

Estatística e Delineamento Experimental 2025-26

Análise de Variância de Efeitos Fixos

Elsa Gonçalves

(Adaptado, Cadima, J. (2021). O Modelo Linear. ISA, ULisboa)

Análise de Variância (ANOVA) de efeitos fixos

A Regressão Linear visa modelar uma variável resposta numérica (quantitativa), à custa de uma ou mais variáveis preditoras, igualmente numéricas.

Mas uma **variável resposta numérica** pode depender de variáveis **qualitativas (categóricas)**, ou seja, de um ou mais **factores**.

A **Análise de Variância (ANOVA)** é uma metodologia estatística para lidar com este tipo de situações.

A ANOVA foi desenvolvida nos anos 30 do Século XX, na Estação Experimental Agrícola de Rothamstead (Inglaterra), por **R.A. Fisher**.

Exemplo motivador: os lírios

Até aqui ignorou-se que os 150 lírios do conjunto de dados *iris* referem-se a 50 observações em cada uma de *três diferentes espécies*.



iris setosa



iris versicolor




iris virginica

Poderão os valores médios de cada característica morfométrica *diferir consoante as espécies*?

Objectivo: testar a igualdade de médias duma variável, em diferentes **contextos** (neste exemplo, para diferentes espécies de lírios).

Dois exemplos: os lírios por espécie



As larguras das pétalas parecem diferir entre as espécies dos lírios.
As larguras das sépalas diferem menos. Eis as médias amostrais:

$$\bar{y}_{seto} = 3.428 \quad ; \quad \bar{y}_{vers} = 2.770 \quad ; \quad \bar{y}_{virg} = 2.974$$

As diferenças serão apenas um acaso da amostra?

Objectivo: Testar a igualdade das médias populacionais de cada espécie.

A ANOVA como caso particular do Modelo Linear

A Análise de Variância (ANOVA) lida com variáveis preditoras (explicativas) **qualitativas**. Surgiu historicamente como um método autónomo. Mas, tal como a Regressão Linear, é uma particularização do **Modelo Linear**.

Introduzir a ANOVA através das suas semelhanças com a Regressão Linear permite aproveitar boa parte da teoria estudada até aqui.

Terminologia

Variável resposta Y : uma variável **numérica** (quantitativa), que se pretende estudar e modelar.

Factor : uma variável preditora **categórica** (qualitativa);

Níveis do factor : as diferentes categorias (“valores”) do factor, ou seja, **diferentes situações experimentais** onde se efectuam observações de Y .

Nos exemplos, o factor **Espécie** tem $k = 3$ níveis.

A ANOVA a um Factor - notação

Na **ANOVA a um Factor** (totalmente casualizado), a modelação da variável resposta baseia-se numa única variável preditora categórica.

Admitimos que o factor tem **k níveis** (no exemplo dos lírios, $k = 3$).

Admitimos que há n observações independentes de Y , sendo **n_i** ($i = 1, \dots, k$) correspondentes ao nível i do factor. Logo, $\sum_{i=1}^k n_i = n$.

Delineamentos equilibrados

No caso de igual número de observações em cada nível,

$$n_1 = n_2 = n_3 = \dots = n_k \quad (= n_c),$$

diz-se que estamos perante um **delineamento equilibrado**.

Os delineamentos equilibrados são aconselháveis (mas não obrigatórios), por várias razões que adiante se discutem.

A dupla indexação de Y

Na regressão linear indexam-se as n observações de Y com um único índice, variando de 1 a n ($\{Y_i\}_{i=1}^n$).

Neste novo contexto, é preferível usar **dois índices para indexar as observações de Y** :

- um (i) indica o **nível do factor** a que a observação corresponde;
- outro (j) permite **distinguir as observações num mesmo nível**.

Assim, a j -ésima observação de Y , no i -ésimo nível do factor, é representada por Y_{ij} , (com $i = 1, \dots, k$ e $j = 1, \dots, n_i$).

A equação do modelo

A equação do modelo será mais simples do que na regressão: a única informação disponível para prever Y_{ij} é que a observação corresponde ao nível i do factor.

Não há informação no modelo para explicar diferentes valores de Y em repetições num mesmo nível do factor: será considerada variação aleatória.

Uma primeira equação do modelo é:

$$Y_{ij} = \mu_i + \varepsilon_{ij} \quad \text{com} \quad E[\varepsilon_{ij}] = 0 ,$$

onde μ_i representa o valor esperado das observações Y_{ij} efectuadas no nível i do factor: $\mu_i = E[Y_{ij}] = E[Y | \text{obs. nível } i]$.

Uma equação para Y_{ij}

Para poder enquadrar a ANOVA na teoria do Modelo Linear já estudada, é conveniente re-escrever as médias de nível na forma:

$$E[Y_{ij}] = \mu_i = \mu + \alpha_i .$$

O parâmetro μ é comum a todas as observações, enquanto os parâmetros α_i são específicos para cada nível (i) do factor.

Cada α_i é designado o efeito do nível i .

Admite-se que Y_{ij} oscila aleatoriamente em torno do seu valor médio:

$$Y_{ij} = \mu + \alpha_i + \varepsilon_{ij} ,$$

com $E[\varepsilon_{ij}] = 0$. Mas como relacionar esta equação do modelo com um Modelo Linear?

O modelo ANOVA como um Modelo Linear

A equação geral $Y_{ij} = \mu + \alpha_i + \varepsilon_{ij}$, nas n_1 observações do nível $i = 1$ fica:

$$Y_{1j} = \mu + \alpha_1 + \varepsilon_{1j} ,$$

nas n_2 observações efectuadas no nível $i = 2$ fica:

$$Y_{2j} = \mu + \alpha_2 + \varepsilon_{2j} ,$$

etc.. Este conjunto de k equações pode ser escrita como uma única **equação geral**, que é a equação dum **modelo linear**:

$$Y_{ij} = \mu + \alpha_1 \mathcal{I}_{1ij} + \alpha_2 \mathcal{I}_{2ij} + \dots + \alpha_k \mathcal{I}_{kij} + \varepsilon_{ij} ,$$

onde \mathcal{I}_m é a **variável indicatriz** do nível m do factor:

$$\mathcal{I}_{mij} = \begin{cases} 1 & , \quad \text{se } i = m \\ 0 & , \quad \text{se } i \neq m \end{cases}$$

A relação de base em notação vectorial

Em notação matricial/vectorial, a equação de base será:

$$\begin{aligned}\vec{Y} &= \mu \vec{1}_n + \alpha_1 \vec{\mathcal{J}}_1 + \alpha_2 \vec{\mathcal{J}}_2 + \alpha_3 \vec{\mathcal{J}}_3 + \dots + \alpha_k \vec{\mathcal{J}}_k + \vec{\varepsilon} \\ \Leftrightarrow \vec{Y} &= \mathbf{X}\vec{\beta} + \vec{\varepsilon},\end{aligned}$$

As colunas de \mathbf{X} são: o vector $\vec{1}_n$ e os vectores das indicatrizes $\vec{\mathcal{J}}_i$.
O vector dos parâmetros $\vec{\beta}$ tem elementos: μ e os efeitos α_i .

Num exemplo com $n_1 = 3$, $n_2 = 4$ e $n_3 = 2$ observações:

$$\begin{bmatrix} Y_{11} \\ Y_{12} \\ Y_{13} \\ Y_{21} \\ Y_{22} \\ Y_{23} \\ Y_{24} \\ Y_{31} \\ Y_{32} \end{bmatrix} = \begin{bmatrix} 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 \\ 1 & 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} \mu \\ \alpha_1 \\ \alpha_2 \\ \alpha_3 \end{bmatrix} + \begin{bmatrix} \varepsilon_{11} \\ \varepsilon_{12} \\ \varepsilon_{13} \\ \varepsilon_{21} \\ \varepsilon_{22} \\ \varepsilon_{23} \\ \varepsilon_{24} \\ \varepsilon_{31} \\ \varepsilon_{32} \end{bmatrix}$$

O problema do excesso de parâmetros

Existe um problema “técnico”: as colunas desta matriz \mathbf{X} são **linearmente dependentes** (a soma das indicatrizes é o vector dos n uns) , pelo que a matriz $\mathbf{X}^t\mathbf{X}$ não é invertível. Há um **excesso de parâmetros** no modelo.

Soluções possíveis na equação $Y_{ij} = \mu + \alpha_1 \mathcal{I}_{1ij} + \alpha_2 \mathcal{I}_{2ij} + \dots + \alpha_k \mathcal{I}_{kij} + \varepsilon_{ij}$:

- ① retirar o parâmetro μ do modelo.
 - ▶ corresponde a retirar a coluna de uns da matriz \mathbf{X} ;
 - ▶ cada α_i equivalerá a μ_i , a média do nível;
 - ▶ não se pode generalizar a situações mais complexas;
 - ▶ mais difícil de encaixar na teoria já dada do Modelo Linear.
- ② impor restrições aos parâmetros: e.g., $\sum_{i=1}^k \alpha_i = 0$.
 - ▶ Foi a **solução clássica**, ainda hoje frequente em livros de ANOVA;
 - ▶ mais difícil de encaixar na teoria geral do Modelo Linear.
- ③ **tomar $\alpha_1 = 0$: será a solução utilizada.**
 - ▶ corresponde a **excluir a 1a. variável indicatriz do modelo (e de \mathbf{X})**;
 - ▶ permite aproveitar a teoria do Modelo Linear e é generalizável.

Cada solução tem implicações na forma de interpretar os parâmetros.

A matriz do modelo com a restrição $\alpha_1 = 0$

Com a restrição $\alpha_1 = 0$, a matriz do modelo \mathbf{X} tem colunas $\vec{1}_n, \vec{\mathcal{J}}_2, \dots, \vec{\mathcal{J}}_k$.
No exemplo anterior, tem-se:

$$\begin{bmatrix} Y_{11} \\ Y_{12} \\ Y_{13} \\ Y_{21} \\ Y_{22} \\ Y_{23} \\ Y_{24} \\ Y_{31} \\ Y_{32} \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 1 & 0 & 0 \\ 1 & 0 & 0 \\ 1 & 1 & 0 \\ 1 & 1 & 0 \\ 1 & 1 & 0 \\ 1 & 1 & 0 \\ 1 & 0 & 1 \\ 1 & 0 & 1 \end{bmatrix} \begin{bmatrix} \mu \\ \alpha_2 \\ \alpha_3 \end{bmatrix} + \begin{bmatrix} \varepsilon_{11} \\ \varepsilon_{12} \\ \varepsilon_{13} \\ \varepsilon_{21} \\ \varepsilon_{22} \\ \varepsilon_{23} \\ \varepsilon_{24} \\ \varepsilon_{31} \\ \varepsilon_{32} \end{bmatrix}$$

Agora $\mu = \mu_1$ é o valor médio das observações do nível $i = 1$:

$$\begin{aligned} Y_{1j} &= \mu + \varepsilon_{1j} &\Rightarrow \mu_1 &= E[Y_{1j}] = \mu &, \forall j = 1, \dots, n_1 \\ Y_{2j} &= \mu + \alpha_2 + \varepsilon_{2j} &\Rightarrow \mu_2 &= E[Y_{2j}] = \mu_1 + \alpha_2 &, \forall j = 1, \dots, n_2 \\ Y_{3j} &= \mu + \alpha_3 + \varepsilon_{3j} &\Rightarrow \mu_3 &= E[Y_{3j}] = \mu_1 + \alpha_3 &, \forall j = 1, \dots, n_3 \end{aligned}$$

Os efeitos de nível α_i

Na equação duma ANOVA a um factor (acetato 228), e com a restrição $\alpha_1 = 0$, cada α_i ($i > 1$) representa o **acréscimo** que transforma a média do primeiro nível na média do nível i :

$$\alpha_1 = 0$$

$$\alpha_2 = \mu_2 - \mu_1$$

$$\alpha_3 = \mu_3 - \mu_1$$

$$\vdots \quad \vdots \quad \vdots$$

$$\alpha_k = \mu_k - \mu_1$$

A igualdade de todas as médias populacionais de nível μ_i equivale a que todos os efeitos de nível sejam nulos: $\alpha_i = 0$, $\forall i$.

O modelo ANOVA a 1 factor para efeitos inferenciais

Para completar o modelo ANOVA a um factor, admite-se que os erros aleatórios ε_{ij} têm as mesmas propriedades que numa regressão linear:

Modelo ANOVA a um factor, com k níveis

Existem n observações, Y_{ij} , das quais n_i correspondem ao nível i ($i = 1, \dots, k$) do factor. Tem-se:

- 1 $Y_{ij} = \mu_1 + \alpha_i + \varepsilon_{ij}$, $\forall i=1, \dots, k$, $\forall j=1, \dots, n_i$ ($\alpha_1 = 0$).
- 2 $\varepsilon_{ij} \sim \mathcal{N}(0, \sigma^2)$, $\forall i, j$
- 3 $\{\varepsilon_{ij}\}_{i,j}$ v.a.s independentes.

O modelo tem k parâmetros: a média de Y no primeiro nível do factor, μ_1 , e os acréscimos α_i ($i > 1$) que geram as médias de cada um dos $k - 1$ restantes níveis do factor. Ou seja,

$$\vec{\beta} = (\mu_1, \alpha_2, \alpha_3, \dots, \alpha_k)^t .$$

O modelo ANOVA a um factor - notação vectorial

De forma equivalente, em notação vectorial,

Modelo ANOVA a um factor - notação vectorial

O vector \vec{Y} das n observações verifica:

- 1 $\vec{Y} = \mu_1 \vec{1}_n + \alpha_2 \vec{\mathcal{J}}_2 + \alpha_3 \vec{\mathcal{J}}_3 + \dots + \alpha_k \vec{\mathcal{J}}_k + \vec{\epsilon} = \mathbf{X}\vec{\beta} + \vec{\epsilon}$, sendo
 - ▶ $\vec{1}_n$ o vector de n uns e $\vec{\mathcal{J}}_2, \vec{\mathcal{J}}_3, \dots, \vec{\mathcal{J}}_k$ as variáveis indicatrizes dos níveis indicados;
 - ▶ $\mathbf{X} = \left[\vec{1}_n \mid \vec{\mathcal{J}}_2 \mid \vec{\mathcal{J}}_3 \mid \dots \mid \vec{\mathcal{J}}_k \right]$ a matriz $n \times k$ do modelo; e
 - ▶ $\vec{\beta} = (\mu_1, \alpha_2, \alpha_3, \dots, \alpha_k)^t$ o vector dos parâmetros.
- 2 $\vec{\epsilon} \sim \mathcal{N}_n(\vec{0}, \sigma^2 \mathbf{I}_n)$, sendo \mathbf{I}_n a matriz identidade $n \times n$.

Trata-se de um modelo análogo a um modelo de Regressão Linear Múltipla, diferindo apenas na natureza das variáveis preditoras, que são aqui variáveis indicatrizes dos níveis 2 a k do factor.

O teste aos efeitos do factor

A hipótese de que nenhum dos níveis do factor afecte a média da variável resposta corresponde à hipótese

$$\alpha_2 = \alpha_3 = \dots = \alpha_k = 0$$
$$\Leftrightarrow \mu_1 = \mu_2 = \mu_3 = \dots = \mu_k$$

Dado o paralelismo com os modelos de Regressão Linear, esta hipótese corresponde a dizer que todos os coeficientes das “variáveis preditoras” (na ANOVA, as variáveis indicatrizes $\vec{\mathcal{J}}_i$) são nulos.

É possível testar esta hipótese, através dum teste F de ajustamento global do modelo (ver acetato ??) que, no contexto, chamamos **Teste F aos efeitos do factor**.

O Teste F aos efeitos do factor numa ANOVA

Muda-se a designação de QMR para QMF (Quadrado Médio do Factor):

Teste F aos efeitos do factor


Hipóteses: $H_0 : \alpha_j = 0 \quad \forall i=2,\dots,k$ vs. $H_1 : \exists i=2,\dots,k \text{ t.q. } \alpha_j \neq 0$.
[FACTOR NÃO AFECTA] vs. [FACTOR AFECTA Y]

Estatística do Teste: $F = \frac{QMF}{QMRE} \sim F_{(k-1, n-k)}$ se H_0 .

Nível de significância do teste: α

Região Crítica (Região de Rejeição): Unilateral direita

Rej. H_0 se $F_{calc} > f_{\alpha(k-1, n-k)}$



Notação e graus de liberdade

Neste contexto, existem fórmulas simples para algumas quantidades.

Numa ANOVA a um factor, usamos **SQF**, em vez de **SQR**, para indicar a Soma de Quadrados associada aos efeitos do **F**actor, embora a sua definição seja idêntica (numerador da variância dos valores ajustados).

Numa ANOVA a um factor, o **número de preditores do modelo** (as variáveis indicatrizes dos níveis $2, 3, \dots, k$) é $p = k - 1$ e o **número de parâmetros do modelo** é $p + 1 = k$. Logo, os graus de liberdade associados a cada Soma de Quadrados são:

SQxx	g.l.
SQF	$k - 1$
SQRE	$n - k$

Os **Quadrados Médios** continuam a ser os quocientes das Somas de Quadrados a dividir pelos respectivos graus de liberdade.

Estimadores de parâmetros na ANOVA a um factor

Na ANOVA a um factor, as k colunas de \mathbf{X} são os vectores $\vec{1}_n, \vec{J}_2, \vec{J}_3, \dots, \vec{J}_k$. A matriz identifica as observações de cada nível do factor.

Dada a natureza especial da matriz \mathbf{X} , a fórmula dos parâmetros ajustados, $\vec{\hat{\beta}} = (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \vec{Y}$ gera **estimadores** dos parâmetros populacionais que são as **quantidades amostrais análogas**. Sendo $\bar{Y}_{i.} = \frac{1}{n_i} \sum_{j=1}^{n_i} Y_{ij}$ a média amostral das n_i observações de Y no nível i , tem-se:

$$\begin{array}{rclcl} & \mu_1 & \longrightarrow & \hat{\mu}_1 & = & \bar{Y}_1. \\ \alpha_2 & = & \mu_2 - \mu_1 & \longrightarrow & \hat{\alpha}_2 & = & \bar{Y}_{2.} - \bar{Y}_1. \\ \alpha_3 & = & \mu_3 - \mu_1 & \longrightarrow & \hat{\alpha}_3 & = & \bar{Y}_{3.} - \bar{Y}_1. \\ & \vdots & & & \vdots & & \vdots \\ \alpha_k & = & \mu_k - \mu_1 & \longrightarrow & \hat{\alpha}_k & = & \bar{Y}_{k.} - \bar{Y}_1. \end{array}$$

Os valores ajustados \hat{Y}_{ij}

Valores ajustados \hat{Y}_{ij}

Do que foi visto, decorre que qualquer observação tem valor ajustado igual à média amostral das observações do seu nível:

$$\hat{Y}_{ij} = \underbrace{\hat{\mu}_1 + \hat{\alpha}_i}_{=\hat{\mu}_i} = \bar{Y}_{1.} + (\bar{Y}_{i.} - \bar{Y}_{1.}) = \bar{Y}_{i.}.$$

Os valores ajustados \hat{Y}_{ij} são iguais para todas as observações num mesmo nível i do factor. Tal como na Regressão, estes valores resultam de projectar ortogonalmente o vector \vec{Y} dos valores observados da variável resposta, sobre o subespaço $\mathcal{C}(\mathbf{X}) \subset \mathbb{R}^n$ gerado pelas colunas da matriz \mathbf{X} : $\vec{\hat{Y}} = \mathbf{H}\vec{Y}$.

Numa ANOVA a um factor, o subespaço $\mathcal{C}(\mathbf{X})$ tem natureza especial: todos os vectores de $\mathcal{C}(\mathbf{X})$ têm de ter valor igual nas posições correspondentes a observações dum mesmo nível do factor.

Os resíduos e $SQRE$

Vimos que $\hat{Y}_{ij} = \hat{\mu}_i = \bar{Y}_{i.}$

O resíduo da observação Y_{ij} é dado pela sua diferença em relação à média amostral de nível:

$$E_{ij} = Y_{ij} - \hat{Y}_{ij} = Y_{ij} - \bar{Y}_{i.},$$

A Soma de Quadrados dos Resíduos é dada por:

$$SQRE = \sum_{i=1}^k \sum_{j=1}^{n_i} E_{ij}^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_{i.})^2 = \sum_{i=1}^k (n_i - 1) S_i^2,$$

onde $S_i^2 = \frac{1}{n_i - 1} \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_{i.})^2$ é a variância amostral das n_i observações de Y no i -ésimo nível do factor.

$SQRE$ mede variabilidade no seio dos k níveis.

Fórmulas para delineamentos equilibrados

No caso de um delineamento equilibrado, i.e., $n_1 = n_2 = \dots = n_k (= n_c)$ tem-se $n = n_c \cdot k$, e:

$$SQRE = (n_c - 1) \sum_{i=1}^k S_i^2$$
$$QMRE = \frac{n_c - 1}{n - k} \sum_{i=1}^k S_i^2 = \frac{n_c - 1}{k(n_c - 1)} \sum_{i=1}^k S_i^2 = \frac{1}{k} \sum_{i=1}^k S_i^2 .$$

Assim, em delineamentos equilibrados, o Quadrado Médio Residual é a média (simples) das k variâncias de nível da variável resposta Y .

Em delineamentos não equilibrados, o QMRE é uma média ponderada dos S_i^2 (tendo cada parcela o peso $n_i - 1$).

A Soma de Quadrados associada ao Factor

A Soma de Quadrados associada à Regressão toma, neste contexto, a designação **Soma de Quadrados associada ao Factor** e será representada por **SQF**. Sendo $\bar{Y}_{..} = \frac{1}{n} \sum_{i=1}^k \sum_{j=1}^{n_i} Y_{ij}$ a média da totalidade das n observações, tem-se:

$$\begin{aligned} SQF &= \sum_{i=1}^k \sum_{j=1}^{n_i} \left(\hat{Y}_{ij} - \bar{Y}_{..} \right)^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} \left(\bar{Y}_{i.} - \bar{Y}_{..} \right)^2 \\ \Leftrightarrow \quad SQF &= \sum_{i=1}^k n_i \left(\bar{Y}_{i.} - \bar{Y}_{..} \right)^2 \end{aligned}$$

SQF mede **variabilidade entre as médias amostrais de cada nível**.

Fórmulas para delineamentos equilibrados

No caso de um delineamento equilibrado $n_1 = n_2 = \dots = n_k (= n_c)$,

$$SQF = n_c \sum_{i=1}^k (\bar{Y}_{i.} - \bar{Y}_{..})^2 = n_c(k-1) \cdot S_{\bar{Y}_{i.}}^2,$$

onde $S_{\bar{Y}_{i.}}^2 = \frac{1}{k-1} \sum_{i=1}^k (\bar{Y}_{i.} - \bar{Y}_{..})^2$ indica a variância amostral das k médias de nível amostrais.

$$QMF = \frac{SQF}{k-1} = n_c \cdot S_{\bar{Y}_{i.}}^2.$$

Assim, em delineamentos equilibrados, o Quadrado Médio associado aos efeitos do Factor, QMF , é proporcional à variância das k médias de nível da variável Y .

A relação entre Somas de Quadrados

A relação fundamental entre as três Somas de Quadrados (mesmo com delineamentos não equilibrados) tem um significado particular:

$$\begin{aligned} SQT &= SQF + SQRE \\ \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_{..})^2 &= \sum_{i=1}^k n_i (\bar{Y}_{i.} - \bar{Y}_{..})^2 + \sum_{i=1}^k (n_i - 1) S_i^2 . \end{aligned}$$

onde:

$SQT = (n-1)s_y^2$ mede a variabilidade total das n observações de Y ;

SQF mede a variabilidade entre diferentes níveis do factor (variabilidade inter-níveis);

$SQRE$ mede a variabilidade no seio dos níveis - e que portanto não é explicada pelo factor (variabilidade intra-níveis).


Esta é a origem histórica do nome “Análise da Variância”: a variância de Y é decomposta (“analisada”) em parcelas, associadas a diferentes causas. Aqui, as causas podem ser o efeito do factor ou outras não explicadas pelo modelo (residuais).

O quadro de síntese da ANOVA a 1 Factor

Pode-se coleccionar esta informação numa **tabela-resumo da ANOVA**:

Fonte	g.l.	SQ	QM	f_{calc}
Factor	$k - 1$	$SQF = \sum_{i=1}^k n_i \cdot (\bar{y}_{i.} - \bar{y}_{..})^2$	$QMF = \frac{SQF}{k-1}$	$\frac{QMF}{QMRE}$
Resíduos	$n - k$	$SQRE = \sum_{i=1}^k (n_i - 1) s_i^2$	$QMRE = \frac{SQRE}{n-k}$	
Total	$n - 1$	$SQT = (n - 1) s_y^2$	—	—

Factores no

O  tem uma estrutura de dados específica para variáveis qualitativas (categóricas), designada `factor`, criado pelo comando `factor`, aplicado a um vector contendo os nomes dos vários níveis:

```
> factor(c("Adubo 1", "Adubo 1", ... , "Adubo 5"))
```

NOTA: Explore o comando `rep` para criar repetições de valores.


Factores no R

No objecto `iris`, a coluna `Species` é um factor. A função `summary`, com factores, devolve o número de observações em cada nível

```
> summary(iris)
```

Sepal.Length	Sepal.Width	Petal.Length	Petal.Width	Species
Min. :4.300	Min. :2.000	Min. :1.000	Min. :0.100	setosa :50
1st Qu.:5.100	1st Qu.:2.800	1st Qu.:1.600	1st Qu.:0.300	versicolor:50
Median :5.800	Median :3.000	Median :4.350	Median :1.300	virginica :50
Mean :5.843	Mean :3.057	Mean :3.758	Mean :1.199	
3rd Qu.:6.400	3rd Qu.:3.300	3rd Qu.:5.100	3rd Qu.:1.800	
Max. :7.900	Max. :4.400	Max. :6.900	Max. :2.500	

ANOVAs a um Factor no

Para efectuar uma ANOVA a um Factor no , convém **organizar os dados numa `data.frame` com duas colunas**:

- 1 uma para os valores (numéricos) da **variável resposta**;
- 2 outra para o **factor** (com a indicação dos seus níveis).

As fórmulas usadas no R para especificar uma ANOVA a um factor são semelhantes às da regressão linear, indicando o factor como variável preditora. O R cria as variáveis indicatrizes necessárias.

Fórmulas para ANOVAs no R

Para efectuar uma ANOVA de larguras das pétalas sobre espécies, nos dados dos $n = 150$ lírios, a fórmula é:

$$\text{Petal.Width} \sim \text{Species}$$

uma vez que a *data frame* `iris` contém uma coluna de nome `Species` que foi definida como factor.

ANOVAs a um factor no (cont.)

Embora seja possível usar o comando `lm` para efectuar uma ANOVA (a ANOVA é caso particular do Modelo Linear), o comando `aov` organiza a informação da forma mais tradicional numa ANOVA.

Uma ANOVA com os lírios

Eis a ANOVA da largura de pétalas sobre espécies, nos lírios:

```
> aov(Petal.Width ~ Species, data=iris)
```

Call:

```
aov(formula = Petal.Width ~ Species, data = iris)
```

Terms:

	Species	Residuals
Sum of Squares	80.41333	6.15660
Deg. of Freedom	2	147

Residual standard error: 0.20465

ANOVAs a um factor no (cont.)

A função `summary` também pode ser aplicada ao resultado de uma ANOVA, produzindo o quadro-resumo completo da ANOVA.

ANOVA da largura das sépalas

Eis o resultado da ANOVA do segundo exemplo do acetato 223:

```
> iris.aov <- aov(Sepal.Width ~ Species , data=iris)
> summary(iris.aov)
```

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
Species	2	11.35	5.672	49.16	<2e-16 ***
Residuals	147	16.96	0.115		

Neste caso, rejeita-se claramente a hipótese de que os acréscimos de nível, α_i , sejam todos nulos, pelo que se **rejeita a hipótese de larguras médias de sépalas iguais em todas as espécies**. Conclusão: **o factor (espécie) afecta a variável resposta (largura da sépala)**.

A exploração ulterior de H_1

A Hipótese Nula, no teste F numa ANOVA a 1 Factor, afirma que todos os níveis do factor têm efeito nulo, isto é, que a média da variável resposta Y é igual nos k níveis do Factor:

$$\begin{aligned}\alpha_2 &= \alpha_3 = \dots = \alpha_k = 0 \\ \Leftrightarrow \mu_1 &= \mu_2 = \mu_3 = \dots = \mu_k\end{aligned}$$

A Hipótese Alternativa diz que **pelo menos um** dos níveis do factor tem uma **média de Y diferente** do primeiro nível:

$$\begin{aligned}\exists i \quad \text{tal que} \quad \alpha_i &\neq 0 \\ \Leftrightarrow \exists i \quad \text{tal que} \quad \mu_1 &\neq \mu_i\end{aligned}$$

Ou seja, **nem todas as médias de nível de Y são iguais**

A exploração ulterior de H_1 (cont.)

Caso se opte pela Hipótese Alternativa, fica em aberto (excepto quando $k = 2$) a questão de **saber quais os níveis do factor cujas médias diferem entre si.**

Mesmo com $k = 3$, a rejeição de H_0 pode dever-se a:

$$\mu_1 = \mu_2 \neq \mu_3 \quad \text{i.e.,} \quad \alpha_2 = 0 ; \alpha_3 \neq 0$$

$$\mu_1 = \mu_3 \neq \mu_2 \quad \text{i.e.,} \quad \alpha_3 = 0 ; \alpha_2 \neq 0$$

$$\mu_1 \neq \mu_2 = \mu_3 \quad \text{i.e.,} \quad \alpha_2 = \alpha_3 \neq 0;$$

$$\mu_i \text{ todos diferentes} \quad \text{i.e.,} \quad \alpha_2 \neq \alpha_3 \text{ e } \alpha_2, \alpha_3 \neq 0.$$

Como optar entre estas diferentes alternativas?

A exploração ulterior de H_1 (cont.)

Podem efectuar-se testes *t-Student* aos α_i s, com base na teoria já estudada anteriormente (recorde-se que um modelo ANOVA é um modelo linear).

Mas quanto maior for k , mais sub-hipóteses alternativas existem, mais testes haverá para fazer.

A multiplicação do número de testes faz perder o controlo do nível de significância α **global** para o conjunto de todos os testes.

Testes de hipóteses alternativos, relativos a todas as diferenças $\mu_i - \mu_j$ de pares de médias populacionais de Y , permitem **controlar o nível de significância global α do conjunto dos testes**. Tais testes chamam-se **testes de comparações múltiplas** de médias.

As comparações múltiplas

O nível de significância α nos testes de comparação múltipla é a probabilidade de rejeitar **qualquer** das hipóteses $\mu_i = \mu_j$, caso todas sejam verdade, ou seja, é um nível de significância **global**.

Alternativamente, podem-se construir **intervalos de confiança** para cada diferença $\mu_i - \mu_j$, com um nível $(1 - \alpha) \times 100\%$ de confiança de que os verdadeiros valores de $\mu_i - \mu_j$ pertencem a **todos** os intervalos.

A mais frequente abordagem de comparações múltiplas leva o nome de **Tukey**, embora em rigor só seja válido para **delineamentos equilibrados**.

Testes de Tukey na ANOVA a um factor

Dado um delineamento a um factor, equilibrado.

Teste de Tukey às diferenças de médias de nível

Hipóteses: $H_0 : \mu_i = \mu_j, \forall i, j$ vs. $H_1 : \exists i, j \text{ t.q. } \mu_i \neq \mu_j$.
[FACTOR NÃO AFECTA] vs. [FACTOR AFECTA Y]

Nível de significância (global) do teste: α


Regra: **Rejeitar** $\mu_i = \mu_j$ se $|\bar{Y}_{i.} - \bar{Y}_{j.}| > q_{\alpha(k, n-k)} \sqrt{\frac{QMRE}{n_c}}$,
sendo $q_{\alpha(k, n-k)}$ o valor que numa **distribuição de Tukey** com
parâmetros k e $n - k$, deixa à direita uma região de probabilidade α .

O teste permite não apenas rejeitar H_0 globalmente, como identificar o(s) par(es) de níveis (i, j) responsáveis pela rejeição (a diferença das respectivas médias amostrais excede o termo de comparação), **permitindo assim conclusões sobre diferenças significativas em cada par de médias.**

Distribuição de Tukey

Distribuição Tukey na ANOVA a um factor: lírios

Eis a função densidade da distribuição de Tukey, correspondente ao exemplo dos lírios, com $k = 3$ e $n - k = 147$:



Na *webpage* da disciplina encontra-se uma [tabela da distribuição de Tukey](#).

Intervalos de Confiança para $\mu_i - \mu_j$


Alternativamente, podem construir-se intervalos de confiança para todas as diferenças de pares de médias de nível, $\mu_i - \mu_j$, com um grau de confiança global $(1 - \alpha) \times 100\%$.

Concretamente, tem-se $(1 - \alpha) \times 100\%$ de confiança em como todas as diferenças de médias de nível $\mu_i - \mu_j$ estão em intervalos da forma:


$$\left[(\bar{y}_{i\cdot} - \bar{y}_{j\cdot}) - q_{\alpha(k,n-k)} \sqrt{\frac{QMRE}{n_c}} , (\bar{y}_{i\cdot} - \bar{y}_{j\cdot}) + q_{\alpha(k,n-k)} \sqrt{\frac{QMRE}{n_c}} \right]$$

Se para qualquer par (i, j) de níveis, o intervalo correspondente não contém o valor zero, então $\mu_i = \mu_j$ não é admissível.

Comparações Múltiplas de Médias no

As comparações múltiplas de médias de nível, com base no resultado de Tukey, podem ser facilmente efectuadas no .

O termo de comparação nos testes a $\mu_i - \mu_j = 0$ é $q_{\alpha(k, n-k)} \cdot \sqrt{\frac{QMRE}{n_c}}$.

Os quantis $q_{\alpha(k, n-k)}$ duma distribuição de Tukey são calculados no , através da função `qtukey`.

O quantil de ordem $1 - \alpha$ na distribuição de Tukey obtém-se assim:

```
> qtukey(1- $\alpha$ , k, n-k)
```

O valor de \sqrt{QMRE} é dado pelo comando `aov`, sob a designação “*Residual standard error*”.

Comparações Múltiplas de Médias no

O comando **TukeyHSD** calcula os intervalos de confiança a $(1 - \alpha) \times 100\%$ para as diferenças de médias.

Tukey nos lírios

```
> TukeyHSD(aov(Sepal.Width ~ Species, data=iris))
```

```
Tukey multiple comparisons of means
```

```
95% family-wise confidence level
```

```
$Species
```

	diff	lwr	upr	p adj
versicolor-setosa	-0.658	-0.81885528	-0.4971447	0.0000000
virginica-setosa	-0.454	-0.61485528	-0.2931447	0.0000000
virginica-versicolor	0.204	0.04314472	0.3648553	0.0087802

O intervalo a 95% de confiança para $\mu_2 - \mu_1$ (versicolor-setosa) é

] -0.8189 , -0.4971 [.

Nenhum dos intervalos inclui o valor zero, concluindo-se que $\mu_i \neq \mu_j$, para qualquer $i \neq j$, ou seja, todas as médias de espécie são diferentes.

Comparações Múltiplas de Médias no (cont.)

O valor de prova indicado (p_{adj}) é o menor valor de α para o qual uma dada diferença de médias, $\bar{y}_{i.} - \bar{y}_{j.}$, seria considerada não significativa.

Tukey nos lírios (cont.)

```
> TukeyHSD(aov(Sepal.Width ~ Species, data=iris))
```

Tukey multiple comparisons of means

95% family-wise confidence level

\$Species

	diff	lwr	upr	p_{adj}
versicolor-setosa	-0.658	-0.81885528	-0.4971447	0.0000000
virginica-setosa	-0.454	-0.61485528	-0.2931447	0.0000000
virginica-versicolor	0.204	0.04314472	0.3648553	0.0087802


Assim, para $\alpha \leq 0.00878$, a diferença de médias amostrais para as espécies *virginica* e *versicolor* já seria considerada não significativa. Ou seja, apenas intervalos com mais de $(1 - \alpha) \times 100\% = 99.122\%$ de confiança para essa diferença de médias conteriam o valor zero.

Representação gráfica das comparações múltiplas

A função `plot`, aplicada ao resultado da função `TukeyHSD`, permite visualizar os intervalos de confiança para as comparações das médias de nível.

Tukey nos lírios (cont.)

```
> plot(TukeyHSD(aov(Sepal.Width ~ Species, data=iris)))
```



Representação gráfica das comparações múltiplas

Usando `library(agricolae)` e a função `HSD.test`, também se obtêm as comparações das médias de nível.

Tukey nos lírios (cont.)

```
> iris.aov<-aov(Sepal.Width ~ Species, data=iris)
> library (agricolae)
> HSD.test(iris.aov, "Species",console=TRUE)
```

--

Critical Value of Studentized Range: 3.348424


Minimun Significant Difference: 0.1608553

Treatments with the same letter are not significantly different.

	Sepal.Width	groups
setosa	3.428	a
virginica	2.974	b
versicolor	2.770	c

Delineamentos não equilibrados

Quando o delineamento da ANOVA a um Factor não é equilibrado (isto é, existe diferente número de observações nos vários níveis do factor), os teste/ICs de Tukey agora enunciados não são, em rigor, válidos.

Mas, para delineamentos em que o desequilíbrio no número de observações não seja muito acentuado, é possível um resultado aproximado, que a função TukeyHSD do  incorpora.

Análise de Resíduos na ANOVA a 1 Factor

A validade dos pressupostos do modelo estuda-se de forma idêntica ao que foi visto na Regressão Linear, tal como os diagnósticos para observações especiais. Mas há **algumas particularidades**.

Numa ANOVA a um factor, os resíduos aparecem empilhados em k colunas nos gráficos de e_{ij} vs. \hat{y}_{ij} , porque qualquer valor ajustado $\hat{y}_{ij} = \bar{y}_i$ é igual para observações num mesmo nível do factor.

Este padrão **não** corresponde a qualquer violação dos pressupostos do modelo.


Por outro lado, **todas as observações dum mesmo nível do factor terão idêntico efeito alavanca, igual a $\frac{1}{n_i}$** . Sobretudo no caso de delineamentos equilibrados, isto torna os gráficos de efeitos alavanca pouco úteis neste contexto.

Análise de Resíduos na ANOVA a 1 Factor (cont.)

Padrão de resíduos numa ANOVA a 1 Factor.

Gráfico de resíduos nos lírios

```
> plot(aov(Sepal.Width ~ Species, data=iris), which=1, pch=16)
```



Estes gráficos continuam a ser úteis para validar o pressuposto de homogeneidade de variâncias dos erros aleatórios.

Violações aos pressupostos da ANOVA

As n_i repetições em cada um dos k níveis do factor, permitem **testar formalmente se as variâncias dos erros aleatórios diferem entre os níveis do factor** (testes de Bartlett ou de Levene, que não são dados).

Violações aos pressupostos do modelo não têm sempre igual gravidade. Alguns comentários gerais:

- O teste F da ANOVA e as comparações múltiplas de Tukey são **relativamente robustos a desvios à hipótese de normalidade**.
- As **violações ao pressuposto de variâncias homogêneas são em geral menos graves no caso de delineamentos equilibrados**, mas podem ser graves em delineamentos não equilibrados.
- A **falta de independência entre erros aleatórios é a violação mais grave dos pressupostos** e deve ser evitada, o que é em geral possível com um delineamento experimental adequado.

Uma advertência

Na formulação clássica do modelo ANOVA a um Factor, e a partir da equação-base

$$Y_{ij} = \mu + \alpha_i + \varepsilon_{ij}, \quad \forall i, j$$

em vez de impor a condição $\alpha_1 = 0$, impõe-se a condição $\sum_i \alpha_i = 0$.

Esta condição alternativa:

- Muda a forma de interpretar os parâmetros (μ é agora uma espécie de **média geral de Y** e α_i o desvio da média do nível i em relação a essa média geral);
- Muda os estimadores dos parâmetros.
- **Não** muda o resultado do teste F à existência de efeitos do factor, nem a qualidade global do ajustamento.

Delineamentos factoriais a dois factores

Vamos agora considerar delineamentos experimentais com dois factores.

A existência de mais do que um factor pode resultar de:

- pretender-se realmente estudar eventuais efeitos de mais do que um factor sobre a variável resposta;
- a tentativa de controlar a variabilidade experimental.

Historicamente, à segunda situação corresponde a designação **blocos**. Na primeira fala-se apenas em factores. Mas são situações análogas.

Um exemplo

Pretende-se analisar o rendimento de 5 diferentes variedades de trigo. Os rendimentos são também afectados pelos tipo de solos usados.

Nem sempre é possível ter terrenos homogéneos numa experiência. Mesmo que seja possível, pode não ser desejável, por se limitar a validade dos resultados a um único tipo de solos.

Admita-se que estamos interessados em quatro terrenos, com solos diferentes. Cada terreno pode ser dividido em cinco parcelas viáveis para o trigo, tendo-se ao todo 20 parcelas.

Em vez de repartir aleatoriamente as 5 variedades pelas 20 parcelas, é preferível forçar cada tipo de terreno a conter uma parcela com cada variedade. Apenas dentro dos terrenos haverá casualização.

Um exemplo (cont.)

A situação descrita no acetato anterior é a seguinte:

Terreno 1	Var.1	Var.3	Var.4	Var.5	Var.2
-----------	-------	-------	-------	-------	-------

Terreno 2	Var.4	Var.3	Var.5	Var.1	Var.2
-----------	-------	-------	-------	-------	-------

Terreno 3	Var.2	Var.4	Var.1	Var.3	Var.5
-----------	-------	-------	-------	-------	-------

Terreno 4	Var.5	Var.2	Var.4	Var.1	Var.3
-----------	-------	-------	-------	-------	-------

Houve uma **restrição à casualização total**: dentro de cada terreno há casualização, mas obriga-se cada terreno a ter uma parcela associada a cada nível do factor **variedade**.

A situação agora descrita corresponde a ter introduzido **um segundo factor**, o **factor terreno**. Neste exemplo temos um **delineamento factorial a dois factores** (*two-way ANOVA*), sendo um dos factores a **variedade de trigo** e o outro o **tipo de solos**.

Representação delineamento factorial (2 factores)

Um **delineamento factorial** é um delineamento em que **há observações para todas as possíveis combinações de níveis de cada factor**.

		Factor B				
Níveis		B_1	B_2	B_3	...	B_b
FACTOR A	A_1	× × ×	× × ×	× × ×	...	× × ×
	A_2	× × ×	× × ×	× × ×	...	× × ×
	A_3	× × ×	× × ×	× × ×	...	× × ×
	⋮	⋮	⋮	⋮	⋮	⋮
	A_a	× × ×	× × ×	× × ×	...	× × ×

Atenção: Esta esquematização **não** corresponde a qualquer organização **espacial**.

Célula: cruzamento dum nível dum Factor com um nível do outro Factor. Corresponde a uma **situação experimental**. Nesta esquematização, há **ab células**, cada uma com 3 observações.

Modelos ANOVA a 2 Factores: notação

Admita-se a existência de:

- Uma **variável resposta** Y ;
- Um **Factor A**, com a níveis;
- Um **Factor B**, com b níveis;
- n observações, com pelo menos uma em cada uma das **ab situações experimentais (células)**.

O número de observações na célula correspondente ao nível i do factor A, e j do factor B é representado por **n_{ij}** .

O número total de observações é:
$$n = \sum_{i=1}^a \sum_{j=1}^b n_{ij}.$$

Notação

Cada observação da variável resposta é identificada com **três índices**,

$$Y_{ijk}$$

onde:

- i indica o **nível i do Factor A** ($i = 1, 2, \dots, a$).
- j indica o **nível j do Factor B** ($j = 1, 2, \dots, b$).
- k indica a **repetição k na célula (i, j)** ($k = 1, 2, \dots, n_{ij}$).

Delineamento equilibrado

Se o número de observações for igual em todas as células, $n_{ij} = n_c, \forall i, j$, estamos perante um **delineamento equilibrado**.

Estudaremos **dois diferentes modelos ANOVA** para um delineamento **factorial com 2 factores**.

Modelo ANOVA a 2 factores (sem interacção)

Um **primeiro modelo** prevê a existência de dois diferentes tipos de efeitos associados aos níveis de cada factor. Admite-se que o **valor esperado de cada observação** Y_{ijk} é da forma:

$$E[Y_{ijk}] = \mu_{ij} = \mu + \alpha_i + \beta_j, \quad \forall i, j, k.$$

O parâmetro μ é **comum** a todas as observações.

Cada parâmetro α_i é um **acréscimo** que pode diferir entre níveis do Factor A, e é designado o **efeito do nível i do factor A**.

Cada parâmetro β_j é um **acréscimo** que pode diferir entre níveis do Factor B, e é designado o **efeito do nível j do factor B**.

Admite-se que todos estes parâmetros são **constantes**.

Admite-se que **a variação de Y_{ijk} em torno do seu valor médio é aleatória** e dada por um **erro aleatório** aditivo, ε_{ijk} (com $E[\varepsilon_{ijk}] = 0$):

$$Y_{ijk} = \mu + \alpha_i + \beta_j + \varepsilon_{ijk},$$

As variáveis indicatrizes de nível de cada factor

A equação de base do modelo ANOVA a 2 factores (sem interacção) também pode ser escrita na forma vectorial, recorrendo a **variáveis indicatrizes de pertença a cada nível de cada factor**.

\vec{Y} o vector **aleatório** n -dimensional com a totalidade das observações da variável resposta.

$\vec{1}_n$ o vector de n uns.

$\vec{\mathcal{I}}_{A_i}$ a **variável indicatriz de pertença ao nível i do Factor A**.

$\vec{\mathcal{I}}_{B_j}$ a **variável indicatriz de pertença ao nível j do Factor B**.

$\vec{\varepsilon}$ o vector **aleatório** dos n erros aleatórios.

A equação-base em notação vectorial (cont.)

Se se admitissem efeitos para **todos** os níveis de ambos os factores, temos a equação-base:

$$\vec{Y} = \mu \vec{1}_n + \alpha_1 \vec{\mathcal{J}}_{A_1} + \alpha_2 \vec{\mathcal{J}}_{A_2} + \dots + \alpha_a \vec{\mathcal{J}}_{A_a} + \beta_1 \vec{\mathcal{J}}_{B_1} + \beta_2 \vec{\mathcal{J}}_{B_2} + \dots + \beta_b \vec{\mathcal{J}}_{B_b} + \vec{\varepsilon}$$

A matriz do modelo **X** definida com base nesta equação teria como colunas os vectores $\vec{1}_n, \vec{\mathcal{J}}_{A_1}, \vec{\mathcal{J}}_{A_2}, \dots, \vec{\mathcal{J}}_{A_a}, \vec{\mathcal{J}}_{B_1}, \vec{\mathcal{J}}_{B_2}, \dots, \vec{\mathcal{J}}_{B_b}$.

Nessa matriz haveria dependências lineares por duas diferentes razões:

- a soma das indicatrizes do Factor A daria a coluna dos uns, $\vec{1}_n$;
- a soma das indicatrizes do Factor B daria a coluna dos uns, $\vec{1}_n$.

Agora, **são necessárias duas** restrições aos parâmetros, não podendo estimar-se parâmetros α_i e β_j para todos os níveis de cada Factor.

A matriz \mathbf{X} sem restrições no modelo

$$\mathbf{X} = \left[\begin{array}{c|ccc|ccc} 1 & 1 & 0 & \dots & 0 & 1 & 0 & \dots & 0 \\ 1 & 1 & 0 & \dots & 0 & 1 & 0 & \dots & 0 \\ 1 & 1 & 0 & \dots & 0 & 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & 0 & \dots & 0 & 0 & 0 & \dots & 1 \\ 1 & 1 & 0 & \dots & 0 & 0 & 0 & \dots & 1 \\ \hline 1 & 0 & 1 & \dots & 0 & 1 & 0 & \dots & 0 \\ 1 & 0 & 1 & \dots & 0 & 1 & 0 & \dots & 0 \\ 1 & 0 & 1 & \dots & 0 & 1 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & 0 & 1 & \dots & 0 & 0 & 0 & \dots & 1 \\ 1 & 0 & 1 & \dots & 0 & 0 & 0 & \dots & 1 \\ \hline \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots \\ \hline 1 & 0 & 0 & \dots & 1 & 1 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & 0 & 0 & \dots & 1 & 0 & 0 & \dots & 1 \\ 1 & 0 & 0 & \dots & 1 & 0 & 0 & \dots & 1 \end{array} \right]$$

\uparrow
 $\vec{\mathbf{1}}_n$

\uparrow
 $\vec{\mathcal{J}}_{A_1}$

\uparrow
 $\vec{\mathcal{J}}_{A_2}$

\dots

\uparrow
 $\vec{\mathcal{J}}_{A_a}$

\uparrow
 $\vec{\mathcal{J}}_{B_1}$

\uparrow
 $\vec{\mathcal{J}}_{B_2}$

\dots

\uparrow
 $\vec{\mathcal{J}}_{B_b}$

A exclusão da coluna $\vec{\mathbf{1}}_n$ não resolve o problema.

Equação em notação vectorial, com restrições

Excluimos da equação do modelo as parcelas associadas ao primeiro nível de cada Factor, isto é, impõem-se as duas restrições:

$$\alpha_1 = 0 \quad \text{e} \quad \beta_1 = 0 ,$$

o que corresponde a excluir as colunas $\vec{\mathcal{J}}_{A_1}$ e $\vec{\mathcal{J}}_{B_1}$ da matriz \mathbf{X} .

A equação-base do modelo ANOVA a 2 Factores, sem interacção, fica:

$$\vec{\mathbf{Y}} = \mu \vec{\mathbf{1}}_n + \alpha_2 \vec{\mathcal{J}}_{A_2} + \dots + \alpha_a \vec{\mathcal{J}}_{A_a} + \beta_2 \vec{\mathcal{J}}_{B_2} + \dots + \beta_b \vec{\mathcal{J}}_{B_b} + \vec{\boldsymbol{\varepsilon}}$$

O parâmetro μ fica o valor esperado das observações na célula (1, 1):

$$Y_{11k} = \mu + \varepsilon_{11k} \quad \Rightarrow \quad E[Y_{11k}] = \mu = \mu_{11} .$$

A matriz do delineamento na ANOVA a 2 Factores (sem interacção), com as restrições $\alpha_1 = 0$ e $\beta_1 = 0$

$$\mathbf{X} = \left[\begin{array}{c|ccc|ccc}
 1 & 0 & \dots & 0 & 0 & \dots & 0 \\
 1 & 0 & \dots & 0 & 0 & \dots & 0 \\
 1 & 0 & \dots & 0 & 1 & \dots & 0 \\
 \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\
 1 & 0 & \dots & 0 & 0 & \dots & 1 \\
 1 & 0 & \dots & 0 & 0 & \dots & 1 \\
 \hline
 1 & 1 & \dots & 0 & 0 & \dots & 0 \\
 1 & 1 & \dots & 0 & 0 & \dots & 0 \\
 1 & 1 & \dots & 0 & 0 & \dots & 0 \\
 \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\
 1 & 1 & \dots & 0 & 0 & \dots & 1 \\
 1 & 1 & \dots & 0 & 0 & \dots & 1 \\
 \hline
 \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\
 \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\
 \hline
 1 & 0 & \dots & 1 & 0 & \dots & 0 \\
 \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\
 1 & 0 & \dots & 1 & 0 & \dots & 1 \\
 1 & 0 & \dots & 1 & 0 & \dots & 1
 \end{array} \right]$$

\uparrow
 $\vec{1}_n$

\uparrow
 $\vec{\mathcal{J}}_{A_2}$

\dots

\uparrow
 $\vec{\mathcal{J}}_{A_a}$

\uparrow
 $\vec{\mathcal{J}}_{B_2}$

\dots

\uparrow
 $\vec{\mathcal{J}}_{B_b}$

O modelo ANOVA a dois factores, sem interacção

Juntando os pressupostos necessários à inferência,

Modelo ANOVA a dois factores, sem interacção

Existem n observações, Y_{ijk} , n_{ij} das quais associadas à célula (i,j) ($i = 1, \dots, a; j = 1, \dots, b$). Tem-se:

- 1 $Y_{ijk} = \mu_{11} + \alpha_i + \beta_j + \varepsilon_{ijk}$, $\forall i=1, \dots, a; j=1, \dots, b; k=1, \dots, n_{ij}$ ($\alpha_1 = 0; \beta_1 = 0$).
- 2 $\varepsilon_{ijk} \sim \mathcal{N}(0, \sigma^2)$, $\forall i, j, k$
- 3 $\{\varepsilon_{ijk}\}_{i,j,k}$ v.a.s independentes.

O modelo tem $a + b - 1$ parâmetros desconhecidos:

- o parâmetro μ_{11} ;
- os $a-1$ acréscimos α_i ($i > 1$); e
- os $b-1$ acréscimos β_j ($j > 1$).

Testando a existência de efeitos

Um teste de ajustamento global do modelo tem como hipótese nula que **todos** os efeitos, quer do factor A, quer do Factor B são simultaneamente nulos, mas **não distingue entre os efeitos de cada factor**.

Mais útil será **testar separadamente a existência dos efeitos de cada factor**. Seria útil dispôr de **dois** testes, para as hipóteses:

- Teste I: $H_0 : \alpha_i = 0, \quad \forall i = 2, \dots, a ;$
- Teste II: $H_0 : \beta_j = 0, \quad \forall j = 2, \dots, b.$

Teste aos efeitos do Factor B

O modelo ANOVA a 2 Factores, sem interacção (Acetato 280) tem equação vectorial:

$$\vec{Y} = \mu \vec{1}_n + \alpha_2 \vec{\mathcal{J}}_{A_2} + \dots + \alpha_a \vec{\mathcal{J}}_{A_a} + \beta_2 \vec{\mathcal{J}}_{B_2} + \dots + \beta_b \vec{\mathcal{J}}_{B_b} + \vec{\epsilon}$$

Sendo um Modelo Linear pode-se aplicar a teoria conhecida para este tipo de modelos e testar as hipóteses:

$$H_0 : \beta_j = 0, \quad \forall j = 2, \dots, b \quad \text{vs.} \quad H_1 : \exists j \text{ tal que } \beta_j \neq 0,$$

através dum teste F parcial comparando o modelo completo

$$(\text{Modelo } M_{A+B}) \quad Y_{ijk} = \mu_{11} + \alpha_i + \beta_j + \epsilon_{ijk},$$

com o submodelo de equação de base

$$(\text{Modelo } M_A) \quad Y_{ijk} = \mu_{11} + \alpha_i + \epsilon_{ijk},$$

que é um modelo ANOVA a 1 Factor (factor A).

A construção do teste aos efeitos do Factor B

Assim,

- Ajusta-se o modelo completo M_{A+B} e o submodelo M_A .
- Obtêm-se as respectivas Somas de Quadrados Residuais, que designamos $SQRE_{A+B}$ e $SQRE_A$.
- Efectua-se o teste F parcial indicado. A estatística de teste é:

$$\text{(Efeitos Factor B)} \quad F = \frac{\overbrace{SQRE_A - SQRE_{A+B}}^{=SQB}}{b-1} \bigg/ \frac{SQRE_{A+B}}{n-(a+b-1)} = \frac{QMB}{QMRE}$$

definindo $QMB = \frac{SQB}{b-1} = \frac{SQRE_A - SQRE_{A+B}}{b-1}$.

- F tem distribuição $F_{[b-1, n-(a+b-1)]}$ sob $H_0 : \beta_j = 0, \forall j$.

A construção do teste aos efeitos do Factor A

Consideremos também um teste aos efeitos do Factor A, definido de forma um pouco diferente.

Defina-se:

- $SQA = SQF_A$, a Soma de Quadrados do Factor no Modelo M_A ;
- $QMA = \frac{SQA}{a-1}$, o Quadrado Médio do Factor no Modelo M_A ;
- $SQRE_{A+B}$ e $QMRE = \frac{SQRE_{A+B}}{n-(a+b-1)}$, como antes.

É possível provar que, caso $\alpha_i = 0, \forall i=2,\dots,a$, a estatística

$$F = \frac{QMA}{QMRE} = \frac{\frac{SQA}{a-1}}{\frac{SQRE_{A+B}}{n-(a+b-1)}}$$

tem distribuição $F_{(a-1, n-(a+b-1))}$.

O Teste F aos efeitos do factor A

Sendo válido o Modelo de ANOVA a dois factores, sem interacção:

Teste F aos efeitos do factor A

Hipóteses: $H_0 : \alpha_i = 0 \quad \forall i=2,\dots,a$ vs. $H_1 : \exists i=2,\dots,a \text{ t.q. } \alpha_i \neq 0$.
[A NÃO AFECTA Y] vs. [A AFECTA Y]


Estatística do Teste: $F = \frac{QMA}{QMRE} \curvearrowright F_{(a-1, n-(a+b-1))}$ se H_0 .

Nível de significância do teste: α

Região Crítica (Região de Rejeição): Unilateral direita

Rejeitar H_0 se

$$F_{calc} > f_{\alpha(a-1, n-(a+b-1))}$$



O Teste F aos efeitos do factor B

Sendo válido o Modelo de ANOVA a dois factores, sem interacção:

Teste F aos efeitos do factor B

Hipóteses: $H_0 : \beta_j = 0 \quad \forall j=2,\dots,b$ vs. $H_1 : \exists j=2,\dots,b \text{ t.q. } \beta_j \neq 0.$
[B NÃO AFECTA Y] vs. [B AFECTA Y]


Estatística do Teste: $F = \frac{QMB}{QMRE} \sim F_{(b-1, n-(a+b-1))}$ se H_0 .

Nível de significância do teste: α

Região Crítica (Região de Rejeição): Unilateral direita

Rejeitar H_0 se

$$F_{calc} > f_{\alpha}(b-1, n-(a+b-1))$$



A nova decomposição de SQT

Tendo em conta as Somas de Quadrados antes definidas, tem-se:

$$SQB = SQRE_A - SQRE_{A+B}$$

$$SQA = SQF_A = SQT - SQRE_A$$

Somando estas SQs a $SQRE_{A+B}$, obtém-se:

A decomposição de SQT


$$SQA + SQB + SQRE_{A+B} = SQT$$

que é uma **nova decomposição de SQT** , em três parcelas, associadas ao facto de haver agora dois factores com efeitos previstos no modelo, mais a variabilidade residual.


Quadro-resumo ANOVA a 2 Factores (sem interacção)

Fonte	g.l.	SQ	QM	f_{calc}
Factor A	$a - 1$	$SQA = SQF_A$	$QMA = \frac{SQA}{a-1}$	$\frac{QMA}{QMRE}$
Factor B	$b - 1$	$SQB = SQRE_A - SQRE_{A+B}$	$QMB = \frac{SQB}{b-1}$	$\frac{QMB}{QMRE}$
Resíduos	$n - (a + b - 1)$	$SQRE = SQRE_{A+B}$	$QMRE = \frac{SQRE}{n - (a + b - 1)}$	
Total	$n - 1$	$SQT = (n - 1) s_y^2$	—	—

ANOVA a dois Factores, sem interacção no

Para efectuar uma ANOVA a dois Factores (sem interacção) no , convém **organizar os dados numa `data.frame` com três colunas:**

- 1 uma para os valores (numéricos) da variável resposta;
- 2 outra para o **factor** A (com a indicação dos seus níveis);
- 3 outra para o **factor** B (com a indicação dos seus níveis).

As fórmulas utilizadas no  para indicar uma ANOVA a dois Factores, sem interacção, são semelhantes às usadas na Regressão Linear com dois preditores, devendo o nome dos dois factores ser separado pelo símbolo **+**:

$$y \sim fA + fB$$

Um exemplo clássico: os rendimentos de cevada

O rendimento de $a=5$ variedades de cevada (*manchuria*, *svansota*, *velvet*, *trebi* e *peatland*) foi registado em $b=6$ diferentes localidades^a. Em cada localidade foi semeada (com casualização) uma parcela com cada variedade ($n=30$).

```
> summary(aov(Y1 ~ Var + Loc, data=immer))
```

	Df	Sum Sq	Mean Sq	F value	Pr(>F)	
Var	4	2756.6	689.2	4.2309	0.01214	*
Loc	5	17829.8	3566.0	21.8923	1.751e-07	***
Residuals	20	3257.7	162.9			

Há indicação de efeitos significativos (ao nível $\alpha=0.05$) entre variedades e muito significativos entre localidades. Num modelo ignorando os efeitos de localidades, desaparecia a significância dos efeitos de variedade:

```
> summary(aov(Y1 ~ Var, data=immer))
```

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
Var	4	2756.6	689.2	0.817	0.5264
Residuals	25	21087.6	843.5		

^a Dados em Immer, Hayes e LeRoy Powers, Statistical adaptation of barley varietal adaptation, Journal of the American Society for Agronomy, 26, 403-419, 1934.

Trocando a ordem dos factores

Atenção: A forma como foram definidas as Somas de Quadrados de cada factor é diferente: $SQB = SQRE_A - SQRE_{A+B}$ e $SQA = SQF_A$.

A troca do papel dos factores A e B produz resultados diferentes em delineamentos não equilibrados. Designando por M_B o modelo ANOVA a um factor, mas apenas com o factor que temos chamado B, tem-se:

$$SQB = SQF_B = SQT - SQRE_B$$

$$SQA = SQRE_B - SQRE_{A+B} .$$

Continua a ser verdade que SQT se pode decompor na forma

$$SQT = SQA + SQB + SQRE_{A+B} .$$

Justificam-se testes análogos aos dos acetatos 285 e 286. Mas as duas formas alternativas de definir SQA e SQB apenas produzem resultados iguais no caso de delineamentos equilibrados, pelo que só nesse caso a ordem dos factores é arbitrária. (Ver também o Ex. ANOVA 9)

As várias médias amostrais

Sejam, num delineamento equilibrado:

$\overline{Y}_{i..}$ a média amostral das $b n_c$ observações do nível i do Factor A,
$$\overline{Y}_{i..} = \frac{1}{b n_c} \sum_{j=1}^b \sum_{k=1}^{n_c} Y_{ijk}$$

$\overline{Y}_{.j.}$ a média amostral das $a n_c$ observações do nível j do Factor B,
$$\overline{Y}_{.j.} = \frac{1}{a n_c} \sum_{i=1}^a \sum_{k=1}^{n_c} Y_{ijk}$$

$\overline{Y}_{...}$ a média amostral da totalidade das $n = a b n_c$ observações,
$$\overline{Y}_{...} = \frac{1}{n} \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^{n_c} Y_{ijk}.$$

SQA e SQB em delineamentos equilibrados

Num **delineamento equilibrado**, SQA é igual à Soma de Quadrados do Factor (SQF_A) do Modelo M_A , apenas com o Factor A (acetato 284).

Nesse modelo, os valores ajustados são $\hat{Y}_{ijk} = \bar{Y}_{i..}$ (acetato 240). Assim, num **delineamento equilibrado**, tem-se:

$$SQF_A = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^{n_c} (\underbrace{\hat{Y}_{ijk}}_{=\bar{Y}_{i..}} - \bar{Y}_{...})^2 = bn_c \cdot \sum_{i=1}^a (\bar{Y}_{i..} - \bar{Y}_{...})^2 = SQA .$$

Da mesma forma, num **delineamento equilibrado**, SQB é a Soma de Quadrados do Factor (SQF_B) do Modelo M_B , apenas com o Factor B. Nesse modelo, os valores ajustados são $\hat{Y}_{ijk} = \bar{Y}_{.j.}$, logo:

$$SQF_B = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^{n_c} (\underbrace{\hat{Y}_{ijk}}_{=\bar{Y}_{.j.}} - \bar{Y}_{...})^2 = an_c \cdot \sum_{j=1}^b (\bar{Y}_{.j.} - \bar{Y}_{...})^2 = SQB .$$

Fórmulas para delineamentos equilibrados (cont.)

Se o delineamento é equilibrado, ou seja, $n_{ij} = n_c$, $\forall i, j$, tem-se:

- $\hat{\mu}_{11} = \bar{Y}_{1..} + \bar{Y}_{.1.} - \bar{Y}_{...}$
- $\hat{\alpha}_i = \bar{Y}_{i..} - \bar{Y}_{1..}$
- $\hat{\beta}_j = \bar{Y}_{.j.} - \bar{Y}_{.1.}$

Tendo em conta a equação base do Modelo, os valores ajustados de cada observação dependem apenas das médias dos respectivos níveis em cada factor e da média geral de todas as observações:

$$\hat{Y}_{ijk} = \hat{\mu}_{11} + \hat{\alpha}_i + \hat{\beta}_j = \bar{Y}_{i..} + \bar{Y}_{.j.} - \bar{Y}_{...}, \quad \forall i, j, k$$

Aviso: Ao contrário do que sucede na ANOVA a um factor, os valores ajustados \hat{Y}_{ijk} não são a média das observações de Y na célula (i, j) .

O quadro-resumo da ANOVA a 2 Factores (sem interacção; delineamento equilibrado)

Fonte	g.l.	SQ	QM	f_{calc}
Factor A	$a - 1$	$SQA = bn_c \cdot \sum_{i=1}^a (\bar{y}_{i..} - \bar{y}_{...})^2$	$QMA = \frac{SQA}{a-1}$	$\frac{QMA}{QMRE}$
Factor B	$b - 1$	$SQB = an_c \cdot \sum_{j=1}^b (\bar{y}_{.j.} - \bar{y}_{...})^2$	$QMB = \frac{SQB}{b-1}$	$\frac{QMB}{QMRE}$
Resíduos	$n - (a + b - 1)$	$SQRE = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^{n_c} [y_{ijk} - (\bar{y}_{i..} + \bar{y}_{.j.} - \bar{y}_{...})]^2$	$QMRE = \frac{SQRE}{n - (a + b - 1)}$	
Total	$n - 1$	$SQT = (n - 1) s_y^2$	—	—

A interpretação dos parâmetros

A interpretação do significado dos parâmetros do modelo depende da convenção usada para resolver o problema da multicolinearidade das colunas da matriz \mathbf{X} .

Vejamos a interpretação dos parâmetros resultante da convenção $\alpha_1 = \beta_1 = 0$.

Uma observação de Y efectuada na célula $(1, 1)$, correspondente ao cruzamento do primeiro nível de cada factor, será da forma:

$$Y_{11k} = \mu_{11} + \underbrace{\alpha_1}_{=0} + \underbrace{\beta_1}_{=0} + \varepsilon_{11k} \quad \implies \quad E[Y_{11k}] = \mu_{11}$$

O parâmetro μ_{11} corresponde ao valor esperado da variável resposta Y na célula cujas indicatrizes foram excluídas da matriz do delineamento.

A interpretação dos parâmetros α_i

Uma observação de Y efectuada na célula $(i, 1)$, com $i > 1$ (cruzamento dum nível do factor A diferente do primeiro, com o primeiro nível do Factor B) é da forma:

$$Y_{i1k} = \mu_{11} + \alpha_i + \underbrace{\beta_1}_{=0} + \varepsilon_{i1k} \quad \Rightarrow \quad \mu_{i1} = E[Y_{i1k}] = \mu_{11} + \alpha_i$$

O parâmetro $\alpha_i = \mu_{i1} - \mu_{11}$ corresponde ao acréscimo no valor esperado da variável resposta Y associado a observações do nível $i > 1$ do Factor A (relativamente às observações do primeiro nível do Factor A), quando $j = 1$. Designa-se o efeito do nível i do factor A.

Interpretação dos parâmetros α_i

Tabela com médias populacionais de célula (situação experimental):

		Factor B				
Níveis		B_1	B_2	B_3	\dots	B_b
FACTOR A	A_1	μ_{11}	μ_{12}	μ_{13}	\dots	μ_{1b}
	A_2	$\mu_{21} = \mu_{11} + \alpha_2$	μ_{22}	μ_{23}	\dots	μ_{2b}
	A_3	$\mu_{31} = \mu_{11} + \alpha_3$	μ_{32}	μ_{33}	\dots	μ_{3b}
	\vdots	\vdots	\vdots	\vdots	\ddots	\vdots
	A_a	$\mu_{a1} = \mu_{11} + \alpha_a$	μ_{a2}	μ_{a3}	\dots	μ_{ab}

A interpretação dos parâmetros β_j

Uma observação de Y efectuada na célula $(1,j)$, com $j > 1$ (cruzamento do primeiro nível do factor A com um nível do Factor B diferente do primeiro) é da forma:

$$Y_{1jk} = \mu_{11} + \underbrace{\alpha_1}_{=0} + \beta_j + \varepsilon_{1jk} \quad \Rightarrow \quad \mu_{1j} = E[Y_{1jk}] = \mu_{11} + \beta_j$$

O parâmetro $\beta_j = \mu_{1j} - \mu_{11}$ corresponde ao acréscimo no valor esperado da variável resposta Y associado a observações do nível j do Factor B (relativamente às observações do primeiro nível do Factor B), quando $i = 1$. Designa-se o efeito do nível j do factor B.

Interpretação dos parâmetros β_j

Tabela com médias populacionais de célula (situação experimental):

		Factor B				
Níveis		B_1	B_2	B_3	...	B_b
Factor A	A_1	μ_{11}	$\mu_{12} = \mu_{11} + \beta_2$	$\mu_{13} = \mu_{11} + \beta_3$...	$\mu_{1b} = \mu_{11} + \beta_b$
	A_2	μ_{21}	μ_{22}	μ_{23}	...	μ_{2b}
	A_3	μ_{31}	μ_{32}	μ_{33}	...	μ_{3b}
	\vdots	\vdots	\vdots	\vdots	\ddots	\vdots
	A_a	μ_{a1}	μ_{a2}	μ_{a3}	...	μ_{ab}

Observações de Y no caso geral

Mas este modelo é pouco flexível: não existem mais parâmetros e os valores esperados nas restantes células já estão fixados.

Para observações de Y efectuadas numa célula genérica (i,j) , com $i > 1$ e $j > 1$, tem-se:

$$Y_{ijk} = \mu_{11} + \alpha_i + \beta_j + \varepsilon_{ijk} \quad \Longrightarrow \quad \mu_{ij} = E[Y_{ijk}] = \mu_{11} + \alpha_i + \beta_j.$$

Todas as parcelas destes valores esperados de Y já foram usados. Não há flexibilidade para descrever as médias de células com $i > 1$ e $j > 1$.

Um modelo sem efeitos de interacção é utilizado sobretudo quando existe uma única observação em cada célula, i.e., $n_{ij} = 1, \forall i,j$.

Modelos com interacção

Um modelo ANOVA a 2 Factores, **sem interacção**, foi considerado para um **delineamento factorial**, isto é, em que se cruzam todos os níveis de um e outro factor. Mas **trata-se dum modelo pouco flexível**.

Na presença de **repetições nas células**, a forma mais natural de modelar um delineamento com dois factores é a de prever a existência de **um terceiro tipo de efeitos**: os **efeitos de interacção**.

A ideia é incorporar na equação base do modelo para Y_{ijk} uma parcela $(\alpha\beta)_{ij}$ que permita que em cada célula haja um **efeito específico associado à combinação dos níveis i do Factor A e j do Factor B**:

$$Y_{ijk} = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \varepsilon_{ijk} .$$

Os valores esperados de Y_{ijk} (modelo com interacção)

Vamos admitir as seguintes restrições aos parâmetros:

$$\alpha_1 = 0 \quad ; \quad \beta_1 = 0 \quad ; \quad (\alpha\beta)_{1j} = 0, \forall j \quad ; \quad (\alpha\beta)_{i1} = 0, \forall i.$$

Tem-se, a partir da equação $Y_{ijk} = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \varepsilon_{ijk}$:

- Para a primeira célula ($i = j = 1$): $\mu_{11} = E[Y_{11k}] = \mu$.
- Nas restantes células $(1, j)$ do primeiro nível do Factor A:
 $\mu_{1j} = E[Y_{1jk}] = \mu_{11} + \beta_j$.
- Nas restantes células $(i, 1)$ do primeiro nível do Factor B:
 $\mu_{i1} = E[Y_{i1k}] = \mu_{11} + \alpha_i$.
- Nas células genéricas (i, j) , com $i > 1$ e $j > 1$,
 $\mu_{ij} = E[Y_{ijk}] = \mu_{11} + \alpha_i + \beta_j + (\alpha\beta)_{ij}$.

Os efeitos α_i e β_j designam-se efeitos principais de cada Factor.

Os valores esperados de Y_{ijk} (modelo com interacção)

Efeito das restrições $\alpha_1 = 0$; $\beta_1 = 0$; $(\alpha\beta)_{ij} = 0$ se $i = 1$ ou $j = 1$:

		Factor B				
Níveis		B_1	B_2	B_3	...	B_b
FACTOR A	A_1	x x x	x x x	x x x	...	x x x
	A_2	x x x	x x x	x x x	. . .	x x x
	A_3	x x x	x x x	x x x	. . .	x x x
	\vdots	\vdots	\vdots	\vdots	\ddots	\vdots
	A_a	x x x	x x x	x x x	. . .	x x x

As observações que **não** estão associadas a A_1 (primeira linha) têm **efeitos** α_j .

As observações que **não** estão associadas a B_1 (primeira coluna) têm **efeitos** β_j .

As observações que **não** são da primeira coluna nem da primeira linha têm **efeitos de interacção** $(\alpha\beta)_{ij}$.

O modelo ANOVA a dois factores, com interacção

Juntando os pressupostos necessários à inferência,

Modelo ANOVA a dois factores, com interacção (Modelo M_{A*B})

Existem n observações, Y_{ijk} , n_{ij} das quais associadas à célula (i,j) ($i = 1, \dots, a; j = 1, \dots, b$). Tem-se:

- 1 $Y_{ijk} = \mu_{11} + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \varepsilon_{ijk}$, $\forall i=1, \dots, a; j=1, \dots, b; k=1, \dots, n_{ij}$
($\alpha_1=0; \beta_1=0; (\alpha\beta)_{ij}=0$, se $i=1$ e/ou $j=1$).
- 2 $\varepsilon_{ijk} \sim \mathcal{N}(0, \sigma^2)$
- 3 $\{\varepsilon_{ijk}\}_{i,j,k}$ v.a.s independentes.

O modelo tem **ab parâmetros** desconhecidos:

- a **1** média da célula de referência, μ_{11} ;
- os **$a-1$** acréscimos α_i ($i > 1$);
- os **$b-1$** acréscimos β_j ($j > 1$); e
- os **$(a-1)(b-1)$** efeitos de interacção $(\alpha\beta)_{ij}$, para $i > 1, j > 1$.

Variáveis indicatrizes de célula

A **versão vectorial** da equação do modelo com interacção associa os novos efeitos $(\alpha\beta)_{ij}$ a **variáveis indicatrizes** das respectivas células.

A equação-base do modelo ANOVA a 2 Factores, com interacção, é:

$$\begin{aligned}\vec{Y} = & \mu \vec{1}_n + \alpha_2 \vec{\mathcal{I}}_{A_2} + \dots + \alpha_a \vec{\mathcal{I}}_{A_a} + \beta_2 \vec{\mathcal{I}}_{B_2} + \dots + \beta_b \vec{\mathcal{I}}_{B_b} + \\ & + (\alpha\beta)_{22} \vec{\mathcal{I}}_{A_2:B_2} + (\alpha\beta)_{23} \vec{\mathcal{I}}_{A_2:B_3} + \dots + (\alpha\beta)_{ab} \vec{\mathcal{I}}_{A_a:B_b} + \vec{\epsilon}\end{aligned}$$

onde $\vec{\mathcal{I}}_{A_i:B_j}$ representa a **variável indicatriz da célula** correspondente ao nível i do Factor A e nível j do factor B.

Este modelo com **ab parâmetros** é designado **modelo M_{A*B}**

Modelo ANOVA a 2 factores, com interacção (cont.)

A matriz \mathbf{X} do delineamento é agora constituída por ab colunas:

- uma coluna de uns, $\vec{1}_n$, associada ao parâmetro μ_{11} .
- $a-1$ colunas de indicatrizes de nível do factor A, $\vec{\mathcal{I}}_{A_i}$, ($i > 1$), associadas aos parâmetros α_i .
- $b-1$ colunas de indicatrizes de nível do factor B, $\vec{\mathcal{I}}_{B_j}$, ($j > 1$), associadas aos parâmetros β_j .
- $(a-1)(b-1)$ colunas de indicatrizes de célula, $\vec{\mathcal{I}}_{A_i:B_j}$, ($i, j > 1$), associadas aos efeitos de interacção $(\alpha\beta)_{ij}$.

Como em modelos anteriores, $\vec{\hat{Y}} = \mathbf{H}\vec{Y}$, sendo \mathbf{H} a matriz que projecta ortogonalmente sobre o espaço $\mathcal{C}(\mathbf{X})$ gerado pelas colunas desta matriz \mathbf{X} .

E também,
$$SQRE_{A*B} = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^{n_{ij}} (Y_{ijk} - \hat{Y}_{ijk})^2.$$

Os três testes ANOVA

Neste delineamento, desejamos fazer um teste à existência de cada um dos três tipos de efeitos:

- Teste I: $H_0 : (\alpha\beta)_{ij} = 0, \quad \forall i = 2, \dots, a, \quad \forall j = 2, \dots, b ;$
- Teste II: $H_0 : \alpha_i = 0, \quad \forall i = 2, \dots, a ;$ e
- Teste III: $H_0 : \beta_j = 0, \quad \forall j = 2, \dots, b .$

As estatísticas de teste para cada um destes três testes obtêm-se a partir da decomposição da Soma de Quadrados Total (ou seja, da *análise da variancia*) em parcelas convenientes.

Testando efeitos de interacção

Para testar a existência de efeitos de interacção,

$$H_0 : (\alpha\beta)_{ij} = 0, \quad \forall i = 2, \dots, a, \quad \forall j = 2, \dots, b,$$

pode efectuar-se um teste F parcial comparando o modelo

$$(\text{Modelo } M_{A*B}) \quad Y_{ijk} = \mu_{11} + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \varepsilon_{ijk},$$

com o submodelo sem efeitos de interacção

$$(\text{Modelo } M_{A+B}) \quad Y_{ijk} = \mu_{11} + \alpha_i + \beta_j + \varepsilon_{ijk},$$

Designa-se **Soma de Quadrados associada à interacção** à diferença

$$SQAB = SQRE_{A+B} - SQRE_{A*B}$$

Testando os efeitos principais de cada Factor

Para testar os efeitos principais dos Factor B ($H_0 : \beta_j = 0, \forall j = 2, \dots, b$) e do Factor A ($H_0 : \alpha_i = 0, \forall i = 2, \dots, a$) pode partir-se dos modelos

$$\begin{array}{ll} \text{(Modelo } M_{A+B}) & Y_{ijk} = \mu_{11} + \alpha_i + \beta_j + \varepsilon_{ijk} \\ \text{(Modelo } M_A) & Y_{ijk} = \mu_{11} + \alpha_i + \varepsilon_{ijk} , \end{array}$$

Defina-se:

$$\begin{array}{lcl} SQB & = & SQRE_A - SQRE_{A+B} \\ SQA & = & SQF_A = SQT - SQRE_A \end{array}$$

Nota: Estas duas Somas de Quadrados definem-se da mesma forma que no modelo sem efeitos de interacção.

A decomposição de SQT

Definimos :

$$SQAB = SQRE_{A+B} - SQRE_{A*B}$$

$$SQB = SQRE_A - SQRE_{A+B}$$

$$SQA = SQF_A = SQT - SQRE_A$$

Somando estas Somas de Quadrados a $SQRE_{A*B}$, obtém-se:

$$SQT = SQRE_{A*B} + SQAB + SQA + SQB$$

Esta **decomposição de SQT** gera as quantidades nas quais se baseiam as estatísticas dos três testes associados ao Modelo M_{A*B} .

O quadro-resumo

Com base na decomposição do acetato 311 podemos construir o **quadro resumo da ANOVA a 2 Factores, com interacção**.

Fonte	g.l.	SQ	QM	f_{calc}
Factor A	$a - 1$	SQA	$QMA = \frac{SQA}{a-1}$	$\frac{QMA}{QMRE}$
Factor B	$b - 1$	SQB	$QMB = \frac{SQB}{b-1}$	$\frac{QMB}{QMRE}$
Interacção	$(a - 1)(b - 1)$	SQAB	$QMAB = \frac{SQAB}{(a-1)(b-1)}$	$\frac{QMAB}{QMRE}$
Resíduos	$n - ab$	SQRE	$QMRE = \frac{SQRE}{n-ab}$	
Total	$n - 1$	$SQT = (n - 1) s_y^2$	—	—

Os **graus de liberdade** de cada tipo de efeito são o **número de parâmetros** desse tipo que sobram após a imposição das restrições.

Como em qualquer modelo linear, os **graus de liberdade residuais** são o número de observações (n) **menos** o número de parâmetros do modelo (ab).

O Teste F aos efeitos de interacção

Sendo válido o Modelo ANOVA a dois factores, com interacção:

Teste F aos efeitos de interacção

Hipóteses: $H_0 : (\alpha\beta)_{ij} = 0 \quad \forall i,j$ vs. $H_1 : \exists i,j \text{ t.q. } (\alpha\beta)_{ij} \neq 0$.
[NÃO HÁ INTERACÇÃO] vs. [HÁ INTERACÇÃO]


Estatística do Teste: $F = \frac{QMAB}{QMRE} \sim F_{((a-1)(b-1), n-ab)} \text{ se } H_0$.

Nível de significância do teste: α

Região Crítica (Região de Rejeição): Unilateral direita

Rejeitar H_0 se

$$F_{calc} > f_{\alpha((a-1)(b-1), n-ab)}$$



O Teste F aos efeitos principais do factor A

Sendo válido o Modelo ANOVA a 2 factores com interacção tem-se:

Teste F aos efeitos principais do factor A


Hipóteses: $H_0 : \alpha_i = 0 \quad \forall i=2,\dots,a$ vs. $H_1 : \exists i=2,\dots,a \text{ t.q. } \alpha_i \neq 0$.
[\nexists EFEITOS DE A] vs. [\exists EFEITOS DE A]

Estatística do Teste: $F = \frac{QMA}{QMRE} \sim F_{(a-1, n-ab)} \text{ se } H_0$.

Nível de significância do teste: α

Região Crítica (Região de Rejeição): Unilateral direita

Rejeitar H_0 se
 $F_{calc} > f_{\alpha(a-1, n-ab)}$



O Teste F aos efeitos principais do factor B

Sendo válido o Modelo ANOVA a 2 factores com interacção tem-se:

Teste F aos efeitos principais do factor B


Hipóteses: $H_0 : \beta_j = 0 \quad \forall j=2,\dots,b$ vs. $H_1 : \exists j=2,\dots,b \text{ t.q. } \beta_j \neq 0$.
[\nexists EFEITOS DE B] vs. [\exists EFEITOS DE B]

Estatística do Teste: $F = \frac{QMB}{QMRE} \sim F_{(b-1, n-ab)} \text{ se } H_0$.


Nível de significância do teste: α

Região Crítica (Região de Rejeição): Unilateral direita

Rejeitar H_0 se
 $F_{calc} > f_{\alpha(b-1, n-ab)}$



ANOVA a dois Factores, com interacção no

Para efectuar uma ANOVA a dois Factores, com interacção, no , organizam-se os dados de forma igual à usada para o modelo sem interacção: uma `data.frame` com três colunas:

- 1 uma para a variável resposta;
- 2 outra para o factor A;
- 3 outra para o factor B.

As fórmulas utilizadas no  para indicar uma ANOVA a dois Factores, com interacção, recorrem ao símbolo `*`:

$$y \sim fA * fB$$

sendo `y` o nome da variável resposta e `fA` e `fB` os nomes dos factores.

Estimação da interacção necessita de repetições

Para se poder estudar efeitos de interacção, é necessário que haja repetições nas células.

Os graus de liberdade do *SQRE* neste modelo são $n - ab$. Se houver uma única observação em cada célula, tem-se $n = ab$, ou seja, tantos parâmetros quantas as observações existentes. Nesse caso, nem sequer será possível definir o Quadrado Médio Residual, *QMRE*.

Num delineamento com uma única observação por célula é obrigatório optar por um modelo sem interacção.

Havendo repetições, é mais natural considerar um modelo com interacção e deixar que a conclusão sobre a existência, ou não, desse tipo de efeitos resulte do estudo do modelo.

Não constando do modelo, eventuais efeitos de interacção irão inflacionar a variabilidade residual, não explicada pelo modelo.

Valores ajustados de Y no modelo com interacção

Às médias já definidas no estudo do modelo a dois Factores, sem efeitos de interacção, (acetato 292):

$\bar{Y}_{i..}$ - nível i do Factor A;

$\bar{Y}_{.j.}$ - nível j do Factor B;

$\bar{Y}_{...}$ - global;

acrescentam-se agora as médias de cada célula:

$$\bar{Y}_{ij.} = \frac{1}{n_{ij}} \sum_{k=1}^{n_{ij}} Y_{ijk} .$$

Os **valores ajustados** \hat{Y}_{ijk} são iguais para todas as observações numa mesma célula, e são dados pela **média amostral da célula**:

$$\hat{Y}_{ijk} = \bar{Y}_{ij.} .$$

Estimadores de parâmetros

Os estimadores dos parâmetros num modelo ANOVA a 2 Factores, com **interacção**, são dadas pelas quantidades amostrais correspondentes às definições populacionais de cada parâmetro (ver acetato 303):

- $\mu = \mu_{11} \Rightarrow \hat{\mu} = \hat{\mu}_{11} = \bar{Y}_{11.}$
- $\alpha_i = \mu_{i1} - \mu_{11} \Rightarrow \hat{\alpha}_i = \bar{Y}_{i1.} - \bar{Y}_{11.} \quad (i > 1)$
- $\beta_j = \mu_{1j} - \mu_{11} \Rightarrow \hat{\beta}_j = \bar{Y}_{1j.} - \bar{Y}_{11.} \quad (j > 1)$
- $(\alpha\beta)_{ij} = \mu_{ij} - \cancel{\mu_{11}} - \underbrace{\alpha_i}_{=\mu_{i1} - \cancel{\mu_{11}}} - \underbrace{\beta_j}_{=\mu_{1j} - \mu_{11}} = \mu_{ij} + \mu_{11} - \mu_{i1} - \mu_{1j}$
 $\Rightarrow (\hat{\alpha\beta})_{ij} = (\bar{Y}_{ij.} + \bar{Y}_{11.}) - (\bar{Y}_{i1.} + \bar{Y}_{1j.}) \quad (i, j > 1)$

Intervalos de confiança ou testes de hipóteses para qualquer parâmetro individual, ou combinações lineares desses parâmetros, podem ser efectuados utilizando a teoria geral do Modelo Linear.

Soma de Quadrados Residual

Como os valores ajustados correspondem às medias amostrais da célula onde se efectuaram as observações, $\hat{Y}_{ijk} = \bar{Y}_{ij.}$, tem-se:

$$SQRE = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^{n_{ij}} (Y_{ijk} - \hat{Y}_{ijk})^2 = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^{n_{ij}} (Y_{ijk} - \bar{Y}_{ij.})^2$$

$$\Leftrightarrow \textcolor{red}{SQRE} = \sum_{i=1}^a \sum_{j=1}^b (n_{ij} - 1) \textcolor{red}{S}_{ij}^2,$$

sendo S_{ij}^2 a variância amostral das observações de Y na célula (i,j) .

Num delineamento equilibrado, tem-se $n = n_c ab$, e o **Quadrado Médio Residual** será a média simples das variâncias amostrais de célula, S_{ij}^2 :

$$QMRE = \frac{SQRE}{n - ab} = \frac{\cancel{n_c} \uparrow}{ab(\cancel{n_c} \uparrow)} \sum_{i=1}^a \sum_{j=1}^b S_{ij}^2 = \frac{1}{ab} \sum_{i=1}^a \sum_{j=1}^b S_{ij}^2.$$

Outras SQs para delineamentos equilibrados

Para delineamentos equilibrados (com n_c observações por célula) é possível obter igualmente fórmulas simples para as **Somas de Quadrados** associadas aos efeitos principais de cada factor.

Estas fórmulas correspondem (tal como no modelo sem efeitos de interacção) às Somas de Quadrados associadas a cada factor, caso se ajustasse (aos mesmos dados) um modelo ANOVA apenas com esse factor:

$$SQA = bn_c \sum_{i=1}^a (\bar{Y}_{i..} - \bar{Y}_{...})^2$$

$$SQB = an_c \sum_{j=1}^b (\bar{Y}_{.j.} - \bar{Y}_{...})^2$$

Um exemplo:

Dietas de leitões

Variável resposta: Coeficiente de Utilização Digestiva para a celulose (CEL).

Factor A: Fibra (a=2 tipos de fibra).

Factor B: Enzima (b=2 níveis – com e sem enzima na dieta).

Nas $ab=4$ situações experimentais há $n_{ij}=12$ repetições (**delineamento equilibrado**).

```
> leitoes.aov <- aov(CEL ~ Fibra*Enzima , data=leitoes)
```

```
> summary(leitoes.aov)
```

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
Fibra	1	0.0239	0.02385	1.450	0.23500
Enzima	1	0.1376	0.13760	8.364	0.00593 **
Fibra:Enzima	1	0.0257	0.02567	1.560	0.21824
Residuals	44	0.7239	0.01645		

Neste exemplo, apenas a adição de enzima tem efeito significativo sobre o coeficiente de utilização digestiva.

Exemplo

Dietas de leitões

Como $a=b=2$, há apenas um efeito de cada tipo:

$$\vec{Y} = \mu \vec{1}_n + \alpha_2 \vec{\mathcal{I}}_{A_2} + \beta_2 \vec{\mathcal{I}}_{B_2} + (\alpha\beta)_{22} \vec{\mathcal{I}}_{A_2:B_2} + \vec{\epsilon}$$

É fácil sintetizar as conclusões:

Teste I:	$H_0 : \alpha_2 = 0$	$p\text{-value} = 0.23500 \Rightarrow$	Não rejeitar $H_0 : \alpha_2 = 0$
Teste II:	$H_0 : \beta_2 = 0$	$p\text{-value} = 0.00593 \Rightarrow$	Optar por $H_1 : \beta_2 \neq 0$
Teste III:	$H_0 : (\alpha\beta)_{2,2} = 0$	$p\text{-value} = 0.21824 \Rightarrow$	Não rejeitar $H_0 : (\alpha\beta)_{2,2} = 0$

		Enzima	
		sem	com
Fibra	1	μ_{11}	$\mu_{12} = \mu_{11} + \beta_2$
	2	$\mu_{21} = \mu_{11} + \alpha_2$	$\mu_{22} = \mu_{11} + \alpha_2 + \beta_2 + (\alpha\beta)_{2,2}$

Comparações múltiplas de médias de células

Havendo ab células, a comparação das médias de cada par de células envolve $\binom{ab}{2}$ comparações.

O número potencialmente grande de comparações possíveis entre **médias de célula** aconselha a utilização de **métodos de comparação múltipla**, que permitam controlar globalmente o nível de significância do conjunto de testes de hipóteses (ou grau de confiança do conjunto de intervalos de confiança).

O mais utilizado dos métodos de comparação múltipla está associado ao nome de **Tukey**. Foi já introduzido no estudo de delineamentos a 1 Factor. Adapta-se facilmente à comparação múltipla de **médias de células**.

O Teste de Tukey

Teste de Tukey para médias de células

Admite-se que o delineamento é **equilibrado**, com $n_c > 1$ repetições em todas as ab células.

Rejeita-se a igualdade das médias das células (i,j) e (i',j') , a favor da hipótese $\mu_{ij} \neq \mu_{i'j'}$, se

$$|\bar{Y}_{ij.} - \bar{Y}_{i'j'.}| > q_{\alpha(ab, n-ab)} \cdot \sqrt{\frac{QMRE}{n_c}},$$

sendo $q_{\alpha(ab, n-ab)}$ o valor que deixa à direita uma região de probabilidade α numa distribuição de Tukey com parâmetros $k = ab$ (o número total de médias de célula) e $\nu = n - ab$ (os graus de liberdade associados ao $QMRE$).

Intervalos de Confiança para $\mu_{ij} - \mu_{i'j'}$


Intervalos de Confiança de Tukey

Com grau de confiança global $(1 - \alpha) \times 100\%$, todas as diferenças de médias de pares de células, $\mu_{ij} - \mu_{i'j'}$, estão em intervalos da forma:


$$\left] (\bar{y}_{ij.} - \bar{y}_{i'j'.}) - q_{\alpha(ab, n-ab)} \sqrt{\frac{QMRE}{n_c}} \quad , \quad (\bar{y}_{ij.} - \bar{y}_{i'j'.}) + q_{\alpha(ab, n-ab)} \sqrt{\frac{QMRE}{n_c}} \right[$$

Conclui-se que $\mu_{ij} \neq \mu_{i'j'}$ se o intervalo correspondente a este par de células não contém o valor zero.

Tukey no

A obtenção dos Intervalos de Confiança de Tukey no , para a diferença da média de células, no caso de um delineamento a dois Factores, é análogo ao caso de um único factor:

```
> TukeyHSD(aov(y ~ fA * fB, data=dados))
```

O  produz também intervalos de confiança para as **médias de nível** de cada Factor isoladamente. Também pode ser usada a função **HSD.test** da `library(agricolae)`:

```
> HSD.test(leitoes.aov, c("fA","fB"), console=TRUE)
```

É possível representar graficamente estes Intervalos de Confiança encaixando o comando anterior na função `plot`.

Visualização gráfica de efeitos de interacção


A existência de **efeitos de interacção** em delineamentos factoriais a dois factores transparece em gráficos onde:

- O **eixo horizontal** é associado aos níveis de **um factor** (e.g., fA);
- no **eixo vertical** são indicados os valores médios da **variável resposta** Y em cada célula;
- **para cada célula**, indica-se um **ponto** cujas coordenadas são determinadas pelo nível do primeiro factor e respectiva média de célula da variável resposta;
- **unem-se com segmentos de recta** os pontos correspondentes a um mesmo nível do segundo factor (e.g., fB).

A cada problema correspondem sempre dois possíveis gráficos de **interacção**, pois é arbitrária a escolha de qual o factor associado ao eixo horizontal, e qual o que define os pontos a serem unidos.

Como ler os gráficos de interacção

Havendo interacção, as linhas estarão longe de qualquer paralelismo (exemplo à esquerda). A inexistência de interacção significativa produz linhas aproximadamente “paralelas” (exemplo à direita).



A confirmação da significância dos efeitos de interacção exige que se efectue o respectivo teste F .

Análise dos Resíduos

A validade dos pressupostos do Modelo relativos aos erros aleatórios pode ser estudada de forma análoga ao que foi visto para um delineamento a 1 Factor.

Os resíduos relativos a uma mesma célula aparecem em ab colunas verticais num gráfico de E_{ijk} vs. \hat{Y}_{ijk} .

A hipótese de heterogeneidade de variâncias entre diferentes células pode ser testada recorrendo a testes de hipóteses (como o Teste de Bartlett), mas essa matéria não será leccionada.

Uma advertência

Na formulação clássica do modelo ANOVA a dois Factores, com interacção, e a partir da equação-base $Y_{ijk} = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \varepsilon_{ijk}$, em vez de impor as condições $\alpha_1 = \beta_1 = (\alpha\beta)_{i1} = (\alpha\beta)_{1j} = 0$ ($\forall i, j$), admitem-se as restrições:

- $\sum_i \alpha_i = 0$;
- $\sum_j \beta_j = 0$;
- $\sum_i (\alpha\beta)_{ij} = 0$, $\forall j$;
- $\sum_j (\alpha\beta)_{ij} = 0$, $\forall i$.

Estas condições alternativas:

- mudam a forma de interpretar os parâmetros;
- mudam os estimadores dos parâmetros;
- **não** mudam o resultado dos testes F à existência de efeitos.

Delineamentos factoriais com vários factores

Um **delineamento factorial** (isto é, com observações para todas as combinações de níveis de cada factor) pode ser definido com qualquer número de factores.

Num delineamento **factorial a três factores** – A, B e C – cada observação da variável resposta indexa-se com **quatro índices**: Y_{ijkl} indica a observação l no nível i do Factor A, nível j do Factor B e nível k do Factor C. A equação de base para Y_{ijkl} prevê a existência de **sete tipos de efeitos**:

- três **efeitos principais** de cada factor, α_i , β_j e γ_k .
- três **efeitos de interacção dupla** associados a cada combinação de níveis de dois Factores diferentes: $(\alpha\beta)_{ij}$, $(\alpha\gamma)_{ik}$ e $(\beta\gamma)_{jk}$.
- um **efeito de tripla interacção** para as **células** onde se cruzam níveis dos três factores: $(\alpha\beta\gamma)_{ijk}$

O modelo factorial a três factores

A equação de base do modelo é agora:

$$Y_{ijkl} = \mu_{111} + \alpha_i + \beta_j + \gamma_k + (\alpha\beta)_{ij} + (\alpha\gamma)_{ik} + (\beta\gamma)_{jk} + (\alpha\beta\gamma)_{ijk} + \varepsilon_{ijkl} .$$

A Soma de Quadrados Total é decomposta em **oito parcelas**: SQA, SQB, SQC, SQAB, SQAC, SQBC, SQABC e SQRE, de forma análoga ao visto antes.

Os **graus de liberdade** associados a cada tipo de efeito generalizam conceitos anteriores.

Há **sete testes**: um para cada tipo de efeitos. As estatísticas desses sete testes são todas do tipo $\frac{QM_x}{QMRE}$, onde x designa o tipo de efeitos em questão.

As estatísticas desses testes terão, sob H_0 , distribuição F com graus de liberdade dados pelos g.l. do numerador e do denominador, respectivamente.

Delineamentos hierarquizados

Delineamentos que, superficialmente, podem confundir-se com os delineamentos factoriais são delineamentos com **dois (ou mais) factores**, mas em que **os níveis de um dos factores variam consoante os níveis do outro factor**.

Exemplo (do Segundo Teste, 2008/9): pretende-se estudar o **índice de desempenho** (variável resposta), em várias tarefas, de três **tractores** de diferentes modelos (factor A), cada um dos quais é conduzidos por quatro **tractoristas** (factor B).


Se os mesmos 4 tractoristas conduzirem os 3 tractores, o delineamento é factorial e aplicam-se os modelos antes considerados.

Mas **se para cada modelo de tractor existir um grupo de quatro diferentes tractoristas especializados** (ao todo 12 tractoristas), o delineamento não é factorial, mas antes **hierarquizado**: só é possível identificar os tractoristas (níveis do factor B), após especificar o tractor (nível do factor A).

Delineamentos hierarquizados (cont.)

Existe uma **hierarquia** dos factores: só identificamos os níveis de um factor (**factor subordinado**) após ter identificado o nível do outro factor (**factor dominante**) com que se trabalha.

	Tractor A ₁	Tractor A ₂	Tractor A ₃
Tractorista A ₁ 1	×	-	-
Tractorista A ₁ 2	×	-	-
Tractorista A ₁ 3	×	-	-
Tractorista A ₁ 4	×	-	-
Tractorista A ₂ 1	-	×	-
Tractorista A ₂ 2	-	×	-
Tractorista A ₂ 3	-	×	-
Tractorista A ₂ 4	-	×	-
Tractorista A ₃ 1	-	-	×
Tractorista A ₃ 2	-	-	×
Tractorista A ₃ 3	-	-	×
Tractorista A ₃ 4	-	-	×




Um tal delineamento diz-se **hierarquizado** (*nested*, em inglês).

Delineamentos hierarquizados (cont.)

Existe uma **hierarquia** dos factores: só identificamos os níveis de um factor (**factor subordinado**) após ter identificado o nível do outro factor (**factor dominante**) com que se trabalha.

	Tractor A ₁	Tractor A ₂	Tractor A ₃
Tractorista A ₁ 1	×	-	-
Tractorista A ₁ 2	×	-	-
Tractorista A ₁ 3	×	-	-
Tractorista A ₁ 4	×	-	-
Tractorista A ₂ 1	-	×	-
Tractorista A ₂ 2	-	×	-
Tractorista A ₂ 3	-	×	-
Tractorista A ₂ 4	-	×	-
Tractorista A ₃ 1	-	-	×
Tractorista A ₃ 2	-	-	×
Tractorista A ₃ 3	-	-	×
Tractorista A ₃ 4	-	-	×



Um tal delineamento diz-se **hierarquizado** (*nested*, em inglês).

Um delineamento hierarquizado pode ser visto como um **delineamento factorial** (muito) **incompleto**. **Deixa de fazer sentido falar em efeitos de interacção** entre os níveis de cada Factor.

O modelo a 2 Factores, hierarquizados

Seja b_i o número de níveis do Factor B (folhas terminais do dendrograma), subordinados ao nível i do Factor A (ramo). b_i pode ser diferente para cada nível i do factor dominante.

Cada observação é representada por uma v.a. com **três índices**, Y_{ijk} :

i nível do factor dominante ($i = 1, \dots, a$);

j nível do factor subordinado ($j = 1, \dots, b_i$);

k repetição para a célula (i, j) , com $k = 1, \dots, n_{ij}$.

A equação base do modelo inclui **efeitos de nível do Factor A** e **efeitos de nível do factor B (subordinado)**:

$$Y_{ijk} = \mu + \alpha_i + \beta_{j(i)} + \varepsilon_{ijk} ,$$


com $\alpha_1 = 0$ e $\beta_{1(i)} = 0$, $\forall i$. Com estas restrições, $\mu = \mu_{11}$.

Não faz sentido falar em efeitos do nível j do Factor B, sem especificar qual o nível do Factor A a que nos referimos. Nem faz sentido falar em efeitos de interacção.

Restrições nos delineamentos hierarquizados

Cada ramo associado ao Factor dominante **excepto o primeiro** tem efeito α_j .

Cada folha terminal associada ao Factor subordinado **excepto a primeira de cada ramo** tem efeito $\beta_{j(i)}$.



Os valores esperados de Y_{ijk}

Tem-se:

- Para a primeira célula ($i = j = 1$): $E[Y_{11k}] = \mu = \mu_{11}$.
- Nas restantes células do primeiro nível do Factor A ($i = 1; j > 1$):
 $\mu_{1j} = E[Y_{1jk}] = \mu_{11} + \beta_{j(1)}$.
- Nos restantes primeiros níveis do factor B ($i > 1; j = 1$):
 $\mu_{i1} = E[Y_{i1k}] = \mu_{11} + \alpha_i$.
- Nas células genéricas (i, j), com $i > 1$ e $j > 1$,
 $\mu_{ij} = E[Y_{ijk}] = \mu_{11} + \alpha_i + \beta_{j(i)}$.

Os efeitos α_i e $\beta_{j(i)}$ designam-se efeitos dos níveis de cada Factor.

Variáveis indicatrizes e número de parâmetros

Como em modelos anteriores, a cada parâmetro associa-se uma variável indicatriz das observações correspondentes. Assim:

- um parâmetro μ_{11} , associado à coluna de uns, $\vec{1}_n$.
- $(a - 1)$ parâmetros α_i , associados às indicatrizes $\vec{\mathcal{I}}_{A_i}$ de cada nível $i > 1$ do Factor A.
- $\sum_{i=1}^a (b_i - 1)$ parâmetros $\beta_{j(i)}$, associados às indicatrizes $\vec{\mathcal{I}}_{B_{j(i)}}$ de cada nível $j > 1$ do Factor B, para $i = 1, \dots, a$.

O no. de parâmetros é igual ao no. de situações experimentais:

$$1 + (a - 1) + \sum_{i=1}^a (b_i - 1) = \cancel{1} + \cancel{a} - \cancel{1} + \sum_{i=1}^a b_i - \underbrace{\sum_{j=1}^a 1}_{=a} = \sum_{i=1}^a b_i$$

Se houver sempre $b = b_i$ níveis do Factor B, em cada nível i do Factor A, haverá ab parâmetros no modelo.

O modelo ANOVA a dois factores, hierarquizados

Juntando os pressupostos necessários à inferência,

Modelo ANOVA a dois factores, hierarquizados (Modelo $M_{A/B}$)

Seja A o Factor dominante e B o Factor subordinado.

Existem n observações, Y_{ijk} , n_{ij} das quais associadas à célula (i,j) ($i = 1, \dots, a ; j = 1, \dots, b_i$). Tem-se:

- 1 $Y_{ijk} = \mu_{11} + \alpha_i + \beta_{j(i)} + \varepsilon_{ijk} , \quad \forall i=1, \dots, a ; j=1, \dots, b_i ; k=1, \dots, n_{ij}$
($\alpha_1 = 0 ; \beta_{1(i)} = 0 , \forall i$).
- 2 $\varepsilon_{ijk} \sim \mathcal{N}(0, \sigma^2) , \quad \forall i, j, k$
- 3 $\{\varepsilon_{ijk}\}_{i,j,k}$ v.a.s independentes.

Os dois testes ANOVA

Neste delineamento, pretende-se testar a existência de cada um dos dois tipos de efeitos previstos no modelo:

- $H_0 : \alpha_i = 0, \quad \forall i = 2, \dots, a$; e
- $H_0 : \beta_{j(i)} = 0, \quad \forall i = 1, \dots, a \text{ e } j = 2, \dots, b_i.$

As estatísticas de teste para cada um destes testes obtêm-se a partir da decomposição da Soma de Quadrados Total em três parcelas, correspondentes aos dois tipos de efeito e à variabilidade residual.

As Somas de Quadrados associadas a cada tipo de efeito definem-se de forma análoga à usada em delineamentos anteriores.

A decomposição de SQT

Para efectuar a decomposição da Soma de Quadrados Total, consideremos os modelos

(Modelo $M_{A/B}$)

$$Y_{ijk} = \mu_{11} + \alpha_i + \beta_{j(i)} + \varepsilon_{ijk} ,$$

(Modelo M_A)

$$Y_{ijk} = \mu_{11} + \alpha_i + \varepsilon_{ijk} ,$$

Designa-se **Soma de Quadrados associada aos efeitos de B** a

$$SQB(A) = SQRE_A - SQRE_{A/B}$$

e **Soma de Quadrados associada aos efeitos de A** a

$$SQA = SQF_A = SQT - SQRE_A$$

Juntamente com $SQRE_{A/B}$, tem-se:

$$SQT = SQA + SQB(A) + SQRE_{A/B}$$

Algumas fórmulas

Como $SQA = SQF_A$ (Modelo 1 Factor):

$$SQA = \sum_{i=1}^a \sum_{j=i}^{b_i} \sum_{k=1}^{n_{ij}} (\underbrace{\hat{Y}_{ijk}}_{=\bar{Y}_{i..}} - \bar{Y}_{...})^2 = \sum_{i=1}^a \sum_{j=i}^{b_i} n_{ij} (\bar{Y}_{i..} - \bar{Y}_{...})^2 .$$

Num **delineamento equilibrado**, tem-se: $SQA = n_c \sum_{i=1}^a b_i (\bar{Y}_{i..} - \bar{Y}_{...})^2$

No modelo a 2 factores hierarquizado também se tem:

$$\hat{Y}_{ijk} = \bar{Y}_{ij.}$$

Logo, a Soma de Quadrados Residual também é soma ponderada das variâncias de célula $S_{ij}^2 = \frac{1}{n_{ij}-1} \sum_{k=1}^{n_{ij}} (Y_{ijk} - \bar{Y}_{ij.})^2$:

$$SQRE = \sum_{i=1}^a \sum_{j=i}^{b_i} \sum_{k=1}^{n_{ij}} (Y_{ijk} - \underbrace{\hat{Y}_{ijk}}_{=\bar{Y}_{ij.}})^2 = \sum_{i=1}^a \sum_{j=i}^{b_i} (n_{ij}-1) S_{ij}^2 .$$

Graus de liberdade

Os **graus de liberdade** associados a cada tipo de efeito são dados por:

- $g.l.(SQA) = a - 1$, o número de parâmetros associados aos efeitos de nível de A .
- $g.l.[SQB(A)] = \sum_{i=1}^a (b_i - 1)$, o número de parâmetros associados aos efeitos de nível de B .
- $g.l.(SQRE) = n - \sum_{i=1}^a b_i$, o número de observações menos o número total de parâmetros do modelo.

Quadro-resumo da ANOVA a 2 Factores hierarquizados

Fonte	g.l.	SQ	QM	f_{calc}
Factor A	$a - 1$	SQA	$QMA = \frac{SQA}{a-1}$	$\frac{QMA}{QMRE}$
Factor B(A)	$\sum_{i=1}^a (b_i - 1)$	SQB(A)	$QMB(A) = \frac{SQB(A)}{\sum_{i=1}^a (b_i - 1)}$	$\frac{QMB(A)}{QMRE}$
Resíduos	$n - \sum_{i=1}^a b_i$	SQRE	$QMRE = \frac{SQRE}{n - \sum_{i=1}^a b_i}$	
Total	$n - 1$	$SQT = (n - 1) S_y^2$	—	—

O Teste F aos efeitos do factor A (dominante)

Sendo válido o Modelo de ANOVA a 2 factores hierarquizados, tem-se:

Teste F aos efeitos do factor A (dominante)


Hipóteses: $H_0 : \alpha_i = 0 \quad \forall i=2,\dots,a$ vs. $H_1 : \exists i=2,\dots,a \text{ t.q. } \alpha_i \neq 0$.
[FACTOR A NÃO AFECTA Y] vs. [FACTOR A AFECTA Y]

Estatística do Teste: $F = \frac{QMA}{QMRE} \sim F_{(a-1, n-\sum_i b_i)} \text{ se } H_0$.

Nível de significância do teste: α

Região Crítica (Região de Rejeição): Unilateral direita

Rejeitar H_0 se
 $F_{calc} > f_{\alpha(a-1, n-\sum_i b_i)}$



O Teste F aos efeitos do factor B (subordinado)

Sendo válido o Modelo de ANOVA a dois factores hierarquizado,

Teste F aos efeitos do factor B (subordinado)

Hipóteses: $H_0 : \beta_{j(i)} = 0 \quad \forall j=2,\dots,b_i, i=1,\dots,a$ vs. $H_1 : \exists i,j \text{ t.q. } \beta_{j(i)} \neq 0$.
[FACTOR B NÃO AFECTA] vs. [FACTOR B AFECTA Y]


Estatística do Teste: $F = \frac{QMB(A)}{QMRE} \sim F_{(\sum_i (b_i-1), n-\sum_i b_i)} \text{ se } H_0$.

Nível de significância do teste: α


Região Crítica (Região de Rejeição): Unilateral direita

Rejeitar H_0 se


$$F_{calc} > f_{\alpha(\sum_i (b_i-1), n-\sum_i b_i)}$$



ANOVA a dois Factores hierarquizados no

Para efectuar uma ANOVA a dois Factores hierarquizados no , organizam-se os dados como nos anteriores modelos com dois factores, ou seja, numa `data.frame` com três colunas:

- 1 uma para a variável resposta;
- 2 outra para o factor A;
- 3 outra para o factor B.

A **fórmula** utilizada no  para indicar uma ANOVA a dois Factores hierarquizados é semelhante às anteriores, mas com o nome dos dois factores separado pelo símbolo **/**. Se o factor *fA* é dominante:

$$y \sim fA / fB$$

Um exemplo

Exemplo de delineamento hierarquizado

No exemplo de tratores/tractoristas, o delineamento era **equilibrado**, com $n_c = 5$ observações em cada célula (situação experimental).

A tabela-resumo produzida pelo comando `aov` é a seguinte:

```
> summary(aov(indice ~ tractor/tractorista, data=tratores))
```

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
tractor	2	1696	847.8	35.92	2.90e-10 ***
tractor:tractorista	9	2272	252.5	10.70	6.99e-09 ***
Residuals	48	1133	23.6		

Neste caso, há efeitos significativos dos diferentes tipos de tratores sobre a variável resposta, e também efeitos significativos dos tractoristas que conduzem os tratores.

Comparações múltiplas de médias

Caso se conclua pela existência de efeitos do factor subordinado, é natural querer comparar médias da variável resposta nas $\sum_{i=1}^a b_i$ diferentes situações experimentais.

Comparações múltiplas de Tukey podem ser efectuadas, caso o delineamento seja equilibrado, isto é, se houver o mesmo número de observações em cada situação experimental.

Neste caso, os parâmetros da distribuição de Tukey serão

- o número de situações experimentais, $k = \sum_{i=1}^a b_i$; e
- os graus de liberdade associados ao *QMRE*, $v = n - \sum_{i=1}^a b_i$.

Tukey – Um exemplo

Tukey com os dados dos tractoristas

Há $b_1 + b_2 + b_3 = 12$ situações experimentais, logo $\binom{12}{2} = 66$ comparações de pares de médias dessas situações experimentais. O termo de comparação de Tukey para diferenças de médias de célula é:

$$q_{0.05(12,48)} \cdot \sqrt{\frac{QMRE}{n_c}} = 4.856029 \times \frac{4.85793}{\sqrt{5}} = 10.55$$

As médias de célula são:

```
> model.tables(tractores.aov, type="means")
```

```
[...]
```

	tractorista			
tractor	1	2	3	4
1	61.8	67.8	62.6	52.6
2	75.8	75.2	55.8	77.0
3	76.8	69.6	74.4	73.4



O maior índice médio de desempenho é $\bar{y}_{24.} = 77.0$. A azul estão as médias que não diferem significativamente da maior média. A preto ficam as que diferem.

Validação do modelo

A **análise de resíduos** para validar os pressupostos do modelo, é **análoga** à de modelos anteriores.

Gráficos de resíduos no exemplo dos tratores

```
> plot(tratores.aov, which=c(1,2))
```



Comentários finais

Os métodos ANOVA que estudámos generalizam os testes t de comparação de médias de duas amostras para o caso de haver mais do que duas amostras.

Em particular

- A estatística F do teste à existência de efeitos de nível do Factor, num modelo ANOVA a 1 Factor, quando $k = 2$ (factor com 2 níveis), é o quadrado da estatística t à diferença de médias de duas populações, no caso de **amostras independentes**.
- A estatística F do teste à existência de efeitos de nível do Factor, num modelo ANOVA a 1 Factor com blocos casualizados (i.e., a 2 Factores, sem interacção e uma única observação por célula), quando $a = 2$ (factor com 2 níveis), é o quadrado da estatística t à diferença de médias de duas populações, no caso de **amostras emparelhadas**.

Comparações múltiplas alternativas

O problema da comparação de múltiplas médias (de nível de factor ou de células), que abordámos pela teoria de Tukey tem alternativas.

A mais conceituada das alternativas baseia-se na teoria de **Scheffé**. Produz intervalos de confiança maiores (ao mesmo nível $(1 - \alpha) \times 100\%$ de confiança) do que os intervalos de Tukey.

Quer Tukey, quer Scheffé, podem ser generalizados para obter testes/intervalos de confiança sobre **combinações lineares das médias** de nível ou de células.

A correcção de Bonferroni

Outra alternativa a Tukey consiste em efectuar testes de hipóteses usuais para comparar duas médias, mas **reduzir o nível de significância para cada teste individual de comparação de médias**, de forma a garantir que o nível de significância global não exceda os α desejados.

Equivalentemente, **aumenta-se o grau de confiança de cada intervalo de confiança individual para a diferença de médias**, de forma a garantir que o grau de confiança global não fique abaixo dos $1 - \alpha$ desejados.

As alterações nos graus de confiança/níveis de significância baseiam-se na **desigualdade de Bonferroni**.

A desigualdade de Bonferroni

Admita que se pretendem efectuar r comparações de médias, através de ICs, e que se deseja um grau de confiança global $1 - \alpha$.

Seja A_j o acontecimento aleatório “o j -ésimo intervalo contém a verdadeira diferença de médias populacionais”, e $1 - \alpha_j$ o respectivo grau de confiança. Queremos que $P \left[\bigcap_{j=1}^r A_j \right]$ exceda $1 - \alpha$. Ora,

$$P \left[\bigcap_{j=1}^r A_j \right] = 1 - P \left[\bigcup_{j=1}^r \bar{A}_j \right] \geq 1 - \sum_{j=1}^r P[\bar{A}_j] = 1 - \sum_{j=1}^r \alpha_j .$$

Logo, desde que se escolha $\sum_{j=1}^r \alpha_j = \alpha$, tem-se a garantia de um grau de confiança global de pelo menos $1 - \alpha$. O usual é escolher $\alpha_j = \alpha/r$.

Vantagens e inconvenientes

A **correção de Bonferroni** é aplicável em qualquer situação onde se deseje efectuar vários testes de hipóteses/intervalos de confiança e se pretende controlar o nível de significância/grau de confiança global. **É aplicável mesmo quando os delineamentos não são equilibrados.**

Tem o inconveniente de, para r grande, exigir valores muito pequenos para α/r .

Trata-se de uma **desigualdade**, pelo que poderia não ser necessário reduzir tanto o valor de α_j em cada caso individual.