
Análise Descritiva

Fabrício Jailson Barth

Abril de 2014

Acesso aos dados

```
require(UsingR)
```

```
data(survey)
```

```
head(survey)
```

```
data(iris)
```

```
head(iris)
```

Caracterização dos dados

No R, é possível testar se um atributo é **qualitativo** (factor) ou **quantitativo** (numeric).

```
is.numeric(survey$Pulse)
```

```
is.factor(survey$Sex)
```

```
is.numeric(survey$Smoke)
```

```
is.factor(survey$Height)
```

```
is.numeric(iris$sepal.length)
```

```
is.factor(iris$class)
```

```
help(survey)
```

Caracterização dos dados

- A escala define as operações que podem ser realizadas sobre os valores do atributo.
- Em relação à escala, os atributos podem ser classificados como **nominais**, **ordinais**, **discreto** e **contínuo**.
- Os dois primeiros são do tipo qualitativo e os dois últimos são quantitativos.

-
- Na escala **nominal**, os valores são apenas **nomes diferentes**, carregando a menor quantidade de informação possível. Não existe uma relação de ordem entre seus valores.
 - Os valores em uma escala **ordinal** refletem também uma ordem das categorias representadas. Dessa forma, além dos operadores de igualdade e desigualdade, operadores como $<$, $>$, \geq , \leq podem ser utilizados.

-
- Baseado na descrição anterior, os atributos dos datasets iris e jogar podem ser classificados como indicado nas tabelas abaixo:

```
survey$Pulse = quantitativo
```

```
survey$Sex = nominal (qualitativo)
```

```
survey$Smoke = ordinal (qualitativo)
```

```
survey$Height = quantitativo
```

```
iris$sepal.length = racional (quantitativo contínuo)
```

```
iris$sepal.width = racional (quantitativo contínuo)
```

```
iris$petal.length = racional (quantitativo contínuo)
```

```
iris$petal.width = racional (quantitativo contínuo)
```

```
iris$class = nominal (qualitativo)
```

Exploração de dados

Uma das formas mais simples de explorar um conjunto de dados é a extração de medidas de uma área da estatística denominada estatística descritiva. A estatística descritiva resume de forma quantitativa as principais características de um conjunto de dados. Tais características podem ser:

-
- Frequência;
 - Localização ou tendência central (por exemplo, a média);
 - Dispersão ou espalhamento (por exemplo, o desvio padrão);
 - Distribuição ou formato.

No R é trivial identificar a média e mediana de um dado conjunto de valores para um atributo qualquer, como apresentado abaixo:

```
mean(survey$Pulse)
```

```
median(survey$Pulse)
```

Ou sumarizar todos estes valores através de um único comando:

```
summary(survey$Pulse)
```

Além das informações textuais obtidas por

```
summary(iris$sepalwidth)
```

É possível obter um resumo visual da centralidade dos dados através do gráfico *boxplot*. No R é simples gerar este tipo de gráfico.


```
par(mfrow=c(1,2))
```

```
boxplot(iris$Sepal.Width,  
        outline= FALSE, main="Boxplot",  
        xlab="Sepal Width")
```

```
boxplot(iris$Sepal.Width,  
        main="Boxplot modificado",  
        xlab="Sepal Width")
```


Boxplot

Boxplot



Sepal Width

Boxplot modificado



Sepal Width

Boxplot modificado

O segundo gráfico ilustra uma variação do gráfico *boxplot*, conhecida como *boxplot* modificado. Neste gráfico, os valores acima do limite superior e abaixo do limite inferior são considerados *outliers*. Neste gráfico, 4 valores *outliers* são representados por círculos, 3 maiores que o 3o quartil + $1,5 \times (3\text{o quartil} - 1\text{o quartil})$ e 1 menor que $1\text{o quartil} - 1,5 \times (3\text{o quartil} - 1\text{o quartil})$.

Espalhamento de valores

As medidas mais utilizadas para avaliar o **espalhamento** de valores é a **variância** e o **desvio padrão**. Sendo que o desvio padrão é dado pela raiz quadrada da variância.

Desvio padrão:

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (1)$$


Variância:

$$s = \frac{1}{n - 1} \sum_{i=1}^n (x_i - \bar{x})^2 \quad (2)$$

`var(iris$sepal.length)`


Plot

```
plot(iris$Petal.Length, iris$Petal.Width, pch=19)
```





Plot

```
plot(iris$Petal.Length, iris$Petal.Width, pch=21,  
     bg=c("red","green","yellow")[as.numeric(iris$Species)])  
legend(locator(1), levels(iris$Species),  
       fill=c("red","green","yellow"))
```




Comparando valores

```
par(mfrow=c(1,2))  
plot(jitter(as.numeric(iris$Species)), iris$Petal.Length, pch=19, xlab="Species")  
plot(iris$Petal.Length ~ iris$Species)
```




Histograma

```
> hist(iris$Petal.Length)
> summary(iris$Petal.Length)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
 1.000  1.600  4.350  3.758  5.100  6.900
> var(iris$Petal.Length)
[1] 3.116278
```




Histograma

```
> hist(iris$Sepal.Width)
> summary(iris$Sepal.Width)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
 2.000  2.800  3.000  3.057  3.300  4.400
> var(iris$Sepal.Width)
[1] 0.1899794
```



Scatter Plot

```
plot(iris[,1:4], pch=21,  
     bg=c("red","green","yellow")[as.numeric(iris$Species)])
```




Correlação

- Dados multivariados permitem análises da relação entre dois ou mais atributos. Por exemplo, para atributos quantitativos, pode-se utilizar uma medida de correlação para identificar a relação linear entre dois atributos.

```
> cor(iris[,1:4])
              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
```

Resumindo a relação entre dados numéricos

```
library(psych)  
pairs.panels(iris[,1:4])
```



Material de **consulta**

- Faceli, Lorena, Gama, Carvalho. Inteligência Artificial: uma abordagem de aprendizado de máquina, 2011. Capítulo 2: Análise de Dados.
- Cursos: *Computing for Data Analysis* e *Data Analysis* da www.coursera.org