

BNPdensity: Paquete R para estimación de densidades y clasificación

Luis E. Nieto-Barajas

(conjunto con E. Barrios e I. Prüster)

Departamento de Estadística, ITAM, Mexico

v0.5 Encuentro de usuarios de R

30 de marzo, 2012


Contenido

- Introducción
- Paquete BNPdensity
- Ejemplos


Objetivos

- **Clasificación:** Recuperar los componentes de una mezcla de subpoblaciones en un conjunto de datos
- **Estimación de densidades:** Estimar de manera adecuada la función de densidad a partir de un conjunto de datos

Datos de galaxias.



Datos de enzimas.



Introducción

- Estimación de densidades es un problema de naturaleza **no paramétrica**
- Comúnmente se usan modelos de mezcla

$$f(x) = \int k(x|y)P(dy),$$

donde $k(x|y)$ es un kernel de probabilidad paramétrico y P es la distribución de pesos de mezcla

Introducción

- Enfoques:

Introducción

- Enfoques:
 - **Clásico**: Si tomamos a P como la f.d.e. \Rightarrow popular estimador de kernel (Silverman, 1986)

$$\hat{f}(x) = \sum_{i=1}^n \frac{1}{n} k(x|X_i, \sigma)$$

Introducción

- Enfoques:
 - **Clásico**: Si tomamos a P como la f.d.e. \Rightarrow popular estimador de kernel (Silverman, 1986)

$$\hat{f}(x) = \sum_{i=1}^n \frac{1}{n} k(x|X_i, \sigma)$$

- **Bayesiano**: Asignar a P una distribución inicial (NP) $\Rightarrow f(x)$ es una función de densidad aleatoria y el estimador Bayesiano es

$$\hat{f}(x) = E \left\{ \int k(x|y) P(dy) \mid X_1, \dots, X_n \right\}$$

Introducción

- Enfoques:
 - **Clásico**: Si tomamos a P como la f.d.e. \Rightarrow popular estimador de kernel (Silverman, 1986)

$$\hat{f}(x) = \sum_{i=1}^n \frac{1}{n} k(x|X_i, \sigma)$$

- **Bayesiano**: Asignar a P una distribución inicial (NP) $\Rightarrow f(x)$ es una función de densidad aleatoria y el estimador Bayesiano es

$$\hat{f}(x) = E \left\{ \int k(x|y) P(dy) \middle| X_1, \dots, X_n \right\}$$

- Usaremos el enfoque Bayesiano con $P \sim \mathcal{P}$, donde \mathcal{P} denota la ley de un proceso estocástico que asigna probabilidad uno a las medidas de probabilidad discretas

Estimación Bayesiana

- Representación jerárquica del modelo Bayesiano

$$\begin{aligned}
 X_i | Y_i, \phi &\stackrel{\text{ind}}{\sim} k(\cdot | Y_i, \phi) \\
 Y_i | P &\stackrel{\text{iid}}{\sim} P, \\
 P &\sim \mathcal{P} \\
 \phi &\sim \pi(\phi)
 \end{aligned}$$

donde

- \mathcal{P} denota la ley de una medida aleatoria normalizada
- $P(\cdot) = A(\cdot)/A(\infty)$ con A un proceso aditivo creciente con intensidad de Lévy $\nu(ds, dv)$
- Tomaremos $\mathbb{X} \subseteq \mathbb{R}$ y $\mathbb{Y} \subseteq \mathbb{R}^m$

Casos particulares

- Si consideramos $k(\cdot|\mu, \sigma)$ parametrizado en términos de media μ y desviación estándar σ

Casos particulares

- Si consideramos $k(\cdot|\mu, \sigma)$ parametrizado en términos de media μ y desviación estándar σ
- Mezcla Tipo 1 (**MixNRM1**)

$$X_i | Y_i, \phi \stackrel{\text{ind}}{\sim} k(\cdot | Y_i, \phi)$$

$$Y_i | P \stackrel{\text{iid}}{\sim} P,$$

$$P \sim \mathcal{P}$$

$$\phi \sim \pi(\phi)$$

Casos particulares

- Si consideramos $k(\cdot|\mu, \sigma)$ parametrizado en términos de media μ y desviación estándar σ
- Mezcla Tipo 1 (**MixNRM1**)

$$\begin{aligned}
 X_i | Y_i, \phi &\stackrel{\text{ind}}{\sim} k(\cdot | Y_i, \phi) \\
 Y_i | P &\stackrel{\text{iid}}{\sim} P, \\
 P &\sim \mathcal{P} \\
 \phi &\sim \pi(\phi)
 \end{aligned}$$

- Mezcla Tipo 2 (**MixNRM2**)

$$\begin{aligned}
 X_i | Y_i, Z_i &\stackrel{\text{ind}}{\sim} k(\cdot | Y_i, Z_i) \\
 (Y_i, Z_i) | P &\stackrel{\text{iid}}{\sim} P, \\
 P &\sim \mathcal{P}
 \end{aligned}$$

Opciones de kernels

- Kernel normal:

$$k(x|\mu, \sigma) = \frac{1}{\sqrt{2\pi}b} \exp\left\{-\frac{1}{2b^2}(x-a)^2\right\} \mathbb{I}_{\mathbb{R}}(x), \quad a = \mu, \quad b = \sigma$$

- Kernel doble exponencial:

$$k(x|\mu, \sigma) = \frac{1}{2b} \exp\left\{-\frac{1}{b}|x-a|\right\} \mathbb{I}_{\mathbb{R}}(x), \quad a = \mu, \quad b = \sigma/\sqrt{2}$$

- kernel gamma:

$$k(x|\mu, \sigma) = \frac{b^a}{\Gamma(a)} x^{a-1} e^{-bx} \mathbb{I}_{\mathbb{R}^+}(x), \quad a = \mu^2/\sigma^2, \quad b = \mu/\sigma^2$$

- kernel log-normal:

$$k(x|\mu, \sigma) = \frac{1}{x\sqrt{2\pi}b} \exp\left\{-\frac{1}{2b^2}(\log x - a)^2\right\} \mathbb{I}_{\mathbb{R}^+}(x),$$

$$\text{con } a = \log\left(\frac{\mu}{\sqrt{1+\sigma^2/\mu^2}}\right) \text{ y } b = \sqrt{\log\left(1 + \frac{\sigma^2}{\mu^2}\right)}$$

Medidas de centralidad $E(P) = P_0$

- Normal:

$$p_0(x|\mu, \sigma) = \frac{1}{\sqrt{2\pi}b} \exp \left\{ -\frac{1}{2b^2}(x - a)^2 \right\} \mathbb{I}_{\mathbb{R}}(x),$$

con $a = \mu$ y $b = \sigma$.

- Gamma:

$$p_0(x|\mu, \sigma) = \frac{b^a}{\Gamma(a)} x^{a-1} e^{-bx} \mathbb{I}_{\mathbb{R}^+}(x),$$

con $a = \mu^2/\sigma^2$ y $b = \mu/\sigma^2$.

Algoritmo general

- 1 Simular la latente $U|\mathbf{Y}$: generar una propuesta $U^* \sim \text{Ga}(\delta, \delta/U^{[t]})$ con $\delta = 2$, y tomar $U^{[t+1]} = U^*$ con prob. $q_1(U^*, U^{[t]})$, e.o.c. tomar $U^{[t+1]} = U^{[t]}$.
- 2 Simular trayectorias de la parte del proceso sin puntos fijos de discontinuidad A^* : generar $\vartheta_j \sim \text{Ga}(1, 1)$ y encontrar $J_j^{[t+1]}$ resolviendo numericamente la ecuación $\sum_{i=1}^j \vartheta_i = M(J_i)$; generar $\tau_i^{[t+1]}$ de P_0 . Parar de simular cuando $J_{\ell+1} / \sum_{i=1}^{\ell} J_i < \epsilon$, digamos $\epsilon = 0.0001$.
- 3 Remuestrear los valores únicos $\{Y_j^*\}$: **obtener los valores únicos $Y_j^{*[t]}$ de $\{Y_1^{[t]}, \dots, Y_n^{[t]}\}$ y sus frecuencias $n_j^{[t]}$** . Si $m = 2$ con k parametrizado en términos de media y desviación estándar, generar una propuesta $(Y_j^{*(1)})^\lambda \sim k(\bar{X}_j, (Y_j^{*(2)})^{[t]} / \sqrt{n_j^{[t]}})$ y tomar $(Y_j^{*(1)})^{[t+1]}$ igual a $(Y_j^{*(1)})^\lambda$ con probabilidad $q_2((Y_j^{*(1)})^\lambda, (Y_j^{*(1)})^{[t]})$ e.o.c. tomar $(Y_j^{*(1)})^{[t+1]} = (Y_j^{*(1)})^{[t]}$. Similarmente, generar una propuesta $(Y_j^{*(2)})^\lambda \sim \text{Ga}(\delta, \delta/Y_j^{*(2)})$ con $\delta = 3$ y tomar $(Y_j^{*(2)})^{[t+1]} = (Y_j^{*(2)})^\lambda$ con prob. $q_3((Y_j^{*(2)})^\lambda, Y_j^{*(2)})^{[t]}$ e.o.c. tomar $(Y_j^{*(2)})^{[t+1]} = (Y_j^{*(2)})^{[t]}$.
- 4 Simular los saltos fijos del proceso, $\{J_j^*\}$: renombrar los r distintos elementos en \mathbf{Y} as $Y_j^{*[t+1]}$ y registrar se frecuencia, digamos $n_j^{[t+1]}$, $j = 1, \dots, r$. Generar los saltos $J_j^{*[t+1]} \sim \text{Ga}(n_j^{[t+1]} - \gamma, \kappa + u^{[t+1]})$.
- 5 Simular el vector latente \mathbf{Y} : para cada $i = 1, \dots, n$, generar $Y_i^{[t+1]}$ de su distribución discreta evaluando el kernel $k(X_i | \cdot, \phi^{[t]})$ en las distintas localizaciones $\bar{\tau}_i$'s.
- 6 Simular ϕ : si $\phi \neq \emptyset$ y una dist. inicial para ϕ es asignada, generar una propuesta $\phi^\lambda \sim \text{Ga}(\delta, \delta/\phi^{[t]})$ con $\delta = 3$ y tomar $\phi^{[t+1]} = \phi^\lambda$ con prob. $q_4(\phi^\lambda, \phi^{[t]})$, y e.o.c. tomar $\phi^{[t+1]} = \phi^{[t]}$.
- 7 Evaluar una trayectoria de la densidad aleatoria $f(x|\bar{A}^{[t+1]}, \phi^{[t+1]})$.

Comp2

```

comp2 <- function (y, z)
{
  if (length(y) != length(z))
    stop("Vectors y and z should have equal length!")
  n <- length(y)
  matY <- outer(y, y, "==")
  matZ <- outer(z, z, "==")
  mat <- matY & matZ
  jstar <- led <- rep(FALSE, n)
  for (j in seq(n)) {
    if (!led[j]) {
      jstar[j] <- TRUE
      if (j == n)
        break
      ji <- seq(j + 1, n)
      tt <- mat[ji, j] %in% TRUE
      led[ji] <- led[ji] | tt
    }
    if (all(led[-seq(j)]))
      break
  }
  ystar <- y[jstar]
  zstar <- z[jstar]
  nstar <- apply(as.matrix(mat[, jstar]), 2, sum)
  rstar <- length(nstar)
  idx <- match(y, ystar)
  return(list(ystar = ystar, zstar = zstar, nstar = nstar,
             rstar = rstar, idx = idx))
}

```

BNPdensity

- Paquete **BNPdensity**

BNPdensity

- Paquete **BNPdensity**
- Comandos

BNPdensity

- Paquete **BNPdensity**
- Comandos
 - **MixNRMI1**

```
MixNRMI1(x, probs = c(0.025, 0.5, 0.975), Alpha = 1,  
Beta = 0, Gama = 0.4, distr.k = 1, distr.p0 = 1, mu.p0  
= mean(x), sigma.p0 = 1.5 * sd(x), asigma = 0.1, bsigma  
= 0.1, delta = 3, Delta = 2, Nm = 50, Nx = 100, Nit =  
1000, Pbi = 0.1, epsilon = NULL, printtime = TRUE)
```

BNPdensity

- Paquete **BNPdensity**
- Comandos

- **MixNRMII1**

```
MixNRMII1(x, probs = c(0.025, 0.5, 0.975), Alpha = 1,  
Beta = 0, Gama = 0.4, distr.k = 1, distr.p0 = 1, mu.p0  
= mean(x), sigma.p0 = 1.5 * sd(x), asigma = 0.1, bsigma  
= 0.1, delta = 3, Delta = 2, Nm = 50, Nx = 100, Nit =  
1000, Pbi = 0.1, epsilon = NULL, printtime = TRUE)
```

- **MixNRMII2**

```
MixNRMII2(x, probs = c(0.025, 0.5, 0.975), Alpha = 1,  
Beta = 0, Gama = 0.4, distr.k = 1, distr.py0 = 1,  
mu.py0 = mean(x), sigma.py0 = 1.5 * sd(x), distr.pz0 =  
2, mu.pz0 = 0.1, sigma.pz0 = 0.1, delta = 3, Delta = 2,  
Nm = 50, Nx = 100, Nit = 1000, Pbi = 0.1, epsilon =  
NULL, printtime = TRUE)
```

BNPdensity

- Salida
 - xx: Rejilla de evaluación de la densidad
 - qx: Estimadores de la densidad: media y cuantiles
 - cpo: medida de bondad de ajuste para cada dato
 - R: Número de componente de mezcla

Ejemplo 1

- Cargar paquete

```
library(BNPdensity)
```

- Fijar semilla

```
set.seed(123456)
```

- Cargar datos


```
data(galaxy)
```

```
x<-galaxy
```

- Ajuste del modelo (bajo especificaciones modificadas)


```
Galaxy2.out <- MixNRMI2(x, Alpha = 1, Beta = 0.015, Gama =  
0.5, distr.k = 1, distr.py0 = 2, mu.py0 = 20, sigma.py0 =  
20, distr.pz0 = 2, mu.pz0 = 1, sigma.pz0 = 1, Nit = 5000,  
Pbi = 0.2)
```

Datos de galaxias (Estimador de densidad)




Datos de galaxias (Número de componentes)

Trace of R




Histogram of R




Datos de galaxias (Bondad de ajuste)

Scatter plot of CPO's



Boxplot of CPO's



Ejemplo 2

- Fijar semilla

```
set.seed(123456)
```

- Cargar datos


```
data(enzyme)
```

```
x<-enzyme
```

- Ajuste del modelo (bajo especificaciones modificadas)


```
Enzyme2.out <- MixNRMI2(x, Alpha = 1, Beta = 0.007, Gama =  
0.5, distr.k = 2, distr.py0 = 2, mu.py0 = 10, sigma.py0 =  
10, distr.pz0 = 2, mu.pz0 = 1, sigma.pz0 = 1, Nit = 5000,  
Pbi = 0.2)
```

Datos de enzimas (Estimador de densidad)




Datos de enzimas (Número de componentes)

Trace of R




Histogram of R




Datos de enzimas (Bondad de ajuste)

Scatter plot of CPO's



Boxplot of CPO's



Ejemplo 3

- Cargar datos

```
data(acidity)
x<-acidity
```
- Ajuste del modelo (bajo especificaciones por defecto)

```
out<-MixNRMI1(x)
```
- Graficación de los estimadores

```
attach(out)
m<-ncol(qx)
ymax <- max(qx[,m])
par(mfrow=c(1,1))
hist(x,probability=TRUE,breaks=20,col=grey(.9),ylim=c(0,ymax))
lines(xx,qx[,1],lwd=2)
lines(xx,qx[,2],lty=3,col=4)
lines(xx,qx[,m],lty=3,col=4)
detach()
```

Datos de grado de acidez en lagos

