 2, lty = 2)
hist(posterior$gamma, "FD", freq = FALSE, main = NA, xlab = expression(gamma))
abline(v = gamma, col = 2, lty = 2)
hist(posterior$beta, "FD", freq = FALSE, main = NA, xlab = expression(beta))
abline(v = beta, col = 2, lty = 2)

```



Παρατηρούμε ότι η prior του  $\alpha$  δεν είναι καθόλου αποδοτική ως ανεξάρτητη προτεινόμενη συνάρτηση πυκνότητας πιθανότητας.

β. Ορίζουμε:

$$n_1 = \sum_{i=1}^n \mathbb{1}_{\{z_i=1\}}, \quad S_{XY} = \sum_{i=1}^n \mathbb{1}_{\{z_i=0\}} x_i y_i, \quad S_\beta = \sum_{i=1}^n \mathbb{1}_{\{z_i=0\}} e^{\beta x_i}.$$

Η πλήρης πιθανοφάνεια, δηλαδή η από κοινού πιθανοφάνεια των παρατηρούμενων μεταβλητών  $y_i$  και των λανθανουσών μεταβλητών  $z_i$ , δίνεται από τη σχέση:

$$\begin{aligned} f(y, z \mid \alpha, \beta, \gamma) &= \prod_{i=1}^n f(y_i, z_i \mid \alpha, \beta, \gamma) \\ &= \prod_{i=1}^n f(z_i \mid \gamma) f(y_i \mid z_i, \alpha, \beta) \\ &= \prod_{i=1}^n [P(Z_i = 1 \mid \gamma) f_{\text{Poisson}}(y_i \mid \alpha)]^{\mathbb{1}_{\{z_i=1\}}} [P(Z_i = 0 \mid \gamma) f_{\text{Poisson}}(y_i \mid \alpha e^{\beta x_i})]^{\mathbb{1}_{\{z_i=0\}}} \\ &= \prod_{i=1}^n \left( \gamma e^{-\alpha} \frac{\alpha^{y_i}}{y_i!} \right)^{\mathbb{1}_{\{z_i=1\}}} \left[ (1 - \gamma) e^{-\alpha e^{\beta x_i}} \frac{\alpha^{y_i} e^{\beta x_i y_i}}{y_i!} \right]^{\mathbb{1}_{\{z_i=0\}}} \\ &= \prod_{i=1}^n (\gamma e^{-\alpha})^{\mathbb{1}_{\{z_i=1\}}} \left[ (1 - \gamma) e^{\beta x_i y_i - \alpha e^{\beta x_i}} \right]^{\mathbb{1}_{\{z_i=0\}}} \prod_{i=1}^n \frac{\alpha^{y_i}}{y_i!} \\ &\propto \gamma^{n_1} e^{-n_1 \alpha} \cdot (1 - \gamma)^{n - n_1} e^{\beta S_{XY} - \alpha S_\beta} \cdot \alpha^{n \bar{y}} \\ &= \alpha^{n \bar{y}} e^{-(S_\beta + n_1) \alpha} \cdot \gamma^{n_1} (1 - \gamma)^{n - n_1} \cdot e^{S_{XY} \beta}. \end{aligned}$$

Επομένως, παίρνουμε τις δεσμευμένες posterior κατανομές των  $\alpha$  και  $\gamma$  ως εξής:

$$\begin{aligned} \pi(\alpha \mid \beta, \gamma, z, y) &\propto \pi(\alpha, \beta, \gamma, z \mid y) \\ &\propto \pi(\alpha, \beta, \gamma) \cdot f(y, z \mid \alpha, \beta, \gamma) \\ &\propto \alpha e^{-\alpha} \cdot \alpha^{n \bar{y}} e^{-(S_\beta + n_1) \alpha} \\ &= \alpha^{n \bar{y} + 1} e^{-(S_\beta + n_1 + 1) \alpha}, \end{aligned}$$

$$\begin{aligned} \pi(\gamma \mid \alpha, \beta, z, y) &\propto \pi(\alpha, \beta, \gamma) \cdot f(y, z \mid \alpha, \beta, \gamma) \\ &\propto \gamma^{n_1} (1 - \gamma)^{n - n_1}. \end{aligned}$$

Δηλαδή,

$$\begin{aligned} \alpha \mid \beta, z, y &\sim \text{Gamma}(n \bar{y} + 2, S_\beta + n_1 + 1), \\ \gamma \mid z &\sim \text{Beta}(n_1 + 1, n - n_1 + 1). \end{aligned}$$

Επιπλέον, παίρνουμε τη δεσμευμένη posterior κατανομή του  $\beta$  ως εξής:

$$\begin{aligned} \pi(\beta \mid \alpha, z, y) &\propto \pi(\alpha, \beta, \gamma) \cdot f(y, z \mid \alpha, \beta, \gamma) \\ &\propto e^{-\beta^2/2 + S_{XY} \beta - \alpha S_\beta}, \end{aligned}$$

η οποία δεν είναι κάποια γνωστή κατανομή.

Τέλος, παίρνουμε τη δεσμευμένη posterior κατανομή των λανθανουσών μεταβλητών  $z_i$  ως εξής:

$$f(z_i \mid y_i, \alpha, \beta, \gamma) \propto f(y_i, z_i \mid \alpha, \beta, \gamma) \propto (\gamma e^{-\alpha})^{\mathbb{1}_{\{z_i=1\}}} \left[ (1 - \gamma) e^{\beta x_i y_i - \alpha e^{\beta x_i}} \right]^{\mathbb{1}_{\{z_i=0\}}}.$$

Δηλαδή,

$$(z_i | y_i, \alpha, \beta, \gamma) \sim \text{Bernoulli} \left( \frac{\gamma e^{-\alpha}}{\gamma e^{-\alpha} + (1 - \gamma) e^{\beta x_i y_i - \alpha e^{\beta x_i}}} \right).$$

Για να πάρουμε δείγμα από αυτήν την από κοινού posterior κατανομή, χρησιμοποιούμε τον αλγόριθμο MCMC που φαίνεται παρακάτω.

---

**Algorithm 3.3** Markov Chain Monte Carlo

---

Ξεκινάμε με αρχικές τιμές  $\alpha^{(0)}, \gamma^{(0)}, \beta^{(0)}, z^{(0)}$ .

Επαναλαμβάνουμε τα παρακάτω βήματα:

1: Προσομοιώνουμε  $\alpha^{(\ell)} \sim \text{Gamma}(n\bar{y} + 2, S_{\beta^{(\ell-1)}} + n_1 + 1)$ .

2: Προσομοιώνουμε  $\gamma^{(\ell)} \sim \text{Beta}(n_1 + 1, n - n_1 + 1)$ .

3: Προσομοιώνουμε  $\beta^* \sim \mathcal{N}(\beta^{(\ell-1)}, \sigma_\beta^2)$  και  $U_\beta \sim U(0, 1)$ .

4: Υπολογίζουμε τον λόγο:

$$A_\beta = \frac{\pi(\beta^* | \alpha^{(\ell)}, z^{(\ell-1)}, y)}{\pi(\beta^{(\ell-1)} | \alpha^{(\ell)}, z^{(\ell-1)}, y)}.$$

5: Αν  $U_\beta < A_\beta$ , τότε θέτουμε  $\beta^{(\ell)} = \beta^*$ . Διαφορετικά, θέτουμε  $\beta^{(\ell)} = \beta^{(\ell-1)}$ .

6: Υπολογίζουμε τις πιθανότητες  $p_i = P(Z_i = 1 | y_i, \alpha^{(\ell)}, \gamma^{(\ell)}, \beta^{(\ell)})$ .

7: Προσομοιώνουμε  $U_i \sim U(0, 1)$ .

8: Αν  $U_i < p_i$ , τότε θέτουμε  $z_i^{(\ell)} = 1$ . Διαφορετικά, θέτουμε  $z_i^{(\ell)} = 0$ .

---

```
prob = function(Y, X, alpha, gamma, beta) {  
  logprob = cbind(log(gamma) - alpha, log(1 - gamma) + beta * X * Y - alpha *  
    exp(beta * X))  
  maximum = apply(logprob, 1, max)  
  unnormalized = exp(logprob - maximum)  
  return(unnormalized[, 1]/rowSums(unnormalized))  
}
```

```
MCMCpois = function(Y, X, alpha0, gamma0, beta0, betasd, niter, nburn) {  
  n = length(Y)  
  S = sum(Y)  
  alpha = numeric(niter)  
  gamma = numeric(niter)  
  beta = numeric(niter)  
  Z = matrix(0, niter, n)  
  alpha[1] = alpha0  
  gamma[1] = gamma0  
  beta[1] = beta0  
  Z[1, ] = rbinom(n, 1, prob(Y, X, alpha[1], gamma[1], beta[1]))
```



```


for (i in 2:niter) {
  n1 = sum(Z[i - 1, ])
  Sbeta = sum(exp(beta[i - 1] * X[Z[i - 1, ] == 0]))
  alpha[i] = rgamma(1, S + 2, Sbeta + n1 + 1)
  gamma[i] = rbeta(1, n1 + 1, n - n1 + 1)
  betastar = rnorm(1, beta[i - 1], betasd)
  logA = (beta[i - 1]^2 - betastar^2)/2 + sum(X[Z[i - 1, ] == 0] * Y[Z[i -
    1, ] == 0]) * (betastar - beta[i - 1]) + alpha[i] * (Sbeta - sum(exp(betastar *
    X[Z[i - 1, ] == 0])))
  beta[i] = ifelse(log(runif(1)) < logA, betastar, beta[i - 1])
  Z[i, ] = rbinom(n, 1, prob(Y, X, alpha[i], gamma[i], beta[i]))
}
return(list(alpha = alpha[-(1:nburn)], gamma = gamma[-(1:nburn)], beta = beta[-(1:nburn)],
  Z = Z[-(1:nburn), ]))
}

```

```

posterior = MCMCpois(Y, X, 1, 0.5, 0, 0.05, 5000, 1000)
par(mfrow = c(1, 3))
plot(posterior$alpha, type = "l", ylab = expression(alpha))
abline(h = alpha, col = 2, lty = 2)
plot(posterior$gamma, type = "l", ylab = expression(gamma))
abline(h = gamma, col = 2, lty = 2)
plot(posterior$beta, type = "l", ylab = expression(beta))
abline(h = beta, col = 2, lty = 2)

```



```

hist(posterior$alpha, "FD", freq = FALSE, main = NA, xlab = expression(alpha))
abline(v = alpha, col = 2, lty = 2)

```

```
hist(posterior$gamma, "FD", freq = FALSE, main = NA, xlab = expression(gamma))
abline(v = gamma, col = 2, lty = 2)
hist(posterior$beta, "FD", freq = FALSE, main = NA, xlab = expression(beta))
abline(v = beta, col = 2, lty = 2)
```

