

# Análise por *quadrat counts* em R

Elias T. Krainski & Paulo J. Ribeiro Jr.

Última Atualização: 2 de agosto de 2006

A análise por *quadrats* é uma técnica de análise estatística bastante simples, cujo objetivo é avaliar o padrão espacial de incidência de doenças em plantas. Para esta análise estão implementados até o momento o índice de dispersão binomial, o índice de dispersão Poisson e o modelo beta-binomial. Para uma análise conjunta de várias avaliações, também foi implementada a estimativa da lei de Taylor, (Madden & Hughes 1995).

## 1 Contagens por *quadrats* - *quadrat counts*

Um *quadrat* é uma sub-região definida a partir do número de linhas e número de plantas nas linhas a serem abrangidas. Os dados de *Pinta Preta dos Citrus* de Itajobi serão usados como exemplo, cujo mapa está na Figura 1.

Carregando os dados:

```
> data(gItajobi)  
  
> plot(gItajobi, pch = 20)
```

A função `quadrat.count()` implementa a contagem por *quadrats*. Os argumentos dessa função são:

```
> args(quadrat.count)  
  
function (obj, dx, dy = dx, complet = TRUE, random = FALSE, N = NULL,  
        p.quadrats = 1, p.quadrats.random = FALSE, criteria = 0.1,  
        death = 1, healt = 0)  
NULL
```

No `help` pode ser vista uma descrição detalhada de cada argumento. Os principais são `obj` que indica o objeto que contém os dados, `dx` que indica o número de linhas abrangido pelo *quadrat* e `dy` que indica o número de plantas na linha abrangido pelo *quadrat*. Por default `dy` é igual à `dx`, bastando informar apenas este argumento.

Com esta função podem ser avaliados todos os possíveis *quadrats* na dimensão especificado pelo número de linhas e plantas na linha. O objeto retornado é uma lista contendo o número de plantas doentes em cada *quadrat*, o número total de plantas em cada `q` e o número nominal de plantas em cada *quadrat*.

Contagem por *quadrats*  $20 \times 20$ :

```
> quadrat.count(gItajobi, 20)
```

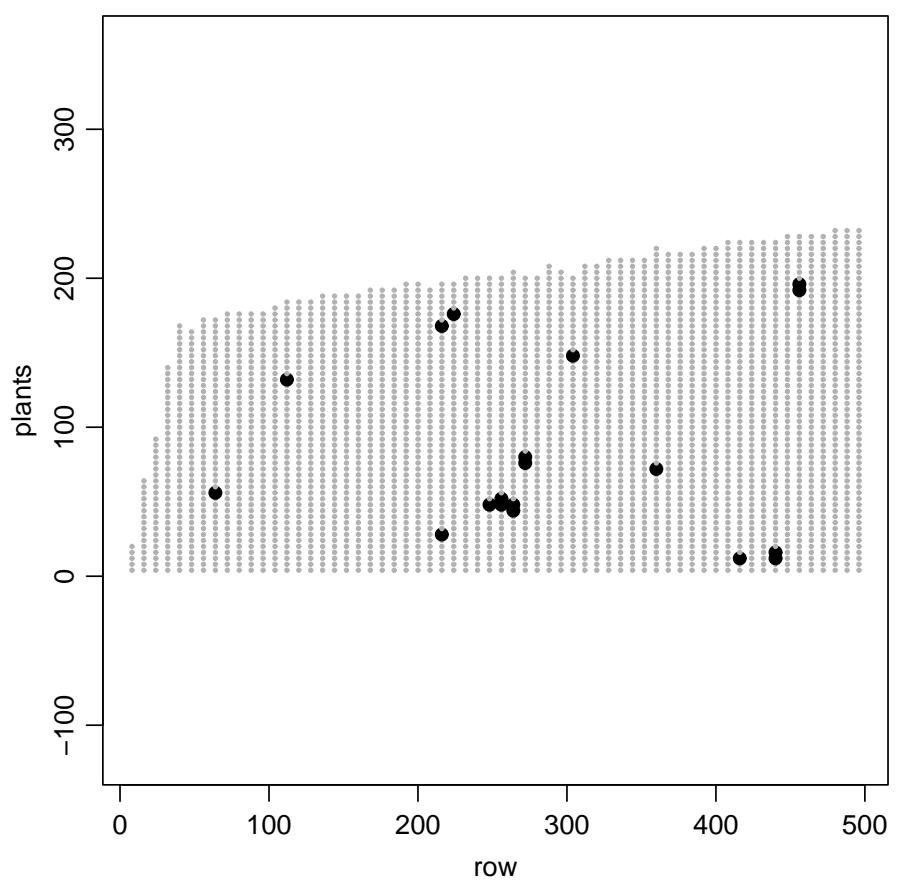


Figura 1: Incidência de pinta preta dos *Citrus* no talhão de Itajobi.

```
$y
 [,1] [,2] [,3]
[1,]    1    1    0
[2,]    8    1    2
[3,]    4    0    2
```

```
$n
 [,1] [,2] [,3]
[1,] 381 338 76
[2,] 400 400 196
[3,] 400 400 305
```

```
$dq
[1] 400
```

Observa-se no resultado o efeito da irregularidade das bordas.

Contagem por *quadrats*  $20 \times 10$ :

```
> quadrat.count(gItajobi, 20, 10)
```

```
$y
 [,1] [,2] [,3] [,4] [,5] [,6]
[1,]    0    1    0    1    0    0
[2,]    1    7    0    1    2    0
[3,]    3    1    0    0    2    0
```

```
$n
 [,1] [,2] [,3] [,4] [,5] [,6]
[1,] 195 186 173 165 76    0
[2,] 200 200 200 200 188   8
[3,] 200 200 200 200 200 105
```

```
$dq
[1] 200
```

Pode-se selecionar os *quadrats* aleatoriamente:

```
> quadrat.count(gItajobi, 20, 10, ran = T)
```

```
$y
[1] 0 1 1 1 1 0 0 2 0 3 5 0 6 0 2 0 1 5
```

```
$n
[1] 200 200 200 200 200 200 200 200 200 200 200 200 200 200 200 200 200
[18] 200
```

```
$dq
[1] 200
```

Pode-se selecionar os *quadrats* aleatoriamente e sem desconsiderar os *quadrats* incompletos:

```

> quadrat.count(gItajobi, 20, 10, ran = T, comp = F)

$y
[1] 1 1 0 2 0 2 0 0 1 1 3 0 3 0 0 0 6 0

$n
[1] 200 200 195 158 133 97 170 139 200 200 200 200 200 200 3 56 150 200
[18] 140

$dq
[1] 200

```

## 2 Índice de dispersão binomial

O índice de dispersão binomial é baseado em dados de *quadrat counts*. É a razão da variância observada pela variância teórica. Todos os *quadrats* analisados devem ter o mesmo número de plantas. Quando as dimensões da matriz de dados não é múltipla das dimensões do *quadrat*, os dados “excedentes” são desconsiderados da análise. Se faltar alguma planta para completar um *quadrat* dentro do talhão, este também é desconsiderado da análise.

Argumentos da função:

```

> args(disp.quadrats)

function (data, dx, dy = dx, counts.return = FALSE, by.evaluations = FALSE,
         death = 1, healt = 0, model = c("binomial", "Poisson", "beta-binomial"),
         alpha = 0.05, random = FALSE, N = NULL, p.quadrats = 1, p.quadrats.random = FALSE,
         complet = TRUE, evaluation = "all", digits = 5, verbose = FALSE,
         bb.args = list(ini.p = NULL, ini.theta = NULL, usage = c("fitdistr",
                     "mle")), ...)
NULL

```

Fazendo a análise:

```

> disp.quadrats(gItajobi, dx = 7)

$`7x7`
      n   N   nN      p obs.var theor.var index p.value    pattern
Av1 49 46 2254 0.0071 0.00036    0.00014  2.47        0 Aggregate

> disp.quadrats(gItajobi, dx = 10, dy = 10)

$`10x10`
      n   N   nN      p obs.var theor.var index p.value    pattern
Av1 100 23 2300 0.00696 0.00025    7e-05  3.61        0 Aggregate

> disp.quadrats(gItajobi, dx = 10, dy = 10, random = TRUE)

$`10x10`
      n   N   nN      p obs.var theor.var index p.value    pattern
Av1 100 36 3600 0.00861 0.00021    9e-05  2.42  1e-05 Aggregate

```

```

> disp.quadrats(gItajobi, dx = c(2, 2, 5), dy = c(2, 5, 10))
$`2x2`
   n   N   nN      p obs.var theor.var index p.value   pattern
Av1 4 738 2952 0.00644 0.00225    0.0016  1.41        0 Aggregate

$`2x5`
   n   N   nN      p obs.var theor.var index p.value   pattern
Av1 10 286 2860 0.00664 0.00118    0.00066  1.79        0 Aggregate

$`5x10`
   n   N   nN      p obs.var theor.var index p.value   pattern
Av1 50 50 2500 0.0068  5e-04    0.00014   3.7        0 Aggregate

Havendo mais de uma avaliação feita ao longo do tempo no mesmo talhão, podemos optar a forma da saída: por avaliação ou por tamanhos de quadrats, usando o argumento by.evaluations.
Carregando um conjunto de dados validados de MSC:

```

```

> data(v303.geo)

```

Fazendo a análise das três primeiras avaliações:

```

> disp.quadrats(v303.geo, dx = 2:5, dy = 2 * (2:5), death = 1:3,
+   evaluation = 1:3)
$`2x4`
   n   N   nN      p obs.var theor.var index p.value   pattern
Av1 8 108 864 0.0255 0.00489    0.00310  1.58 0.00013 Aggregate
Av2 8 108 864 0.0301 0.00522    0.00365  1.43 0.00233 Aggregate
Av3 8 108 864 0.0764 0.01193    0.00882  1.35 0.00893 Aggregate

$`3x6`
   n   N   nN      p obs.var theor.var index p.value   pattern
Av1 18 38 684 0.0263 0.00179    0.00142  1.26 0.13484 Random
Av2 18 38 684 0.0322 0.00227    0.00173  1.32 0.09511 Random
Av3 18 38 684 0.0833 0.00797    0.00424  1.88 0.00097 Aggregate

$`4x8`
   n   N   nN      p obs.var theor.var index p.value   pattern
Av1 32 20 640 0.0281 0.00194    0.00085  2.27 0.00121 Aggregate
Av2 32 20 640 0.0344 0.00174    0.00104  1.67 0.03273 Aggregate
Av3 32 20 640 0.0813 0.00539    0.00233  2.31 0.00098 Aggregate

$`5x10`
   n   N   nN      p obs.var theor.var index p.value   pattern
Av1 50 9 450 0.0289 0.00051    0.00056  0.911  0.506 Random
Av2 50 9 450 0.0333 0.00070    0.00064  1.086  0.369 Random
Av3 50 9 450 0.0822 0.00234    0.00151  1.553  0.133 Random

> disp.quadrats(v303.geo, dx = 2, dy = 5, by.evaluations = FALSE,
+   death = 1:3)

```

```
$`2x5`
```

	n	N	nN	p	obs.var	theor.var	index	p.value	pattern
Av1	10	80	800	0.0262	0.00424	0.00256	1.66	0.00021	Aggregate
Av2	10	80	800	0.0300	0.00441	0.00291	1.51	0.00219	Aggregate
Av3	10	80	800	0.0737	0.01158	0.00683	1.70	0.00011	Aggregate
Av4	10	80	800	0.0925	0.01640	0.00839	1.95	0.00000	Aggregate
Av5	10	80	800	0.1025	0.01620	0.00920	1.76	0.00004	Aggregate
Av6	10	80	800	0.1588	0.02423	0.01335	1.81	0.00001	Aggregate
Av7	10	80	800	0.2575	0.03235	0.01912	1.69	0.00012	Aggregate
Av8	10	80	800	0.2600	0.03129	0.01924	1.63	0.00037	Aggregate
Av9	10	80	800	0.3187	0.03445	0.02171	1.59	0.00070	Aggregate
Av10	10	80	800	0.3362	0.03702	0.02232	1.66	0.00021	Aggregate
Av11	10	80	800	0.4925	0.04298	0.02499	1.72	0.00007	Aggregate
Av12	10	80	800	0.5550	0.04554	0.02470	1.84	0.00001	Aggregate
Av13	10	80	800	0.6188	0.05142	0.02359	2.18	0.00000	Aggregate
Av14	10	80	800	0.6312	0.05028	0.02328	2.16	0.00000	Aggregate
Av15	10	80	800	0.6650	0.05344	0.02228	2.40	0.00000	Aggregate
Av16	10	80	800	0.6837	0.05429	0.02162	2.51	0.00000	Aggregate
Av17	10	80	800	0.7712	0.03397	0.01764	1.93	0.00000	Aggregate
Av18	10	80	800	0.8337	0.02556	0.01386	1.84	0.00001	Aggregate
Av19	10	80	800	0.8387	0.02468	0.01352	1.82	0.00001	Aggregate
Av20	10	80	800	0.8788	0.01916	0.01065	1.80	0.00002	Aggregate
Av21	10	80	800	0.9337	0.01239	0.00619	2.00	0.00000	Aggregate
Av22	10	80	800	0.9337	0.01239	0.00619	2.00	0.00000	Aggregate
Av23	10	80	800	0.9337	0.01239	0.00619	2.00	0.00000	Aggregate
Av24	10	80	800	0.9800	0.00289	0.00196	1.47	0.00402	Aggregate
Av25	10	80	800	0.9800	0.00289	0.00196	1.47	0.00402	Aggregate

### 3 Índice de dispersão de Poisson

Para o índice de dispersão de Poisson, a função considera os dados de todos os *quadrats* onde o número de plantas considerado é maior que um quarto do número de plantas definido pelo tamanho nominal do *quadrat* e não considera os dados de *quadrats* com menor número de plantas.

```
> disp.quadrats(gItajobi, dx = 10, model = "Pois")  
  
$`10x10`  


|     | n  | np   | p       | obs.var | theor.var | index | p.value | pattern   |
|-----|----|------|---------|---------|-----------|-------|---------|-----------|
| Av1 | 36 | 2896 | 0.00656 | 1.76    | 0.643     | 2.73  | 0       | Aggregate |

  
> disp.quadrats(gItajobi, dx = 10, model = "Pois", random = TRUE)  
  
$`10x10`  


|     | n  | np   | p       | obs.var | theor.var | index | p.value | pattern   |
|-----|----|------|---------|---------|-----------|-------|---------|-----------|
| Av1 | 36 | 3600 | 0.00639 | 1.89    | 0.639     | 2.97  | 0       | Aggregate |


```

## 4 Modelo beta-binomial

Assumindo o modelo binomial ou de Poisson, assume-se que a probabilidade de incidência no talhão é constante em todo o talhão, porém no caso de haver agregação essa suposição não é razoável e o índice de dispersão é maior que um. Supondo que a probabilidade de incidência é variável, pode-se modelar os dados de *quadrat counts* por uma distribuição beta-binomial.

A distribuição beta-binomial é uma composição da distribuição binomial com a densidade beta, (Skellam 1948). A distribuição beta-binomial tem dois parâmetros:  $\pi$ , que representa a incidência média no talhão, e  $\theta$  que mede a variação da incidência. O parâmetro  $\theta$ , no contexto dos dados de incidência de doenças, pode ser interpretado como um índice de agregação espacial da doença. Se  $\theta > 0$ , o padrão da doença é agregado (Griffiths 1979).

As estimativas de máxima verossimilhança para a incidência média  $p$  e o parâmetro de agregação  $\theta$  do modelo beta-binomial não tem expressões fechadas. Para obter essas estimativas, utiliza-se um procedimento iterativo de minimização (maximização) numérica, que pode não convergir.

```
> disp.quadrats(v303.geo, dx = 2, dy = 5, death = 1:3, model = "beta-binomial")  
$`2x5'  
      N     n   nN   prob  theta p.value    pattern  
Av1  100 9.45 945 0.0238 0.0986 0.01229 Aggregate  
Av2  100 9.45 945 0.0283 0.0692 0.04202 Aggregate  
Av3  100 9.45 945 0.0778 0.0695 0.01948 Aggregate  
Av4  100 9.45 945 0.0948 0.0993 0.00174 Aggregate  
Av5  100 9.45 945 0.1041 0.0781 0.00829 Aggregate  
Av6  100 9.45 945 0.1570 0.0984 0.00147 Aggregate  
Av7  100 9.45 945 0.2520 0.0829 0.00392 Aggregate  
Av8  100 9.45 945 0.2568 0.0700 0.01075 Aggregate  
Av9  100 9.45 945 0.3175 0.0617 0.01882 Aggregate  
Av10 100 9.45 945 0.3357 0.0722 0.00781 Aggregate  
Av11 100 9.45 945 0.4925 0.0936 0.00124 Aggregate  
Av12 100 9.45 945 0.5522 0.1153 0.00016 Aggregate  
Av13 100 9.45 945 0.6086 0.1602 0.00000 Aggregate  
Av14 100 9.45 945 0.6210 0.1633 0.00000 Aggregate  
Av15 100 9.45 945 0.6530 0.1822 0.00000 Aggregate  
Av16 100 9.45 945 0.6714 0.1892 0.00000 Aggregate  
Av17 100 9.45 945 0.7616 0.1175 0.00013 Aggregate  
Av18 100 9.45 945 0.8219 0.1190 0.00016 Aggregate  
Av19 100 9.45 945 0.8262 0.1202 0.00015 Aggregate  
Av20 100 9.45 945 0.8730 0.1045 0.00097 Aggregate  
Av21 100 9.45 945 0.9272 0.1406 0.00018 Aggregate  
Av22 100 9.45 945 0.9272 0.1406 0.00018 Aggregate  
Av23 100 9.45 945 0.9272 0.1406 0.00018 Aggregate  
Av24 100 9.45 945 0.9711 0.1058 0.00730 Aggregate  
Av25 100 9.45 945 0.9711 0.1058 0.00730 Aggregate
```

### 4.1 Detalhes da estimação

O procedimento de estimação dos parâmetros da distribuição beta-binomial, está implementado em detalhes na função `betabinom.citrus()`.

```

> args(betabinom.citrus)

function (data, dx, dy = dx, check.args = NULL, ini.prob = NULL,
ini.theta = NULL, usage = c("fitdistr", "mle"), ...)
NULL

```

Nos argumentos dessa função precisamos entrar com os dados no argumento `data`, as dimensões dos *quadrats* nos argumentos `dx` e `dy` e as informações dos códigos identificadores do *status* das plantas em forma de lista nomeada.

Duas funções podem ser utilizadas na minimização numérica: a `fitdistr()` do pacote **MASS**, (Venables & Ripley 2002) e a função `mle()` do pacote **stats4**. A primeira, retorna simplesmente as estimativas dos parâmetros e dos erros-padrão obtidos do hessiano numérico. A segunda, retorna um resultado que possibilita explorar as verossimilhanças perfilhadas. A escolha dessa função é informada no argumento `usage`.

Nos dados de PPC podemos utilizar a função `fitdistr`, fazendo:

```

> (bb1ita <- betabinom.citrus(gItajobi, dx = 10))

valid evaluations: 1
      prob      theta
0.00638   0.01934
(0.00236) (0.01330)

```

## 4.2 Verossimilhanças perfilhadas

Utilizando `usage='mle'`, retorna-se um objeto da classe `mle`. Com esse resultado, podemos estudar as verossimilhanças perfilhadas, para aproximar intervalos de confiança para as estimativas e visualizar.

```
> bb.ita <- betabinom.citrus(gItajobi, dx = 10, usage = "mle")
```

valid evaluations: 1

Obtendo o sumário:

```
> summary(bb.ita)
```

Maximum likelihood estimation

Call:

```
mle(minuslogl = function(prob, theta) -sum(dbetabinom(x = y,
size = size, prob = prob, theta = theta, log = TRUE)), start = list(prob = ini.p
theta = ini.theta))
```

Coefficients:

	Estimate	Std. Error
prob	0.00638	0.00236
theta	0.01934	0.01330

-2 log L: 62.6

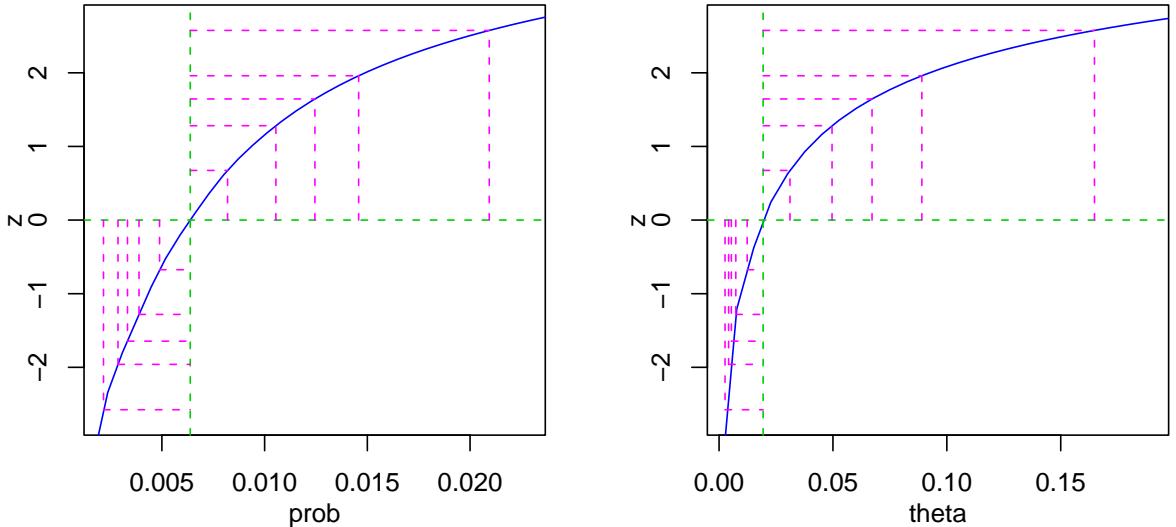


Figura 2: Visualização da verossimilhança perfilhada para os parâmetros da distribuição beta-binomial aplicada aos dados de Itajobi

Para obter o intervalo de confiança para as estimativas a partir das verossimilhanças perfilhadas, faz-se:

```
> prof <- profile(bb.ita)
> confint(prof)

      2.5 % 97.5 %
prob  0.00288 0.0146
theta  0.00463 0.0890
```

As verossimilhanças perfilhadas podem ser plotadas, como na Figura 2.

```
> par(mfrow = c(1, 2), mar = c(3, 3, 3, 0.5), mgp = c(2, 1,
+          0))
> plot(prof, absVal = FALSE)
```

## 5 Lei de Taylor

A estimação dos parâmetros da Lei de Taylor é feita a partir do cálculo da variância observada e da variância esperada em observações feitas em vários talhões ou em vários ocasiões no mesmo talhão.

Usando a função `Taylor.citrus` podemos estimar os parâmetros da Lei de Taylor para usando as avaliações feitas em um talhão.

```
> Tay <- Taylor.citrus(v303.geo, dx = 5, random = FALSE, death = 1:3)
> Tay
```

```

      a      b
2.16 1.20

> summary(Tay)

Summary of disease incidence:
    Min. 1st Qu. Median     Mean 3rd Qu.     Max.
    0.0257   0.2600   0.6110   0.5330   0.8300   0.9800
Estimates and confidence intervals of Taylor Law:
    2.5 % estimate 97.5 %
a 1.54      2.16      2.77
b 1.09      1.20      1.31
Thue an evidences of an aggregatedpattern.

```

```

> TayR <- Taylor.citrus(v303.geo, dx = 5, random = TRUE, death = 1:3)
> TayR

```

```

      a      b
2.18 1.22

> summary(TayR)

Summary of disease incidence:
    Min. 1st Qu. Median     Mean 3rd Qu.     Max.
    0.0294   0.2140   0.5600   0.5230   0.8080   0.9820
Estimates and confidence intervals of Taylor Law:
    2.5 % estimate 97.5 %
a 1.46      2.18      2.91
b 1.08      1.22      1.35
Thue an evidences of an aggregatedpattern.

```

Podemos fazer o gráfico para as duas análises usando a função `plot()`. Esta função foi programada para mostrar a incidência no eixo horizontal e o índice de dispersão na vertical, Figura 3.

```

> par(mfrow = c(1, 2), mar = c(3, 3, 3, 0.5), mgp = c(2, 1,
+          0))
> plot(Tay)
> plot(TayR)

```

## 6 Número ótimo de *quadrats* aleatórios

Na análise por *quadrats* existe arbitrariedade na definição dos qs, quanto à tamanho, forma e o modo como são selecionados. Os *quadrats* podem ser fixos no talhão, definindo-os a partir de um extremo do talhão, ou aleatórios, definindo-os em qualquer posição no talhão. Na seleção aleatória dos *quadrats*, podemos selecionar uma amostra aleatória representativa. Então precisamos de um método que nos permita escolher o número ótimo de *quadrats* selecionados aleatoriamente.

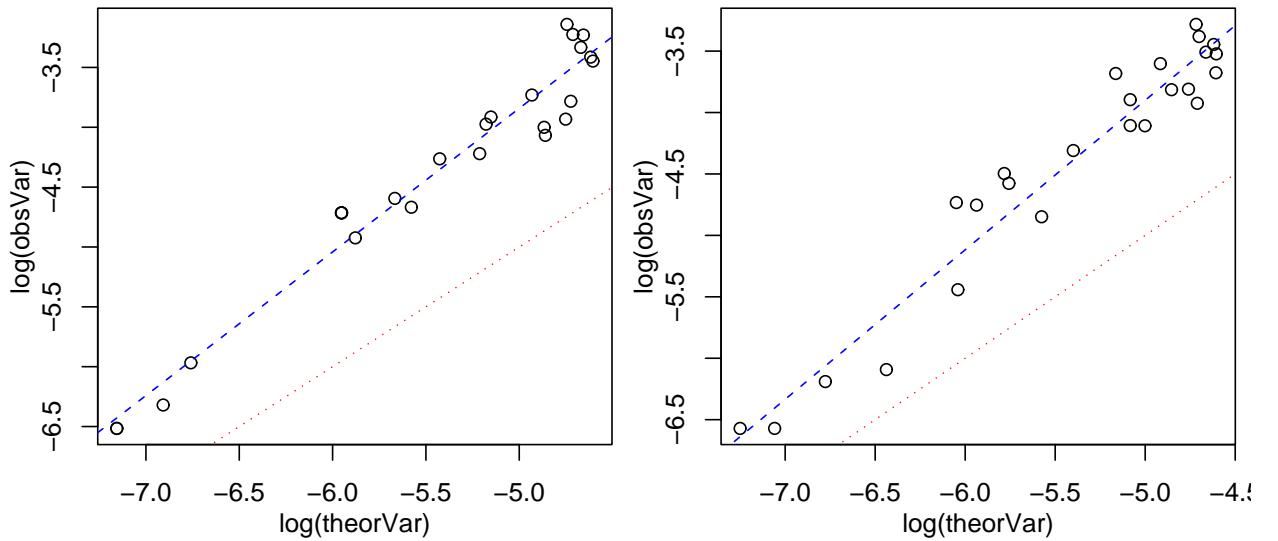


Figura 3: Logarítmico da variância observada versus logarítmico da variância teórica.

É razoável assumir que a análise feita a partir de *quadrats* selecionados aleatoriamente, será confiável em proporção ao número *quadrats*. Também é razoável assumir que o ganho em precisão na análise decai a medida em que aumenta-se o número de *quadrats*. Dessa forma, várias análises feitas com poucos *quadrats* selecionados aleatoriamente terá resultados mais variáveis que a análises feitas com um número maior de *quadrats*.

A metodologia implementada consiste em:

- realizar  $n$  análises com  $N$  *quadrats* selecionados aleatoriamente,
- realizar outras  $n$  análises com  $N + 1$  *quadrats*
- repetir o passo anterior até um critério ser atingido

É difícil escolher um critério que seja eficaz para detectar que a estabilidade foi atingida para determinado  $N$ . As técnicas de controle de qualidade podem ser úteis para avaliar a estabilidade de uma medida ao longo de várias amostras. Para ilustrar, calculou-se o índice de dispersão binomial tomando-se, inicialmente  $N$  *quadrats* aleatórios com  $N$  entre 3 e 100, repetindo-se  $n = 3$  vezes a análise para cada  $N$ .

```
> set.seed(153)
> res1 <- sim.N.quadrats(gItajobi, dx = 10, ini.N = 3, k = 100)
> qcc1 <- qcc(res1, type = "xbar")

> qcc2 <- qcc(res1, type = "R")
```

Na Figura 4 vê-se o gráfico de controle da média do índice de dispersão entre cada uma das 3 análises feitas para cada  $N$ . Os valores do eixo horizontal do gráfico representam o número de *quadrats* selecionados. Observa-se que a média do índice de dispersão binomial é mais variável quando se toma poucos *quadrats* e torna-se mais estável a medida que a análise é feita com maior número de *quadrats*.

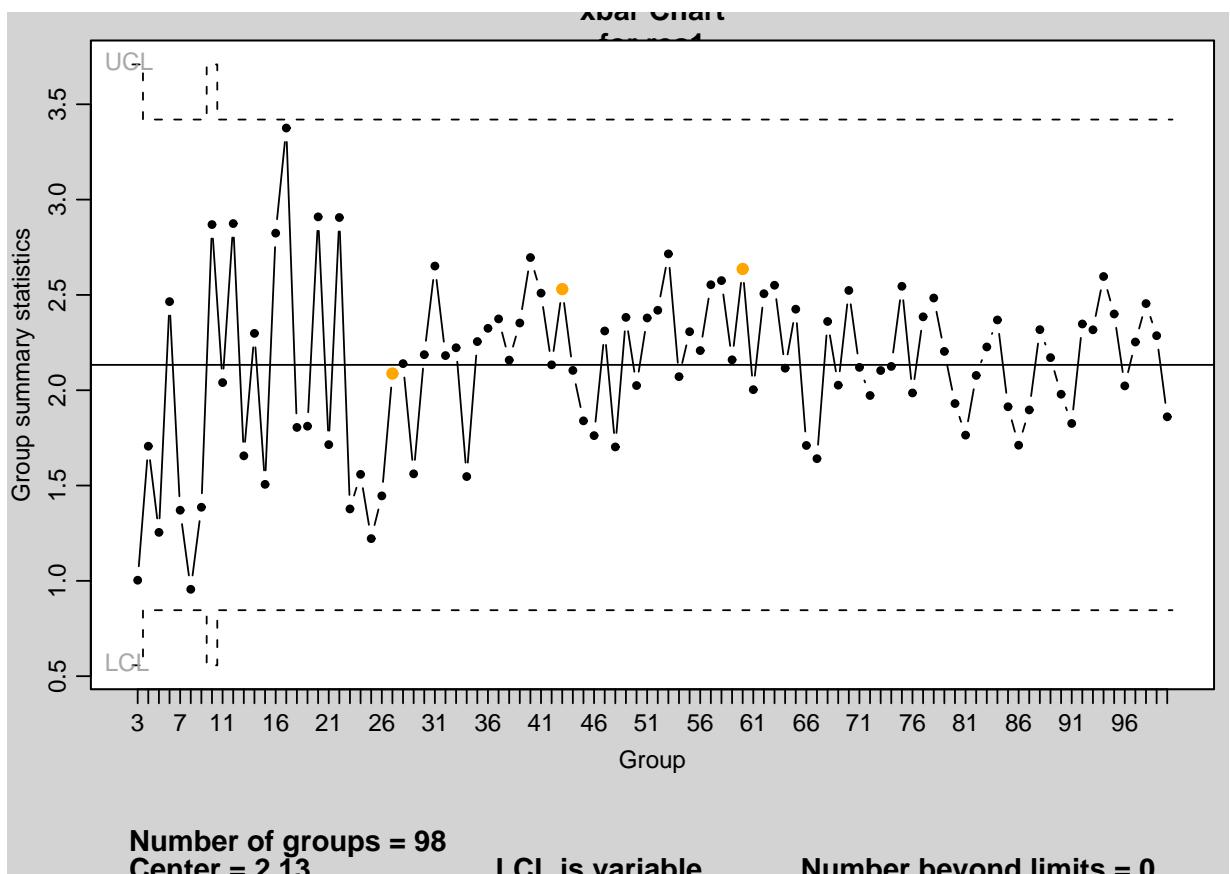


Figura 4: Carta de controle para média do índice de dispersão das 3 análises para análises de 3 a 100 quadrats

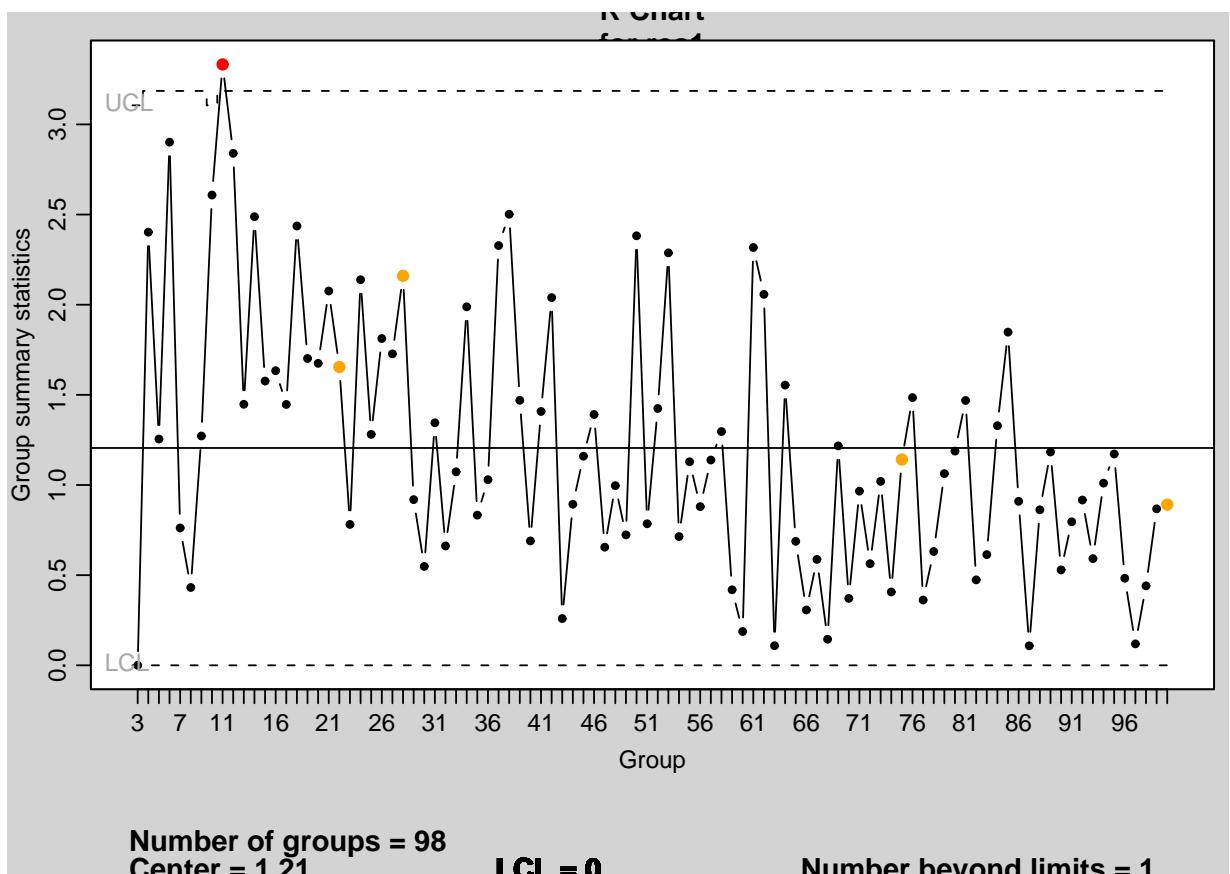


Figura 5: Carta de controle para a amplitude do índice de dispersão das 3 análises para cada análises de 3 a 100 *quadrats*

Na Figura 5 vê-se o gráfico de controle da amplitude do índice de dispersão entre cada uma das 3 análises feitas para cada  $N$ . Observa-se que a amplitude entre o índice de dispersão das três análises diminui a medida que o número de *quadrats* aumenta.

Nos gráficos de controle os pontos coloridos em vermelho representam pontos fora dos limites de controle e os pontos laranja aparecem quando uma seqüência de 5 valores ocorre abaixo ou acima da média. Esses pontos são detectados pelas funções `beyond.limits()` e `violating.runs()` do pacote **qcc**, respectivamente. No caso do gráfico da amplitude, quando ocorre um ponto laranja, muito provavelmente este estará abaixo da média, indicando que houve uma estabilização da amplitude abaixo da amplitude média.

A função `sim.N.quadrats()` realiza a análise por *quadrats* aleatórios iniciando com valor para  $N$  informado e repetindo  $n$  vezes. Quando se atinge certo número  $k$  de valores de  $N$ , é feito um gráfico de controle para detectar se houve *violating runs*. Se não houve, continua-se fazendo a análise para números crescentes de *quadrats* e refaz-se o gráfico de controle para os últimos  $k$  valores de  $N$  considerados.

```
> args(sim.N.quadrats)

function (obj, dx, dy = dx, complet = TRUE, ini.N = 5, n = 3,
         k = 10, stat = "index", death = 1, healt = 0, model = c("binomial",
                  "Poisson", "beta-binomial"), type = "R", alpha = 0.05,
         evaluation = 1, N.max = 100, verbose = FALSE)
NULL

> (res2 <- sim.N.quadrats(gItajobi, dx = 10))

      am1    am2    am3
5  0.753  0.753  1.512
6  0.403  3.015  6.061
7  1.090  1.451  3.704
8  1.482  3.708  4.329
9  4.879  1.548  3.060
10 1.064  1.856  4.173
11 3.791  2.195  2.715
12 0.914  1.774  1.077
13 0.835  0.821  2.270
14 1.469  1.277  2.206
15 1.767  4.264  4.027
16 0.946  4.283  3.135
17 3.036  0.911  1.638
18 3.742  1.630  0.884
19 0.927  1.352  4.297
```

Na Figura 6 visualiza-se um gráfico de controle para a amplitude dos valores do índice de dispersão obtidos da análise.

```
> qcc3 <- qcc(res2, type = "R")
```

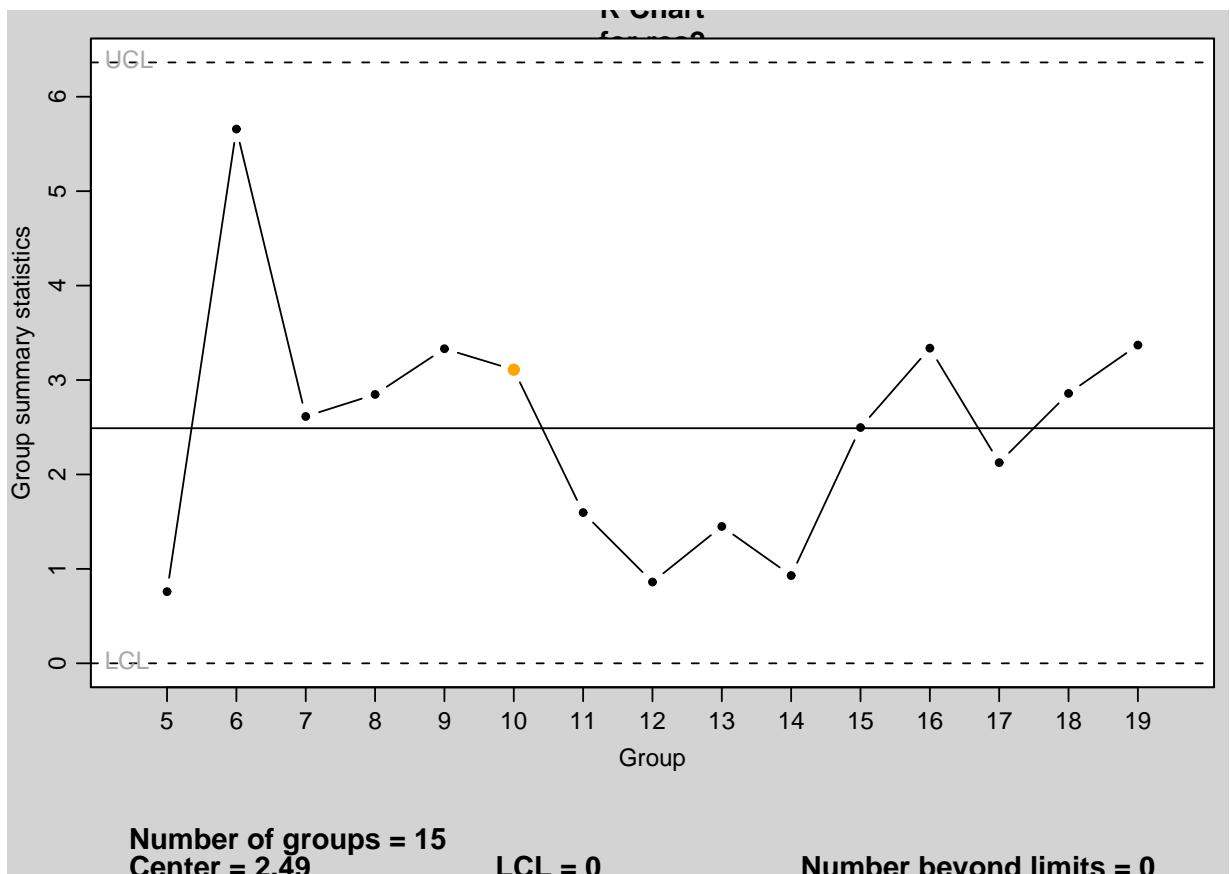


Figura 6: Carta de controle para a amplitude do índice de dispersão das 3 análises para cada valor de N a partir de 5 e interrompido pelo critério adotado

## Agradecimentos

Este trabalho foi desenvolvido como parte das atividades do convênio firmado entre o Fundo de Defesa da Citricultura (FUNDECITRUS) e o Departamento de Estatística da Universidade Federal do Paraná e financiado pelo FUNDECITRUS.

## Referências

- Griffiths, D. A. (1979). Maximum likelihood estimation for the beta-binomial distribution and an application to household distribution of total number of a disease, *Biometrics* .
- Madden, L. V. & Hughes, G. (1995). Plant disease incidence: Distributions, heterogeneity, and temporal analysis, *Phytopathology* .
- Skellam, J. G. A. (1948). A probability distribution derived from the binomial distribution by regarding the probability of success as variable between the sets of trials, *Journal of Royal Statistical Society, Series B* .
- Venables, W. N. & Ripley, B. D. (2002). *Modern Applied Statistics with S*, Fourth edition.