

## O princípio da parcimónia na RLM

Recordemos o **princípio da parcimónia** na modelação: queremos um modelo que descreva adequadamente a relação entre as variáveis, mas que **seja o mais simples (parcimonioso) possível**.

Caso se disponha de um modelo de Regressão Linear Múltipla com um ajustamento considerado adequado, a aplicação deste princípio traduz-se em saber se **será possível obter um modelo com menos variáveis preditoras, sem perder significativamente em termos de qualidade de ajustamento**.

## Modelo e Submodelos

Se dispomos de um modelo de Regressão Linear Múltipla, com relação de base

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_4 + \beta_5 x_5 ,$$

chamamos **submodelo** a um modelo de regressão linear múltipla contendo apenas algumas das variáveis preditoras, e.g.,

$$Y = \beta_0 + \beta_2 x_2 + \beta_5 x_5 ,$$

Podemos identificar o submodelo pelo conjunto  $\mathcal{S}$  das variáveis preditoras que pertencem ao submodelo. No exemplo,  $\mathcal{S} = \{2, 5\}$ .

O modelo e o submodelo são idênticos se  $\beta_j = 0$  para qualquer variável  $x_j$  cujo índice não pertença a  $\mathcal{S}$ .

## Comparando modelo e submodelos

Para comparar um modelo e um seu submodelo (identificado pelo conjunto  $\mathcal{S}$  dos índices das suas variáveis), precisamos de optar entre as hipóteses:

$$H_0 : \beta_j = 0, \quad \forall j \notin \mathcal{S} \quad \text{vs.} \quad H_1 : \exists j \notin \mathcal{S} \quad \text{tal que} \quad \beta_j \neq 0.$$

[SUBMODELO = MODELO]

[SUBMODELO  $\neq$  MODELO]

NOTA: Esta discussão só envolve coeficientes  $\beta_j$  de variáveis preditoras ( $j > 0$ ). O coeficiente  $\beta_0$  faz sempre parte dos submodelos e não é relevante do ponto de vista da parcimónia.

Caso não se rejeite  $H_0$ , opta-se pelo submodelo (mais parcimonioso).

Caso se rejeite  $H_0$ , opta-se pelo modelo completo (ajusta-se significativamente melhor).

Este coeficiente  $\beta_0$  não é relevante do ponto de vista da parcimónia: a sua presença não implica trabalho adicional de recolha de dados, nem de interpretação do modelo. Apenas permite um melhor ajustamento.

## Estatística de teste para comparar modelo/submodelo

A estatística de teste compara as Somas de Quadrados Residuais do:

- modelo completo (referenciado pelo índice  $C$ ); e do
- submodelo (referenciado pelo índice  $S$ )

Seja  $k$  o número de preditores do submodelo ( $k+1$  parâmetros). Tem-se, sob  $H_0$  ( $\beta_j=0$ , para todas as variáveis  $x_j$  que não estão no submodelo):

$$F = \frac{\frac{SQRE_S - SQRE_C}{p-k}}{\frac{SQRE_C}{n-(p+1)}} \sim F_{[p-k, n-(p+1)]}$$

**Nota:** Necessariamente  $SQRE_S \geq SQRE_C$ .

São os valores grandes da estatística que levantam dúvidas sobre  $H_0$ .

## O teste a um submodelo (teste $F$ parcial)

### Teste $F$ de comparação dum modelo com um seu submodelo

Dado o Modelo de Regressão Linear Múltipla,

Hipóteses:

$$H_0 : \beta_j = 0, \quad \forall j \notin \mathcal{J} \quad \text{vs.} \quad H_1 : \exists j \notin \mathcal{J} \quad \text{tal que} \quad \beta_j \neq 0.$$

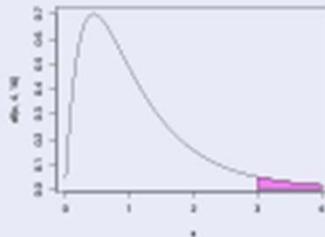
Estatística do Teste:

$$F = \frac{\frac{SQRE_S - SQRE_C}{p-k}}{\frac{SQRE_C}{n-(p+1)}} \sim F_{[p-k, n-(p+1)]}, \text{ sob } H_0.$$

Nível de significância do teste:  $\alpha$

Região Crítica (Região de Rejeição): Unilateral direita

Rejeitar  $H_0$  se  $F_{calc} > f_{\alpha[p-k, n-(p+1)]}$



## Expressão alternativa para a estatística do teste

A estatística do teste  $F$  parcial pode ser escrita na forma alternativa:

$$F = \frac{n - (p + 1)}{p - k} \cdot \frac{R_C^2 - R_S^2}{1 - R_C^2}.$$

**NOTA:** A Soma de Quadrados Total apenas depende dos valores observados da variável resposta  $Y$  e não do modelo ajustado. Assim,  $SQT$  é igual no modelo completo e no submodelo.

As hipóteses do teste também se podem escrever como

$$H_0 : R_C^2 = R_S^2 \quad \text{vs.} \quad H_1 : R_C^2 > R_S^2,$$

A hipótese  $H_0$  indica que o grau de relacionamento linear entre  $Y$  e o conjunto dos preditores é idêntico no modelo e no submodelo.

Caso não se rejeite  $H_0$ , opta-se pelo submodelo (mais parcimonioso).

Caso se rejeite  $H_0$ , opta-se pelo modelo completo (ajusta-se significativamente melhor).

## Teste $F$ parcial: formulação alternativa

### Teste $F$ de comparação dum modelo com um seu submodelo

Dado o Modelo de Regressão Linear Múltipla,

Hipóteses:

$$H_0 : \mathcal{R}_C^2 = \mathcal{R}_S^2 \quad \text{vs.} \quad H_1 : \mathcal{R}_C^2 > \mathcal{R}_S^2 .$$

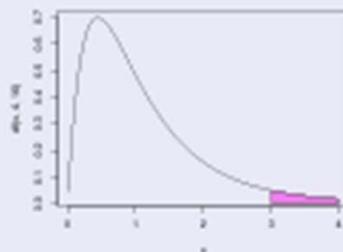
Estatística do Teste:

$$F = \frac{n-(p+1)}{p-k} \cdot \frac{R_C^2 - R_S^2}{1 - R_C^2} \sim F_{[p-k, n-(p+1)]}, \text{ sob } H_0.$$

Nível de significância do teste:  $\alpha$

Região Crítica (Região de Rejeição): Unilateral direita

Rejeitar  $H_0$  se  $F_{calc} > f_{\alpha[p-k, n-(p+1)]}$



## Relações dos testes $F$ parcial

O teste de ajustamento **global** é equivalente a um teste  $F$  parcial comparando um modelo linear e o submodelo nulo (sem preditores).

**Caso o modelo e submodelo difiram num único preditor**,  $X_i$ , o teste  $F$  parcial é equivalente ao teste  $t$  com as hipóteses  $H_0 : \beta_j = 0$  vs.  $H_1 : \beta_j \neq 0$ .

Nesse caso, não apenas as hipóteses dos dois testes são iguais, como a estatística do teste  $F$  parcial é o quadrado da estatística do teste  $t$  referido.

- as hipóteses dos dois testes são iguais ( $H_0 : \beta_j = 0$  vs.  $H_1 : \beta_j \neq 0$ );
- a estatística do teste  $F$  parcial é o quadrado da estatística do teste  $t$  referido:

$$F_{calc} = T_{calc}^2$$

Tem-se  $p - k = 1$ , e como é sabido, se uma variável aleatória  $T$  tem distribuição  $t_v$ , então o seu quadrado,  $T^2$  tem distribuição  $F_{1,v}$ .

Numa regressão linear **simples**, o teste  $t$  ao declive da recta ser nulo é equivalente ao teste  $F$  de ajustamento global. A segunda destas estatísticas de teste é o quadrado da primeira.

## Ainda o exemplo dos lírios

**Teste F Parcial de comparação de um modelo (com p preditores) com um seu submodelo (com k preditores)**

**Submodelo:**  $\text{PetalWidth} = \beta_0 + \beta_3 \text{PetalLength}$

**Modelo completo:**  $\text{PetalWidth} = \beta_0 + \beta_1 \text{SepalLength} + \beta_2 \text{SepalWidth} + \beta_3 \text{PetalLength}$

$$H_0: \beta_1 = \beta_2 = 0 \quad \text{vs.} \quad H_1: \exists_{j=1,2}: \beta_j \neq 0$$

```
proc reg data=iris;
  model PetalWidth = SepalLength SepalWidth PetalLength;
  test SepalLength, SepalWidth;
run;
```

### The SAS System

The REG Procedure  
Model: MODEL1

| Test 1 Results for Dependent Variable PetalWidth |     |             |         |        |
|--|-----|-------------|---------|--------|
| Source   | DF  | Mean Square | F Value | Pr > F |
| Numerator  | 2   | 0.46490     | 12.62   | <.0001 |
| Denominator                                      | 146 | 0.03685     |         |        |

$$n - (p + 1)$$

$$\frac{SQRE_C}{n - (p + 1)}$$

$F_{calc} =$

$$\frac{\frac{SQRE_S - SQRE_C}{p - k}}{\frac{SQRE_C}{n - (p + 1)}}$$

Rejeita-se a hipótese nula (para qualquer nível de significância usual), portanto, a qualidade do ajustamento dos dois modelos difere significativamente.

## Ainda o exemplo dos lírios

**Teste F Parcial de comparação de um modelo (com p preditores) com um seu submodelo (com k preditores)**

**Submodelo:**  $\text{PetalWidth} = \beta_0 + \beta_3 \text{PetalLength}$

**Modelo completo:**  $\text{PetalWidth} = \beta_0 + \beta_1 \text{SepalLength} + \beta_2 \text{SepalWidth} + \beta_3 \text{PetalLength}$

De forma equivalente:

$$H_0 : \mathcal{R}_C^2 = \mathcal{R}_S^2 \quad \text{vs.} \quad H_1 : \mathcal{R}_C^2 > \mathcal{R}_S^2$$

Os valores dos coeficientes de determinação amostrais ( $R_S^2 = 0.9271$  e  $R_C^2 = 0.9379$ ) são significativamente diferentes.

```
proc reg data=iris;  
  model PetalWidth = PetalLength/clb covb xpx;  
run;
```

|                |          |          |        |
|----------------|----------|----------|--------|
| Root MSE       | 0.20648  | R-Square | 0.9271 |
| Dependent Mean | 1.19933  | Adj R-Sq | 0.9266 |
| Coeff Var      | 17.21659 |          |        |

```
proc reg data=iris;  
  model PetalWidth = SepalLength SepalWidth  
  PetalLength/clb covb xpx R CLI CLM ;  
run;
```

|                |          |          |        |
|----------------|----------|----------|--------|
| Root MSE       | 0.19197  | R-Square | 0.9379 |
| Dependent Mean | 1.19933  | Adj R-Sq | 0.9366 |
| Coeff Var      | 16.00615 |          |        |

Exercícios:

- 1) Usando os valores dos coeficientes de determinação dos dois modelos ajustados verifique que o valor do  $F_{\text{ParcialCalc}} = 12.62$  (slide anterior);
- 2) Usando os valores das somas dos quadrados dos resíduos dos dois modelos ajustados verifique que o valor do  $F_{\text{ParcialCalc}} = 12.62$  (slide anterior).

## Ainda o exemplo dos lírios

Exercícios (continuação):

Relembrando alguns resultados do ajustamento do modelo completo:

```
proc reg data=iris;  
  model PetalWidth = SepalLength SepalWidth PetalLength/clb covb xpx R CLI CLM ;  
run;
```

| Parameter Estimates |    |                    |                |         |         |                       |          |
|---------------------|----|--------------------|----------------|---------|---------|-----------------------|----------|
| Variable            | DF | Parameter Estimate | Standard Error | t Value | Pr >  t | 95% Confidence Limits |          |
| Intercept           | 1  | -0.24031           | 0.17837        | -1.35   | 0.1800  | -0.59283              | 0.11221  |
| SepalLength         | 1  | -0.20727           | 0.04751        | -4.36   | <.0001  | -0.30115              | -0.11338 |
| SepalWidth          | 1  | 0.22283            | 0.04894        | 4.55    | <.0001  | 0.12611               | 0.31955  |
| PetalLength         | 1  | 0.52408            | 0.02449        | 21.40   | <.0001  | 0.47568               | 0.57249  |

3) a) Utilize um teste F parcial para ver se é possível concluir que os modelos com e sem o preditor SepalLength têm ajustamento significativamente diferente (utilize  $\alpha = 0.05$ ).

b) Qual o coeficiente de determinação do submodelo resultante da exclusão dessa variável?

## Como escolher um submodelo?

O teste  $F$  parcial (teste aos modelos encaixados) permite-nos optar entre um modelo e um seu submodelo. Por vezes, um submodelo pode ser sugerido por:

- **razões de índole teórica**, sugerindo que determinadas variáveis preditoras não sejam, na realidade, importantes para influenciar os valores de  $Y$ .
- **razões de índole prática**, como a dificuldade, custo ou volume de trabalho associado à recolha de observações para determinadas variáveis preditoras.

Nestes casos, pode ser claro que submodelo(s) se deseja testar.

## Como escolher um submodelo? (cont.)

Mas em muitas situações não é evidente qual o subconjunto de variáveis preditoras que se deseja considerar no submodelo. Pretende-se apenas ver se o modelo é simplificável. Nestes casos, a opção por um submodelo não é um problema fácil.

Dadas  $p$  variáveis preditoras, o número de subconjuntos, de qualquer cardinalidade, excepto 0 (modelo nulo) e  $p$  (o modelo completo) que é possível escolher é dado por  $2^p - 2$ . A tabela seguinte indica o número desses subconjuntos para  $p = 5, 10, 15, 20, 30$ .

| $p$ | $2^p - 2$     |
|-----|---------------|
| 5   | 30            |
| 10  | 1 022         |
| 15  | 32 766        |
| 20  | 1 048 574     |
| 30  | 1 073 741 822 |

Para valores de  $p$  pequenos, é possível analisar todos os possíveis subconjuntos. Com algoritmos e rotinas informáticas adequadas, a pesquisa completa de todos os possíveis subconjuntos ainda é possível para valores grandes de  $p$  (até  $p \approx 35$ ). Mas para  $p$  muito grande, uma pesquisa completa é computacionalmente inviável.

Não é legítimo optar pela exclusão de várias variáveis preditoras **em simultâneo**, com base nos testes  $t$  à significância de cada coeficiente  $\beta_j$  no modelo completo.

De facto, os testes  $t$  aos coeficientes  $\beta_j$  admitem que todas as restantes variáveis pertencem ao modelo. A exclusão de um qualquer preditor altera o ajustamento: altera os valores estimados  $b_j$  e os respectivos erros padrão das variáveis que permanecem no submodelo. Pode acontecer que um preditor seja dispensável num modelo completo, mas deixe de o ser num submodelo, ou viceversa.

## Algoritmos de pesquisa sequenciais

Caso não esteja disponível *software* apropriado, ou se o número  $p$  de preditores for demasiado grande, pode recorrer-se a **algoritmos de pesquisa** que simplificam uma regressão linear múltipla **sem analisar todo os possíveis submodelos e sem a garantia de obter os melhores subconjuntos**.

Vamos considerar um **algoritmo** que, em cada passo, exclui uma **variável preditora**, até alcançar uma **condição de paragem** considerada adequada, ou seja, um **algoritmo de exclusão sequencial** (*backward elimination*).

Existem variantes deste algoritmo, não estudadas aqui:

- **algoritmo de inclusão sequencial** (*forward selection*).
- **algoritmos de exclusão/inclusão alternada** (*stepwise selection*).

## O algoritmo de exclusão sequencial com testes aos $\beta_j$

- 1 ajustar o modelo completo, com os  $p$  preditores;
  - 2 definir um nível de significância  $\alpha$  para os testes de hipóteses a  $\beta_j = 0$ ;
  - 3 para todas as variáveis rejeita-se  $H_0 : \beta_j = 0$ ?
    - ▶ **Se sim:** não é possível simplificar o modelo (passar ao ponto 4).
    - ▶ **Se não:** variáveis em que **não** se rejeita  $H_0$  são dispensáveis (candidatas à exclusão).
      - ★ se apenas existe uma candidata a sair, **excluir essa variável**;
      - ★ se existir mais do que uma variável candidata a sair, **excluir a variável associada ao maior  $p$ -value** (isto é, ao valor da estatística  $t$  mais próxima de zero)
- Reajustar o modelo após a exclusão da variável e repetir este ponto 3**
- 4 Quando não existirem variáveis candidatas a sair, ou quando sobrar um único preditor, o algoritmo pára. Tem-se então o **submodelo final**.

## Critério de Informação de Akaike

O  disponibiliza funções para automatizar pesquisas sequenciais de submodelos, semelhantes à que aqui foi enunciada, mas em que o critério de exclusão duma variável em cada passo se baseia no **Critério de Informação de Akaike (AIC)**.

### Critério de Informação de Akaike (AIC)

O AIC é uma **medida geral da qualidade de ajustamento de modelos**. No contexto duma **Regressão Linear Múltipla com  $k$  variáveis preditoras**, define-se como

$$AIC = n \cdot \ln \left( \frac{SQRE_k}{n} \right) + 2(k + 1) .$$

**Nota:** O AIC pode tomar valores negativos.

## Interpretando o AIC

$$AIC = n \cdot \ln \left( \frac{SQRE_k}{n} \right) + 2(k+1)$$

- a primeira parcela é função crescente de  $SQRE_k$ , i.e., quanto melhor o ajustamento, mais pequena a primeira parcela;
- a segunda parcela mede a complexidade do modelo ( $k+1$  é o número de parâmetros), pelo que quanto mais parcimonioso o modelo, mais pequena a segunda parcela.

Assim, o AIC depende simultaneamente da qualidade do ajustamento e da simplicidade do modelo.

Um modelo para a variável resposta  $Y$  é considerado **melhor** que outro se tiver um **AIC menor** (quando ajustados com os mesmos dados).

## Algoritmo de exclusão sequencial com base no AIC

Pode definir-se um algoritmo de exclusão sequencial, com base no critério AIC:

- ajustar o modelo completo e calcular o respectivo AIC.
- ajustar cada submodelo com menos **uma** variável e calcular o respectivo AIC.
- Se nenhum dos AICs dos submodelos considerados for inferior ao AIC do modelo anterior, o algoritmo termina sendo o modelo anterior o modelo final.  
Caso alguma das exclusões reduza o AIC, efectua-se a exclusão que mais reduz o AIC e regressa-se ao ponto anterior.

## As duas variantes dos algoritmos

Os algoritmos de exclusão sequencial baseados nos testes  $t$  ou no AIC coincidem nas variáveis a excluir, podendo diferir apenas no momento de paragem.

Em geral, um algoritmo de exclusão sequencial baseado no AIC é mais cauteloso na exclusão, sobretudo se o valor de  $\alpha$  usado nos testes  $t$  for baixo. Nos algoritmos baseados nos testes  $t$ , é aconselhável usar valores mais elevados de  $\alpha$ , como  $\alpha = 0.10$ .

Um algoritmo de exclusão sequencial não garante a identificação do "melhor submodelo" com um dado número de preditores. Apenas identifica, de forma computacionalmente ligeira, submodelos "bons".

Deve ser usado com bom senso e o submodelo obtido cruzado com outras considerações (e.g., o custo ou dificuldade de obtenção de cada variável, ou o papel que a teoria relativa ao problema em questão reserva a cada preditor).

## Exemplo: prever a percentagem de músculo em carcaça de porcos a partir de 7 preditores

```

proc reg data=porcos;
model Musculo = Area Gordurasubcut Peso Rendimento Gordurarenalpel Comprimento LarguraAnca /clb
covb xpx R CLI CLM ;
output out=out_reg p=predicted_value;
test Area, Gordurasubcut, Peso, Rendimento;
RUN;
quit;

```

| Parameter Estimates |    |                    |                |         |         |                       |          |
|---------------------|----|--------------------|----------------|---------|---------|-----------------------|----------|
| Variable            | DF | Parameter Estimate | Standard Error | t Value | Pr >  t | 95% Confidence Limits |          |
| Intercept           | 1  | 54.11487           | 9.27061        | 5.84    | <.0001  | 33.91594              | 74.31380 |
| Area                | 1  | 0.06200            | 0.70162        | 0.09    | 0.9310  | -1.46670              | 1.59070  |
| Gordurasubcut       | 1  | -0.93861           | 0.36030        | -2.61   | 0.0230  | -1.72363              | -0.15359 |
| Peso                | 1  | 0.24489            | 0.26196        | 0.93    | 0.3683  | -0.32587              | 0.81565  |
| Rendimento          | 1  | 0.00623            | 0.08323        | 0.07    | 0.9416  | -0.17511              | 0.18756  |
| Gordurarenalpel     | 1  | -0.01436           | 0.00714        | -2.01   | 0.0673  | -0.02991              | 0.00119  |
| Comprimento         | 1  | 0.01774            | 0.04832        | 0.37    | 0.7199  | -0.08755              | 0.12302  |
| LarguraAnca         | 1  | 0.11974            | 0.06255        | 1.91    | 0.0797  | -0.01654              | 0.25602  |

- Há 6 preditores cuja exclusão individual é admissível (com  $\alpha = 0.05$ ).
- **Mas não é legítimo concluir que Area, Peso, Rendimento, Gordurarenalpel, Comprimento e LarguraAnca são dispensáveis em conjunto.**

## O algoritmo de exclusão sequencial com testes aos $\beta_j$ (com $\alpha = 0.10$ )

ajustar o modelo completo, com os  $p$  preditores

Modelo inicial, Completo,  $p = 7$

model Musculo = Area Gordurasubcut Peso Rendimento  
Gordurarenalpel Comprimento LarguraAnca

The REG Procedure  
Model: MODEL1  
Dependent Variable: Musculo

|                             |    |
|-----------------------------|----|
| Number of Observations Read | 20 |
| Number of Observations Used | 20 |

| Source          | DF | Sum of Squares | Mean Square | F Value | Pr > F |
|-----------------|----|----------------|-------------|---------|--------|
| Model           | 7  | 77.98252       | 11.14036    | 21.50   | <.0001 |
| Error           | 12 | 6.21748        | 0.51812     |         |        |
| Corrected Total | 19 | 84.20000       |             |         |        |

|                |          |          |        |
|----------------|----------|----------|--------|
| Root MSE       | 0.71981  | R-Square | 0.9262 |
| Dependent Mean | 54.30000 | Adj R-Sq | 0.8831 |
| Coeff Var      | 1.32561  |          |        |

| Variable        | DF | Parameter Estimate | Standard Error | t Value | Pr >  t | 95% Confidence Limits |          |
|-----------------|----|--------------------|----------------|---------|---------|-----------------------|----------|
| Intercept       | 1  | 54.11487           | 9.27061        | 5.84    | <.0001  | 33.91594              | 74.31380 |
| Area            | 1  | 0.06200            | 0.70162        | 0.09    | 0.9310  | -1.46670              | 1.59070  |
| Gordurasubcut   | 1  | -0.93861           | 0.36030        | -2.61   | 0.0230  | -1.72363              | -0.15359 |
| Peso            | 1  | 0.24489            | 0.26196        | 0.93    | 0.3683  | -0.32587              | 0.81565  |
| Rendimento      | 1  | 0.00623            | 0.08323        | 0.07    | 0.9416  | -0.17511              | 0.18756  |
| Gordurarenalpel | 1  | -0.01436           | 0.00714        | -2.01   | 0.0673  | -0.02991              | 0.00119  |
| Comprimento     | 1  | 0.01774            | 0.04832        | 0.37    | 0.7199  | -0.08755              | 0.12302  |
| LarguraAnca     | 1  | 0.11974            | 0.06255        | 1.91    | 0.0797  | -0.01654              | 0.25602  |

para todas as variáveis rejeita-se  $H_0 : \beta_j = 0$ ?  
( $\alpha = 0.10$ )



se existir mais do que uma variável candidata a sair, excluir a variável associada ao maior  $p$ -value (isto é, ao valor da estatística  $t$  mais próxima de zero)

## Exemplo (continuação)

Reajustar o modelo após a exclusão da variável rendimento

model Musculo = Area Gordurasubcut Peso Gordurarenalpel Comprimento LarguraAnca

| Parameter Estimates |    |                    |                |         |         |                       |            |
|---------------------|----|--------------------|----------------|---------|---------|-----------------------|------------|
| Variable            | DF | Parameter Estimate | Standard Error | t Value | Pr >  t | 95% Confidence Limits |            |
| Intercept           | 1  | 54.50052           | 7.40466        | 7.36    | <.0001  | 38.50373              | 70.49732   |
| Area                | 1  | 0.05151            | 0.66065        | 0.08    | 0.9390  | -1.37575              | 1.47877    |
| Gordurasubcut       | 1  | -0.94880           | 0.32059        | -2.96   | 0.0111  | -1.64138              | -0.25621   |
| Peso                | 1  | 0.25275            | 0.23057        | 1.10    | 0.2929  | -0.24536              | 0.75087    |
| Gordurarenalpel     | 1  | -0.01427           | 0.00677        | -2.11   | 0.0549  | -0.02889              | 0.00034730 |
| Comprimento         | 1  | 0.01672            | 0.04456        | 0.38    | 0.7135  | -0.07955              | 0.11300    |
| LarguraAnca         | 1  | 0.11927            | 0.05981        | 1.99    | 0.0675  | -0.00994              | 0.24849    |

para todas as variáveis rejeita-se  $H_0 : \beta_j = 0$ ?

( $\alpha = 0.10$ )



se existir mais do que uma variável candidata a sair, excluir a variável associada ao maior *p-value* (isto é, ao valor da estatística *t* mais próxima de zero)

## Exemplo (continuação)

Reajustar o modelo após a exclusão da variável Area

model Musculo = Gordurasubcut Peso Gordurarenalpel Comprimento LarguraAnca

| Parameter Estimates |    |                    |                |         |         |                       |          |
|---------------------|----|--------------------|----------------|---------|---------|-----------------------|----------|
| Variable            | DF | Parameter Estimate | Standard Error | t Value | Pr >  t | 95% Confidence Limits |          |
| Intercept           | 1  | 54.95081           | 4.46691        | 12.30   | <.0001  | 45.37024              | 64.53139 |
| Gordurasubcut       | 1  | -0.96660           | 0.21686        | -4.46   | 0.0005  | -1.43173              | -0.50147 |
| Peso                | 1  | 0.25637            | 0.21768        | 1.18    | 0.2585  | -0.21050              | 0.72325  |
| Gordurarenalpel     | 1  | -0.01457           | 0.00534        | -2.73   | 0.0162  | -0.02602              | -0.00313 |
| Comprimento         | 1  | 0.01747            | 0.04195        | 0.42    | 0.6834  | -0.07251              | 0.10745  |
| LarguraAnca         | 1  | 0.11937            | 0.05764        | 2.07    | 0.0573  | -0.00425              | 0.24298  |

para todas as variáveis rejeita-se  $H_0 : \beta_j = 0$ ?  
( $\alpha = 0.10$ )



se existir mais do que uma variável candidata a sair, excluir a variável associada ao maior *p-value* (isto é, ao valor da estatística *t* mais próxima de zero)



## Exemplo (continuação)

Reajustar o modelo após a exclusão da variável Comprimento

```
model Musculo = Gordurasubcut Peso Gordurarenalpel LarguraAnca
```

| Parameter Estimates |    |                    |                |         |         |                       |          |
|---------------------|----|--------------------|----------------|---------|---------|-----------------------|----------|
| Variable            | DF | Parameter Estimate | Standard Error | t Value | Pr >  t | 95% Confidence Limits |          |
| Intercept           | 1  | 55.95724           | 3.65149        | 15.32   | <.0001  | 48.17427              | 63.74020 |
| Gordurasubcut       | 1  | -0.98841           | 0.20456        | -4.83   | 0.0002  | -1.42443              | -0.55240 |
| Peso                | 1  | 0.26808            | 0.20982        | 1.28    | 0.2208  | -0.17915              | 0.71531  |
| Gordurarenalpel     | 1  | -0.01423           | 0.00512        | -2.78   | 0.0141  | -0.02515              | -0.00331 |
| LarguraAnca         | 1  | 0.12268            | 0.05549        | 2.21    | 0.0430  | 0.00441               | 0.24095  |

para todas as variáveis rejeita-se  $H_0 : \beta_j = 0$ ?



( $\alpha = 0.10$ )

se apenas existe uma candidata a sair, excluir essa variável;

## Exemplo (continuação)

Reajustar o modelo após a exclusão da variável **Peso**

```
model Musculo = Gordurasubcut Gordurarenalpel LarguraAnca
```

| Parameter Estimates |    |                    |                |         |         |                       |          |
|---------------------|----|--------------------|----------------|---------|---------|-----------------------|----------|
| Variable            | DF | Parameter Estimate | Standard Error | t Value | Pr >  t | 95% Confidence Limits |          |
| Intercept           | 1  | 60.21488           | 1.52200        | 39.56   | <.0001  | 56.98839              | 63.44138 |
| Gordurasubcut       | 1  | -0.92545           | 0.20242        | -4.57   | 0.0003  | -1.35456              | -0.49633 |
| Gordurarenalpel     | 1  | -0.01721           | 0.00465        | -3.70   | 0.0019  | -0.02707              | -0.00734 |
| LarguraAnca         | 1  | 0.11380            | 0.05613        | 2.03    | 0.0596  | -0.00519              | 0.23279  |

para todas as variáveis rejeita-se  $H_0 : \beta_j = 0?$   
( $\alpha = 0.10$ )



Quando não existirem variáveis candidatas a sair, ou quando sobrar um único preditor, o algoritmo pára. Tem-se então o **submodelo final**.

**Submodelo final:**

```
model Musculo = Gordurasubcut Gordurarenalpel LarguraAnca
```

|                |          |          |        |
|----------------|----------|----------|--------|
| Root MSE       | 0.66078  | R-Square | 0.9170 |
| Dependent Mean | 54.30000 | Adj R-Sq | 0.9015 |
| Coeff Var      | 1.21690  |          |        |

| Parameter Estimates |    |                    |                |         |         |                       |          |
|---------------------|----|--------------------|----------------|---------|---------|-----------------------|----------|
| Variable            | DF | Parameter Estimate | Standard Error | t Value | Pr >  t | 95% Confidence Limits |          |
| Intercept           | 1  | 60.21488           | 1.52200        | 39.56   | <.0001  | 56.98839              | 63.44138 |
| Gordurasubcut       | 1  | -0.92545           | 0.20242        | -4.57   | 0.0003  | -1.35456              | -0.49633 |
| Gordurarenalpel     | 1  | -0.01721           | 0.00465        | -3.70   | 0.0019  | -0.02707              | -0.00734 |
| LarguraAnca         | 1  | 0.11380            | 0.05613        | 2.03    | 0.0596  | -0.00519              | 0.23279  |

# Algoritmo de exclusão sequencial com base no AIC

Um modelo para a variável resposta  $Y$  é considerado **melhor** que outro se tiver um **AIC menor** (quando ajustados com os mesmos dados).

```
proc reg data=porcos;  
model Musculo = Area Gordurasubcut Peso  
Rendimento Gordurarenalpel Comprimento  
LarguraAnca /clb covb xpx R CLI CLM  
selection=adjrsq aic;  
RUN;
```

| Number in Model | Adjusted R-Square | R-Square | AIC      | Variables in Model  |
|-----------------|-------------------|----------|----------|---|
| 4               | 0.9052            | 0.9252   | -13.1025 | Gordurasubcut Peso Gordurarenalpel LarguraAnca                        |
| 3               | 0.9015            | 0.9170   | -13.0365 | Gordurasubcut Gordurarenalpel LarguraAnca                             |
| 5               | 0.8997            | 0.9261   | -11.3487 | Gordurasubcut Peso Gordurarenalpel Comprimento LarguraAnca            |
| 5               | 0.8987            | 0.9253   | -11.1425 | Area Gordurasubcut Peso Gordurarenalpel LarguraAnca                   |
| 5               | 0.8985            | 0.9252   | -11.1101 | Gordurasubcut Peso Rendimento Gordurarenalpel LarguraAnca             |
| 4               | 0.8971            | 0.9188   | -11.4592 | Gordurasubcut Gordurarenalpel Comprimento LarguraAnca                 |
| 4               | 0.8962            | 0.9181   | -11.2878 | Area Gordurasubcut Gordurarenalpel LarguraAnca                        |
| 4               | 0.8956            | 0.9176   | -11.1738 | Gordurasubcut Rendimento Gordurarenalpel LarguraAnca                  |
| 6               | 0.8920            | 0.9261   | -9.3580  | Area Gordurasubcut Peso Gordurarenalpel Comprimento LarguraAnca       |
| 6               | 0.8920            | 0.9261   | -9.3543  | Gordurasubcut Peso Rendimento Gordurarenalpel Comprimento LarguraAnca |
| 5               | 0.8915            | 0.9201   | -9.7781  | Gordurasubcut Rendimento Gordurarenalpel Comprimento LarguraAnca      |
| 6               | 0.8909            | 0.9253   | -9.1440  | Area Gordurasubcut Peso Rendimento Gordurarenalpel LarguraAnca        |
| 5               | 0.8905            | 0.9193   | -9.5898  | Area Gordurasubcut Gordurarenalpel Comprimento LarguraAnca            |
| 5               | 0.8900            | 0.9189   | -9.5004  | Area Gordurasubcut Rendimento Gordurarenalpel LarguraAnca             |
| 6               | 0.8842            | 0.9208   | -7.9614  | Area Gordurasubcut Rendimento Gordurarenalpel Comprimento LarguraAnca |
| 2               | 0.8834            | 0.8957   | -10.4631 | Gordurasubcut Gordurarenalpel   |

■ ■ ■