

Elementos de Computação em R para Inferência Estatística

PJ

6 de novembro de 2013

1 Inferência para parâmetros da distribuição Gama

1.1 Densidade

Parametrização 1:

Esta é a parametrização utilizada nas funções `{r,p,q,d}gamma()` do R com:

$\alpha = shape = a$ e $\beta = scale = s$ ($rate = 1/scale$).

Note que $a = 0$ define uma fdp trivial com toda massa de probabilidade em zero. Existe um alerta importante na documentação da função sobre a capacidade do computador em representar pequenos valores que ocorrem para certos valores dos parâmetros:

Note that for smallish values of shape (and moderate scale) a large parts of the mass of the Gamma distribution is on values of x so near zero that they will be represented as zero in computer arithmetic. So `rgamma` can well return values which will be represented as zero. (This will also happen for very large values of scale since the actual generation is done for `scale=1`.)

Funções e expressões: densidade, esperança, variância, (log)-verossimilhança, escore e hessiano:

$$\begin{aligned} Y &\sim G(\alpha, \beta) \\ f(y|\alpha, \beta) &= \frac{1}{\Gamma(\alpha) \beta^\alpha} y^{\alpha-1} \exp\{-y/\beta\} \quad y \geq 0 \quad \alpha \geq 0 \quad \beta > 0 \\ E[Y] &= \alpha\beta \quad Var[Y] = \alpha\beta^2 \\ L((\alpha, \beta)|y) &= \left(\frac{1}{\Gamma(\alpha) \beta^\alpha} \right)^n \prod_{i=1}^n y_i^{\alpha-1} \exp\{-y_i/\beta\} \\ l((\alpha, \beta)|y) &= n \left(-\log(\Gamma(\alpha)) - \alpha \log(\beta) + (\alpha - 1)\overline{\log(y)} - \bar{y}/\beta \right) \end{aligned} \tag{1}$$

Função escore:

$$\begin{cases} \frac{dl}{d\beta} &= n \left(-\frac{\alpha}{\beta} + \frac{\bar{y}}{\beta^2} \right) \\ \frac{d}{d\alpha} &= n \left(-\psi(\alpha) - \log(\beta) + \overline{\log y} \right) \end{cases} \tag{2}$$

em que $\psi(\alpha) = \frac{d}{d\alpha} \log(\Gamma(\alpha)) = \frac{\Gamma'(\alpha)}{\Gamma(\alpha)}$ é a função digama (calculada no R com função `digamma()`).

Hessiano:

$$H(\alpha, \beta) = \begin{bmatrix} \frac{d^2l}{d\beta^2} & \frac{d^2l}{d\alpha d\beta} \\ \frac{d^2l}{d\alpha d\beta} & \frac{d^2l}{d\alpha^2} \end{bmatrix} = \begin{bmatrix} n \left(\frac{\alpha}{\beta^2} - 2\frac{\bar{y}}{\beta^3} \right) & -\frac{n}{\beta} \\ -\frac{n}{\beta} & -n\psi'(\alpha) \end{bmatrix} \tag{3}$$

em que $\psi'(\alpha) = \frac{d^2}{dt^2} \log(\Gamma(t))$ é a função *trigama* (calculada no R com função `trigamma()`).

Funções concentradas (perfilhadas):

Para este caso não existem expressões fechadas para o estimador de máxima verossimilhança. As funções dadas anteriormente são funções de dois parâmetros (α e β) mas, neste caso, é possível reduzir a dimensionalidade e escrevê-las como funções de apenas um parâmetro. Para isto considerar-se o comportamento da função no estimador de máxima verossimilhança. Igualando a zero primeira função escore em 2 obtemos uma expressão fechada para um dos parâmetros dada por:

$$\hat{\alpha}\hat{\beta} = \bar{y}. \quad (4)$$

Pode-se então isolar um dos parâmetros e reescrever as funções de verossimilhança, escore e hessiana como funções de apenas um parâmetro. Substituindo β por $\hat{\beta} = \bar{y}/\hat{\alpha}$ temos que a log-verossimilhança (1) pode ser escrita na forma concentrada (perfilhada) como função apenas do parâmetro α :

$$pl(\alpha|y) = l_{\hat{\beta}}(\alpha|y) = n \left(-\log(\Gamma(\alpha)) - \alpha(\log(\bar{y}) - \log(\alpha)) + (\alpha - 1)\overline{\log(y)} - \alpha \right). \quad (5)$$

A função escore fica:

$$U_{\hat{\beta}}(\alpha) = n \left(-\psi(\alpha) - \log \bar{y} + \log(\alpha) + \overline{\log y} \right). \quad (6)$$

O hessiano para α é:

$$H_{\hat{\beta}}(\alpha) = n \left(-\psi'(\alpha) + \frac{1}{\alpha} \right). \quad (7)$$

Alternativamente, substituindo $\alpha = \hat{\alpha} = \bar{y}/\hat{\beta}$ pode-se obter expressões para o parâmetro β

Obtenção das estimativas de máxima verossimilhança

O EMV é solução conjunta de

$$\begin{cases} \overline{\log y} - \log \beta + &= \psi(\bar{y}/\beta) \\ \hat{\alpha}\hat{\beta} &= \bar{y} \end{cases}$$

que neste caso devem ser obtidas por algorítimos numéricos. Diferentes algorítimos podem ser utilizados conforme será ilustrado mais adiante. Quatro opções serão consideradas:

1. algorítmos de maximização:
 - (a) da log-verossimilhança de dois parâmetros,
 - (b) da log-verossimilhança concentrada (de um parâmetro) com posterior substituição em (4) para obtenção da estimativa do outro parâmetro
2. algorítmos de solução de equações (obtidas igualando a zero as funções escore);
 - (a) do sistema de equações de dois parâmetros,
 - (b) do sistema concentrado (equação de um parâmetro) com posterior substituição em (4) para obtenção da estimativa do outro parâmetro.

Parametrização 2:

Rizzo (2008) e outros autores utilizam a parametrização com $r = \alpha$, $\lambda = 1/\beta$ em que λ é o parâmetro de taxa (*rate*). Esta é também a parametrização original do S e S-Plus.

Densidade, esperança, variância, (log)verossimilhança, escore e hessiano:

$$\begin{aligned}
Y &\sim G(r, \lambda) \\
f(y|r, \lambda) &= \frac{\lambda^r}{\Gamma(r)} y^{r-1} \exp\{-\lambda y\} \quad y \geq 0 \quad r \geq 0 \quad \lambda > 0 \\
E[Y] &= r/\lambda \quad Var[Y] = r/\lambda^2 \\
L((r, \lambda)|y) &= \left(\frac{\lambda^r}{\Gamma(r)} \right)^n \prod_{i=1}^n y_i^{r-1} \exp\{-\lambda y_i\} \\
l((r, \lambda)|y) &= n \left(r \log(\lambda) - \log(\Gamma(r)) + (r-1)\overline{\log(y)} - \lambda \bar{y} \right)
\end{aligned} \tag{8}$$

Função escore:

$$\begin{cases} \frac{dl}{d\lambda} = n \left(\frac{r}{\lambda} - \bar{y} \right) \\ \frac{d}{dr} = n \left(\log(\lambda) - \frac{\Gamma'(r)}{\Gamma(r)} + \overline{\log y} \right) \end{cases}$$

Igualando as funções a zero, da primeira equação temos $\hat{\lambda} = \hat{r}/\bar{y}$. Substituindo λ por $\hat{\lambda}$ a segunda expressão é escrita como:

$$n \left(\log \frac{\hat{r}}{\bar{y}} + \overline{\log y} - \frac{\Gamma'(r)}{\Gamma(r)} \right) = 0$$

O MLE é solução conjunta de:

$$\begin{cases} \log \lambda + \overline{\log y} = \psi(\lambda \bar{y}) \\ \bar{y} = r/\lambda \end{cases} \tag{9}$$

em que $\psi(t) = \frac{d}{dt} \log(\Gamma(t)) = \frac{\Gamma'(t)}{\Gamma(t)}$ (função `digamma()`).

Parametrização 3:

Aitkin (2010) menciona duas parametrizações sendo a primeira, a mesma implementada no R, apontada como a mais usual, e uma segunda parametrizada por $r = \alpha$ e $\mu = \alpha\beta$.

Esta última parametrização tem propriedades interessantes para inferência. A primeira é a ortogonalidade entre r e μ na matriz de informação. Além disto em geral μ é o usualmente o parâmetro de interesse para inferências e r é um parâmetro *nuisance*. Finalmente a parametrização é adequada para modelagem estatística na qual usualmente se propõe um modelo de regressão para média μ , como por exemplo em modelos lineares generalizados (*GLM*).

Densidade, esperança, variância e verossimilhança:

$$\begin{aligned}
Y &\sim G(r, \mu) \\
f(y|r, \mu) &= \frac{r^r}{\Gamma(r) \mu^r} y^{r-1} \exp\{-ry/\mu\} \quad y \geq 0 \quad r \geq 0 \quad \mu \geq 0 \\
E[Y] &= \mu \quad Var[Y] = \mu^2/r \\
L((r, \mu)|y) &= \left(\frac{r^r}{\Gamma(r) \mu^r} \right)^n \prod_{i=1}^n y_i^{r-1} \exp\{-ry_i/\mu\} \\
l((r, \mu)|y) &= n \left(r(\log(r) - \log(\mu)) - \log(\Gamma(r)) + (r-1)\overline{\log(y)} - \frac{r}{\mu} \bar{y} \right)
\end{aligned}$$

Função escore:

$$\begin{cases} \frac{dl}{d\mu} = n \left(-\frac{r}{\mu} + \frac{r\bar{y}}{\mu^2} \right) \\ \frac{d}{dr} = n \left(\log(r) + 1 - \log(\mu) - \frac{\Gamma'(r)}{\Gamma(r)} + \overline{\log y} - \frac{\bar{y}}{\mu} \right) \end{cases}$$

Igualando as funções a zero, da primeira equação temos $\hat{\mu} = \bar{y}$. Substituindo μ por $\hat{\mu}$ a segunda expressão é escrita como:

$$n \left(\log(\hat{r}) + 1 - \log(\bar{y}) - \frac{\Gamma'(\hat{r})}{\Gamma(\hat{r})} + \overline{\log y} - 1 \right) = 0$$

O *MLE* é solução conjunta de:

$$\begin{cases} \log \hat{r} - \psi(\hat{r}) = \log \bar{y} - \overline{\log y} \\ \hat{\mu} = \bar{y} \end{cases}$$

em que $\psi(t) = \frac{d}{dt} \log(\Gamma(t)) = \frac{\Gamma'(t)}{\Gamma(t)}$ (calculado no R pela função `digamma()`).

1.2 Códigos R para obtenção das estimativas

Não é possível obter *MLE* em forma analítica fechada para ambos parâmetros da distribuição Gama sendo então necessário o uso de métodos numéricos para obter estimativas. Algumas abordagens numéricas possíveis são:

1. *via* solução de equações (função escore)
 - a. conjunta para dois parâmetros: resolução numérica do sistema de duas equações
 - b. por substituição: resolução numérica de uma equação para encontrar a estimativa de um parâmetro que é substituída na equação conhecida para obter a estimativa do outro parâmetro.
2. *via* maximização de função de log-verossimilhança
 - a. maximização bidimensional (encontra numericamente estimativas dos 2 parâmetros)
 - b. unidimensional (verossimilhança concentrada/perfilhada para 1 parâmetro, seguida de substituição para o outro parâmetro)

Gerando dados (simulados).

Estatísticas amostrais que são as quantidades calculadas com os dados utilizadas nas avaliações das funções.

```
> ## amostra = list(media, media.logs)
> am <- list(media=mean(dadosG),
+ media.logs = mean(log(dadosG)), n=length(dadosG))
```

Estimação utilizando métodos numéricos utilizando a **Parametrização 2**.

```

> set.seed(201107)
> dadosG <- rgamma(20, shape = 4.5, rate=2)
> hist(dadosG, prob=T, xlim=c(0,5), main="",
+       panel.first=lines(density(dadosG)));rug(dadosG)
> curve(dgamma(x, shape = 4.5, rate=2), 0, 5, add=T, lwd=2)

```

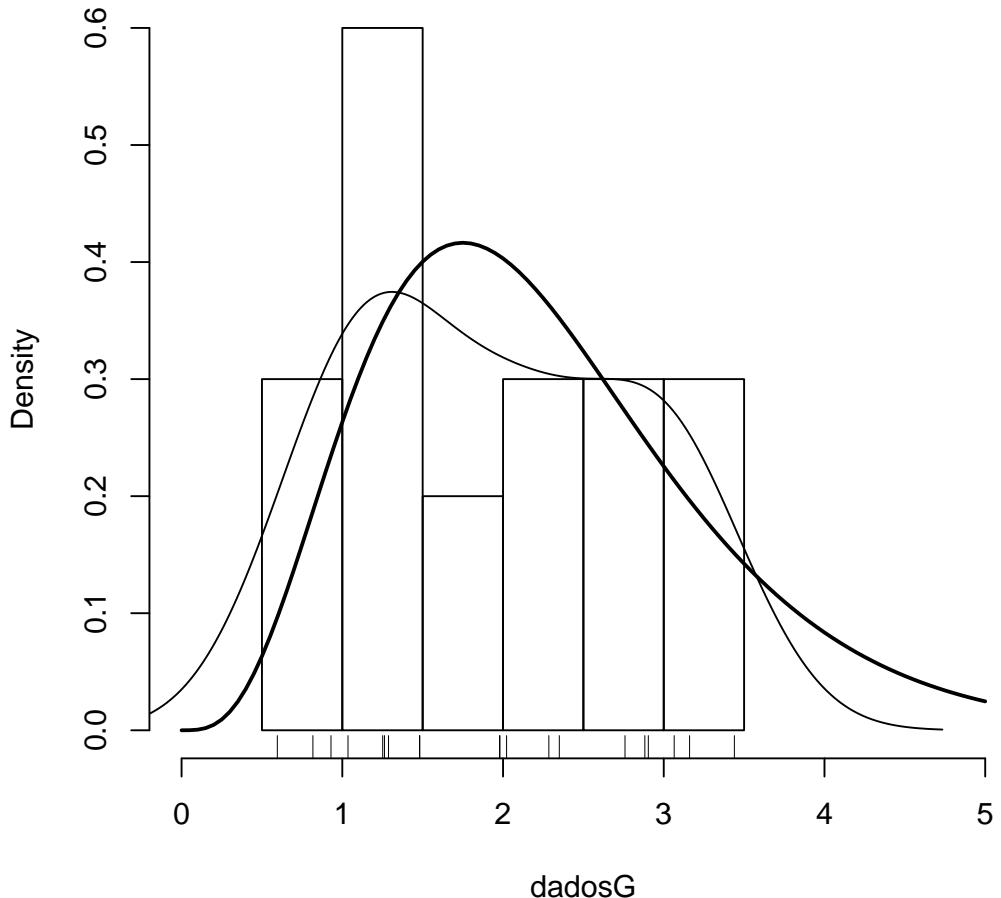


Figura 1: Histograma, densidade empírica e *rug* dos dados originais e densidade da distribuição simulada (linha grossa)

(1.a.) Equações de estimação Definimos uma função em R com sistema de equações definido em 9. As estimativas são dadas pela solução deste sistema que é obtida utilizando a função `multirroot()` do pacote `rootSolve`.

```
> Umat <- function(par, amostra){
+   lambda <- par[1] ; r = par[2]
+   UlamUr <- local({
+     c(n * ((r/lambda) - media),
+       n*(log(lambda) - digamma(lambda*media) + media.logs))
+   }, env=amostra)
+   return(UlamUr)
+ }
> #Umat(c(2,3), am)
> require(rootSolve)
> multirroot(f=Umat, start=c(1,1), amostra=am)

$root
[1] 2.408413 4.692590

$f.root
[1] -9.368136e-07 1.964242e-07

$iter
[1] 6

$estim.precis
[1] 5.666189e-07
```

(1.b.) Equações de estimação - substituição

$$\left(\log \frac{\hat{r}}{\bar{y}} + \overline{\log y} - \frac{\Gamma'(r)}{\Gamma(r)} \right) = 0 \quad (\text{numericamente})$$

$$\hat{\lambda} = \hat{r}/\bar{y} \quad (\text{substituição})$$

A função `uniroot()` pode ser usada para resolver numericamente uma equação.

```
> Ulam <- function(lambda, amostra){
+   with(amostra, digamma(lambda*media) - media.logs - log(lambda))
+ }
> (lambda.est <- uniroot(Ulam, lower=1e-3, upper=1e5, amostra=am)$root)

[1] 2.40842

> (r.est <- lambda.est * am$media)

[1] 4.692604
```

(2.a.) Maximização da função de log-verossimilhança (2 parâmetros) A função de (negativo) log-verossimilhança pode ser definida no R como uma função a 2 parâmetros da seguinte forma.

```
> neglLik <- function(par, amostra, modelo=2){
+   if(modelo == 1){
+     alpha <- par[1]; beta <- par[2]
+     ll <- with(amostra, n*(-alpha*log(beta) - log(gamma(alpha)) +
+       (alpha-1) * media.logs - media/beta))
+   }
+   if(modelo == 2){
+     r <- par[1]; lambda <- par[2]
+     ll <- with(amostra, n*(r*log(lambda) - log(gamma(r)) +
+       (r-1) * media.logs - lambda * media))
+   }
+   if(modelo == 3){
+     r <- par[1]; mu <- par[2]
+     ll <- with(amostra, n*(r*(log(r) - log(mu)) - log(gamma(r)) +
+       (r-1) * media.logs - (r/mu) * media))
+   }
+   return(-ll)
+ }
```

A seguir é mostrada a obtenção das estimativas em cada parametrização. Para impor limites no espaço paramétrico utiliza-se os argumentos `lower` e `upper` e `method="L-BFGS-B"`.

```
> (mod1 <- optim(c(1,1), neglLik, amostra=am, method="L-BFGS-B", modelo=1,
+   lower=c(0,0), upper=c(Inf, Inf))$par)
```

```
[1] 4.6924351 0.4152265
```

```
> (mod2 <- optim(c(1,1), neglLik, amostra=am, method="L-BFGS-B", modelo=2,
+   lower=c(0,0), upper=c(Inf, Inf))$par)
```

```
[1] 4.692593 2.408415
```

```
> (mod3 <- optim(c(1,1), neglLik, amostra=am, method="L-BFGS-B", modelo=3,
+   lower=c(0,0), upper=c(Inf, Inf))$par)
```

```
[1] 4.692591 1.948416
```

Obtenção de estimativas em uma parametrização a partir das estimativas de outra parametrização é obtida diretamente.

```
> 1/mod1[2]
```

```
[1] 2.408324
```

```
> prod(mod1)
```

```
[1] 1.948423
```

Comentários sobre reparametrização

- Reparametrização para garantir validade do espaço paramétrico

No exemplo da Gama, ambos parâmetros devem ser não negativos em todas as parametrizações. Alternativamente a usar `lower` e `upper`, pode-se redefinir a função com a opção de que os parâmetros sejam fornecidos em escala logarítmica e desta forma possam assumir valores nos reais. Note que isto exclui o valor nulo do espaço paramétrico original. Aproveitamos a redefinição da função de (negativo) log-verossimilhança para ilustrar sintaxes em R escrevendo a função usando `switch()` para definir a opção de parametrização.

```
> neglLik <- function(par, amostra, modelo=2, logpar=FALSE){  
+   if(logpar) par <- exp(par)  
+   ll <- switch(modelo,  
+     "1" = {alpha <- par[1]; beta <- par[2];  
+             with(amostra, n*(-alpha*log(beta)-log(gamma(alpha)) +  
+                   (alpha-1) * media.logs - media/beta))},  
+     "2" = {alpha <- par[1]; lambda <- par[2] ;  
+             with(amostra, n*(alpha*log(lambda)-log(gamma(alpha)) +  
+                   (alpha-1) * media.logs - lambda * media))},  
+     "3" = {alpha <- par[1]; mu <- par[2] ;  
+             with(amostra, n*(alpha*(log(alpha)-log(mu))-log(gamma(alpha)) +  
+                   (alpha-1) * media.logs - (alpha/mu) * media))}  
+   return(-ll)  
+ }
```

Obtendo novamente as estimativas (nas escalas logarítmicas e original) agora com o método padrão da função `optim()`.

```
> (mod1r <- optim(log(c(1,1)), neglLik, amostra=am, modelo=1, log=T)$par)  
[1] 1.5460915 -0.8791401  
  
> rbind(mod1, exp(mod1r))  
  
 [,1]      [,2]  
mod1 4.692435 0.4152265  
      4.693091 0.4151398  
  
> (mod2r <- optim(log(c(1,1)), neglLik, amostra=am, modelo=2, log=T)$par)  
[1] 1.5458999 0.8788993  
  
> rbind(mod2, exp(mod2r))  
  
 [,1]      [,2]  
mod2 4.692593 2.408415  
      4.692192 2.408247  
  
> (mod3r <- optim(log(c(1,1)), neglLik, amostra=am, modelo=3, log=T)$par)
```

```
[1] 1.5458160 0.6670942
> rbind(mod3, exp(mod3r))
```

[,1]	[,2]
mod3	4.692591 1.948416 4.691798 1.948567

- Reparametrização para interpretabilidade dos parâmetros
COMENTAR
- Reparametrização ortogonalização
COMENTAR
- Melhor comportamento (quadrático) da função.
COMENTAR. Invariância dos estimadores de M.V. e transformação direta de limites de intervalos de confiança baseados na verossimilhança ou *deviance*.

(2.b.) Maximização da função de log-verossimilhança concentrada (1 parâmetro)

Quando possível é conveniente (numericamente) reduzir a dimensionalidade da maximização numérica utilizando a verossimilhança concentrada/perfilhada. No exemplo substituímos a expressão do estimador que possui forma fechada $\hat{\lambda} = \hat{r}/\bar{y}$ na função verossimilhança (8) e obtemos a função de verossimilhança em função de apenas um parâmetro.

$$l(r|y) = n \left(r \log(\hat{\lambda}) - \log(\Gamma(r)) + (r-1)\overline{\log(y)} - \hat{\lambda}\bar{y} \right) \quad (10)$$

$$= n \left(r \log(r/\bar{y}) - \log(\Gamma(r)) + (r-1)\overline{\log(y)} - r \right) \quad (11)$$

Esta função é definida e usada para obter a estimativa de r que na sequência é substituída em $\hat{\lambda} = \hat{r}/\bar{y}$ para obter a estimativa de λ .

```
> neglLik1 <- function(par, amostra, modelo=2, logpar=FALSE){
+   if(logpar) par <- exp(par)
+   ll <- switch(modelo,
+     "1" = {alpha <- amostra$media/par; beta <- par;
+             with(amostra, n*(-log(gamma(alpha)) - alpha*log(beta) +
+                           (alpha-1) * media.logs - media/beta))},
+     "2" = {alpha <- par * amostra$media; lambda <- par;
+             with(amostra, n*(alpha*log(lambda) - log(gamma(alpha)) +
+                           (alpha-1) * media.logs - lambda * media))},
+     "3" = {with(amostra, n*(par*(log(par)-log(media)) -
+                               log(gamma(par)) + (par-1)*media.logs-par))})
+   return(-ll)
+ }
```

Como a otimização agora é em apenas uma dimensão utiliza-se a função `optimize()`. As estimativas em cada parametrização são obtidas com:

```
> (est1 <- optimize(neglLik1, lower=0.001, upper=100, amostra=am, modelo=1)$min)
[1] 0.4152092
```

```

> (est2 <- optimize(neglLik1, lower=0.001, upper=100, amostra=am, modelo=2)$min)
[1] 2.408401

> (est3 <- optimize(neglLik1, lower=0.001, upper=100, amostra=am, modelo=3)$min)
[1] 4.692589

```

mas, na prática, basta obter em uma dessas e as estimativas em outras parametrizações são obtidas de forma trivial.

```

> 1/est1
[1] 2.408424

> am$media/est1
[1] 4.692613

> am$media*est2
[1] 4.692568

```

1.3 Uso de algumas funções do R

O R e seus pacotes oferece funções que facilitam os procedimentos acima, bem como cálculos posteriores como intervalos, matriz de covariâncias, dentre outras. Dentre as funções "facilitadoras" já prontas e disponíveis estão a `mle()` do pacote `stats4` e `mle2()` do pacote `bbmle`. Nestas funções os parâmetros são passados na forma de listas.

Inicialmente define-se a função de (negativo)log-verossimilhança

```

> nllLik <- function(r, lambda){
+     lambda <- exp(lambda); r <- exp(r)
+     ll <- am$n*(r*log(lambda) - log(gamma(r)) +
+             (r-1)*am$media.logs - lambda*am$media)
+     return(-ll)
+ }

```

que é maximizada para obter as estimativas.

```

> require(stats4)
> args(mle)

function (minuslogl, start = formals(minuslogl), method = "BFGS",
    fixed = list(), nobs, ...)
NULL

> (est.mle1 <- mle(nllLik, start=list(r=log(2), lambda=log(2)),
+                   method="L-BFGS-B", lower=c(0,0)))

```

```
Call:  
mle(minuslogl = nllik, start = list(r = log(2), lambda = log(2)),  
    method = "L-BFGS-B", lower = c(0, 0))
```

```
Coefficients:  
      r     lambda  
1.545982 0.878965
```

Vários resumos e funções extratoras estão imediatamente disponíveis para saídas da `mle()`.

```
> ## resumo  
> summary(est.mle1)
```

Maximum likelihood estimation

```
Call:  
mle(minuslogl = nllik, start = list(r = log(2), lambda = log(2)),  
    method = "L-BFGS-B", lower = c(0, 0))
```

```
Coefficients:  
      Estimate Std. Error  
r       1.545982 0.3056496  
lambda 0.878965 0.3226093
```

-2 log L: 49.52223

```
> ## valor da verossimilhança maximizada  
> logLik(est.mle1)
```

'log Lik.' -24.76112 (df=2)

```
> ## AIC  
> AIC(est.mle1)
```

[1] 53.52223

```
> ## estimativas  
> coef(est.mle1)
```

```
      r     lambda  
1.545982 0.878965
```

```
> ## matriz de covariâncias  
> vcov(est.mle1)
```

```
      r     lambda  
r       0.09342171 0.09342167  
lambda 0.09342167 0.10407675
```

```
> ## IC baseado na verossimilhança (deviance) perfilhada  
> confint(est.mle1, level=0.95)
```

```
> par(mfrow=c(1,2))
> plot(profile(est.mle1))
```

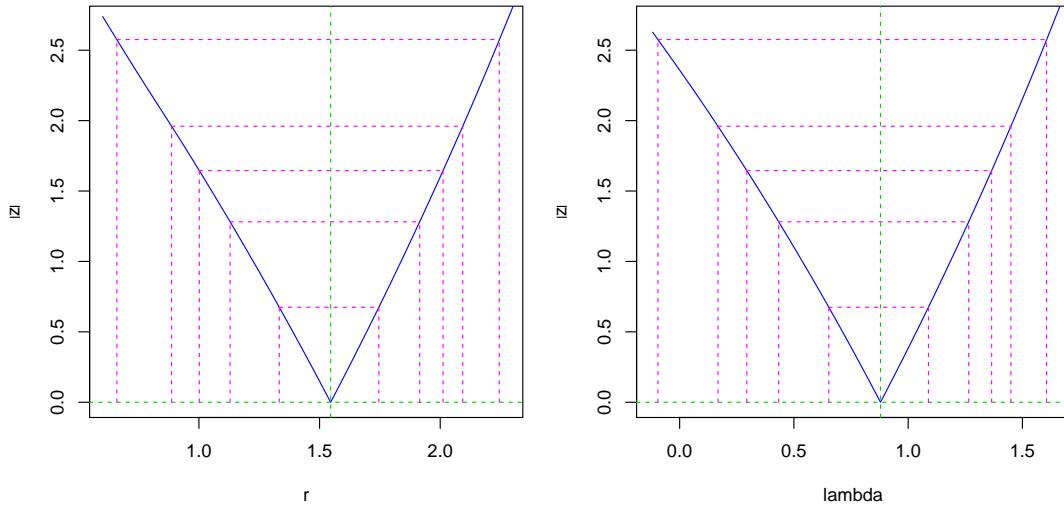


Figura 2: Perfis de verossimilhança (na escala de raiz da deviance) para parâmetros do modelo Gama sob a parametrização 2.

Profiling...

2.5 %	97.5 %
r	0.8868132 2.093177
lambda	0.1675541 1.449452

Assim como funções gráficas também são definidas como por exemplo os perfis de verossimilhança (expressos como raízes da função deviance) mostrados na Figura 2

1.4 Visualizações da função de verossimilhança

A seguir vamos visualizar as superfícies de verossimilhança para cada uma das três parametrizações.

Uma função mais conveniente para visualização é a função **deviance** definida por:

$$D(\theta) = -2[l(\theta) - l(\hat{\theta})]$$

que é definida como uma função no R:

```
> devFun <- function(theta, est, llFUN, ...){
+   return(2 * (llFUN(theta, ...) - llFUN(est, ...)))
+ }
```

A seguir tomamos as estimativas e verificamos que as funções estão retornando valores corretamente.

```
> (ests <- c(r.est, lambda.est))
[1] 4.692604 2.408420

> ## verossimilhancas originais (2 parâmetros)
> neglLik(ests, amostra=am, modelo=2)
```

```

[1] 24.76112

> neglLik(log(est), amostra=am, modelo=2, logpar=T)
[1] 24.76112

> ## verossimilhanças concentradas
> neglLik1(est[2], amostra=am, modelo=2)
[1] 24.76112

> neglLik1(log(est[2]), amostra=am, modelo=2, logpar=T)
[1] 24.76112

> ## fc deviance (2 parâmetros)
> devFun(est, est=mod2, llFUN=neglLik, amostra=am, modelo=2)
[1] 8.101608e-11

> devFun(log(est), est=mod2r, llFUN=neglLik, amostra=am, modelo=2, logp=T)
[1] -1.014605e-07

> ## fc deviance concentrada (1 parâmetro)
> devFun(est[2], est=mod2[2], llFUN=neglLik1, amostra=am, modelo=2)
[1] 8.057555e-11

> devFun(log(est[2]), est=mod2r[2], llFUN=neglLik1, amostra=am, modelo=2, logp=T)
[1] -5.047529e-08

> ## agora para outros valores que não soas os EMV
> neglLik(c(4,2.5), amostra=am, modelo=2)
[1] 26.55084

> neglLik(log(c(4,2.5)), amostra=am, modelo=2, logpar=T)
[1] 26.55084

> neglLik1(2.5, amostra=am, modelo=2)
[1] 24.76866

> neglLik1(log(2.5), amostra=am, modelo=2, logpar=T)
[1] 24.76866

> devFun(c(4,2.5), est=mod2, llFUN=neglLik, amostra=am, modelo=2)

```

```
[1] 3.579439

> devFun(log(c(4,2.5)), est=mod2r, llFUN=neglLik, amostra=am, modelo=2, logp=T)

[1] 3.579439

> devFun(2.5, est=mod2[2], llFUN=neglLik1, amostra=am, modelo=2)

[1] 0.01508588

> devFun(log(2.5), est=mod2r[2], llFUN=neglLik1, amostra=am, modelo=2, logp=T)

[1] 0.01508583
```

Para obter os gráficos da função de verossimilhança uni e bidimensional é conveniente vetorizar a função para que possa receber uma sequencia de valores do(s) parametro(s) que serão usados na construção do gráfico (isto é equivalente a fazer um *for-loop*). A função deviance vetorizada é definida como se segue e conferimos com os valores obtidos anteriormente.

```
> Ofun <- Vectorize(function(x,y, ...) devFun(c(x,y), ...))
> Ofun(4, 2.5, est=ests, llFUN=neglLik, amostra=am, modelo=2)

[1] 3.579439

> Ofun(log(4), log(2.5), est=log(ests), llFUN=neglLik, amostra=am, modelo=2, logpar=T)

[1] 3.579439
```

Para obter o gráfico da função deviance a dois parâmetros, definimos uma malha de valores e avaliamos a função a cada ponto da malha. Note que vamos fazer na escala original e também logarítmica dos parâmetros. Começamos com a **parametrização 1** e as superfícies são mostradas na Figura 3.

```
> alphaGR <- seq(1.6,10.5, len=100)
> betaGR <- seq(0.17,1.35, len=100)
> GRdev <- outer(alphaGR, betaGR, FUN = Ofun, est=mod1, llFUN=neglLik, amostra=am, modelo=2)
> alphaGR1 <- seq(log(1.6),log(10.5), len=100)
> betaGR1 <- seq(log(0.17),log(1.35), len=100)
> GRdevl <- outer(alphaGR1, betaGR1, FUN = Ofun, est=log(mod1), llFUN=neglLik, amostra=am, modelo=2)
```

Passamos agora à **parametrização 2** e após a definição da malha e avaliação da função, as superfícies são mostradas na Figura 4.

```
> rGR <- seq(1.6,10.7, len=100)
> lambdaGR <- seq(0.7,5.6, len=100)
> GRdev <- outer(rGR, lambdaGR, FUN=Ofun, est=mod2, llFUN=neglLik, amostra=am)
> rGR1 <- seq(log(1.6),log(10.7), len=100)
> lambdaGR1 <- seq(log(0.7),log(5.6), len=100)
> GRdevl <- outer(rGR1, lambdaGR1, FUN=Ofun, est=log(mod2), llFUN=neglLik, amostra=am, modelo=2)
```

O mesmo procedimento é repetido para **parametrização 3** com superfícies mostradas na Figura 5.

```

> par(mfrow=c(2,2))
> LEVELS <- c(0.99,0.95,0.9,0.7,0.5,0.3,0.1,0.05)
> contour(alphaGR,betaGR, GRdev, levels=qchisq(LEVELS,df=2),
+           labels=LEVELS, xlab=expression(alpha),ylab=expression(beta))
> points(t(mod1), pch=19, cex=0.6)
> persp(alphaGR, betaGR, GRdev)
> contour(alphaGR1,betaGR1, GRdevl, levels=qchisq(LEVELS,df=2),
+           labels=LEVELS, xlab=expression(log(alpha)),ylab=expression(log(beta)))
> points(t(log(mod1)), pch=19, cex=0.6)
> persp(alphaGR1, betaGR1, GRdevl)

```

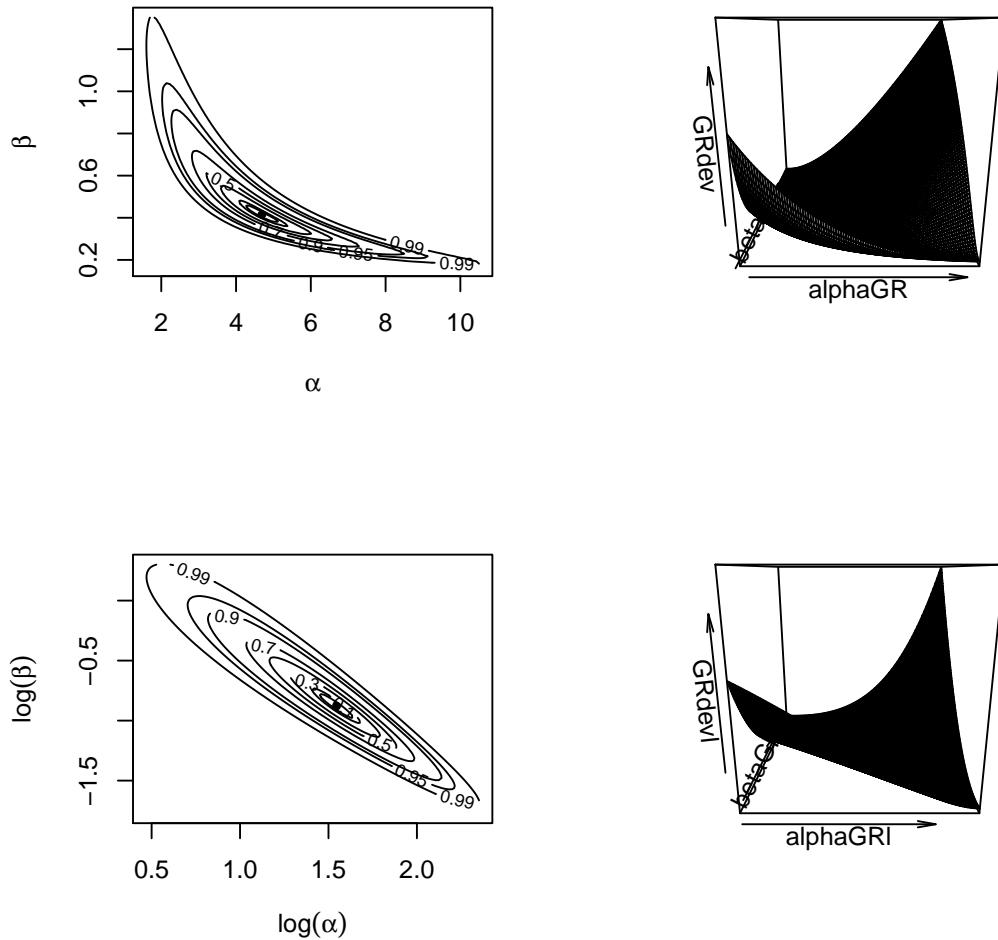


Figura 3: **Parametrização 1:** superfícies de verossimilhanças (expressa como deviance) a dois parâmetros. Gráficos superiores com parâmetros originais e inferiores na escala logarítmica.

```

> par(mfrow=c(2,2))
> contour(rGR,lambdaGR, GRdev, levels=qchisq(LEVELS,df=2),
+           labels=LEVELS, xlab=expression(r),ylab=expression(lambda))
> points(t(mod2), pch=19, cex=0.6)
> persp(rGR, lambdaGR, GRdev)
> contour(rGRI,lambdaGRI, GRdevl, levels=qchisq(LEVELS,df=2),
+           labels=LEVELS, xlab=expression(log(r)),ylab=expression(log(lambda)))
> points(t(log(mod2)), pch=19, cex=0.6)
> persp(rGRI, lambdaGRI, GRdevl)

```

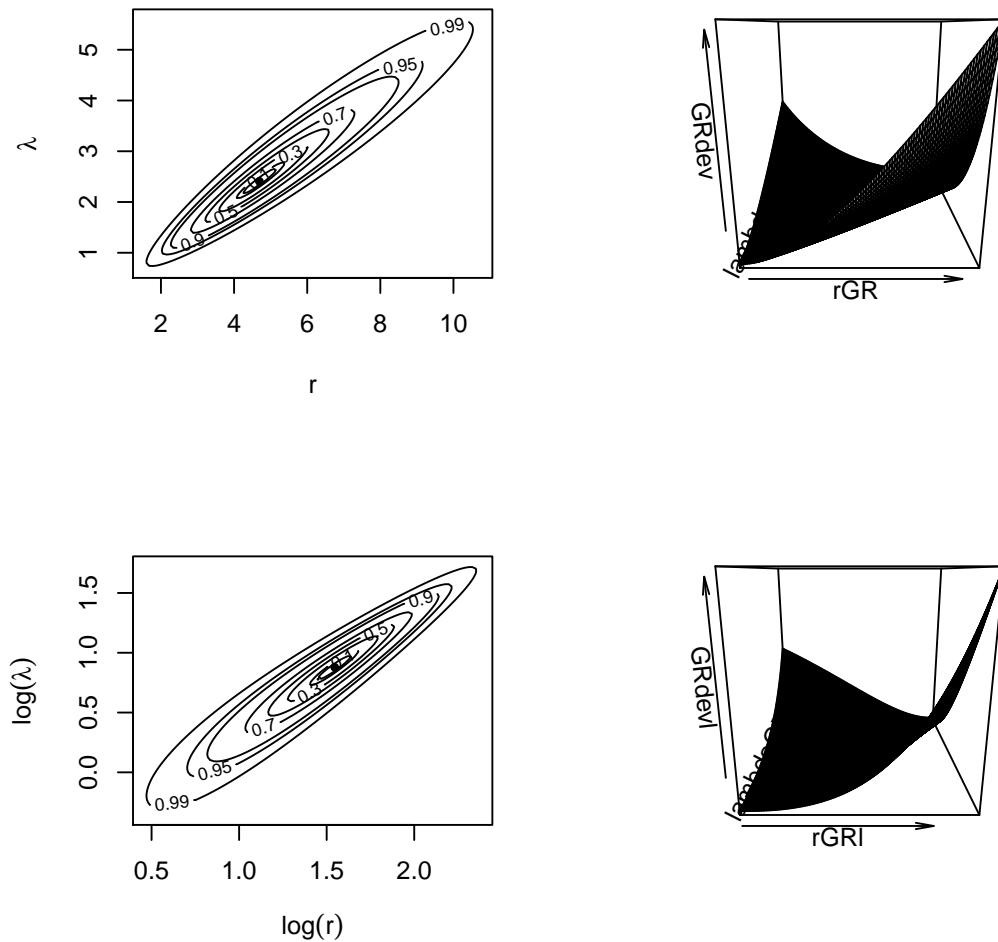


Figura 4: **Parametrização 2:** superfícies de verossimilhanças (expressa como deviance) a dois parâmetros. Gráficos superiores com parâmetros originais e inferiores na escala logarítmica.

```

> par(mfrow=c(2,2))
> contour(rGR, muGR, GRdev, levels=qchisq(LEVELS,df=2),
+           labels=LEVELS, xlab=expression(r), ylab=expression(lambda))
> points(t(mod3), pch=19, cex=0.6)
> persp(rGR, muGR, GRdev)
> contour(rGRI, muGRI, GRdevl, levels=qchisq(LEVELS,df=2),
+           labels=LEVELS, xlab=expression(log(r)), ylab=expression(log(lambda)))
> points(t(log(mod3)), pch=19, cex=0.6)
> persp(rGRI, muGRI, GRdevl)

```

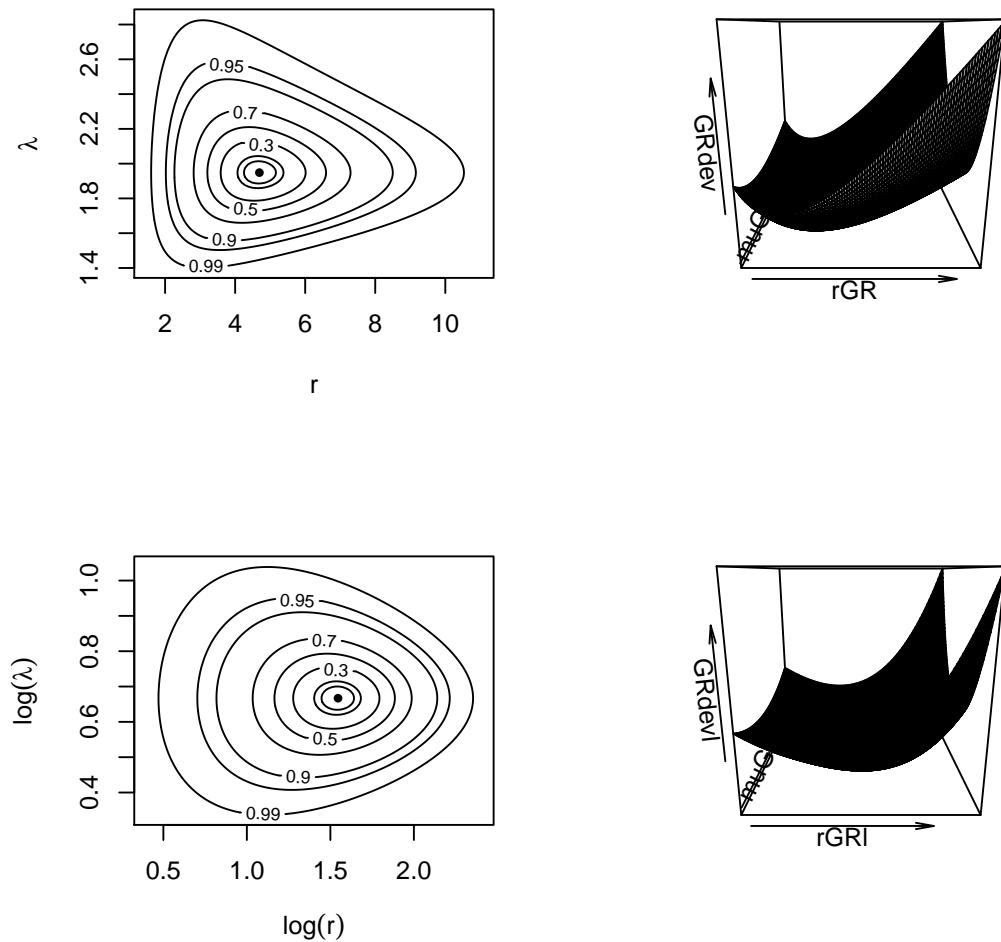


Figura 5: **Parametrização 3:** superfícies de verossimilhanças (expressa como deviance) a dois parâmetros. Gráficos superiores com parâmetros originais e inferiores na escala logarítmica.

```

> rGR <- seq(1.5,11, len=100)
> muGR <- seq(1.4,2.83, len=100)
> GRdev <- outer(rGR, muGR, FUN = Ofun, est=mod3, llFUN=neglLik, amostra=am, modelo=3)
> rGR1 <- seq(log(1.5),log(11), len=100)
> muGR1 <- seq(log(1.4),log(2.83), len=100)
> GRdevl <- outer(rGR1, muGR1, FUN = Ofun, est=log(mod3), llFUN=neglLik, amostra=am, mode

```

Gráficos feitos utilizando a reparametrização em escala logarítmica reduzem a assimetria na função. A última parametrização apresenta uma superfície mais próxima da ortogonalidade.

Unidimensional, verossimilhança perfilhada

```

> #devFun(lambdaGR, est=ests[2], llFUN=neglLik1, amostra=am)
> curve(devFun(x, est=ests[2], llFUN=neglLik1, amostra=am), from=0.9, to=5,
+        xlab=expression(lambda), ylab=expression(P1(lambda)))
> ## cortes definidos por probabilidades
> (corteICs <- qchisq(c(0.90, 0.95, 0.99), df=1))

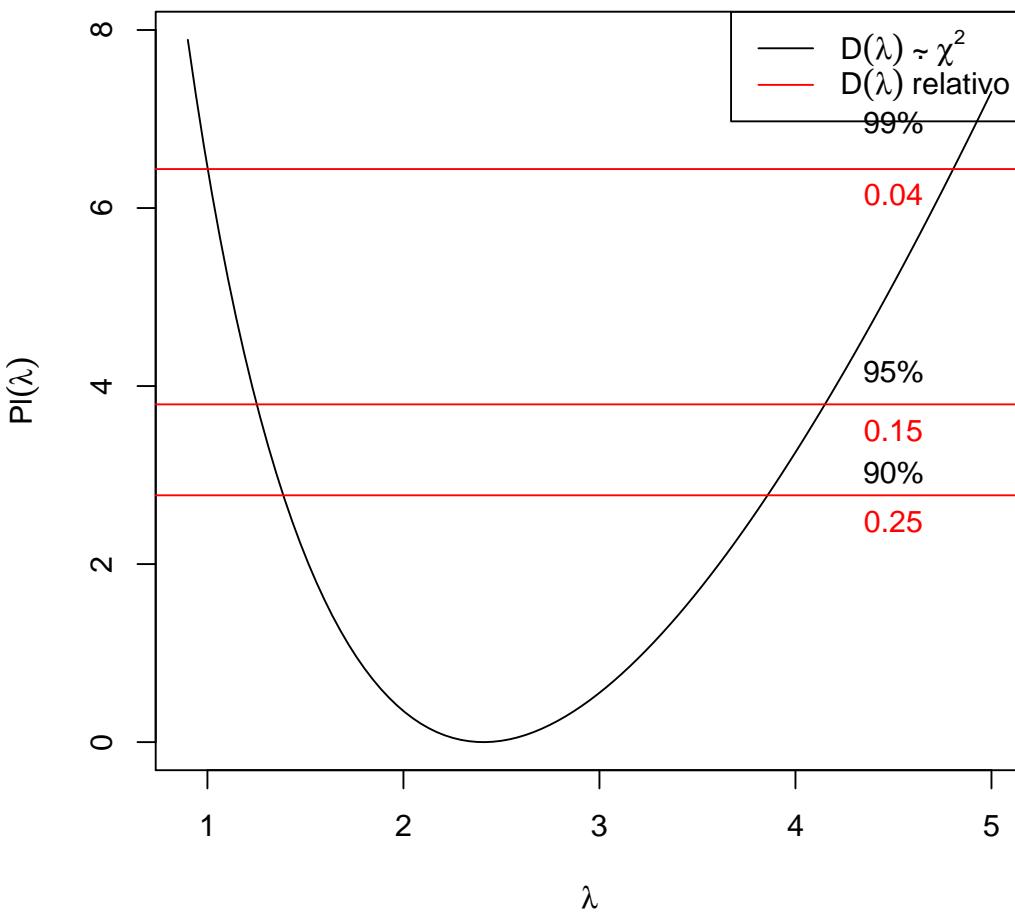
[1] 2.705543 3.841459 6.634897

> text(4.5, corteICs, c("90%", "95%", "99%"), pos=3)
> ## cortes definidos por percentuais da MV
> (corteICs <- -2*log(c(0.25, 0.15, 0.04)))

[1] 2.772589 3.794240 6.437752

> abline(h=corteICs, col=2)
> text(4.5, corteICs, c(0.25, 0.15, 0.04), pos=1, col=2)
> legend("topright", c(expression(D(lambda)~tilde(.)^chi^2),
+                         expression(D(lambda)^relativo)), lty=1, col=1:2)

```



Os gráficos e funções poderiam ser obtidos em escala logarítmica para os parâmetros e os intervalos por transformação dos limites dos IC's baseados em verossimilhança, dada a propriedade de invariância.

Aproximação Quadrática - Aproximação de Taylor de 2a ordem da função verossimilhança e *deviance* ao redor do estimador de M.V. $\hat{\theta}$.

$$\begin{aligned} l(\theta) &= l(\hat{\theta}) + (\theta - \hat{\theta})l'(\hat{\theta}) + \frac{1}{2}(\theta - \hat{\theta})^2l''(\hat{\theta}) \\ &= l(\hat{\theta}) + \frac{1}{2}(\theta - \hat{\theta})^2l''(\hat{\theta}) \end{aligned}$$

Uma vez que pela definição de E.M.V. $l'(\hat{\theta}) = 0$. A aproximação da função *deviance* fica:

$$\begin{aligned} D(\theta) &= -2[l(\theta) - l(\hat{\theta})] \\ &\approx -2[l(\hat{\theta}) + \frac{1}{2}(\theta - \hat{\theta})^2l''(\hat{\theta}) - l(\hat{\theta})] \\ &= -(\theta - \hat{\theta})^2l''(\hat{\theta}) \end{aligned}$$

As expressões consideram θ escalar, mas a extensão para um vetor de parâmetros é trivial.

Complementos: falta ainda completar texto com alguns tópicos como:

- Mostrar como fica a aproximação quadrática em cada parametrização em 1-D (perfilhada) e 2-D
- obter I_0/I_e para cada parametrização
- Comparar I_0/I_e com o hessiano numérico
- Escrever o algoritmo Newton-Rapson
- escrever e usar as funções gradiente na otimização para funções 1-D e 2-D
- ilustrar obtenção dos intervalos por diferentes métodos (incluindo simulação para mostrar taxas de cobertura)
- ...