

Análise de Regressão Linear Múltipla

Análise de Regressão Linear Múltipla

O modelo de regressão linear múltipla postula a existência de uma relação linear entre uma variável dependente ou explicada (Y) e p variáveis independentes ou explicativas X_1, \dots, X_p

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \beta_p X_p + \varepsilon$$

- X_1, \dots, X_p as variáveis explicativas ou independentes medidas sem erro (não aleatórias);
- ε a variável aleatória residual na qual se procuram incluir todas as influências no comportamento da variável Y que não podem ser explicadas linearmente pelo comportamento das variáveis X_1, \dots, X_p e os possíveis erros de medição;
- $\beta_0, \beta_1, \dots, \beta_p$ os parâmetros desconhecidos do modelo (a estimar);

Análise de Regressão Linear Múltipla

Temos então n variáveis aleatórias

$$Y_1 = \beta_0 + \beta_1 x_{11} + \beta_2 x_{12} + \beta_3 x_{13} + \dots + \beta_p x_{1p} + \varepsilon_1$$

$$Y_2 = \beta_0 + \beta_1 x_{21} + \beta_2 x_{22} + \beta_3 x_{23} + \dots + \beta_p x_{2p} + \varepsilon_2$$

$$Y_3 = \beta_0 + \beta_1 x_{31} + \beta_2 x_{32} + \beta_3 x_{33} + \dots + \beta_p x_{3p} + \varepsilon_3$$

\vdots

$$Y_n = \beta_0 + \beta_1 x_{n1} + \beta_2 x_{n2} + \beta_3 x_{n3} + \dots + \beta_p x_{np} + \varepsilon_n$$

Em notação matricial temos

$$\begin{pmatrix} Y_1 \\ Y_2 \\ Y_3 \\ \vdots \\ Y_n \end{pmatrix} = \begin{pmatrix} 1 & x_{11} & x_{12} & x_{13} & \dots & x_{1p} \\ 1 & x_{21} & x_{22} & x_{23} & \dots & x_{2p} \\ 1 & x_{31} & x_{32} & x_{33} & \dots & x_{3p} \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & x_{n3} & \dots & x_{np} \end{pmatrix} \times \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_p \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

Análise de Regressão Linear Múltipla

Estimação dos Parâmetros

A metodologia que se utiliza na regressão linear múltipla é similar que a estudada na regressão linear simples.

A melhor equação ajustada desta forma será aquela que faça mínima a soma de quadrados das desviações das Y observadas e das Y estimadas, onde o modelo estimado é

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X_1 + \hat{\beta}_2 X_2 + \hat{\beta}_3 X_3 + \dots + \hat{\beta}_p X_p$$

Análise de Regressão Linear Múltipla

Assim o sistema de equações normais é

$$(\mathbf{X}'\mathbf{X})\hat{\beta} = \mathbf{X}'\mathbf{Y}$$

da onde resolvendo para $\hat{\beta}$ obtemos

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$$

aqui $(\mathbf{X}'\mathbf{X})^{-1}$ representa a matriz inversa de $(\mathbf{X}'\mathbf{X})$. Notar que $(\mathbf{X}'\mathbf{X})$ é simétrica.

Propriedades do Estimador $\hat{\beta}$

Em forma similar ao caso simples, o estimador de mínimos quadrados tem as seguintes propriedades:

- 1 $\hat{\beta}$ é não viciado, ou seja $E(\hat{\beta}) = \beta$, isto significa que para todo $j = 0, 1, \dots, p$, $E(\hat{\beta}_j) = \beta_j$
- 2 $\text{Var}(\hat{\beta}) = \sigma^2(\mathbf{X}'\mathbf{X})^{-1}$
- 3 O estimador mínimo-quadrático $\hat{\beta}$ é o melhor estimador linear de β no sentido que é o que tem a menor variância.

Análise de Regressão Linear Múltipla

Estimação da Variância σ^2

No modelo de regressão linear múltipla com p variáveis preditoras (com o intercepto há no total $p+1$ parâmetros a estimar), o estimador da variância dos errors esta dado por:

$$\hat{\sigma}^2 = \frac{\sum \varepsilon_i^2}{n - p - 1} = \frac{(\mathbf{Y} - \mathbf{X}\hat{\beta})'(\mathbf{Y} - \mathbf{X}\hat{\beta})}{n - p - 1} = \frac{SQE}{n - p - 1}$$

O numerador da expressão representa a soma de quadrados dos resíduos (uma das fontes de variação da análise de variância)

Análise de Regressão Linear Múltipla

Testes sobre os coeficientes de regressão

Queremos testar se a influência de uma variável explicativa sobre a variável dependente não é significativa. Para isso testamos a hipótese nula que o coeficiente para esta variável é nulo:

$$\begin{cases} H_0 : \beta_i = 0 \\ H_1 : \beta_i \neq 0 \end{cases}$$

Se H_0 for rejeitada então temos evidência de que $\beta_i \neq 0$, isto é a variável explicativa X_i é útil na predição do valor da variável dependente.

Se H_0 não for rejeitada então a variável explicativa X_i é geralmente retirada da equação de regressão pois não influencia significativamente a variável resposta Y .

Análise de Regressão Linear Múltipla

Os resultados podem ser convenientemente resumidos na tabela da ANOVA.

ANOVA

Fontes de variação	Soma dos quadrados	Graus de liberdade	Quadrados médios	Razão F
devido à Regressão	SQR	p	QMR	$F = \frac{QMR}{QME}$
devido aos resíduos	SQE	n-p-1	QME	
total	SQT	n-1		


Exemplo 1

Se deseja construir um modelo de regressão para obter o volume de madeira de uma cerejeira em função da altura do tronco e do diâmetro do mesmo a um metro do solo e da idade da árvore. Foi tomada uma amostra de 31 árvores.

Obs	Diâmet	Alt	Ida	Vol	Obs	Diâmet	Alt	Ida	Vol
1	8,3	70	2	10,3	17	12,9	85	10	33,8
2	8,6	65	1	10,3	18	13,3	86	13	27,4
3	8,8	63	4	10,2	19	13,7	71	6	25,7
4	10,5	72	1	16,4	20	13,8	64	13	24,9
5	10,7	81	9	18,8	21	14	78	11	34,5
6	10,8	83	8	19,7	22	14,2	80	12	31,7
7	11	66	9	15,6	23	14,5	74	9	36,3
8	11	75	5	18,2	24	16	72	10	38,3
9	11,1	80	6	22,6	25	16,3	77	12	42,6
10	11,2	75	8	19,9	26	17,3	81	8	55,4
11	11,3	79	5	24,2	27	17,5	82	11	55,7
12	11,4	76	5	21	28	17,9	80	10	58,3
13	11,4	76	13	21,4	29	18	80	13	51,5
14	11,7	69	3	21,3	30	18	80	14	51
15	12	75	4	19,1	31	20,6	87	10	67
16	12,9	74	9	22,2					

Exemplo 1

Diagrama de Dispersão



Exemplo 1

Ajuste do Modelo

Regression Analysis: Volume versus Diâmetro; Altura; Idade

Analysis of Variance

Source	DF	Adj SS	Adj MS	F-Value	P-Value
Regression	3	6990,4	2330,13	228,04	0,000
Error	27	275,9	10,22		
Total	30	7266,3			

Model Summary

S	R-sq	R-sq(adj)
3,19656	96,20%	95,78%

Coefficients

Term	Coef	SE Coef	T-Value	P-Value
Constant	-56,84	7,33	-7,75	0,000
Diâmetro	4,829	0,261	18,48	0,000
Altura	0,350	0,109	3,21	0,003
Idade	-0,478	0,209	-2,29	0,030





Regression Equation

Volume = -56,84 + 4,829 Diâmetro + 0,350 Altura - 0,478 Idade

Exemplo 1

Análise de Resíduos



Residual Plots for Volume



Exemplo 1

Normalidade dos Erros

Summary Report for RESI



95% Confidence Intervals




Anderson-Darling Normality Test

A-Squared	0,25
P-Value	0,712
Mean	0,00000
StDev	3,03252
Variance	9,19618
Skewness	-0,141109
Kurtosis	-0,424661
N	31
Minimum	-6,37614
1st Quartile	-1,96867
Median	-0,39563
3rd Quartile	2,77730
Maximum	5,45177
95% Confidence Interval for Mean	-1,11234 1,11234
95% Confidence Interval for Median	-1,18250 1,28270
95% Confidence Interval for StDev	2,42332 4,05349

Exemplo 2

Num estudo feito em 50 estudantes, na Universidade de Porto Rico, mostrou-se que o Índice Geral dos Estudantes estão em função da pontuação de aptidão à matemática, aproveitamento matemático e tipo de escola (1 pública e 2 privada). Escolher um modelo e justificar.

Diagrama de Dispersão



Exemplo 2

Ajuste do Modelo 1

Regression Analysis: IGS versus escola; aproveitamento; aptidão

Analysis of Variance

Source	DF	Adj SS	Adj MS	F-Value	P-Value
Regression	3	6952	2317,3	19,54	0,000
Error	46	5455	118,6		
Total	49	12407			

Model Summary

S	R-sq	R-sq(adj)
10,8896	56,03%	53,17%

Coefficients





Term	Coef	SE Coef	T-Value	P-Value
Constant	135,9	24,5	5,55	0,000
escola	1,93	3,09	0,63	0,535
aproveitamento	0,1970	0,0315	6,25	0,000
aptidão	0,0569	0,0314	1,81	0,077

Regression Equation

Exemplo 2

Análise de Resíduos




Residual Plots for IGS



Exemplo 2

Normalidade dos Erros

Summary Report for RESI



Anderson-Darling Normality Test

A-Squared 0,32
P-Value 0,519

Mean -0,0000
StDev 10,5510
Variance 111,3231
Skewness 0,360807
Kurtosis 0,855738
N 50

Minimum -23,5773
1st Quartile -6,4897
Median -1,3652
3rd Quartile 6,8398
Maximum 31,9043

95% Confidence Interval for Mean
-2,9986 2,9986

95% Confidence Interval for Median
-4,4608 4,6428

95% Confidence Interval for StDev
8,8136 13,1479

Exemplo 2

Ajuste do Modelo 2

Regression Analysis: IGS versus aproveitamento; aptidão

Analysis of Variance

Source	DF	Adj SS	Adj MS	F-Value	P-Value
Regression	2	6906	3452,8	29,50	0,000
Error	47	5501	117,0		
Total	49	12407			

Model Summary

S	R-sq	R-sq(adj)
10,8188	55,66%	53,77%

Coefficients


Term	Coef	SE Coef	T-Value	P-Value
Constant	138,6	24,0	5,78	0,000
aproveitamento	0,1969	0,0313	6,29	0,000
aptidão	0,0573	0,0312	1,84	0,073

Regression Equation

IGS = 138,6 + 0,1969 aproveitamento + 0,0573 aptidão

Exemplo 2



Análise de Resíduos



Exemplo 2

Normalidade dos Erros

Summary Report for RESI_1



Anderson-Darling Normality Test

A-Squared 0,28
P-Value 0,631

Mean -0,0000
StDev 10,5957
Variance 112,2698
Skewness 0,361124
Kurtosis 0,733211
N 50

Minimum -24,3942
1st Quartile -6,4944
Median -1,5055
3rd Quartile 6,4194
Maximum 31,0373

95% Confidence Interval for Mean
-3,0113 3,0113

95% Confidence Interval for Median
-4,8018 3,7606

95% Confidence Interval for StDev
8,8510 13,2037

Exemplo 2

Ajuste do Modelo 3

Regression Analysis: IGS versus aproveitamento

Analysis of Variance

Source	DF	Adj SS	Adj MS	F-Value	P-Value
Regression	1	6511	6511,3	53,01	0,000
Error	48	5896	122,8		
Total	49	12407			

Model Summary

S	R-sq	R-sq(adj)
11,0826	52,48%	51,49%

Coefficients

Term	Coef	SE Coef	T-Value	P-Value
Constant	162,4	20,6	7,87	0,000
aproveitamento	0,2177	0,0299	7,28	0,000





Regression Equation

$$\text{IGS} = 162,4 + 0,2177 \text{ aproveitamento}$$

Exemplo 2

Análise de Resíduos



Residual Plots for IGS



Exemplo 2

Normalidade dos Erros

Summary Report for RESI_2



Anderson-Darling Normality Test

A-Squared 0,54
P-Value 0,155

Mean -0,0000
StDev 10,9690
Variance 120,3181
Skewness -0,30540
Kurtosis 1,58499
N 50

Minimum -35,0313
1st Quartile -6,5328
Median -1,8813
3rd Quartile 8,2936
Maximum 27,6358

95% Confidence Interval for Mean
-3,1173 3,1173

95% Confidence Interval for Median
-4,1712 4,0647

95% Confidence Interval for StDev
9,1627 13,6688