


## Visualização de Dados Multivariados

- Correlograma:

```
# Matriz de correlações
(iris.cor <- cor(iris[-5]))
Sepal.Length Sepal.Width Petal.Length Petal.Width
Sepal.Length 1.0000000 -0.1175698 0.8717538 0.8179411
Sepal.Width -0.1175698 1.0000000 -0.4284401 -0.3661259
Petal.Length 0.8717538 -0.4284401 1.0000000 0.9628654
Petal.Width 0.8179411 -0.3661259 0.9628654 1.0000000
> library(corrplot)
> # correlograma - círculo
> corrplot(iris.cor, method = "circle")
```

✓ círculos




Visualização de Dados com R -- 2017



205

- Correlograma:

```
> # correlograma - pizza
> corrplot(iris.cor, method = "pie")
> # correlograma - cor
> corrplot(iris.cor, method = "color")
```



Visualização de Dados com R -- 2017



206

- Correlograma:





```
> # correlograma - valores
> corrplot(iris.cor, method = "number")
> # correlograma - superior
> corrplot(iris.cor, type = "upper")
```



Visualização de Dados com R -- 2017




207



• Correlograma:

```
> # Agregando nível de significância ao correlograma
> corplot(iris.cor, type="upper", order="hclust", p.mat = p.mat,
+ sig.level = 0.01)
> # Deixando em branco coeficiente não significante
> corplot(iris.cor, type = "upper", order = "hclust", p.mat = p.mat,
+ sig.level = 0.01, insig = "blank")
```




Visualização de Dados com R -- 2017

212

• Correlograma:

```
> # Customizando o correlograma
> col <- colorRampPalette(c("#BB4444", "#EE9988", "#FFFFFF", "#77AADD",
+ "#4477AA"))
> corplot(iris.cor, method="color", col=col(200), type="upper", order="hclust",
+ addCoef.col = "black", # Adiciona coeficiente de correlação
+ tl.col="black", tl.srt=45, # Rotação e cor de texto rótulo
+ # Combinação com significância
+ p.mat = p.mat, sig.level = 0.01, insig = "blank",
+ diag=FALSE # elimina valores da diagonal principal
+ )
```




Visualização de Dados com R -- 2017

213

• Matriz de Correlações – pacote lattice:

```
> library(lattice)
> rgbs.palette <- colorRampPalette(c("blue", "yellow"), space = "rgb")
> levelplot(iris.cor, main = "stage 12-14 array correlation matrix",
+ xlab = "", ylab = "", col.regions = rgbs.palette(120),
+ cuts = 100, at = seq(0, 1, 0.01)
+ )
```




Visualização de Dados com R -- 2017

214

• Matriz de Correlações – pacote lattice:

```
> source ("https://github.com/JVAdams/jvamisc/blob/master/R/plotcor.R")
> library(plotrix)
> library(seriation)
> library(MASS)
> plotcor(cor(iris.cor), mar = c(0.1, 4, 4, 0.1))
```




Visualização de Dados com R -- 2017

215

- Mapa de Calor:

```
> library(gplots)
> library(RColorBrewer)
> heatmap.2(iris.cov, col = brewer.pal(9, "GnBu"), trace ="none",
+   key = FALSE, dend = "none", cexCol = 1.1, cexRow = 1.1, srtCol = 90,
+   labRow = c("Sep.L", "Sep.W", "Pet.L", "Pet.W"),
+   labCol = c("Sep.L", "Sep.W", "Pet.L", "Pet.W"),
+   main = "\n\nMatriz de Correlações\nIris")
```



Visualização de Dados com R -- 2017



216

- Gráfico em html:

- ✓ Gráfico 1:

```
> library(plotly)
> p1 <- plot_ly(data = iris, x =~Sepal.Length, y =~Sepal.Width, split =~Species,
+   showlegend = F)
> p2 <- plot_ly(data = iris, x =~Sepal.Length, y =~Sepal.Width, split =~Species,
+   showlegend = T)
> subplot(p1,p2)
```

- ✓ Gráfico 2:

```
> p1 <-
+   iris %>%
+   group_by(Species) %>%
+   plot_ly(x =~Sepal.Length, color = ~Species) %>%
+   add_markers(y = ~Sepal.Width)
> p2 <-
+   iris %>%
+   group_by(Species) %>%
+   plot_ly(x=~Sepal.Length, color= ~Species) %>%
+   add_markers(y =~Sepal.Width, showlegend = F)
> subplot(p1,p2)
```

Visualização de Dados com R -- 2017



217

## Técnicas Gráficas Multivariadas



- A visualização de dados multivariados é possível se a dimensionalidade for relativamente baixa:
  - ✓ Técnicas gráficas
  - ✓ Técnicas multivariadas como ferramentas de exploração

Visualização de Dados com R -- 2017

218

## Alguns Gráficos Multivariados



- ✓ Star plot
- ✓ Segment diagram
- ✓ Chernoff faces
- ✓ Parallel coordinate plot
- ✓ Andrew's curve
- ✓ Bubble plot
- ✓ Mosaic plot

Visualização de Dados com R -- 2017

219



- Análise multivariada quantitativa
  - ✓ Análise de componentes principais
  - ✓ Biplots
  - ✓ Análise de componentes independentes
  - ✓ Análise de agrupamentos
  - ✓ Análise fatorial

Visualização de Dados com R -- 2017

220


- Análise multivariada categórica:
  - ✓ *Mosaic plots*
  - ✓ Análise de correspondência
  - ✓ Análise de correspondência múltipla

Visualização de Dados com R -- 2017



221

- ### Star Plot
- Estrelas para visualização de dados
  - Formação da estrela:
    - ✓ Raio para cada variável
    - ✓ Comprimento é proporcional à variável
  - Útil para visualização de itens com número arbitrário de variáveis



Visualização de Dados com R -- 2017

226

- Pode ser usado para responder as seguintes perguntas:
  - ✓ Quais variáveis são dominantes para uma determinada observação?
  - ✓ Quais observações são similares?  
(Existem agrupamentos de observações?)
  - ✓ Existem valores discrepantes?

Visualização de Dados com R -- 2017



227

- Exemplo: Flores de íris

✓ Você vê diamantes?

- Alguns são grandes, alguns são pequenos

✓ Dados em sequência

- Setosa, versicolor e virginica

✓ Valores iniciais pequenos

- Setosa é do Alasca!

✓ Há outliers?



Visualização de Dados com R -- 2017

## Resumo

- Antes de uma análise mais aprofundada, sempre realizar uma exploração apropriada dos dados
  - ✓ Verifique se há erros óbvios nos dados
  - ✓ Familiarize-se bastante com os dados
  - ✓ Tente identificar a distribuição dos dados
- Análise exploratória de dados não é uma ciência exata
  - ✓ É uma arte muito importante

234

Visualização de Dados com R -- 2017

## Verificação de Normalidade Multivariada

## Exemplo

- Estudo poluição do ar

✓ Amostra: 41 cidades americanas

✓ Variáveis:

- SO2: concentração no ar (mg/m<sup>3</sup>)
- Temp: temperatura
- Popul: população, em milhares (censo 1970)
- Vento: velocidade média anual (milhas/hora)
- Precip: precipitação média anual (pol)
- Dias: número médio anual de dias de chuva

✓ Dados: *USairpollution* {HSAUR2}

236

Visualização de Dados com R -- 2017

- Carregamento e preparação do conjunto de dados:

```
> library(MVA, HSAUR2) # carrega os pacotes
> data(USairpollution) # carrega o banco de dados
> help(USairpollution) # Descrição do banco de dados

> colunas<- c("SO2", "Temp", "Indust", "Pop",
+ "Vento", "Precip", "Dias")
> colnames(USairpollution)<- colunas
> dados <- USairpollution
```

Visualização de Dados com R -- 2017



237

- Medidas resumo - univariada


	SO2	Temp	Indust	Pop	Vento	Precip	Dias
Min.	8,0	43,5	35,0	71,0	6,0	7,1	36,0
1º Quartil	13,0	50,6	181,0	299,0	8,7	31,0	103,0
Mediana	26,0	54,6	347,0	515,0	9,3	38,7	115,0
Mean	30,1	55,8	463,1	608,6	9,4	36,8	113,9
3º Quartil	35,0	59,3	462,0	717,0	10,6	43,1	128,0
Max.	110,0	75,5	3344,0	3369,0	12,7	59,8	166,0
D. padrão	23,5	7,2	563,5	579,1	1,4	11,8	26,5
C. variação	78,1%	13,0%	121,7%	95,2%	15,1%	32,0%	23,3%

Visualização de Dados com R -- 2017



238

- Histogramas das variáveis



Visualização de Dados com R -- 2017

Verificação quanto a:  
 ✓ Simetria  
 ✓ Modalidade  
 ✓ Pontos atípicos




239

- Estrutura de correlação entre as variáveis

- ✓ Scatterplot matrix

– Separar os gráficos para apresentá-los mais adequadamente



Visualização de Dados com R -- 2017



240

- Matriz de correlações

```
> round(cor(dados), 4)
      SO2 Temp Indust Pop Vento Precip Dias
SO2    1.0000 -0.4336  0.6448  0.4938  0.0947  0.0543  0.3696
Temp   -0.4336  1.0000 -0.1900 -0.0627 -0.3497  0.3863 -0.4302
Indust  0.6448 -0.1900  1.0000  0.9553  0.2379 -0.0324  0.1318
Pop    0.4938 -0.0627  0.9553  1.0000  0.2126 -0.0261  0.0421
Vento   0.0947 -0.3497  0.2379  0.2126  1.0000 -0.0130  0.1641
Precip  0.0543  0.3863 -0.0324 -0.0261 -0.0130  1.0000  0.4961
Dias    0.3696 -0.4302  0.1318  0.0421  0.1641  0.4961  1.0000
```


- ✓ Forte correlação entre SO2 e Indust e Popul
  - Indust e Popul são fortemente correlacionadas
  - Provavelmente predizem SO2 da mesma maneira
- ✓ Correlação entre SO2 e Precip é muito pequena
- ✓ Correlação entre SO2 e Dias é moderada

Visualização de Dados com R -- 2017



241

- Scatterplot matrix com ajuste linear




Visualização de Dados com R -- 2017



242

✓ É provável que modelo linear entre SO2 e Precip e SO2 e dias não perceberá adequadamente a relação entre cada par de variáveis

- Variáveis Indústria e População




✓ Há pontos que se afastam do padrão dos dados

Visualização de Dados com R -- 2017



243

- Gráfico de dispersão com distribuição marginal



✓ Concentração de pontos na faixa inferior de ambas as variáveis

Visualização de Dados com R -- 2017



244

• Gráfico de dispersão com distribuição marginal

✓ Histograma e boxplot

✓Boxplot identifica alguns pontos extremos (univariado)

- Boxplot bivariado
  - ✓ Análogo ao boxplot univariado




✓Boxplot bivariado identifica pontos extremos do vetor de dados (bivariado)

✓Correlação

Todas: 0,9553

Exceto identificadas: 0,7956

✓A redução não é considerável



A scatter plot comparing population (in millions) from the 1970 Census against the number of industries with more than 20 employees. The x-axis ranges from 0 to 3000, and the y-axis ranges from 0 to 3000. Four cities are highlighted: Chicago (top right), Philadelphia (middle top), Detroit (middle left), and Cleveland (bottom left). Each city has a cluster of data points and a dashed elliptical fit. Chicago is an outlier with a very high population and a relatively low number of industries.

Cidade	Indústrias com mais de 20 empregados	População (em milhares - 1970)
Chicago	~1000	~3000
Philadelphia	~1000	~2000
Detroit	~500	~1500
Cleveland	~200	~500

A scatter plot titled 'Indústrias com mais de 20 empregados' versus 'População, em milhares (Censo - 1970)'. The x-axis ranges from 0 to 3500, and the y-axis ranges from 0 to 3500. Numerous data points are plotted, forming a positive linear trend. A convex envelope is drawn around the data points, representing a robust estimation of the correlation.

- Envelope convexo dos dados
- ✓ Análogo ao boxplot univariado
- ✓ Envelope convexo apara valores
- ✓ Estimação robusta da correlação
- ✓ Correlação  
Todas: 0,9553  
Exceto envoltória: 0,9225
- ✓ Correlação estimada após remoção é maior que a relacionado com pontos identificados pelo boxplot bivariado

- Teste de normalidade

- ✓  $H_0$ : dados se ajustam à distribuição normal
- ✓  $H_1$ : dados não se ajustam à distribuição normal

```
> teste<- sapply(colnames(dados), function(x) shapiro.test(dados[[x]])$p.value)
> as.matrix(teste)
[,1]
SO2    9.723376e-06
Temp   2.214972e-02
Indust 2.781101e-09
Pop    3.622798e-08
Vento   6.972580e-01
Precip 3.725311e-02
Dias    2.419457e-01
```


- ✓ Não se rejeita a hipótese de normalidade para as variáveis Vento e Dias

Visualização de Dados com R -- 2017



254

- Gráfico das distâncias generalizadas ( $\chi^2$ ):



- ✓ Gráfico detectou possíveis outliers nos dados multivariados
  - Desvio da variabilidade natural dos dados

Visualização de Dados com R -- 2017



255

## Comentários

- É difícil construir um bom teste global de normalidade conjunta em mais de duas dimensões
- Hipótese de normalidade aparenta estar violada
  - ✓ As marginais aparentam ser normais? E algumas combinações lineares de componentes  $X_i$ ?
  - ✓ Diagramas de dispersão de diferentes características têm aparência elíptica?
  - ✓ Há outliers que devem ser verificados?

Visualização de Dados com R -- 2017

256

- Hipótese de normalidade individual é menos crucial em situações em que o tamanho amostral é grande e as técnicas dependem da média amostral (ou de distâncias envolvendo essa média)

Visualização de Dados com R -- 2017



257

## Exemplos de Aplicação



### Conjunto de Dados – honolulu

- Doenças cardiovasculares
  - ✓ 7.683 casos coletados no Havaí em 1969
  - ✓ Fator de exposição: fumante
- Universo:
  - ✓ Homens doentes com idade entre 45 e 67 anos
  - ✓ Média de Idade da população: 54,36 anos
- Tamanho da amostra: 100
- Dados: *honolulu.txt*

270

Visualização de Dados com R -- 2017

✓ Variáveis codificadas:

- educacao : nível de instrução (1 = nenhuma, 2 = primeiro grau incompleto; 3 = primeiro grau completo; 4 = segundo grau completo; 5 = curso técnico; 6 = curso superior)
- peso, em Kg
- altura, em cm
- Idade, em anos
- fumante : status de fumante (0 = não; 1 = sim)
- atividade : atividade física em casa (1 = sedentário; 2 = moderada; 3 = alta)
- glicose: nível de glicose no sangue em mg percentuais
- colesterol: nível de colesterol sérico em miligramas percentuais
- pressao: pressão sanguínea sistólica, em mmHg



Visualização de Dados com R -- 2017

271

### Importação do conjunto de dados:

```
> dados <- read.table("honolulu.txt", head = TRUE)
> honolulu <- dados[-1]
> dim(honolulu)
[1] 100  9
> str(honolulu)
'data.frame': 100 obs. of 9 variables:
$ educacao : int 2 1 2 2 4 1 3 5 2 ...
$ peso      : int 70 60 62 66 70 59 47 66 56 62 ...
$ altura    : int 165 162 150 165 162 165 160 170 155 167 ...
$ idade     : int 61 52 52 51 53 61 48 54 48 48 ...
$ fumante   : int 1 0 1 1 0 0 0 1 0 0 ...
$ atividade : int 1 2 1 1 1 2 1 1 2 1 ...
$ glicose   : int 107 145 237 91 185 106 177 120 116 105 ...
$ colesterol: int 199 267 272 166 239 189 238 223 279 190 ...
$ pressao   : int 102 138 190 122 128 112 128 116 134 104 ...
> head(honolulu)
  educacao peso altura idade fumante atividade glicose colesterol pressao
1       2     70    165    61      1       1    107      199     102
2       1     60    162    52      0       2    145      267     138
3       1     62    150    52      1       1    237      272     190
4       2     66    165    51      1       1     91      166     122
5       2     70    162    51      0       1    185      239     128
6       4     59    165    53      0       2    106      189     112
```

272

Visualização de Dados com R -- 2017

- Preparação do conjunto de dados:

```
> # Transformação variáveis em fatores
> nomes.col <- c("educacao", "fumante", "atividade")
> honolulu[nomes.col] <- lapply(honolulu[nomes.col], factor)
>
> # Renomeação níveis dos fatores - educacao
> edu.niveis <- c("N", "1I", "1C", "2C", "T", "S")
> levels(honolulu$educacao) <- edu.niveis
> # Renomeação níveis dos fatores - atividade
> ativ.niveis <- c("sedentaria", "moderada", "alta")
> levels(honolulu$atividade) <- ativ.niveis
> # Renomeacao níveis e reordenação níveis - fumante
> fuma.niveis <- c("N", "S")
> levels(honolulu$fumante) <- fuma.niveis
> # transformacao em fator ordenado
> honolulu$educacao <- ordered(honolulu$educacao)
> honolulu$atividade <- ordered(honolulu$atividade)
> head(honolulu)
  educacao peso altura idade fumante atividade glicose colesterol pressao
1      N    70     165   61      S sedentaria 107     199    102
2      N    60     162   52      N moderada 145     267    138
3      N    62     150   52      S sedentaria 237     272    190
4      1I   66     165   51      S sedentaria  91     166    122
5      1I   70     162   51      N sedentaria 185     239    128
6      2C   59     165   53      N moderada 106     189    112
```


Visualização de Dados com R -- 2017



273

- Boxplot: glicose vs. atividade:

```
> # Default
> boxplot(glicose ~ atividade, data = honolulu)
```



Visualização de Dados com R -- 2017




274

- ✓ Há diferença no nível médio de glicose entre os grupos
- ✓ Há diferença das variabilidades dos grupos?
- ✓ Há outliers?

- Boxplot: colesterol vs. fumo:

```
> # Default
> boxplot(colesterol ~ fumante, data = honolulu)
> # Boxplot com caixas coloridas (inversão ordem fatores)
> fator <- relevel(honolulu$fumante, "S")
> boxplot(colesterol ~ fator, data = honolulu, col = c("red", "green"))
```




Visualização de Dados com R -- 2017

275



- Boxplot: colesterol vs. educacao:

```
> # Boxplot com caixas coloridas - qualquer qte. categorias
> library(RColorBrewer)
> QteNiveis <- length(levels(honolulu$educacao))
> cores <- brewer.pal(n = QteNiveis, name = "Set1")
> boxplot(colesterol ~ educacao, data = honolulu, col = cores)
> # Boxplot com caixas proporcionais
> PropNiveis <- prop.table(table(honolulu$educacao))
> boxplot(colesterol ~ educacao, data = honolulu, width = PropNiveis, col = cores)
```



Visualização de Dados com R -- 2017



276

- Boxplot: pressao vs. fumante:
  - ✓ Boxplot customizado

```
> # Boxplot customizado - pontos e caixas proporcionais
> PropNiveis <- prop.table(table(honolulu$fumante))
> boxplot(pressao ~ fumante, data = honolulu, col = c("red", "green"),
+ width = PropNiveis, outpch = NA)
> # Acrescenta pontos
> niveis <- levels(honolulu$fumante)
> for(i in 1:length(niveis))
+ {
+     este.nivel <- niveis[i]
+     valores <- honolulu[honolulu$fumante == este.nivel, "pressao"]
+     # Adiciona perturbação, proporcional à N em cada nível (eixo X)
+     perturbacao <- jitter(rep(i, length(valores)), amount = PropNiveis[i]/2)
+     points(perturbacao, valores, pch = 20, col = rgb(0, 0, 0, 0.2))
+     # Adiciona texto do tamanho dos grupos
+     tipica <- min(max(valores), median(valores)) + IQR(valores)*1.5
+     text(i + PropNiveis[i]/2, tipica, cex = 0.6, font = 2, pos = 4,
+     labels = paste("N = ", length(valores), sep=""))
+ }
```


Visualização de Dados com R -- 2017



277

- Boxplot customizado:

- ✓ Pontos, caixas proporcionais ao tamanho dos grupos, cores




278

Visualização de Dados com R -- 2017

- Scatter plot – Doença cardiovascular:

```
> # Box-plots
> variaveis <- names(iris[-5])
> par(mfrow = c(2, 2))
> for(i in 1: length(variaveis)) {
+ with(iris, {
+     dados <- eval(parse(text = variaveis[i]))
+     boxplot(dados ~ Species, data = iris, main = variaveis[i], cex.axis = 0.85)
+   })
```



- ✓ Qual a relação entre o peso e a altura das pessoas?
- ✓ Percebem-se ‘clusters’?
- ✓ Há diferenças na variabilidade de uma variável, considerados os valores da outra?
- ✓ Há valores atípicos?


Visualização de Dados com R -- 2017



279

- Relação entre as variáveis:

- ✓ Reta de regressão e suavização



281

Visualização de Dados com R -- 2017

## Conjunto de Dados – diamonds

- Preços e outros atributos de diamantes
  - ✓ Conjunto de dados com informações (preços e outros 9 atributos) sobre 53.940 diamantes
  - ✓ Fonte não informada
- Dados: diamonds {ggplot2}

Visualização de Dados com R -- 2017

282



## ✓ Variáveis codificadas:


- price: preço, em US\$ (\$326 a \$18.823)
- carat: peso do diamante, em quilates (0,2 a 5,01)
- cut: qualidade do corte (Fair, Good, Very Good, Premium, Ideal)
- colour: cor do diamante (de J = pior para D = melhor)
- clarity: medida de quanto claro o diamante é (I1 = pior, SI1, SI2, VS1, VS2, VVS1, VVS2, IF = melhor)
- x: comprimento, em mm (0 a 10,74)
- y: largura, em mm (0 a 58,9)
- z: espessura, em mm (0 a 31,8)
- depth: espessura total percentual (43 a 79)  $\frac{z}{\sqrt{x+y}} = \frac{2z}{x+y}$
- table: largura do topo do diamante em relação ao ponto mais largo (43 a 95)

Visualização de Dados com R -- 2017

283



- Desenho esquemático diamante



Visualização de Dados com R -- 2017

284



## • Importação do conjunto de dados:

```
> library(ggplot2)
> dim(diamonds)
[1] 53940   10
> str(diamonds)
Classes 'tbl_df', 'tbl' and 'data.frame':      53940 obs. of  10 variables:
 $ carat : num  0.23 0.21 0.23 0.29 0.31 0.24 0.24 0.26 0.22 0.23 ...
 $ cut   : Ord.factor w/ 5 levels "Fair"  
"Good"  
"Very Good"  
"Premium"  
"Ideal" 
 $ color  : Ord.factor w/ 7 levels "D"  
"E"  
"F"  
"G"  
"H"  
"I"  
"J" 
 $ clarity: Ord.factor w/ 8 levels "I1"  
"SI2"  
"SI1"  
"VS1"  
"VS2"  
"VVS1"  
"VVS2"  
"IF" 
 $ depth  : num  61.5 59.8 56.9 62.4 63.3 62.8 62.3 61.9 65.1 59.4 ...
 $ table  : num  55 61 65 58 58 57 57 55 61 61 ...
 $ price  : int  326 326 327 332 335 335 336 337 337 338 ...
 $ x     : num  3.95 3.89 4.05 4.2 4.34 3.94 3.95 4.07 3.87 4 ...
 $ y     : num  3.98 3.84 4.07 4.23 4.35 3.96 3.98 4.11 3.78 4.05 ...
 $ z     : num  2.43 2.31 2.31 2.63 2.75 2.48 2.47 2.53 2.49 2.39 ...

> head(diamonds)
# A tibble: 6 x 10
  carat    cut color clarity depth table price     x     y     z
  <dbl> <ord> <ord> <ord> <dbl> <dbl> <dbl> <dbl> <dbl>
1 0.23   Ideal   E    SI2    61.5   55   326   3.95   3.98   2.43
2 0.21   Premium E    SI1    59.8   61   326   3.89   3.84   2.31
3 0.23   Good    E    VS1    56.9   65   327   4.05   4.07   2.31
4 0.29   Premium I    VS2    62.4   58   334   4.20   4.23   2.63
5 0.31   Good    J    SI2    63.3   58   335   4.34   4.35   2.75
6 0.24   Very Good J    VVS2   62.8   57   336   3.94   3.96   2.48
> head(diamonds)
```

Visualização de Dados com R -- 2017

285



• Gráfico de barras – clarity versus cut

```
> # Diagrama de barras de 'clareza' categorizado com 'corte'
> ggplot(diamonds, aes(clarity, fill = cut)) + geom_bar()
+ xlab("Clareza") +
+ ggtitle("Conjunto de Dados diamonds") +
+ scale_color_discrete(name = "Corte") +
+ theme(legend.position = c(1, 1), legend.justification = c(1, 1))

Conjunto de Dados diamonds
```

✓ Qual a relação entre as duas variáveis?  
 ✓ Frequências de cut mudam nos níveis de clarity?

286

• Scatter plot – price versus carat

```
> # Peso vs. Preço
> p <- ggplot(data = diamonds, aes(x = carat, y = price)) +
+ geom_point() +
+ xlab("Peso (quilates)") +
+ ylab("Preço (US$)") +
+ ggtitle("Conjunto de Dados diamonds")
> p
```

✓ Gráfico aponta forte relação entre as variáveis  
 – Há outliers importantes  
 – Estrias verticais interessante  
 ✓ Relação aparente ser exponencial  
 – Interessante transformar os dados

287

• Scatter plot – log price versus carat

```
> # Transformação dos dados
> ggplot(data = diamonds, aes(x = log(carat), y = log(price))) +
+ geom_point() +
+ xlab("log(Peso)") +
+ ylab("log(Preço)") +
+ ggtitle("Conjunto de Dados diamonds - Transformado")

Conjunto de Dados diamonds - Transformado
```

✓ Relação agora parece ser linear  
 – Necessária cautela devido a overplotting

288





• Relação entre volume e peso





```
> # Relação entre volume (x*y*z) e peso do diamante
> ggplot(data = diamonds, aes(x = carat, y = x * y * z)) +
+ geom_point() +
+ xlab("Peso (quilates)") +
+ ylab("Volume") +
+ ggtitle("Conjunto de Dados diamonds")

Conjunto de Dados diamonds
```

✓ Espera-se que densidade seja constante  
 – Relação linear entre volume e peso  
 – Maioria dos pontos parece situar-se em uma linha  
 – Há outliers grandes

289





### • Comparação preço unitário por cor

```
> # Comparação preço unitário para níveis de color
> # gráfico de pontos
> bpl <- ggplot(data = diamonds, aes(x = color, y = price/carat)) +
+ geom_point(position = position_jitter(width = 0.4))
> # box-plot
> bp2 <- ggplot(data = diamonds, aes(x = color, y = price/carat)) +
+ geom_boxplot()
> # painel
> grid.arrange(bpl, bp2, nrow=1)
```

✓ À medida em que a cor melhora (da esquerda para a direita):

- Diminui a dispersão dos valores
- Há pouca alteração no centro da distribuição

Visualização de Dados com R -- 2017

298

### • Comparação preço unitário por cor

```
> # Comparação preço unitário para níveis de color - redução overplotting
> bp1 <- ggplot(data = diamonds, aes(x = color, y = price/carat)) +
+ geom_point(position=position_jitter(width=0.4), alpha = I(1/5))+ 
+ ggtitle("I(1/5)")
> bp2 <- ggplot(data = diamonds, aes(x = color, y = price/carat)) +
+ geom_point(position=position_jitter(width=0.4), alpha = I(1/50))+ 
+ ggtitle("I(1/50)")
> bp3 <- ggplot(data = diamonds, aes(x = color, y = price/carat)) +
+ geom_point(position=position_jitter(width=0.4), alpha = I(1/100))+ 
+ ggtitle("I(1/100)")
> grid.arrange(bp1, bp2, bp3, nrow=1)
```

✓ À medida em que a opacidade diminui começamos visualiza-se onde se situa a maior parte dos dados

- Boxplot efetua melhor esta tarefa

Visualização de Dados com R -- 2017

299

### • Distribuição do peso

```
> # Distribuição do Peso
> hsl <- ggplot(data = diamonds, aes(x = carat)) +
+ geom_histogram(aes(y = ..density..)) +
+ xlab("Peso (quilates)") +
+ ylab("Densidade")
> hs2 <- ggplot(data = diamonds, aes(x = carat)) +
+ geom_density() +
+ xlab("Peso (quilates)") +
+ ylab("Densidade")
> grid.arrange(hsl, hs2, nrow=1)
```

✓ Aparentemente à grupos de preços

- Diferentes distribuições de preços

Visualização de Dados com R -- 2017

300

### • Distribuição do peso – suavização

```
> hs3 <- ggplot(data = diamonds, aes(x = carat)) +
+ geom_histogram(aes(y = ..density..)) +
+ geom_density() +
+ xlab("Peso (quilates)") +
+ ylab("Densidade")
> hs3
```

✓ Aparência de multimodalidade dos dados

✓ Importante tentar vários graus de suavização

- No histograma: binwidth controla a quantidade de suavização

Visualização de Dados com R -- 2017

301

• Distribuição do peso  
✓ Pesquisa da quantidade de suavização

```
> # Distribuição do peso - pesquisa da qte de suavização
>
> hs1 <- ggplot(data = diamonds, aes(x = carat)) +
+ geom_histogram(aes(y = ..density..), binwidth = 1.0) +
+ xlab("Peso (quilates)") +
+ ylab("Densidade") +
+ ggtitle("binwidth = 1.0")
> hs2 <- ggplot(data = diamonds, aes(x = carat)) +
+ geom_histogram(aes(y = ..density..), binwidth = 0.1) +
+ xlab("Peso (quilates)") +
+ ylab("Densidade") +
+ ggtitle("binwidth = 0.1")
> hs3 <- ggplot(data = diamonds, aes(x = carat)) +
+ geom_histogram(aes(y = ..density..), binwidth = 0.01) +
+ xlab("Peso (quilates)") +
+ ylab("Densidade") +
+ ggtitle("binwidth = 0.01")
> grid.arrange(hs1, hs2, hs3, nrow=1)
```

302

Visualização de Dados com R -- 2017

• Estimativa de densidade do preço

✓ Gráfico com menor intervalo de classe apresenta as estrias percebidas  
– No scatterplot a maioria ocorre em números “bonitos”

303

Visualização de Dados com R -- 2017

• Distribuição do peso – suavização

```
> hs3 <- ggplot(data = diamonds, aes(x = carat)) +
+ geom_histogram(aes(y = ..density..)) +
+ geom_density() +
+ xlab("Peso (quilates)") +
+ ylab("Densidade")
> hs3
```

✓ Aparência de multimodalidade dos dados  
✓ Importante tentar vários graus de suavização  
– No histograma: binwidth controla a quantidade de suavização

304

Visualização de Dados com R -- 2017

• Densidades do peso por nível de cor

```
> # Comparação distribuição de peso entre níveis de cor
> ggplot(data = diamonds, aes(x = carat, fill = color)) +
+ geom_density(alpha = 0.3) +
+ xlab("Peso (quilates)") +
+ ylab("Densidade") +
+ ggtitle("Conjunto de Dados diamonds") +
+ scale_fill_discrete(name = "Cor") +
+ theme(legend.position = c(1, 0.5))
```

✓ As densidades parecem fáceis de ser lida na comparação as diferentes curvas.  
✓ Importante tentar vários graus de suavização  
✓ Supõem hipóteses que podem não ser verdade para os dados:  
– Densidade contínua, suave e ilimitada

305

Visualização de Dados com R -- 2017

• Histogramas do peso por nível de cor

```
> # Comparação histogramas de peso entre níveis de cor
> ggplot(data = diamonds, aes(x = carat, fill = color)) +
+ geom_histogram(aes(y = ..density..), alpha = 0.3) +
+ xlab("Peso (quilates)") +
+ ylab("Densidade") +
+ ggtitle("Conjunto de Dados diamonds") +
+ scale_fill_discrete(name = "Cor") +
+ theme(legend.position = c(1, 0.5), legend.justification = c(1, 0.5))
```

✓ Interpretação do gráfico é mais difícil

Visualização de Dados com R -- 2017

306

• Densidades de preço por nível de corte

```
> # Comparação distribuição de preço entre níveis de corte
> ggplot(data = diamonds, aes(x = price, fill = cut)) +
+ geom_density(alpha = 0.3) +
+ xlab("Preço (US$)") +
+ ylab("Densidade") +
+ ggtitle("Conjunto de Dados diamonds") +
+ scale_fill_discrete(name = "Corte") +
+ theme(legend.position = c(1, 0.5), legend.justification = c(1, 0.5))
```

✓ Distribuições diferentes por nível de corte  
– Forte assimetria

Visualização de Dados com R -- 2017

307

• Distribuição da variável color:

```
> # Distribuição variável color
> ggplot(data = diamonds, aes(x = color)) +
+ geom_bar() +
+ xlab("Cor do diamante") +
+ ylab("Quantidade")
> ggplot(data = diamonds, aes(x = color)) +
+ geom_bar(aes(weight = carat)) +
+ xlab("Cor do diamante") +
+ ylab("Total de peso (quilates)")
```

✓ Cor dos diamantes ponderado por carat  
– Peso total dos diamantes por nível de cor

Visualização de Dados com R -- 2017

308

• Histogramas de peso por cor:

```
> # Histogramas de Peso condicionado a cor
> ggplot(data = diamonds, aes(x = carat)) +
+ geom_histogram(aes(y = ..density..), binwidth = 0.1) +
+ xlim(0, 3) +
+ facet_grid(color ~ .) +
+ xlab("Peso (quilates)") +
+ ylab("Densidade")
```

✓ Assimetria em direção aos menores valores para diamantes de alta qualidade (cor D)  
– Distribuição torna-se mais plana à medida em que a qualidade diminui

Visualização de Dados com R -- 2017

309

• Histogramas de peso por cor:

```
> # Density plot de Peso condicionado a cor
> ggplot(data = diamonds, aes(x = carat)) +
+ geom_density() +
+ xlim(0, 3) +
+ facet_grid(color ~ .) +
+ xlab("Peso (quilates)") +
+ ylab("Densidade")
```

Densidade

Peso (quilates)

Visualização de Dados com R -- 2017

310

- ✓ Distribuições dos diamantes são mais fáceis de serem comparadas
  - Ignora a quantidade de diamantes em cada nível de cor

• Scatter plot matrix:

✓ Carat, cut, color, clarity, depth

```
> library(GGally)
> ggpairs(diamonds[1:5], upper = list(continuous = "density", combo = "box"),
+ lower = list(continuous = "points", combo = "dot"),
+ mapping = ggplot2::aes(colour = cut, alpha = 0.4),
+ title = "Conjunto de Dados - diamonds"
+ )
```

carat

cut

color

clarity

depth

Visualização de Dados com R -- 2017

311

- ✓ Visualização de pares de variáveis
  - Métricas ou não métricas

• Relação entre preço e peso:

✓ Gráficos com suavização por corte

```
> library(dplyr)
>
> diamonds %>%
+ ggplot(aes(x = carat, y = price)) +
+ geom_point(alpha = 0.5) +
+ facet_grid(~ cut) +
+ stat_smooth(method = lm, formula = y ~ poly(x, 2)) +
+ xlab("Peso (quilates)") +
+ ylab("Preço (US$)") +
+ theme_bw()
```

Preço (US\$)

Peso (quilates)

Fair

Good

Very Good

Premium

Ideal

Visualização de Dados com R -- 2017

312

- ✓ Operador %>% passa a saída do operador da esquerda como o primeiro argumento para o operador da direita

• Relação entre preço e peso:

✓ Gráficos com suavização por corte

Preço (US\$)

Peso (quilates)

Fair

Good

Very Good

Premium

Ideal

Visualização de Dados com R -- 2017

313

- ✓ Preço aumenta com tamanho do diamante
- ✓ Relacionamento é não-linear
- ✓ Há alguns outliers
- ✓ Relacionamento com corte não é forte

- Scatter plot matrix:

```
diamonds %>%
  mutate(volume = x*y*z) %>%
  select(cut, carat, price, volume) %>%
  sample_frac(0.5, replace = TRUE) %>%
  ggpairs(axisLabels = "none") +
  theme_bw()
```

✓ Gráfico informativo:

- Podemos aprender muito sobre a estrutura de covariância dos dados
- Scatterplots (contínua vs. contínua) ou histogramas por grupos (contínua vs. categórica)
- Diagonal: estimativas densidades (dados contínuos), histogramas (categóricos)
- upper: correlação (dados contínuos) ou boxplots por grupos (contínuos vs. categóricos)

314  
Visualização de Dados com R -- 2017

- Scatter plot matrix:

✓ Facilita visualização dos dados

315  
Visualização de Dados com R -- 2017

## Referências

## Bibliografia Recomendada

- DALGAARD, P. *Introductory statistics with R*. Springer, 2002.
- MURRELL, P. *R graphics*. Chapman & Hall, 2006.
- EVERITT, B.; HOTHORN, T. *An Introduction to Applied Multivariate Analysis with R*. Springer, 2011.
- ZELTERMAN, D. *Applied Multivariate Statistics with R*. Springer, 2015.

324  
Visualização de Dados com R -- 2017