


# TESTE PARA FALTA DE AJUSTE

1

Vimos que  $OMR_{Res} = \frac{SOM_{Res}}{n-2} = \frac{\sum \hat{E}_i^2}{n-2} = \frac{\sum (y_i - \hat{y}_i)^2}{n-2}$  é uma estimativa não viesada da variância residual  $\sigma^2$ , sob a suposição de que: "o modelo ajustado é correto"

MODELO PROPOSTO:  $y_i = \mu(x_i) + \epsilon_i$

MODELO CORRETO:  $y_i = \eta(x_i) + \epsilon_i^*$   $\left\{ \begin{array}{l} E(\epsilon_i^*) = 0 \\ Var(\epsilon_i^*) = \sigma^2 \end{array} \right.$



↳ Esse viés estará incluído em  $\epsilon_i$

Desta forma,

$$E(\epsilon_i) = B_i \quad E(\epsilon_i^* + B_i) = B_i$$

$$\begin{aligned} Var(\epsilon_i) &= E(\epsilon_i^2) = E[(\epsilon_i^* + B_i)^2] = \\ &= E[\epsilon_i^{*2} + 2\epsilon_i^* B_i + B_i^2] = E(\epsilon_i^{*2}) + 2B_i E(\epsilon_i^*) + E(B_i^2) \\ &= \sigma^2 + B_i^2 \end{aligned}$$

Proposta: Obter uma estimativa da variância residual  $\sigma^2$  que independa do modelo que está sendo ajustado  $\Rightarrow$  planejando a coleta de observações repetidas de  $Y$  para cada nível de  $X$  distinto.

Considerar  $K$  níveis para variável  $X$  e  $n_i$  repetições de  $Y$  em cada nível de  $X$

|            | $X$      | $Y$                              | Totais   | Médias      |
|------------|----------|----------------------------------|----------|-------------|
| $K$ níveis | $X_1$    | $y_{11} \ y_{12} \dots y_{1n_1}$ | $y_{10}$ | $\bar{y}_1$ |
|            | $X_2$    | $y_{21} \ y_{22} \dots y_{2n_2}$ | $y_{20}$ | $\bar{y}_2$ |
|            | $\vdots$ | $\vdots$                         | $\vdots$ | $\vdots$    |
|            | $\vdots$ | $\vdots$                         | $\vdots$ | $\vdots$    |
|            | $X_K$    | $y_{K1} \ y_{K2} \dots y_{Kn_K}$ | $y_{K0}$ | $\bar{y}_K$ |

Essa outra estimativa para  $\sigma^2$ , que independe do modelo, é dada pelo QErro de uma análise de variância em que os níveis da variável  $X$  são vistos como  $k$  tratamentos em um delineamento experimental (DIC, DBC, DQL)

Considerando um DIC


$$Y_{ij} = \mu_i + \varepsilon_{ij} \quad \begin{matrix} i=1, \dots, k \\ j=1, \dots, n_i \end{matrix}$$

$\downarrow$   
 $\bar{Y}_i$

ANAVA

| FV          | GL    |
|-------------|-------|
| Tratamentos | $k-1$ |
| Erro        | $N-k$ |
| Total       | $N-1$ |

$$N = \sum n_i = n_1 + \dots + n_k$$



$$Y_{ij} = \bar{Y}_i + \varepsilon_{ij}$$

$$\varepsilon_{ij} = Y_{ij} - \bar{Y}_i$$

$$Y_{ij} - \bar{Y}_i = (Y_{ij} - \bar{Y}) - (\bar{Y}_i - \bar{Y})$$

$\downarrow$  DESVIO ERRO PURO  
 $\downarrow$  DESVIO TOTAL  
 $\downarrow$  DESVIO TRAT

Considerando  $i=1, \dots, k$  e  $j=1, \dots, n_i$ , temos:

$$\sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y})^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} [(Y_{ij} - \bar{Y}_i) + (\bar{Y}_i - \bar{Y})]^2$$

$$\downarrow$$

$$= \sum_{i=1}^k \sum_{j=1}^{n_i} [(Y_{ij} - \bar{Y}_i)^2 + 2(Y_{ij} - \bar{Y}_i)(\bar{Y}_i - \bar{Y}) + (\bar{Y}_i - \bar{Y})^2]$$

$$= \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_i)^2 + 2 \sum_{i=1}^k (\bar{Y}_i - \bar{Y}) \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_i) + \sum_{i=1}^k \sum_{j=1}^{n_i} (\bar{Y}_i - \bar{Y})^2$$

$\downarrow$   $\sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_i) = 0$   
 $\downarrow$   $\sum_{j=1}^{n_i} (\bar{Y}_i - \bar{Y}) = n_i (\bar{Y}_i - \bar{Y})$

$$\sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y})^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_i)^2 + \sum_{i=1}^k \sum_{j=1}^{n_i} (\bar{Y}_i - \bar{Y})^2$$

$$\downarrow$$

$$SQ_{Total} = SQ_{Erro\ Puro} + SQ_{Tratamento}$$

$$SQ_{Total} = \sum_{i=1}^K \sum_{j=1}^{n_i} (y_{ij} - \bar{y})^2$$

$$= \sum_{i=1}^K \sum_{j=1}^{n_i} (y_{ij}^2 - 2y_{ij}\bar{y} + \bar{y}^2)$$

$$= \sum_{i=1}^K \sum_{j=1}^{n_i} y_{ij}^2 - 2\bar{y} \sum_{i=1}^K \sum_{j=1}^{n_i} y_{ij} + N\bar{y}^2$$

$$= \sum_{i=1}^K \sum_{j=1}^{n_i} y_{ij}^2 - 2 \left( \frac{\sum_{i=1}^K \sum_{j=1}^{n_i} y_{ij}}{N} \right) \left( \sum_{i=1}^K \sum_{j=1}^{n_i} y_{ij} \right) + \cancel{N} \frac{\left( \sum_{i=1}^K \sum_{j=1}^{n_i} y_{ij} \right)^2}{N^2}$$

$$= \sum_{i=1}^K \sum_{j=1}^{n_i} y_{ij}^2 - \frac{\left( \sum_{i=1}^K \sum_{j=1}^{n_i} y_{ij} \right)^2}{N} \rightarrow \text{TOTAL GERAL } y_{00}$$

$$SQ_{Trat} = \sum_{i=1}^K \sum_{j=1}^{n_i} (\bar{y}_i - \bar{y})^2$$

$$= \sum_{i=1}^K \sum_{j=1}^{n_i} (\bar{y}_i^2 - 2\bar{y}_i\bar{y} + \bar{y}^2)$$

$$= \sum_{i=1}^K \sum_{j=1}^{n_i} \bar{y}_i^2 - 2\bar{y} \sum_{i=1}^K \sum_{j=1}^{n_i} \bar{y}_i + N\bar{y}^2$$

$$= \sum_{i=1}^K n_i \frac{\left( \sum_{j=1}^{n_i} y_{ij} \right)^2}{n_i^2} - 2 \frac{\sum_{i=1}^K \sum_{j=1}^{n_i} y_{ij}}{N} \sum_{i=1}^K n_i \frac{\sum_{j=1}^{n_i} y_{ij}}{n_i} + \cancel{N} \frac{\left( \sum_{i=1}^K \sum_{j=1}^{n_i} y_{ij} \right)^2}{N^2}$$

$$= \sum_{i=1}^K \frac{y_{i.}^2}{n_i} - \frac{\left( \sum_{i=1}^K \sum_{j=1}^{n_i} y_{ij} \right)^2}{N}$$

$$SQ_{ErroPuro} = SQ_{Total} - SQ_{Trat}$$

$$\rightarrow \hat{\sigma}^2$$


Após obter uma estimativa para  $\sigma^2$ , o interesse está em verificar se existe uma relação linear entre as médias dos tratamentos ( $\bar{y}_i$ ) e os níveis da variável X, ou seja, vamos dobrar os K-1 graus de liberdade de TRAT em 1 grau de liberdade para RL e o restante para o que chamamos de DESVIO DE REGRESSÃO

④ modelo estatístico para média de tratamentos e

$$\bar{Y}_i = \beta_0 + \beta_1 X_i + \varepsilon_i \rightarrow E(\bar{Y}_i) = \beta_0 + \beta_1 X_i$$

$$\rightarrow \hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_i$$

Voltando aos desvios



Para um dado  $x_i$

$$\bar{Y}_i - \bar{Y} = (\bar{Y}_i - \hat{Y}_i) + (\hat{Y}_i - \bar{Y})$$

Desvio entre os níveis de x      falta de ajuste      efeito do modelo linear

Considerando  $i=1, \dots, k$  e  $j=1, \dots, n_i$ , temos:

$$\sum_{i=1}^k \sum_{j=1}^{n_i} (\bar{Y}_i - \bar{Y})^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} [(\bar{Y}_i - \hat{Y}_i) + (\hat{Y}_i - \bar{Y})]^2$$

$$= \sum_{i=1}^k \sum_{j=1}^{n_i} [(\bar{Y}_i - \hat{Y}_i)^2 + 2(\bar{Y}_i - \hat{Y}_i)(\hat{Y}_i - \bar{Y}) + (\hat{Y}_i - \bar{Y})^2]$$

$$= \sum_{i=1}^k \sum_{j=1}^{n_i} (\bar{Y}_i - \hat{Y}_i)^2 + 2 \sum_{i=1}^k \sum_{j=1}^{n_i} (\bar{Y}_i - \hat{Y}_i)(\hat{Y}_i - \bar{Y}) + \sum_{i=1}^k \sum_{j=1}^{n_i} (\hat{Y}_i - \bar{Y})^2$$

$$\sum_{i=1}^k \sum_{j=1}^{n_i} (\bar{Y}_i - \bar{Y})^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} (\bar{Y}_i - \hat{Y}_i)^2 + \sum_{i=1}^k \sum_{j=1}^{n_i} (\hat{Y}_i - \bar{Y})^2$$

$$\text{SQTreat} = \text{SQFaltaAjuste} + \text{SQRegressão}$$

$$\begin{aligned}
SQ_{Reg} &= \sum_{i=1}^K \sum_{j=1}^{n_i} (\hat{y}_i - \bar{y})^2 \\
&= \sum_{i=1}^K n_i (\hat{y}_i - \bar{y})^2 \\
&= \sum_{i=1}^K n_i (\hat{\beta}_0 + \hat{\beta}_1 x_i - \bar{y})^2 \\
&= \sum_{i=1}^K n_i (\cancel{\bar{y}} - \hat{\beta}_1 \bar{x} + \hat{\beta}_1 x_i - \cancel{\bar{y}})^2 \\
&= \sum_{i=1}^K n_i [\hat{\beta}_1 (x_i - \bar{x})]^2 \\
&= \sum_{i=1}^K n_i \hat{\beta}_1^2 x_i^2 \\
&= \hat{\beta}_1^2 \sum_{i=1}^K n_i x_i^2 \\
&= \frac{(\sum_{i=1}^K n_i x_i \bar{y}_i)^2}{(\sum_{i=1}^K n_i x_i^2)} \sum_{i=1}^K n_i x_i^2 \\
&= \frac{(\sum_{i=1}^K n_i x_i \bar{y}_i)^2}{\sum_{i=1}^K n_i x_i^2}
\end{aligned}$$

VERIFIQUEM

$$\begin{aligned}
\hat{\beta}_0 &= \bar{y} - \hat{\beta}_1 \bar{x} \\
\hat{\beta}_1 &= \frac{\sum_{i=1}^K n_i x_i \bar{y}_i}{\sum_{i=1}^K n_i x_i^2}
\end{aligned}$$

$$SQ_{Trat} = SQ_{Falta Aj} + SQ_{Reg}$$

$$SQ_{Falta Aj} = SQ_{Trat} - SQ_{Reg}$$

Com esse desdobramento, a Anava fica

| FV           | GL  | SQ                  | Qm                 | Fc                       |
|--------------|-----|---------------------|--------------------|--------------------------|
| Tratamentos  | K-1 | SQ <sub>Trat</sub>  | QM <sub>Trat</sub> | QM <sub>Trat</sub> /QMEP |
| Reg linear   | 1   | SQ <sub>Reg</sub>   | QM <sub>Reg</sub>  | QM <sub>Reg</sub> /QMEP  |
| Falta Ajuste | K-2 | SQ <sub>F.A.</sub>  | QM <sub>F.A.</sub> | QM <sub>F.A.</sub> /QMEP |
| Erro Puro    | N-K | SQ <sub>EP</sub>    | QMEP               | —                        |
| Total        | N-1 | SQ <sub>Total</sub> |                    |                          |

Para Tratamentos:  $H_0: \mu_1 = \mu_2 = \dots = \mu_k = 0$  vs  $H_a$ : pelo menos  $\mu_i \neq 0$

$$F_c = \frac{QM_{Trat}}{QMEP} \sim F_{k-1, N-k}$$

Rejeitamos  $H_0$ , a um nível  $\alpha$  de significância, se  $F_c > F_{tab}$ . Isso significa que pelo menos uma média de tratamento difere das demais.

Para Regressão:  $H_0: \beta_1 = 0$  vs  $H_a: \beta_1 \neq 0$

$$F_c = \frac{QM_{Reg}}{QMEP} \sim F_{1, N-k}$$

Rejeitamos  $H_0$ , a um nível  $\alpha$  de significância, se  $F_c > F_{tab}$ . Isso significa que há evidência da tendência linear entre as variáveis  $X$  e  $Y$ .

Para Falta de Ajuste:  $H_0: \mu(x) = \beta_0 + \beta_1 x$  vs  $H_a: \mu(x) \neq \beta_0 + \beta_1 x$

$$F_c = \frac{QM_{F.A.}}{QMEP} \sim F_{k-2, N-k}$$

Rejeitamos  $H_0$ , a um nível  $\alpha$  de significância, se  $F_c > F_{tab}$ . Isso significa que existem evidências de que o modelo linear não é adequado, havendo necessidade de se procurar outro modelo.

#### 4 Casos:

Caso 1:  $\left\{ \begin{array}{l} \text{Falta Ajuste} \rightarrow \text{não sig} \\ \text{Regressão} \rightarrow \text{não sig} \end{array} \right. \rightarrow \text{Modelo: } \hat{Y}_{ij} = \hat{\beta}_0 = \bar{Y}$

Caso 2:  $\left\{ \begin{array}{l} \text{Falta Ajuste} \rightarrow \text{não sig} \\ \text{Regressão} \rightarrow \text{signif.} \end{array} \right. \rightarrow \text{Modelo: } \hat{Y}_{ij} = \hat{\beta}_0 + \hat{\beta}_1 X_i$

Caso 3:  $\left\{ \begin{array}{l} \text{Falta Ajuste} \rightarrow \text{signif.} \\ \text{Regressão} \rightarrow \text{não sig.} \end{array} \right. \rightarrow \text{Modelo: } \hat{Y}_{ij} = \hat{\beta}_0 + \hat{\beta}_1 X_i + \hat{\beta}_2 X_i^2 \text{ ou maior}$

Caso 4:  $\left\{ \begin{array}{l} \text{Falta Ajuste} \rightarrow \text{signif.} \\ \text{Regressão} \rightarrow \text{signif.} \end{array} \right. \rightarrow \text{Modelo: } \hat{Y}_{ij} = \hat{\beta}_0 + \hat{\beta}_1 X_i + \hat{\beta}_2 X_i^2 \text{ ou maior}$