

1. (4 puntos) Sea  $X$  una población con distribución  $\gamma(p, a)$  de la que se obtiene la muestra aleatoria simple  $\vec{x}$  de tamaño 20 siguiente:

```
## c(1.3, 1.2, 3.5, 4, 2.8, 5.1, 1.5, 2.3, 3.8, 4.3, 3, 2, 0.9,
## 2.5, 1.7, 1.6, 1.1, 1.8, 1.4, 1)
```

Teniendo en cuenta que

$$f_X(x) = \frac{a^p}{\Gamma(p)} x^{p-1} e^{-ax} I(x > 0) \quad E(X) = \frac{p}{a} \quad \text{Var}(X) = \frac{p}{a^2}$$

- a) (1 punto) Halla un estadístico suficiente minimal para  $\theta = (p, a)$ .
- b) (1 punto) Mediante el método de los momentos, halla estimadores para  $p$  y  $a$  y aplícalos a  $\vec{x}$ .
- c) (1 punto) Halla la estimación máximo-verosímil de  $p$  y de  $a$ . Compara el resultado con el del método de los momentos.
- d) (1 punto) Calcula mediante *bootstrap* un intervalo de confianza para  $\mu = p/a$  a nivel  $1 - \alpha = 0,95$ .

## Resolución

1. a) Halla un estadístico suficiente minimal para  $\theta = (p, a)$ .

Para  $x > 0$ ,  $f(x, p, a) = \frac{a^p}{\Gamma(p)} x^{p-1} e^{-ax} \implies \mathcal{L}(\vec{x}, p, a) = \frac{a^{np}}{\Gamma(p)^n} (\prod x_i)^{p-1} e^{-a \sum x_i} \implies T := (\prod X_i, \sum X_i)$  es suficiente por el teorema de factorización, tomando  $h(\vec{x}) = 1$  y  $g(\vec{t}, \vec{\theta}) = g(t_1, t_2, p, a) = \frac{a^{np}}{\Gamma(p)^n} (t_1)^{p-1} e^{-at_2}$ ,  $t_1(\vec{x}) = \prod x_i$ ,  $t_2(\vec{x}) = \sum x_i$ . [Con más rigor, se podría considerar  $x$  arbitrario y tomar  $h(\vec{x}) = I(x_{(1)})$ , etcétera.]

Es minimal porque  $\frac{\mathcal{L}(\vec{x}, p, a)}{\mathcal{L}(\vec{y}, p, a)} = \left( \frac{\prod x_i}{\prod y_i} \right)^{p-1} e^{-a(\sum x_i - \sum y_i)}$  es independiente de  $(p, a)$   
 $\iff \frac{\prod x_i}{\prod y_i} = 1 \wedge \sum x_i - \sum y_i = 0 \iff (\prod x_i, \sum x_i) = (\prod y_i, \sum y_i) \iff T(\vec{x}) = T(\vec{y})$ .

Otra forma de verlo sería considerando que la distribución  $\gamma$  pertenece a la familia exponencial 2-paramétrica, pues su soporte  $(0, \infty)$  no depende de  $\theta$  y

$$f(x, p, a) = \frac{a^p}{\Gamma(p)} \cdot e^{(p-1) \ln x - ax} = c(\theta)h(x)e^{Q_1(\theta)T_1(x) + Q_2(\theta)T_2(x)}$$

con  $c(p, a) = \frac{a^p}{\Gamma(p)}$ ,  $h(x) = 1$ ,  $Q_1(p, a) = p - 1$ ,  $T_1(x) = \ln x$ ,  $Q_2(p, a) = -a$  y  $T_2(x) = x$ , o bien

$$f(x, \eta_1, \eta_2) = \frac{(-\eta_2)^p}{\Gamma(\eta_1 + 1)} \cdot e^{\eta_1 \ln x + \eta_2 x} = c(\eta)h(x)e^{\eta_1 T_1(x) + \eta_2 T_2(x)}$$

con la parametrización natural  $\eta_1 = p - 1$ ,  $\eta_2 = -a$ ,  $\eta = (\eta_1, \eta_2)$ , cuyo espacio paramétrico  $H = \{(\eta_1, \eta_2) \mid \eta_1 > -1, \eta_2 < 0\}$  contiene un abierto de  $\mathbb{R}^2$  (por ejemplo, el abierto  $(0, 1) \times (-1, 1)$  está contenido en  $H$ ), luego  $(\sum T_1(X_i), \sum T_2(X_i)) = (\sum \ln X_i = \ln \prod X_i, \sum X_i)$  es suficiente minimal, luego también  $(\prod X_i, \sum X_i)$  es suficiente minimal, pues inducen la misma partición ( $\ln$  es inyectiva).

b) Mediante el método de los momentos, halla estimadores para  $p$  y  $a$  y aplícalos a  $\vec{x}$ .

$\mu = p/a$ ,  $\sigma^2 = p/a^2 \implies p = \mu^2/\sigma^2$ ,  $a = \mu/\sigma^2 \implies \hat{p}_{MM} = \bar{X}^2/\hat{S}^2$ ,  $\hat{a}_{MM} = \bar{X}/\hat{S}^2$  o, con el estimador sesgado varianza muestral,  $\hat{p}_{MM} = \bar{X}^2/S^2$ ,  $\hat{a}_{MM} = \bar{X}/S^2$

```
mu <- mean(x); s2 <- var(x)
(pMM <- mu^2/s2)

## [1] 3.574151

(aMM <- mu/s2)

## [1] 1.527415

## con el estimador sesgado varianza muestral:
s2 <- mean(x^2) - mu^2
(pMM <- mu^2/s2)

## [1] 3.762265

(aMM <- mu/s2)

## [1] 1.607805
```

Con más rigor, se puede partir de los momentos absolutos:

$$\begin{aligned}
E(X) &= p/a \implies p = a \cdot E(X) \\
E(X^2) &= \text{Var}(X) + E^2(X) = \frac{p}{a^2} + \frac{p^2}{a^2} = \frac{p + p^2}{a^2} \\
&\implies E(X^2) = \frac{a \cdot E(X) + a^2 \cdot E^2(X)}{a^2} \\
&\implies a^2 \cdot E(X^2) = a \cdot E(X) + a^2 \cdot E^2(X) \\
&\implies a \cdot E(X^2) = E(X) + a \cdot E^2(X) \\
&\implies a = \frac{E(X)}{E(X^2) - E^2(X)} \implies \hat{a}_{MM} = \frac{\bar{X}}{\bar{X}^2 - \bar{X}^2} = \frac{\bar{X}}{S^2} \\
&\implies p = \frac{E(X)}{E(X^2) - E^2(X)} E(X) \implies \hat{p}_{MM} = \frac{\bar{X}}{\bar{X}^2 - \bar{X}^2} \bar{X} = \frac{\bar{X}^2}{S^2}
\end{aligned}$$

c) Halla la estimación máximo-verosímil de  $p$  y de  $a$ . Compara el resultado con el del método de los momentos.

$$\begin{aligned}
\mathcal{L}(\vec{x}, p, a) &= \frac{a^{np}}{\Gamma(p)^n} \prod x_i^{p-1} e^{-a \sum x_i} \implies \\
l(a) := \ln \mathcal{L}(\vec{x}, p, a) &= np \ln a - n \ln \Gamma(p) + (p-1) \sum \ln x_i - a \sum x_i \implies \\
0 = l'(a) &= \frac{np}{a} - \sum x_i \implies \begin{cases} l''(a) = -\frac{np}{a^2} < 0 \text{ (máximo)} \\ \hat{a}_{MV} = \hat{p}_{MV}/\bar{X} \end{cases}
\end{aligned}$$

$$\begin{aligned}
l(p) &:= \ln \mathcal{L}(\vec{x}, p, a) = np \ln a - n \ln \Gamma(p) + (p-1) \sum \ln x_i - a \sum x_i \implies \\
0 = l'(p) &= n \ln a - n \frac{\Gamma'(p)}{\Gamma(p)} + \sum \ln x_i = n \ln \frac{p}{X} - n\psi(p) + \sum \ln x_i = \\
&n \ln p - \ln \bar{X} - n\psi(p) + \sum \ln x_i = n \ln p - n\psi(p) + \text{constante} \implies
\end{aligned}$$

$\ln p - \psi(p) = \text{constante} \implies$  existe a lo sumo una única  $p$  que lo satisfaga, ya que  $\ln$  y  $\psi$  son estrictamente crecientes<sup>1</sup> en  $(0, \infty)$

Hay que hallar  $p$  mediante métodos numéricos, bien como raíz de la ecuación anterior, donde  $\psi=\text{digamma}$ ,

```
g <- function (p) n*log(p/mean(x)) - n*digamma(p) + sum(log(x))
uniroot (g, c (1e-100, 100))

## $root
## [1] 3.997045
##
## $f.root
## [1] -6.296073e-08
##
## $iter
## [1] 12
##
## $init.it
## [1] NA
##
## $estim.prec
## [1] 6.103516e-05
```

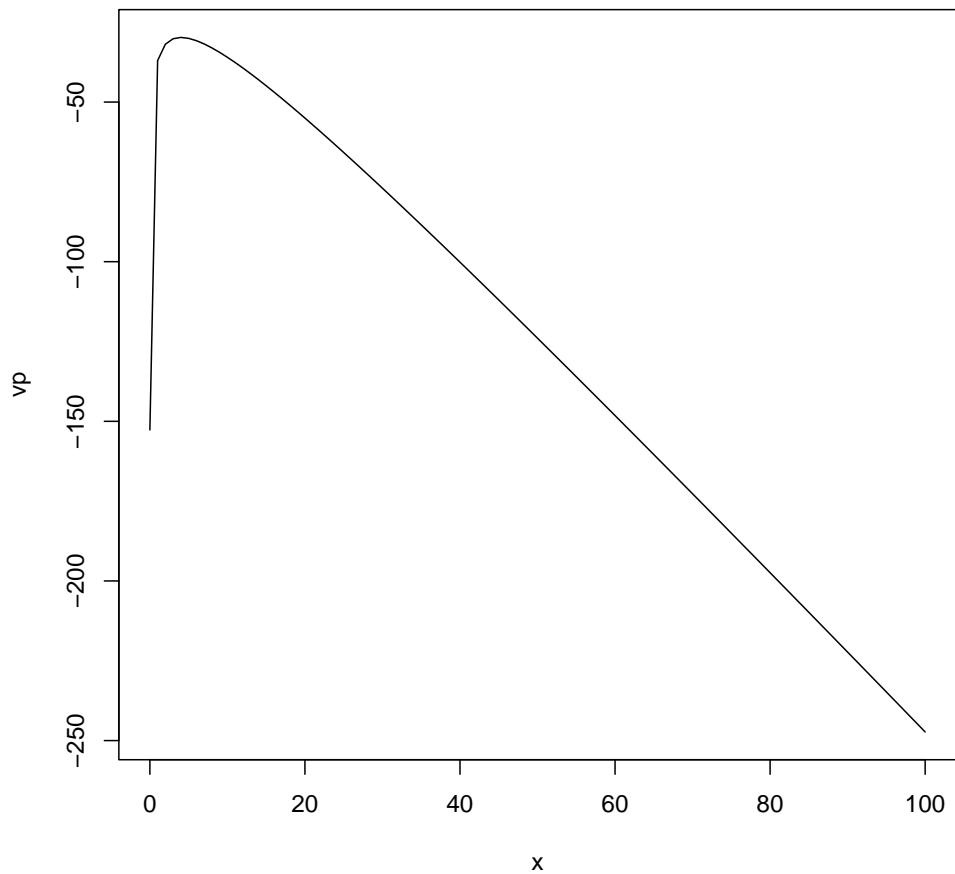
bien mediante la maximización de la verosimilitud perfilada en  $p$ :

$$\ln \mathcal{L}(x, p) = np \ln(p/\bar{x}) - n \ln \Gamma(p) + (p-1) \sum \ln x_i - np$$

```
vp <- function(p)
  n*p*log(p/mean(x))-n*log(gamma(p))+(p-1)*sum(log(x))-n*p
plot(vp,.001,100) # para comprobar comportamiento
```

---

<sup>1</sup>[https://en.wikipedia.org/wiki/Digamma\\_function](https://en.wikipedia.org/wiki/Digamma_function)



```

sol <- optimize(vp, c(0,100), maximum=TRUE)
(pMV <- sol$maximum)

## [1] 3.997042

(aMV <- pMV/mean(x))

## [1] 1.708138

## otra forma: verosimilitud perfilada en "a"
vp <- function(a)
  n*a*mean(x)*log(a)-n*log(gamma(a*mean(x)))+
    (a*mean(x)-1)*sum(log(x))-n*a*mean(x)
sol <- optimize(vp, c(0,100), maximum=TRUE)
(aMV <- sol$maximum)

```

```

## [1] 1.708139
(pMV <- aMV*mean(x))
## [1] 3.997044

## otra forma: maximizar conjuntamente en (p,a)
optim(c(pMM,aMM),
       function(pa)
       {
         p <- pa[1]
         a <- pa[2]
         sum(dgamma(x,p,a,log=TRUE))
       },
       control=list(fnscale=-1))

## $par
## [1] 3.998465 1.709014
##
## $value
## [1] -29.75126
##
## $counts
## function gradient
##      41      NA
##
## $convergence
## [1] 0
##
## $message
## NULL

```

Se observa que las estimaciones obtenidas maximizando la verosimilitud son similares a las del método de los momentos. Pueden preferirse las máximo-verosímiles ya que el estimador de máxima verosimilitud suele tener mejores propiedades que el del método de los momentos.

- d) Calcula mediante *bootstrap* un intervalo de confianza para  $\mu = p/a$  a nivel  $1 - \alpha = 0,95$ .

```

## bootstrap básico paramétrico
distri <- replicate(10000,
{
  mu <- mean(x); s2 <- var(x); p <- mu^2/s2; a <- mu/s2
  mean(rgamma(n,p,a)-mean(x))
})
mean(x)-quantile(distri,c(.975,.025),names=FALSE)

## [1] 1.772318 2.858683

```

```

## bootstrap básico no paramétrico
distri <- replicate(10000, mean(sample(x,,TRUE)-mean(x)))
mean(x)-quantile(distri,c(.975,.025),names=FALSE)

## [1] 1.794875 2.840000

## t-bootstrap: error típico de estima mu = raíz(sigma2/n)
distri <- replicate(10000,
                     mean((xb<-sample(x,,TRUE))-mean(x))/sqrt(var(xb)/n))
mean(x)-quantile(distri,c(.975,.025),names=FALSE)*sqrt(var(x)/n)

## [1] 1.834237 3.030428

## bootstrap percentil
distri <- replicate(10000, mean(sample(x,,TRUE)))
quantile(distri,c(.025,.975),names=FALSE)

## [1] 1.830 2.905

```

El método paramétrico aprovecha el conocimiento de la distribución, por lo que sería en principio el mejor de los cuatro métodos. También el *t-bootstrap* no paramétrico, en parte, ya que aprovecha la expresión paramétrica del error típico. Podrían combinarse ambos:

```

## t-bootstrap paramétrico
mu <- mean(x); s2 <- var(x); p <- mu^2/s2; a <- mu/s2
distri <- replicate(10000,
                     mean(((xb<-rgamma(n,p,a))-mean(x))/sqrt(var(xb)/n)))
mean(x)-quantile(distri,c(.975,.025),names=FALSE)*sqrt(var(x)/n)

## [1] 1.840667 3.045840

```