



# PROCEDIMENTOS DO TIPO STEPWISE

## MAE0350 — MODELOS DE REGRESSÃO I

Cristine Airi Kimura (13783096);

Gabriel Medeiros Cupini (13783116);

João Vitor Guandalini Vicente (15062582);

Oliam Castanha Lima (13686261);

Vicenzo Carlim de Sousa (13686772).

# STEPWISE

## PASSO A PASSO

CONTEXTO: SELECIONAR A MELHOR EQUAÇÃO DE  
REGRESSÃO.

OBJETIVO: IDENTIFICAR O MENOR GRUPO DE VARIÁVEIS EXPLICATIVAS QUE SÃO  
“BOAS” DE ACORDO COM ALGUM CRITÉRIO ESPECÍFICO.





**STEPWISE**

$X_1$  $X_2$  $X_3$  $X_4$ 

*Quantos modelos de regressão podem ser construídos a partir das quatro variáveis preditoras disponíveis?*

- Primeiramente, existe **um** modelo sem variável explicativa alguma, isto é,  $Y_i = \beta_0 + \epsilon_i$ .
- Em seguida, temos **quatro** modelos com uma única variável explicativa ( $X_1, X_2, X_3, X_4$ ).
- Em seguida, temos **seis** modelos com duas variáveis explicativas ( $X_1$  e  $X_2$ ;  $X_1$  e  $X_3$ ;  $X_1$  e  $X_4$ ;  $X_2$  e  $X_3$ ;  $X_2$  e  $X_4$ ;  $X_3$  e  $X_4$ ).
- Em seguida, temos **quatro** modelos com três variáveis explicativas ( $X_1, X_2$  e  $X_3$ ;  $X_1, X_2$  e  $X_4$ ;  $X_1, X_3$  e  $X_4$ ;  $X_2, X_3$  e  $X_4$ ).
- Por fim, temos **um** modelo com as quatro variáveis explicativas, isto é,  $Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3} + \beta_4 x_{i4} + \epsilon_i$ .

**Resposta:**  $2^4 = 16$  modelos.

# PROCEDIMENTO GERAL DA REGRESSÃO *STEPWISE*

*“Escolhe-se uma equação contendo a melhor variável  $X$  e, depois, tentamos construir uma nova equação com adições subsequentes de  $X$ 's, uma por vez, contanto que essas inserções valham a pena.”*

# PROCEDIMENTO GERAL DA REGRESSÃO *STEPWISE*

*“Escolhe-se uma equação contendo a **melhor variável**  $X$  e, depois, tentamos construir uma nova equação com **adições subsequentes** de  $X$ 's, uma por vez, contanto que essas inserções **valham a pena**.”*

- A **ordem da adição** é determinada pelo teste  **$F$ -parcial**;
- O valor  $F$ -parcial mais alto é comparado com um valor “ $F$ -para-inserir” (selecionado ou padrão);
- Após a adição da variável, a equação é examinada.

# PASSO A PASSO

1. Selecionar a variável independente  $Z_1$  mais correlacionada com  $Y$  e encontrar a equação de regressão linear de primeira ordem  $\hat{Y} = f(Z_1)$ ;
2. Checar se a variável  $Z_1$  é significativa;
  - I. Se não for, abandonamos o modelo e adotamos  $Y = \bar{Y}$ ;
  - II. Caso contrário, procuramos pela segunda variável preditora para ser incluída na regressão.
3. Examinar os valores  $F$ -parciais de todas as variáveis preditoras que **não** estão na regressão. A variável  $Z_j$  com o maior valor (por exemplo,  $Z_2$ ) é selecionada e uma segunda equação de regressão  $\hat{Y} = f(Z_1, Z_2)$  é ajustada.
4. **Analisar**: verificar a significância global, observar a melhoria no  $R^2$  e examinar os valores  $F$ -parciais para ambas as variáveis no modelo.
5. O menor desses dois  $F$ 's parciais é comparado com um ponto percentual " $F$ -para-remover" e a variável preditora correspondente é mantida ou não na equação dependendo se o teste é significativo ou não.



# OBSERVAÇÕES SOBRE O PROCEDIMENTO

- O teste da variável preditora menos “útil” na equação atual é realizado em todas as etapas;
- A “melhor” variável explicativa candidata em uma fase anterior pode ser supérflua na fase posterior;
  - Para checar, utilizar o critério da  $F$ -parcial para cada variável na regressão;
  - Julgar a contribuição da variável “menos útil” naquele estágio.
    - Se a variável testada fornecer uma contribuição não significativa, ela é removida do modelo e é calculada a equação ajustada de regressão apropriada para as variáveis restantes no modelo.
- A “melhor” das variáveis (cujo valor  $F$ -parcial dado as preditoras na equação é o maior) é verificada no teste  $F$ -parcial de entrada;
  - Se for aprovado, ela será inserida e voltaremos a verificar todos os  $F$ -parciais em busca de variáveis;
  - Se falhar, uma nova remoção será tentada.
- Eventualmente, quando nenhuma variável na equação pode ser removida e a próxima melhor variável candidata não puder ser mantida, **o processo termina.**



# EXEMPLO – DADOS DE HALD (1952, p. 647)

- Dados originalmente provenientes de “*Efeito da composição do cimento de Portland no calor liberado durante o endurecimento*”, por H. Woods, H. H. Steinour e H. R. Starke, *Industrial and Engineering Chemistry*, 24, 1932, 1207-1214.

- As variáveis são:

$X_1$  = quantidade de aluminato tricálcico,  $3 \text{ CaO} \cdot \text{Al}_2\text{O}_3$ .

$X_2$  = quantidade de silicato tricálcico,  $3 \text{ CaO} \cdot \text{SiO}_2$ .

$X_3$  = quantidade de ferroaluminato tetracálcico,  $4 \text{ CaO} \cdot \text{Al}_2\text{O}_3 \cdot \text{Fe}_2\text{O}_3$ .

$X_4$  = quantidade de silicato dicálcico,  $2 \text{ CaO} \cdot \text{SiO}_2$ .

$Y$  (resposta) = calor liberado em calorias por grama de cimento.

- $X_1$ ,  $X_2$ ,  $X_3$  e  $X_4$  foram mensuradas como porcentagem do peso dos clínqueres com os quais o cimento foi feito.

$X_1$	$X_2$	$X_3$	$X_4$	$Y$	Soma dos $X$ 's
7	26	6	60	78,5	99
1	29	15	52	74,3	97
11	56	8	20	104,3	95
11	31	8	47	87,6	97
7	52	6	33	95,9	98
11	55	9	22	109,2	97
3	71	17	6	102,7	97
1	31	22	44	72,5	98
2	54	18	22	93,1	96
21	47	4	26	115,9	98
1	40	23	34	83,8	98
11	66	9	12	113,3	98
10	68	8	12	109,4	98

# EXEMPLO – DADOS DE HALD (1952, p. 647)

- Matriz de correlação para os dados

Matrix M1				
1.00000	0.22858	-0.82413	-0.24545	0.73072
0.22858	1.00000	-0.13924	-0.97295	0.81625
-0.82413	-0.13924	1.00000	0.02954	-0.53467
-0.24545	-0.97295	0.02954	1.00000	-0.82131
0.73072	0.81625	-0.53467	-0.82131	1.00000

# EXEMPLO – DADOS DE HALD (1952, p. 647)

- Tabela dos testes  $F$ -parciais

**TABLE 15.6. Partial  $F$ -Values for the Hald Data<sup>a</sup>**

Subscripts of Variables in Regression	Partial $F$ -Values of Variables Not in Regression			
	1	2	3	4
—	12.60	21.96	4.40	22.80
1	—	208.58	0.31	159.30
2	146.52	—	11.82	0.43
3	5.81	36.68	—	100.36
4	108.22	0.17	40.29	—
12	—	—	1.83	1.86
13	—	220.55	—	208.24
14	—	5.03	4.24	—
23	68.72	—	—	41.65
24	154.01	—	96.94	—
34	22.11	12.43	—	—
123	—	—	—	0.04
124	—	—	0.02	—
134	—	0.50	—	—
234	4.34	—	—	—

<sup>a</sup> For example,  $F_{3|14} = 4.24$  is the partial  $F$ -value for  $b_3$  given that  $(b_1$  and  $b_4)$  are already in the regression equation. Remember that an intercept  $\beta_0$  is fitted in all of the equations but is not specifically mentioned in the table.

# EXEMPLO – DADOS DE HALD (1952, p. 647)

- Os testes de entrada e saída serão feitos considerando o nível  $\alpha = 0,05$ . Geralmente, é melhor escolher os mesmos níveis de significâncias para ambos os testes.

1) Escolher a primeira variável (mais correlacionada com a resposta e de maior valor  $F$ -parcial para apenas uma variável no modelo).

$r_{4Y} = -0,821$  é a maior correlação com  $Y$  e  $F_{4|1} = 22,80$  é o maior valor  $F$ -parcial.

2) Teste para  $X_4$ . O valor  $F$  de 22,80 é maior que  $F(1, 11; 0,05) = 4,84$ . Manter  $X_4$ .

3) Procurar o próximo “melhor  $X$ ”, que é  $X_1$ , pois

$F_{1|4} = 108,22$  é maior que  $F_{2|4} = 0,17$  e que  $F_{3|4} = 40,29$ .

Inserir  $X_1$  e calcular a equação  $\hat{Y} = f(X_1, X_4)$ .

$$\hat{Y} = 103,10 + 1,440X_1 - 0,614X_4.$$

# EXEMPLO – DADOS DE HALD (1952, p. 647)

Temos  $R^2 = 0,972$  e um  $F$  global = 176,63, que é claramente significativa. Isso completa o passo de entrada.

4) Verificar uma possível saída. Os dois  $F$ 's parciais são  $F_{1|4} = 108,22$  e  $F_{4|1} = 159,30$ . A mais recente variável adicionada  $X_1$  é a mais fraca, mas é significativa pois  $108,22 > F(1, 10; 0,05) = 4,96$ . Vamos manter  $X_4$  e  $X_1$ .

5) Selecionamos, como a próxima variável para entrar, a mais parcialmente correlacionada com a resposta (dadas as variáveis  $X_4$  e  $X_1$  já na regressão). Parece ser a variável  $X_2$ , já que  $F_{2|14} = 5,03$  é maior que  $F_{3|14} = 4,24$ . A equação é:

$$\hat{Y} = 71,65 + 1,452X_1 + 0,416X_2 - 0,237X_4,$$

com  $R^2 = 0,98234$  e um  $F$  global = 166,83 significativa.



# EXEMPLO – DADOS DE HALD (1952, p. 647)

6) Verificar uma possível saída. Os três  $F$ 's parciais são:

$$F_{1|24} = 154,01; F_{2|14} = 5,03 \text{ e } F_{4|12} = 1,86$$

Claramente,  $F_{4|12} = 1,86 < F(1, 9; 0,05) = 5,12$ . Então, devemos remover  $X_4$ . Embora  $F_{2|14} = 5,03$  também seja menor que 5,12, não agimos em relação a  $X_2$ , pois primeiramente recalculamos a equação  $\hat{Y} = f(X_1, X_2)$ . Removemos apenas um  $X$  por vez.

7) A equação ajustada com  $X_1$  e  $X_2$  é:

$$\hat{Y} = 52,58 + 1,468X_1 + 0,662X_2.$$

Os  $F$ 's parciais são  $F_{1|2} = 146,52$  e  $F_{2|1} = 208,58$ . Então, ambas as variáveis são mantidas.  $R^2 = 0,979$  e  $F_{\text{global}} = 229,50$ .

8) Agora, olhamos para uma nova variável candidata e verificamos que  $F_{3|12} = 1,83$  e  $F_{4|12} = 1,86$ . Embora  $X_4$  seja sutilmente melhor, é inútil inseri-la. Portanto, o procedimento termina com o resultado dado no passo 7).

# SELEÇÃO FORWARD

- A seleção *forward* é um procedimento mais simples (porém, menos efetivo), em que apenas a variável mais recentemente adicionada é testada.
- Ela garante que as variáveis inseridas não são subsequentemente removidas, o que pode ser desejável para aplicações específicas.
- Os autores **não** recomendam o uso da seleção **forward**, exceto quando é especificamente desejado não remover nunca as variáveis que foram retidas em estágios anteriores.
- Para o exemplo, no passo 6), apenas a variável  $X_2$  teria sido testada (e rejeitada) e não teríamos visto que  $X_4$  era a variável “mais fraca”.

# ELIMINAÇÃO BACKWARD

- Ao contrário do método *forward*, o *backward stepwise* começa com todas as variáveis incluídas. Em cada iteração, o algoritmo avalia o impacto da remoção de cada variável e exclui aquela que menos contribui para o modelo, até que nenhuma variável atenda ao critério de exclusão.
- Os passos básicos desse procedimento são:
  1. Uma equação de regressão contendo todas as variáveis é calculada;
  2. O valor do teste  $F$ -parcial é calculado para cada variável preditora tratada como se fosse a última variável a ser inserida no modelo de regressão;
  3. O menor valor do teste  $F$ -parcial ( $F_L$ ) é comparado com o nível de significância pré-selecionado ou padrão ( $F_0$ ).
    - I. Se  $F_L < F_0$ , remova a variável  $X_L$  e recalcule a equação de regressão para as variáveis remanescentes. Repita o passo 2.;
    - II. Se  $F_L > F_0$ , adote a equação de regressão calculada.

# ELIMINAÇÃO BACKWARD

Considerações sobre a eliminação *backward*:

- Computacionalmente, é um método de seleção muito econômico;
- É possível ter uma dimensão de todas as variáveis na equação, isto é, produz um senso ao estatístico de que nenhuma variável está faltando;
- Pode não fazer sentido se a matriz  $X'X$  for **mal condicionada**, devido a erros de aproximação.

# NÍVEIS DE SIGNIFICÂNCIA PARA PROCEDIMENTOS DE SELEÇÃO

## Considerações extras sobre o procedimento *stepwise*:

- É típico que o aumento do  $R^2$  seja registrado para cada variável adicionada;
- Os valores  $F$ -para-entrar e  $F$ -para-remover não precisam necessariamente ser iguais, mas algumas considerações devem ser feitas:
  - Com o  $F$ -para-remover sendo maior do que o  $F$ -para-entrar, é possível que variáveis sejam removidas do modelo logo após serem inseridas. Essa situação pode causar um efeito cíclico de inserção e remoção de variáveis em programas que permitem reinserção.



# NÍVEIS DE SIGNIFICÂNCIA PARA PROCEDIMENTOS DE SELEÇÃO

- Os valores  $F$  escolhidos para os testes possuem, cada um, equivalentes valores- $p$ ; entretanto, as estatísticas  $F$  usadas para a realização dos testes de entrada não têm a típica distribuição  $F$  (ao contrário do que é presumido pelo uso do teste  $F$ ), mas sim uma distribuição cuja função de densidade de probabilidade é de difícil obtenção.
  - Os verdadeiros valores- $p$  desses testes são maiores do que os obtidos pelos programas.

## Procedimento alternativo (criado para melhorar a seleção de variáveis):

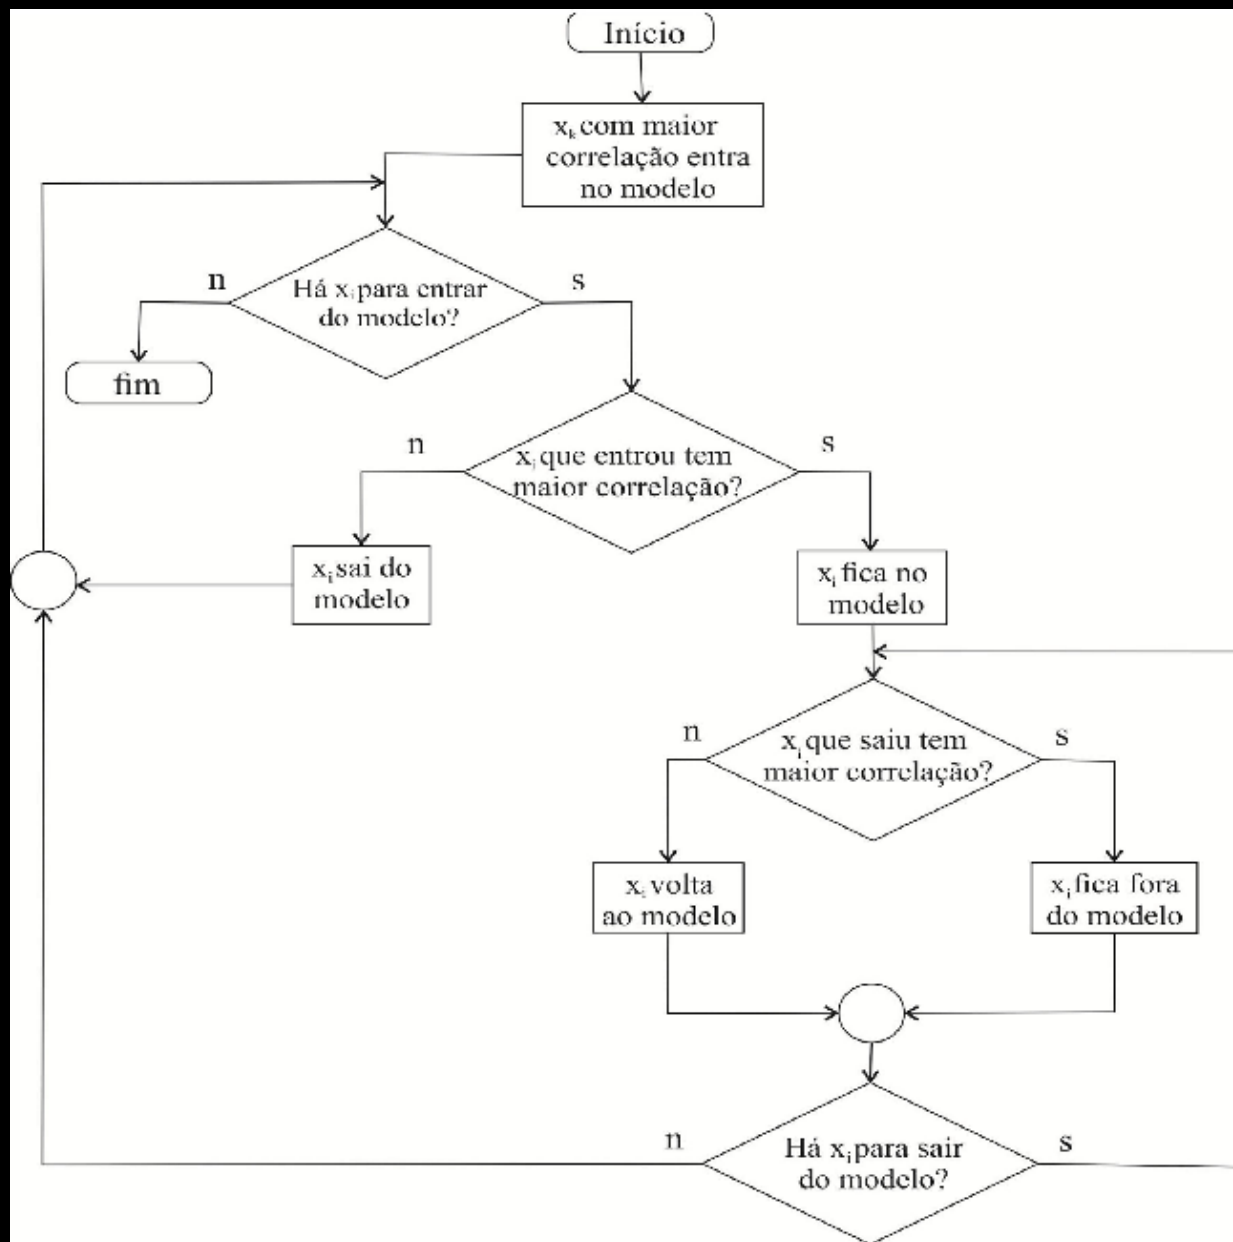
- *Rodar a regressão stepwise, registrar a quantidade  $q$  de variáveis explicativas usadas no modelo final e, então, realizar regressões para todos os conjuntos de  $q$  variáveis do conjunto total e escolher o melhor modelo.*

# VARIAÇÕES DOS MÉTODOS

- Os procedimentos não necessariamente selecionam absolutamente o melhor modelo, mas sim um aceitável para aquele conjunto de dados;
- **Proposta de procedimento alternativo:**
  - Rodar o procedimento de regressão *stepwise* com níveis de aceitação e rejeição;
  - Quando o procedimento parar, determinar o número de variáveis do modelo final;
  - Use as 'j' em 'k' (total) variáveis selecionadas para montar o melhor modelo;
- Quando o procedimento seleciona 2 candidatos muito próximos para o modelo, dizemos que há informações insuficientes nos dados para fazer uma decidir um único modelo;
- O procedimento também falha quando uma grande quantidade de variáveis seriam mais apropriadas para descrever o modelo, mas nunca são analisadas pelo algoritmo de *stepwise*;
- Pode-se forçar o programa a selecionar determinada variável na equação de regressão, quando o estatístico possui a informação de que essa variável tem efeito conhecido.

# CONCLUSÃO E COMENTÁRIOS DOS AUTORES

- Na maioria dos casos, as equações serão as mesmas do método dos mínimos quadrados, mas isso não é garantido;
- É válido destacar também que estatísticos diferentes podem ter interpretações distintas sobre os métodos, isto é, é comum haver escolhas inconsistentes que resultarão em equações totalmente distintas entre os vários métodos que podem ser utilizados para formar a equação de regressão;
- Para os autores (*Draper e Smith*), o método prático de regressão *stepwise* é o favorito, principalmente devido ao avanço tecnológico e a capacidade dos computadores para rodar o algoritmo. Vale lembrar que nenhuma técnica é a melhor sempre, permitindo a utilização de diversos métodos distintos como ferramentas úteis para a descrição dos dados.



## Resumo:

- A regressão *stepwise* envolve a adição procedural das variáveis explicativas ao modelo, até não haver mais nenhuma significativa para a explicação de  $Y$ , junto da remoção, após cada adição, das variáveis no modelo que não são mais significantes para a explicação de  $Y$ .
- É feita a regressão de  $Y$  pela variável  $X_1$  mais correlacionada com ela;
- Realiza-se o teste  $F$  dessa variável. Caso não rejeitemos que  $\beta_1 = 0$ , o procedimento termina, sendo adotado o modelo  $Y = \bar{Y}$ ; caso contrário, o procedimento continua;
- São realizados testes  $F$ -parciais para cada uma das variáveis ainda fora do modelo e a com o maior valor- $F$  é adicionada ao modelo, caso esse valor- $F$  seja maior do que o valor escolhido como aceitável ( $F$ -para-entrar);
- São realizados testes  $F$ -parciais para cada uma das variáveis que estão no modelo e são removidas do modelo as variáveis com valores- $F$  abaixo do valor escolhido como aceitável ( $F$ -para-remover);
- São repetidos os últimos passos, até que nenhuma variável fora do modelo passe no teste para ser adicionada e nenhuma variável dentro do modelo falhe no teste para ser mantida.

Fonte: [Seleção de variáveis \*stepwise\* aplicadas em redes neurais artificiais para previsão de demanda de cargas elétricas](#). Anna Diva P. Lotufo.

# REFERÊNCIAS BIBLIOGRÁFICAS

- DRAPER, N. R.; SMITH, H. Applied Regression Analysis – Third Edition (1998). *Wiley series in probability and statistics*, p. 335-348.