

16.1 Exemplo de aplicação

Dois fungicidas (trt) foram avaliados experimentalmente a campo em delineamento inteiramente casualizado com a cultura da soja. A variável resposta (y) é o rendimento de grãos, em sacas/ha. Ocorre que, por ocasião da aplicação dos fungicidas, as parcelas apresentavam diferentes níveis de incidência e severidade da doença. Assim, a covariável (x) representando a área foliar (%) livre da doença em cada parcela foi também mensurada para fins de controle experimental. O conjunto de dados é `ancova.csv`.

```

1 > soja <- read.csv("https://raw.githubusercontent.com/
  arsilva87/statsbook/main/datasets/ancova.csv",
  colClasses = c("factor", "numeric", "numeric"))
2 > str(soja)
3 'data.frame': 20 obs. of 3 variables:
4 $ trt: Factor w/ 2 levels "1","2": 1 1 1 1 1 1 1 1 ...
5 $ x : num 58.4 50.9 60.5 51.3 68.4 51.7 49.8 57.1 ...
6 $ y : num 51.4 47.9 48.5 41.3 58.4 39.7 44.8 45.1 ...

```

Observe a seguir as médias de rendimento. Há 1.84 sc/ha (110.4 kg/ha) de diferença. Mas, pela ANOVA, essa diferença não é detectável, mesmo não havendo problemas com os pressupostos do modelo.

```

1 > aggregate(y ~ trt, data = soja, FUN = mean)
2   trt      y
3 1    1 48.28
4 2    2 50.12
5
6 > anova(lm(y ~ trt, data = soja))
7 Analysis of Variance Table
8
9 Response: y
10      Df Sum Sq Mean Sq F value Pr(>F)
11 trt    1  16.93  16.928   0.5326 0.4749
12 Residuals 18 572.07  31.782

```

Embora não haja efeito dos tratamentos fungicidas sobre a covariável x , é razoável supor que o efeito (τ_i) dos fungicidas sobre os dados de rendimento de grãos (y_{ij}) seja influenciado pelo valor de x nas respectivas parcelas (x_{ij}). Assim, deve-se incluir no modelo estatístico para o rendimento de grãos o efeito (b) dessa covariável.

$$y_{ij} = \mu + b(x_{ij} - \bar{x}) + \tau_i + \epsilon_{ij}$$

Note que tal modelo é uma mistura dos modelos de regressão

linear e de análise de variância. O termo b representa o coeficiente de regressão, efeito linear de x sobre y em ambos os tratamentos. Observe que x é centrada na média, para que sua inclusão não afete a estimativa da média geral μ . Observe o ajuste do modelo de ANCOVA no R:

```

1 > mod <- lm(y ~ I(x - mean(x)) + trt, data = soja)
2 > mod
3
4 Call:
5 lm(formula = y ~ I(x - mean(x)) + trt, data = soja)
6
7 Coefficients:
8   (Intercept)  I(x - mean(x))          trt2
9      47.0969         0.8273         4.2061

```

Em que se obtém as estimativas: $\bar{y}_1^* = 47.09$, $\bar{y}_2^* = 47.09 + 4.2061 = 51.2961$, das médias de tratamentos, e $\hat{b} = 0.8273$ o efeito da covariável x .

Uma vez que os valores *ajustados* de rendimento (y) para a covariável x são dados por:

$$y_{ij} - b(x_{ij} - \bar{x}) = \mu + \tau_i + \epsilon_{ij}$$

logo percebe-se que as *médias ajustadas* de rendimento podem ser obtidas por:

$$\begin{aligned} \bar{y}_i^* &= \bar{y}_i - \hat{b}(\bar{x}_i - \bar{x}) \\ \bar{y}_1^* &= 48.28 - 0.8273(57.48 - 56.05) = 47.09 \\ \bar{y}_2^* &= 50.12 - 0.8273(54.62 - 56.05) = 51.30 \end{aligned}$$

As diferenças entre tratamentos em relação aos valores de x contribuem com a diferença em rendimento. Assim, note que o modelo de ANCOVA permitiu *amplificar* para 4.21 sc/ha as diferenças entre tratamentos, de modo que as médias ajustadas são estatisticamente diferentes ($p = 0.0026$). Perceba também que um grau de liberdade foi retirado do resíduo para estimar o efeito da covariável x .

```

1 > anova(mod)
2 Analysis of Variance Table
3
4 Response: y
5
6           Df Sum Sq Mean Sq F value    Pr(>F)
7 I(x - mean(x))  1  391.49   391.49   58.305 6.843e-07 ***
8 trt            1   83.36    83.36   12.415 0.002608 **
9 Residuals     17  114.15     6.71

```

```

9 ---
10 Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

A figura 16.1 nos ajuda a perceber o *ajuste* feito pela covariável x no efeito dos tratamentos sobre y . Note que os dados de cada tratamento estão dispersos ao longo de retas (efeito linear de x sobre y). Essas retas possuem a mesma inclinação $\hat{b} = 0.8273$, mas estão deslocadas no eixo x pela diferença existente no campo em termos de ataque da doença nas parcelas, tornando de certa forma ‘injusta’ a comparação dos tratamentos. As médias ajustadas, por outro lado, representam as médias de rendimento dos tratamentos agora centradas num valor comum de ataque da doença (\bar{x}), a média geral de x .

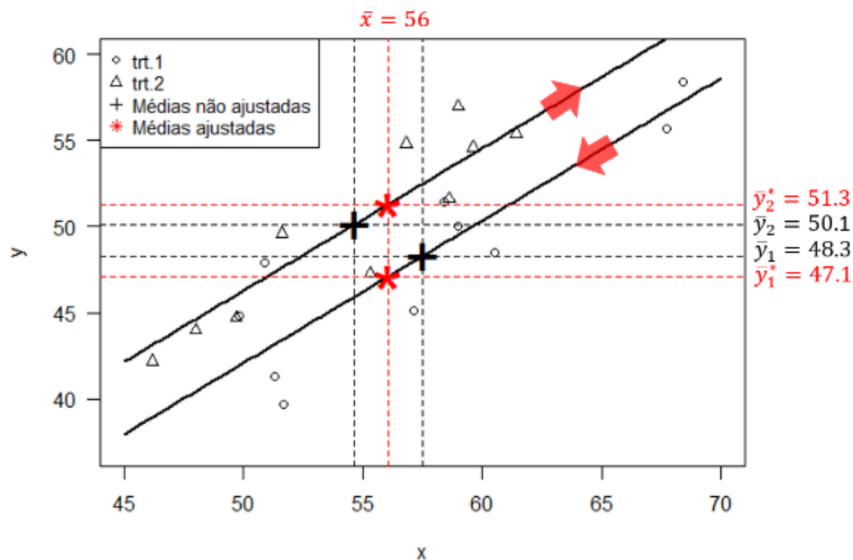


Figura 16.1: Ilustração da análise de covariância

O fato de haver apenas dois tratamentos dispensa testes de médias. Não obstante, a diferença de rendimento entre tratamentos poderia ser testada através de testes post-hoc, utilizando as médias ajustadas¹. A seguir o resultado do teste t (LSD de Fisher) com o pacote *emmeans* (Lenth, 2019).

```

1 > library(emmeans)
2 > pairs(lsmeans(mod, "trt"))
3 contrast estimate SE df t.ratio p.value
4 1 - 2          -4.21 1.19 17 -3.523 0.0026

```

¹Ou médias de mínimos quadrados (*least square means*, do inglês).