

Verificação da suposição de normalidade

(linguagem R)

2026

Em uma amostra aleatória com observações $\mathbf{x}_1, \dots, \mathbf{x}_n$, o vetor de médias e a matriz de covariâncias amostral são denotados por $\bar{\mathbf{x}}$ e $\mathbf{S}$, respectivamente, sendo que $\bar{x}_j = \sum_{i=1}^n x_{ij}/n$, $j = 1, \dots, p$ e $\mathbf{S} = \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^\top / (n-1)$.

Se $\mathbf{X}_1, \dots, \mathbf{X}_n$ é uma amostra aleatória da distribuição $N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, então $D_1^2, \dots, D_n^2$ são variáveis aleatórias independentes com distribuição χ_p^2 , em que

$$D_i^2 = (\mathbf{X}_i - \boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1} (\mathbf{X}_i - \boldsymbol{\mu}), \quad i = 1, \dots, n \quad (1)$$

é o quadrado da distância estatística ou distância de Mahalanobis entre $\mathbf{X}_i$ e $\boldsymbol{\mu}$.

Com os dados da amostra calculamos

$$d_i^2 = (\mathbf{x}_i - \bar{\mathbf{x}})^\top \mathbf{S}^{-1} (\mathbf{x}_i - \bar{\mathbf{x}}), \quad i = 1, \dots, n, \quad (2)$$

que são ordenados resultando em

$$d_{(1)}^2 \leq d_{(2)}^2 \leq \dots \leq d_{(n)}^2. \quad (3)$$

Os valores em (3) são comparados aos respectivos quantis da distribuição χ_p^2 como forma de avaliar a suposição de normalidade. Em linguagem R é utilizada a aproximação

$$E(D_{(i)}^2) \simeq \begin{cases} \text{quantil } \frac{i-3/8}{n+1/4} \text{ de } \chi_p^2, & \text{se } n \leq 10, \\ \text{quantil } \frac{i-1/2}{n} \text{ de } \chi_p^2, & \text{se } n > 10, \quad i = 1, \dots, n. \end{cases} \quad (4)$$

As probabilidades em (4) são obtidas com a função `ppoints` e os quantis são calculados com a função `qchisq`. O padrão de referência no gráfico de dispersão dos n pares de pontos em (3) e (4) é a reta identidade.

Em seguida efetuamos o cálculo em (2) de forma matricial. Iniciamos com a decomposição de Choleski de $\mathbf{S}$ dada por $\mathbf{S} = \mathbf{C}^\top \mathbf{C}$, em que $\mathbf{C}$ é uma matriz triangular superior chamada de “raiz quadrada” de $\mathbf{S}$. Desta forma $\mathbf{S}^{-1} = \mathbf{C}^{-1} \mathbf{C}^{-\top}$ e

$$\begin{aligned} d_i^2 &= (\mathbf{x}_i - \bar{\mathbf{x}})^\top \mathbf{C}^{-1} \mathbf{C}^{-\top} (\mathbf{x}_i - \bar{\mathbf{x}}) \\ &= \{\mathbf{C}^{-\top} (\mathbf{x}_i - \bar{\mathbf{x}})\}^\top \mathbf{C}^{-\top} (\mathbf{x}_i - \bar{\mathbf{x}}), \quad i = 1, \dots, n. \end{aligned} \quad (5)$$

Os vetores p -dimensionais $\mathbf{C}^{-\top} (\mathbf{x}_i - \bar{\mathbf{x}})$ em (5), $i = 1, \dots, n$, são organizados na matriz $\mathbf{B}$ $p \times n$. Finalmente, notamos que d_i^2 em (5) corresponde à soma dos quadrados dos elementos na i -ésima coluna de $\mathbf{B}$.

```
## Conjunto de dados USArrests
? USArrests
```

```
USArrests {datasets}      R Documentation
Violent Crime Rates by US State
```

Description

This data set contains statistics, in arrests per 100,000 residents for assault, murder,

and rape in each of the 50 US states in 1973. Also given is the percent of the population living in urban areas.

Format

A data frame with 50 observations on 4 variables.

```
[,1] Murder numeric Murder arrests (per 100,000)
[,2] Assault numeric Assault arrests (per 100,000)
[,3] UrbanPop numeric Percent urban population
[,4] Rape numeric Rape arrests (per 100,000)
```

Source

World Almanac and Book of facts 1975. (Crime rates).

Statistical Abstracts of the United States 1975, p.20, (Urban rates), possibly available as <https://books.google.ch/books?id=z19qAAAAAAAJ&pg=PA20>.

References


McNeil, D. R. (1977) Interactive Data Analysis. New York: Wiley.

```
names(USArrests)
```

```
## [1] "Murder" "Assault" "UrbanPop" "Rape"
```

```
dados <- USArrests
```

```
pairs(dados, pch = 20, col = "blue", lower.panel = NULL)
```



```
n <- nrow(dados)
p <- ncol(dados)
cat("\n n =", n, ", p =", p, "\n")
```


```
##
##  n = 50 , p = 4
## Posições de plotagem
pplot <- ppoints(n)

## Quantis teóricos
xq2 <- qchisq(pplot, df = p)

## Estimadores
Xb <- colMeans(dados) # média
S <- cov(dados)       # matriz de covariâncias

## Quadrado da distância estatística
difmedia <- t(t(dados) - Xb) # X - Xbarra
C <- chol(S) # "raiz quadrada" de S
B <- t(solve(C)) %*% t(difmedia)
d2 <- sort(colSums(B^2))


# Gráfico
faixa <- range(d2, xq2)
par(mai = c(1.0, 1.0, 0.1, 0.1)) # Margens (em pol)
plot(xq2, d2, xlab = expression(paste("Quantis da distribuição ", chi[p]^2)),
     xlim = faixa, ylim = faixa, ylab = expression(d^2), pch = 20,
     cex.lab = 1.5, cex.axis = 1.5)
abline(0, 1, lty = 2, lwd = 2, col = "red")
```



Os pontos no gráfico de quantis (gráfico QQ) acima estão próximos à reta identidade, com apenas dois mais afastados. Há indicação de boa aproximação pela distribuição normal.


Representando no eixo vertical as diferenças entre os quantis em (4) e $d_{(i)}^2$, $i = 1, \dots, n$, obtemos um gráfico em que a referência é a reta horizontal correspondente à diferença nula.

```
par(mai = c(1.0, 1.1, 0.1, 0.1)) # Margens (em pol)
plot(xq2, xq2 - d2, xlab = expression(paste("Quantis da distribuição ", chi[p]^2)),
     ylab = expression(paste("Quantis da distribuição ", chi[p]^2) - d^2), pch = 20,
     cex.lab = 1.5, cex.axis = 1.5)
abline(h = 0, lty = 2, lwd = 2, col = "red")
```



Em seguida comparamos a função distribuição empírica de d_i^2 , $i = 1, \dots, n$, com a função distribuição de uma variável aleatória χ_p^2 (com $p = 4$).

```
plot(ecdf(d2), main = "", xlab = expression(d^2), pch = 20,
     ylab = "Distribuição acumulada", cex.lab = 1.5, cex.axis = 1.5)
curve(pchisq(x, df = p), add = TRUE, col = "red", lwd = 2)
```



De forma aproximada, a hipótese de normalidade pode ser testada com o teste de Kolmogorov-Smirnov.

```
ks.test(d2, "pchisq", df = p)
```

```
##
## Exact one-sample Kolmogorov-Smirnov test
##
## data: d2
## D = 0.08139, p-value = 0.8682
## alternative hypothesis: two-sided
```

Observação. Testes de normalidade mais formais podem ser encontrados no pacote **MVN** (vide <https://cran.r-project.org/web/packages/MVN/MVN.pdf>).