

1. Dados pareados

```
## Dados sobre escolha de marcas de café em duas compras
## Tabela 9.5, p. 236 em Agresti (1996), Introduction to Categorical
## Data Analysis

tab95 <- matrix(c(93, 17, 44, 7, 10,
                  9, 46, 11, 0, 9,
                  17, 11, 155, 9, 12,
                  6, 4, 9, 15, 2,
                  10, 4, 12, 2, 27), ncol = 5, byrow = TRUE)
rownames(tab95) <- colnames(tab95) <- c("High Point", "Taster's",
                                           "Sanka", "Nescafe", "Brim")

addmargins(tab95)

      High Point Taster's Sanka Nescafe Brim Sum
High Point      93        17     44       7    10 171
Taster's        9         46     11       0     9  75
Sanka          17        11    155       9   12 204
Nescafe         6         4      9      15     2  36
Brim           10        4     12       2    27  55
Sum            135       82    231      33    60 541

n <- sum(tab95)
cat("\n n =", n, "\n")

n = 541

## Proporções amostrais (%)
print(100 * tab95 / n, digits = 2)

      High Point Taster's Sanka Nescafe Brim
High Point      17.2     3.14   8.1    1.29 1.85
Taster's        1.7     8.50   2.0    0.00 1.66
Sanka          3.1     2.03  28.7   1.66 2.22
Nescafe         1.1     0.74   1.7    2.77 0.37
Brim           1.8     0.74   2.2    0.37 4.99

Nota 1. Comente sobre a simetria da distribuição conjunta.

## Distribuições marginais
compral <- margin.table(tab95, margin = 1) / n
compra2 <- margin.table(tab95, margin = 2) / n

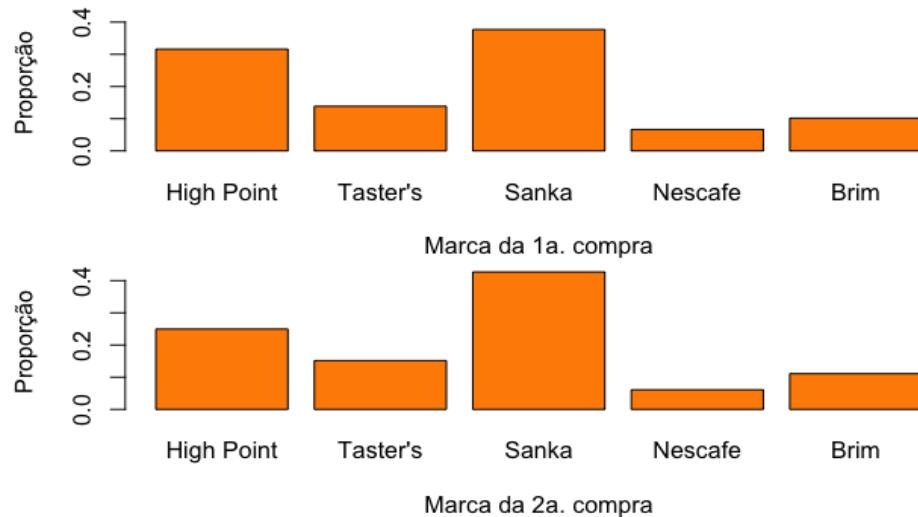
round(rbind(compral, compra2), digits = 2)

      High Point Taster's Sanka Nescafe Brim
compral      0.32    0.14   0.38    0.07 0.10
compra2      0.25    0.15   0.43    0.06 0.11
```

```

r12 <- c(0, max(compral, compra2)) # Intervalo (eixo vertical)
par(mfrow = c(2, 1))
barplot(compral, xlab = "Marca da 1a. compra", ylab = "Proporção",
        ylim = r12)
barplot(compra2, xlab = "Marca da 2a. compra", ylab = "Proporção",
        ylim = r12)

```



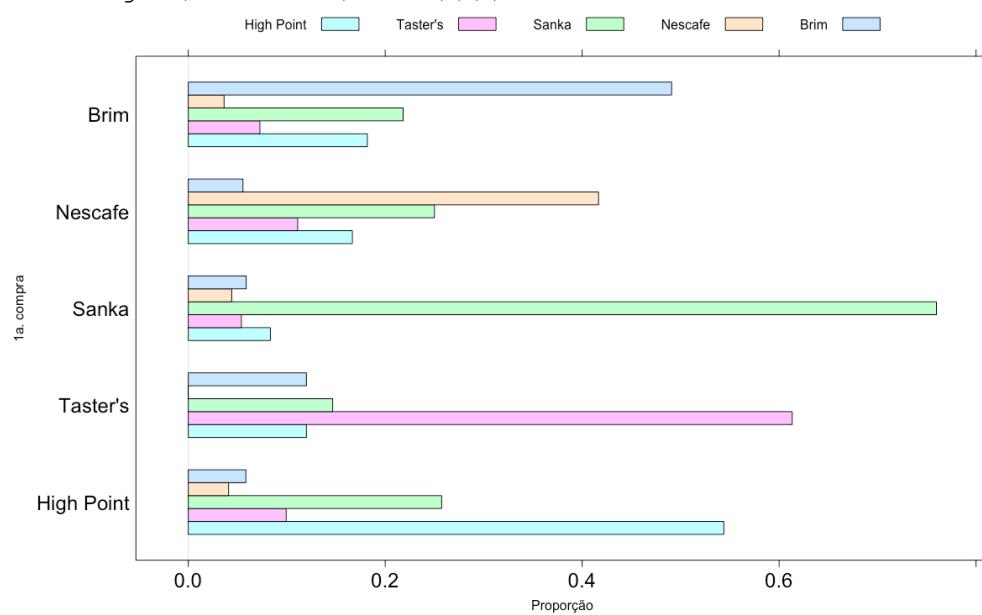
Nota 2. Comente sobre a homogeneidade marginal das distribuições.

```

## Distribuições condicionais (na 1a. compra)
library(lattice)

tab95c <- prop.table(tab95, margin = 1)
barchart(tab95c, xlab = "Proporção", ylab = "1a. compra", stack = FALSE,
          scale = list(cex = 1.5), auto.key = list(space = "top",
          columns = length(colnames(tab95))))

```



Nota 3. Interprete o gráfico acima e comente sobre a independência entre as variáveis.

1.1 Modelos

Em seguida os dados são organizados de uma forma conveniente para o ajuste de modelos log-lineares. A função `as.vector` empilha as colunas de uma matriz.

```
## Dados
compra1 <- factor(colnames(tab95), levels = colnames(tab95))
compra2 <- compra1
dados <- expand.grid(compra1 = compra1, compra2 = compra2)
dados$freq <- as.vector(tab95)
dados

    compra1    compra2 freq
1   High Point High Point  93
2   Taster's  High Point   9
3     Sanka  High Point  17
4   Nescafe  High Point   6
5     Brim  High Point  10
6  High Point   Taster's  17
7  Taster's   Taster's  46
8     Sanka   Taster's  11
9   Nescafe   Taster's   4
10    Brim   Taster's   4
11 High Point      Sanka  44
12 Taster's      Sanka  11
13   Sanka      Sanka 155
14   Nescafe      Sanka   9
15     Brim      Sanka  12
16 High Point    Nescafe   7
17 Taster's    Nescafe   0
18   Sanka    Nescafe   9
19   Nescafe    Nescafe  15
20     Brim    Nescafe   2
21 High Point      Brim  10
22 Taster's      Brim   9
23   Sanka      Brim  12
24   Nescafe      Brim   2
25     Brim      Brim  27

## Modelo de independência
mind <- glm(freq ~ compra1 + compra2, family = poisson, data = dados)

# G2 e X2
X2ind <- sum(resid(mind, type = "pearson")^2)
cat("\n Modelo de independência (g.l. = ", mind$df.residual, ")")
cat("\n G2 = ", mind$deviance, "(p =", pchisq(mind$deviance,
  mind$df.residual, lower.tail = FALSE), ")")
cat("\n X2 = ", X2ind, "(p =", pchisq(X2ind, mind$df.residual,
  lower.tail = FALSE), ")")
```

```

Modelo de independência (g.l. = 16 )
G2 = 346.381 (p = 5.879941e-64 )
X2 = 463.3044 (p = 1.817251e-88 )

```

O ajuste do modelo de simetria requer uma variável auxiliar formada por pares de linhas e colunas (i, j) e tais que os pares (i, j) e (j, i) tenham o mesmo valor da variável sempre que $i \neq j$, para i e $j = 1, \dots, I$, significando que os coeficientes são iguais. Se todos os $I^2 (= 25)$ valores da variável auxiliar forem diferentes, obtemos o modelo saturado.

As funções `pmax` (*parallel maxima*) e `pmin` (*parallel minima*) são usadas para criar a variável auxiliar. Aplicada aos vetores (a_1, a_2, \dots, a_N) e (b_1, b_2, \dots, b_N) , a função `pmax` retorna o vetor com elementos $\max(a_1, b_1), \max(a_2, b_2), \dots, \max(a_N, b_N)$.

```

## Modelo de simetria
# Variável auxiliar com um valor para cada diferente probabilidade
dados$aux <- factor(paste(as.numeric(dados$compral),
  as.numeric(dados$compra2)), pmin(as.numeric(dados$compral),
  as.numeric(dados$compra2)), sep = ","))

```

`dados`

	compral	compra2	freq	aux
1	High Point	High Point	93	1,1
2	Taster's	High Point	9	2,1
3	Sanka	High Point	17	3,1
4	Nescafe	High Point	6	4,1
5	Brim	High Point	10	5,1
6	High Point	Taster's	17	2,1
7	Taster's	Taster's	46	2,2
8	Sanka	Taster's	11	3,2
9	Nescafe	Taster's	4	4,2
10	Brim	Taster's	4	5,2
11	High Point	Sanka	44	3,1
12	Taster's	Sanka	11	3,2
13	Sanka	Sanka	155	3,3
14	Nescafe	Sanka	9	4,3
15	Brim	Sanka	12	5,3
16	High Point	Nescafe	7	4,1
17	Taster's	Nescafe	0	4,2
18	Sanka	Nescafe	9	4,3
19	Nescafe	Nescafe	15	4,4
20	Brim	Nescafe	2	5,4
21	High Point	Brim	10	5,1
22	Taster's	Brim	9	5,2
23	Sanka	Brim	12	5,3
24	Nescafe	Brim	2	5,4
25	Brim	Brim	27	5,5

Nota 4. Crie a variável auxiliar (`aux`) sem utilizar as funções `pmax` e `pmin`.

O número de pares é I^2 , que correspondem a $I + I(I-1)/2 = 15$ pares não redundantes (ou únicos).

```
length(unique(dados$aux))

15

msim <- glm(freq ~ aux, family = poisson, data = dados)

# G2 e X2
X2s <- sum(resid(msim, type = "pearson")^2)
cat("\n Modelo de simetria (g.l. = ", msim$df.residual, ") ")
cat("\n G2 = ", msim$deviance, "(p =", round(pchisq(msim$deviance,
  msim$df.residual, lower.tail = FALSE), 4), ")")
cat("\n X2 = ", X2s, "(p =", round(pchisq(X2s, msim$df.residual,
  lower.tail = FALSE), 4), ")")

  Modelo de simetria (g.l. = 10 )
  G2 = 22.47293 (p = 0.0129 )
  X2 = 20.41236 (p = 0.0256 )
```

Os resultados acima indicam que o modelo de simetria não faz um bom ajuste aos dados ($p < 0,05$). O modelo de quase simetria pode ser obtido a partir do modelo simetria pela adição dos efeitos individuais das compras (“quebram” a simetria).

```
## Modelo de quase simetria
mqsim <- update(msim, . ~ . + compra1 + compra2)

# G2 e X2
X2qs <- sum(resid(mqsim, type = "pearson")^2)
cat("\n Modelo de quase simetria (g.l. = ", mqsim$df.residual, ") ")
cat("\n G2 = ", mqsim$deviance, "(p =", round(pchisq(mqsim$deviance,
  mqsim$df.residual, lower.tail = FALSE), 4), ")")
cat("\n X2 = ", X2qs, "(p =", round(pchisq(X2qs, mqsim$df.residual,
  lower.tail = FALSE), 4), ")")

  Modelo de quase simetria (g.l. = 6 )
  G2 = 9.974047 (p = 0.1257 )
  X2 = 8.530328 (p = 0.2018 )
```

Os resultados acima indicam que não se rejeita o ajuste do modelo de quase simetria ($p > 0,05$).

```
# Frequências esperadas estimadas
festqsim <- matrix(mqsim$fitted.values, ncol = ncol(tab95), byrow = FALSE,
  dimnames = list(rownames(tab95), colnames(tab95)))
round(festqsim, 1)
```

	High Point	Taster's	Sanka	Nescafe	Brim
High Point	93.0	16.8	40.9	7.4	12.9
Taster's	9.2	46.0	11.6	1.7	6.5
Sanka	20.1	10.4	155.0	7.2	11.3
Nescafe	5.6	2.3	10.8	15.0	2.3
Brim	7.1	6.5	12.7	1.7	27.0

Com as estimativas acima, obtemos a estimativa de $(m_{22} / m_{23}) / (m_{12} / m_{13})$:

```
festqsim[2, 2] * festqsim[1, 3] / (festqsim[1, 2] * festqsim[2, 3])
```

9.65773

A estimativa acima pode ser escrita como

$$\frac{P(Y = Taster's | X = Taster's)}{P(Y = Sanka | X = Taster's)} = 9,7 \times \frac{P(Y = Taster's | X = High Point)}{P(Y = Sanka | X = High Point)}$$

São duas opções na primeira compra: *Taster's* ou *High Point*. A chance de escolher entre *Taster's* e *Sanka* na segunda compra é 9,7 vezes maior na primeira opção em relação à segunda opção.

Comparando as marcas *Taster's* e *High Point* como primeira compra, a chance entre *Taster's* e *Sanka* na segunda compra é 9,7 vezes maior quando a primeira compra é *Taster's*.

De acordo com o modelo de quase simetria, a estimativa de $(m_{31} / m_{32}) / (m_{21} / m_{22})$ é a mesma dada acima. De fato,

```
festqsim[3, 1] * festqsim[2, 2] / (festqsim[3, 2] * festqsim[2, 1])
```

9.65773

A estimativa acima pode ser escrita como

$$\frac{P(Y = High Point | X = Sanka)}{P(Y = Taster's | X = Sanka)} = 9,7 \times \frac{P(Y = High Point | X = Taster's)}{P(Y = Taster's | X = Taster's)}$$

São duas opções na primeira compra: *Sanka* ou *Taster's*. A chance de escolher entre *High Point* e *Taster's* na segunda compra é 9,7 vezes maior na primeira opção em relação à segunda opção.

Comparando as marcas *Sanka* e *Taster's* como primeira compra, a chance entre *High Point* e *Taster's* na segunda compra é 9,7 vezes maior quando a primeira compra é *Sanka*.

Para ajustar o modelo de quase independência criamos $I (= 5)$ variáveis auxiliares assumindo em cada par (i, j) valor 0, se $i \neq j$, e valor 1, se $i = j$.

```

## Modelo de quase independência
# Variáveis auxiliares
dados$D1 <- as.numeric(dados$aux == "1,1")
dados$D2 <- as.numeric(dados$aux == "2,2")
dados$D3 <- as.numeric(dados$aux == "3,3")
dados$D4 <- as.numeric(dados$aux == "4,4")
dados$D5 <- as.numeric(dados$aux == "5,5")

mqind <- update(mqind, . ~ . + D1 + D2 + D3 + D4 + D5)

# G2 e X2
X2qind <- sum(resid(mqind, type = "pearson")^2)
cat("\n Modelo de quase independência (g.l. = ", mqind$df.residual, ")")
cat("\n G2 = ", mqind$deviance, "(p =", round(pchisq(mqind$deviance,
  mqind$df.residual, lower.tail = FALSE), 4), ")")
cat("\n X2 = ", X2qind, "(p =", round(pchisq(X2qind, mqind$df.residual,
  lower.tail = FALSE), 4), ")")

Modelo de quase independência (g.l. = 11 )
G2 = 13.78563 (p = 0.2451 )
X2 = 12.24792 (p = 0.3453 )

```

Os resultados acima indicam que não se rejeita o ajuste do modelo de quase independência ($p > 0,05$).

Nota 5. Compare as frequências observadas e as frequências esperadas estimadas usando o modelo de quase independência.

Nota 6. Explique o significado do modelo de quase independência para as escolhas das marcas de café.

Como o modelo de quase independência está encaixado no modelo de quase simetria, os dois modelos podem ser comparados utilizando a estatística de teste baseada na razão de verossimilhanças (G^2), que é especificada com `test = "LRT"`.

```

# Quase independência x quase simetria
anova(mqind, mqsim, test = "LRT")

Model 1: freq ~ compral + compra2 + D1 + D2 + D3 + D4 + D5
Model 2: freq ~ aux + compral + compra2
  Resid. Df Resid. Dev Df Deviance Pr(>Chi)
1        11     13.786
2         6      9.974  5    3.8116   0.5769

```

Nota 7. Com base no teste acima, se você pretende apresentar resultados de apenas um modelo, qual modelo você escolheria?

```

## Teste de homogeneidade marginal
g2hm <- msim$deviance - mqsim$deviance
gl <- msim$df.residual - mqsim$df.residual
cat("\n Teste de homogeneidade marginal \n G2 = ", g2hm,
  "(p =", round(pchisq(g2hm, gl, lower.tail = FALSE), 4),
  ", g.l. = ", gl, ")")

Teste de homogeneidade marginal
G2 = 12.49889 (p = 0.014 , g.l. = 4 )

```

1.2 *kappa* de Cohen

```

# kappa de Cohen
library(vcd)
(k95 <- Kappa(tab95))
confint(k95)

```

Nos resultados abaixo, ASE indica o erro padrão assintótico (*asymptotic standard error*). Os limites do intervalo de confiança assintótico de 95% são indicados por lwr (*lower*: inferior) e upr (*upper*: superior).

	value	ASE	z	Pr(> z)
Unweighted	0.4765	0.02805	16.99	1.060e-64
Weighted	0.4527	0.03297	13.73	6.473e-43

```
k95$Weights
```

	[,1]	[,2]	[,3]	[,4]	[,5]
[1,]	1.00	0.75	0.50	0.25	0.00
[2,]	0.75	1.00	0.75	0.50	0.25
[3,]	0.50	0.75	1.00	0.75	0.50
[4,]	0.25	0.50	0.75	1.00	0.75
[5,]	0.00	0.25	0.50	0.75	1.00

```
confint(k95)
```

Kappa	lwr	upr
Unweighted	0.4214736	0.5314329
Weighted	0.3880910	0.5173130

Nota 8. Para estes dados, a medida *kappa* ponderada (Weighted) é aplicável?

2. Inferência em uma tabela 2×2 com dados pareados

```

## Teste de McNemar
# Dados
# Tabela 10.1, p. 350 em Agresti (1990), Categorical Data Analysis
tab101 <- matrix(c(794, 150, 86, 570), byrow = TRUE, ncol = 2)

```

```

rownames(tab101) <- c("1. Aprovação", "1. Desaprovação")
colnames(tab101) <- c("2. Aprovação", "2. Desaprovação")
addmargins(tab101)

          2. Aprovação 2. Desaprovação Sum
1. Aprovação           794                 150   944
1. Desaprovação        86                  570   656
Sum                   880                 720  1600

n <- sum(tab101)
cat("\n n =", n, "\n")

n = 1600

# Proporções amostrais e teste
prop101 <- prop.table(tab101)
round(prop101, 3)

          2. Aprovação 2. Desaprovação
1. Aprovação           0.496             0.094
1. Desaprovação        0.054             0.356

mcnemar.test(tab101, correct = FALSE)

McNemar's chi-squared = 17.3559, df = 1, p-value = 3.099e-05

mcnemar.test(tab101, correct = TRUE)

McNemar's chi-squared = 16.818, df = 1, p-value = 4.115e-05

# Teste exato (distribuição binomial)
# H1: pi1+ > pi1 (aprovação 1o. > aprovação 2o.)
ns <- tab101[1, 2] + tab101[2, 1] # n*

No cálculo do valor- $p$ , como a distribuição é binomial (discreta), temos que  $P(n_{12} \geq n_{12,\text{obs}}) = 1 - P(n_{12} < n_{12,\text{obs}}) = 1 - P(n_{12} \leq n_{12,\text{obs}} - 1)$ .

valorp <- pbinom(tab101[1, 2] - 1, ns, 0.5, lower.tail = FALSE)
cat("\n Teste exato para H1: pi1+ > pi1\n n12 =", tab101[1, 2],
", n* =", ns, "(p =", valorp, ") \n")

Teste exato para H1: pi1+ > pi1
n12 = 150 , n* = 236 (p = 1.857968e-05 )

# Diferença de aprovação (2o. - 1o.)
(estd <- prop101[2, 1] - prop101[1, 2])

-0.04

```

```

# Erro padrão da estimativa
p1m <- sum(prop101[, 1]) # p1+
pm1 <- sum(prop101[, 1]) # p+1
epest <- sqrt((p1m * (1 - p1m) + pm1 * (1 - pm1) - 2 *
  (prod(diag(prop101)) - prop101[1, 2] * prop101[2, 1])) / n)
cat("\n e.p. (d) =", epest, "\n")

```

e.p. (d) = 0.009549215

```

# Erro padrão da estimativa supondo independência
sqrt((p1m * (1 - p1m) + pm1 * (1 - pm1)) / n)

```

0.01748928

Houve ganho de precisão ($0.01748928 / 0.009549215 = 1,83$).

```

# IC para a diferença de aprovação (2o. - 1o.)
conf <- 0.95
icdif <- estd + c(-1, 1) * qnorm((1 + conf) / 2) * epest
cat("\n IC de", conf * 100, "% para a diferença (2o. - 1o.): \n", icdif,
  "\n")

```

IC de 95 % para a diferença (2o. - 1o.):
-0.05871612 -0.02128388

Nota 9. Interprete o resultado acima. Como você escreveria em um relatório?