

Regressão Linear Múltipla

Frases

“Por serem mais precisos que as palavras, os números são particularmente adequados para transmitir conclusões científicas”

Pagano e Gauvre, 2004



Roteiro

1. Especificação do Modelo
2. Modelo Geral
3. Propriedades Amostrais dos EMQQ
4. Estimação de Intervalos e Testes de Hipótese
5. Qualidade do Ajuste e Teste de Significância
6. Modelo Ampliado
7. Referências



Especificação do Modelo

Exemplo 5 – Rede de Lanchonetes

- Modelo para explicar receita total em cadeia de lanchonete
- Semanalmente decide-se:
 - √ quanto gastar com propaganda e
 - √ quais promoções (preços mais baixos) serão implementadas
- Dados: *lanchonete*
- Fonte: *Hill*



Exemplo 5 – Rede de Lanchonetes

- Despesas de propaganda:
 - √ Aumento despesas gera aumento na receita?
 - √ Aumento de receita é suficiente para justificar despesas?
 - √ Redução de preços leva a aumento ou diminuição de receita total?



Exemplo 5 – Rede de Lanchonetes

- Promoções:

√ Redução de preços leva a aumento ou diminuição de receita total?

√ Situações a ser verificadas:

Redução de preços	→	Pequeno aumento das vendas	Demanda <u>inelástica</u> em relação ao preço
Redução de preços	→	Grande aumento das vendas	Demanda <u>elástica</u> em relação ao preço



Modelo Econômico

$$E(RT) = b_0 + b_1p + b_2a$$


- RT : receita total (\$ mil)
- p : preço médio de todos os produtos
- a : nível de despesas com propaganda (\$ mil)
- Comportamento esperado (ou médio) de muitos pontos de venda distintos
- Componente sistemático



Modelo Econométrico

$$RT_i = b_0 + b_1p_i + b_2a_i + e_i$$

- Incorpora o termo de erro aleatório
- e : todos os fatores que fazem a receita total da semana diferir de seu valor esperado (condições meteorológicas, comportamento dos concorrentes, etc.)



Interpretação dos Parâmetros

- β_1 : Variação em RT (\$ 1000) quando p sofre um aumento de 1 unidade e a é mantido constante:

$$b_1 = \frac{\Delta RT}{\Delta p}, a \text{ cte.} \qquad b_1 = \frac{\partial RT}{\partial p}$$

- ✓ $\beta_1 > 0$: demanda **inelástica** em relação ao preço
aumento de preço ocasiona aumento receita
- ✓ $\beta_1 < 0$: demanda **elástica** em relação ao preço
aumento de preço ocasiona decréscimo receita



Interpretação dos Parâmetros (2)

- β_2 : Variação em RT (\$ 1000) quando a é aumentado de \$1 mil e p é mantido constante. Espera-se que seja positivo:

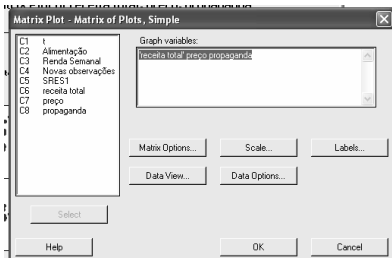
$$b_2 = \frac{\Delta RT}{\Delta a}, p \text{ cte.} \qquad b_2 = \frac{\partial RT}{\partial a}$$

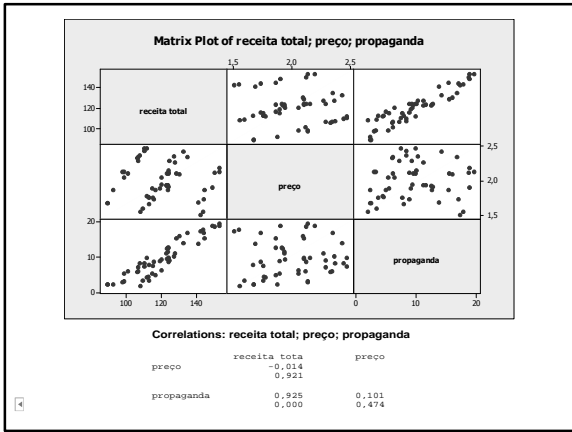
- ✓ $\beta_2 < 1$: aumento de \$1.000 na propaganda ocasionará aumento inferior a \$1.000 em RT
- ✓ $\beta_2 > 1$: aumento na propaganda acarretará aumento maior na receita



Análise Exploratória

Graph > Matrix Plot > Matrix of plots: Simple →





Comentários

- Embora a correlação entre receita Total e preço seja não significativa, o diagrama de dispersão mostra padrões nos pontos;
- A correlação entre Receita Total e propaganda é bastante forte e aparenta haver uma relação linear entre elas
- Preço e propaganda são fracamente correlacionados

Modelo Geral

Regressão Múltipla

- Predizer valores de uma variável dependente (Y) em função de variáveis independentes (X_1, X_2, \dots, X_k).
- Conhecer o quanto as variações de X_j ($j = 1, \dots, k$) podem afetar Y .



Aplicações

X_1 = renda
 X_2 = taxa de juros
 X_3 = poupança



Y = consumo

X_1 = área construída
 X_2 = custo do m²
 X_3 = localização



Y = preço imóvel



Modelo de Regressão Múltipla

- $E\{Y\} = f(X_1, X_2, \dots, X_k)$
- Linear: $E\{Y\} = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k$

Admite-se que X_1, \dots, X_k são variáveis não estocásticas e Y é uma variável aleatória.



Modelo de Regressão Múltipla (2)

- $E\{Y\} = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k$
- O coeficiente β_j representa a variação esperada de Y para cada unidade de variação em X_j ($j = 1, 2, \dots, k$), considerando as outras variáveis independentes fixas.
- O primeiro objetivo é estimar os coeficientes: $\beta_0, \beta_1, \beta_2, \dots, \beta_k$

☐

Modelo de Regressão

AMOSTRA:

obs.	Y	variáveis			
		X ₁	X ₂	...	X _k
1	y ₁	x ₁₁	x ₁₂	...	x _{1k}
2	y ₂	x ₂₁	x ₂₂	...	x _{2k}
...
n	y _n	x _{n1}	x _{n2}	...	x _{nk}

- $E\{Y_i\} = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik}$
- $Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik} + e_i$

termo aleatório

☐

Modelo de Regressão Múltiplo

$$Y_i = b_0 + b_1 X_{i1} + b_2 X_{i2} + \dots + b_k X_{ik} + e_i$$

- β_j : efeito da variação da variável x_{ij} sobre o valor esperado de Y_i , mantidas as outras variáveis constantes
 $\forall i=1, \dots, n$ e $j=1, \dots, k$
- β_0 : intercepto

☐

Supostos do Modelo

- Os erros (e_i) são independentes e variam aleatoriamente segundo uma distribuição (normal) com média zero e variância constante (homocedástico).

A média de todas as variáveis omitidas do modelo é zero (o modelo em média é correto).

Para nenhuma observação a incerteza do modelo será maior ou menor (homocedástico)



Supostos do Modelo

- $cov(e_i, e_j)$: o tamanho do erro de uma observação não tem qualquer influência sobre o tamanho provável do erro de outra observação;
- Nenhuma variável explanatória é uma função linear exata de qualquer outra (multicolinearidade exata)
Nenhuma variável é redundante



Estimativa de Mínimos Quadrados Ordinários para 2 Variáveis

- Minimização da soma dos quadrados das diferenças entre os valores observados e seu valor esperado

$$S(\mathbf{b}_0, \mathbf{b}_1, \mathbf{b}_2) = \sum_{i=1}^n (y_i - E(Y_i))^2 = \sum_{i=1}^n (y_i - \mathbf{b}_0 - \mathbf{b}_1 x_{i1} - \mathbf{b}_2 x_{i2})^2$$

- Os estimadores de mínimos quadrados são obtidos através das derivadas de S em relação a β_0, β_1 e β_2 .

√ Os cálculos não são triviais



Modelos Lineares – Regressão Simples

i	x_i	y_i	$y_i = b_0 + b_1 x_i + e_i$
1	20	98	$98 = \beta_0 + \beta_1 \cdot 20 + e_1$
2	25	110	$110 = \beta_0 + \beta_1 \cdot 25 + e_2$
3	30	112	$112 = \beta_0 + \beta_1 \cdot 30 + e_3$
4	35	115	$115 = \beta_0 + \beta_1 \cdot 35 + e_4$
5	40	122	$122 = \beta_0 + \beta_1 \cdot 40 + e_5$

☐

Notação Matricial – Regressão Simples

$$\begin{pmatrix} 98 \\ 110 \\ 112 \\ 115 \\ 122 \end{pmatrix} = \begin{pmatrix} 1 & 20 \\ 1 & 25 \\ 1 & 30 \\ 1 & 35 \\ 1 & 40 \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \end{pmatrix} + \begin{pmatrix} e_1 \\ e_2 \\ e_3 \\ e_4 \\ e_5 \end{pmatrix}$$

$$Y = X b + e$$

☐

Modelos Lineares – Regressão Múltipla

i	x_{1i}	x_{2i}	y_i
1	20	70	98
2	25	68	110
3	30	83	112
4	35	77	115
5	40	65	122

☐

Notação Matricial – Regressão Múltipla

$$\begin{pmatrix} 98 \\ 110 \\ 112 \\ 115 \\ 122 \end{pmatrix} = \begin{pmatrix} 1 & 20 & 70 \\ 1 & 25 & 68 \\ 1 & 30 & 83 \\ 1 & 35 & 77 \\ 1 & 40 & 65 \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \end{pmatrix} + \begin{pmatrix} e_1 \\ e_2 \\ e_3 \\ e_4 \\ e_5 \end{pmatrix}$$

$$Y = Xb + e$$

Estimador de Mínimos Quadrados

$$Y = Xb + e$$

Estimador de mínimos quadrados de β , isto é, o vetor que minimiza a função $L(\beta) = \epsilon' \epsilon = (Y - X\beta)'(Y - X\beta)$:


$$\Rightarrow \hat{b} = (X'X)^{-1}(X'Y)$$

$$\hat{b} = (\hat{b}_1, \hat{b}_2, \dots, \hat{b}_k)$$

Cálculo das EMQO

- Na prática, usam-se pacotes computacionais para calcular as estimativas de mínimos quadrados (EMQO)
- No Minitab, o caminho é o mesmo:

Stat > Regression > Regression →



Lanchonetes – Regressão Ajustada

Regression Analysis: receita total versus preço; propaganda

The regression equation is
receita total = 105 - 6,64 preço + 2,98 propaganda

Predictor	Coef	SE Coef	T	P
Constant	104,786	6,483	16,16	0,000
preço	-6,642	3,191	-2,08	0,043
propaganda	2,9843	0,1669	17,88	0,000

S = 6,06961 R-Sq = 86,7% R-Sq(adj) = 86,2%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	2	11776,2	5888,1	159,83	0,000
Residual Error	49	1805,2	36,8		
Total	51	13581,4			

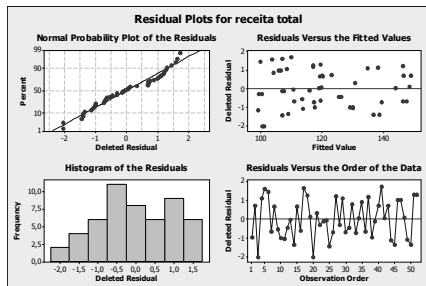
Interpretação

- A demanda aparenta ser elástica em relação ao preço
 - √ Aumento de \$1 no preço leva a queda de \$6.642 na receita
- O coeficiente de propaganda é positivo:
 - √ Aumento de \$1.000 na propaganda resulta aumento de \$2.984 na receita

Interpretação (2)

- Intercepto: Se tanto o preço como as despesas com propaganda fossem zero, a receita seria \$104.790
 - √ Interpretação enganosa

Lanchonetes – Gráfico de Resíduos



Equação para predição

- Prever a receita total para um preço de \$2 e despesa com propaganda de \$1.000:

$$\hat{R}_{\hat{y}} = 104,785 - 6,642(2) + 2,9843(10) = \$121,34$$

- Os modelos de regressão descrevem as variáveis econômicas para valores análogos aos dos dados amostrais. Extrapolar resultados para valores extremos não é recomendado

Estimação da Variância

- A variância é estimada por:

$$\hat{s}^2 = \frac{\sum e_i^2}{n - (k + 1)}$$

onde,

$k+1$: quantidade de parâmetros a estimar

n : tamanho na amostra

- No exemplo da receita total das lanchonetes:

$$\hat{s}^2 = \frac{1.805}{52 - 3} = 36,8$$

- No exemplo da receita total das lanchonetes:

$$\hat{s}^2 = \frac{1.805}{52-3} = 36,8$$



Propriedades Amostrais dos EMQO

Teorema de Gauss – Markov

- Atendidas as hipóteses do modelo de regressão, os EMQO são os melhores estimadores lineares não viciados dos parâmetros (*BLUE – best linear unbiased estimators*).

√ Não é necessária a hipótese de normalidade



Variâncias e Covariâncias dos *EMQO*

- Para o caso de duas variáveis explicativas, temos que:

$$\text{Var}(\hat{\mathbf{b}}_1) = \frac{\mathbf{s}^2}{\sum_{i=1}^n (x_{i1} - \bar{x}_1)^2 (1 - r_{12}^2)}$$

r_{12} : coeficiente de correlação entre X_1 e X_2

- Há fórmulas análogas para as outras variáveis



Conseqüências

- Quanto maior a variância do erro (s^2), maior a variância dos *EMQO*;
 - √ A incerteza global na especificação do modelo é transmitida a seus estimadores
- Quanto maior o tamanho n da amostra, menor é a variância dos *EMQO*
 - √ Mais observações resultam em estimação mais precisa



Conseqüências (2)

- Quanto maior a variação da variável explicativa em torno de sua média, menor a variância do *EMQO*
 - √ Se a variação em x_1 é pequena, é difícil medir seu efeito
- Quanto maior a correlação entre X_1 e X_2 , maior a variância do *EMQO*.
 - √ Se a variação em uma explicativa está relacionada com a variação de outras variáveis, é difícil separar seus efeitos



Matriz de Variâncias e Covariâncias

- Para o caso de duas variáveis explicativas:

$$\Sigma = \begin{bmatrix} \text{Var}(\hat{\beta}_0) & \text{Cov}(\hat{\beta}_0, \hat{\beta}_1) & \text{Cov}(\hat{\beta}_0, \hat{\beta}_2) \\ \text{Cov}(\hat{\beta}_0, \hat{\beta}_1) & \text{Var}(\hat{\beta}_1) & \text{Cov}(\hat{\beta}_1, \hat{\beta}_2) \\ \text{Cov}(\hat{\beta}_0, \hat{\beta}_2) & \text{Cov}(\hat{\beta}_1, \hat{\beta}_2) & \text{Var}(\hat{\beta}_2) \end{bmatrix}$$

- A maioria dos pacotes apresenta esta matriz como um de seus resultados de saída


Cálculo no Minitab

- O Minitab, não apresenta a matriz de variância e covariância em sua saída
- Para seu cálculo:
Stat > Regression > Regression →



- Serão armazenados uma matriz de resultados $(X'X)^{-1}$ e uma constante (MSE)
- No Minitab, matriz é identificada com a letra M e constante com a letra K .
- Os resultados armazenados podem ser verificados em:

Data > Display Data →



Variâncias e Covariâncias – Lanchonetes

- Para se obter a matriz de variâncias e covariâncias, basta se multiplicar o *MSE* (constante) por $(X'X)^{-1}$ (matriz)

```
MTB > Multiply K2 M1 M2
MTB > Print M2

Data Display

Matrix M2
42.0256  -19.8631  -0.161109
-19.8631  10.1837  -0.054021
-0.1611  -0.0540  0.027868
```

Variâncias dos *EMQO* – Lanchonetes

	42,026
	10,184
	0,02787

Estimativas Intervalares e Testes de Hipóteses

Normalidade

- Se acrescentarmos a suposição de normalidade dos erros às hipóteses do modelo, então os *EMQO* são os melhores estimadores não viciados dos parâmetros da regressão;
- Além disso, podemos construir intervalos de confiança e realizar testes de hipóteses



Inferência para β_j

- Distribuição do estimador β_j , $j = 0, 1, \dots, k$:

$$\hat{b}_j \sim N(b_j, ep(\hat{b}_j))$$

- Intervalo de confiança

$$\hat{b}_j - t_{\alpha/2; (n-(k+1))} ep(\hat{b}_j) \leq b_j \leq \hat{b}_j + t_{\alpha/2; (n-(k+1))} ep(\hat{b}_j)$$



Exemplo – Lanchonetes

Regression Analysis: receita total versus preço; propaganda

The regression equation is
receita total = 105 - 6,64 preço + 2,98 propaganda

Predictor	Coef	SE Coef	T	P
Constant	104,786	6,483	16,16	0,000
preço	-6,642	1,191	-2,08	0,043
propaganda	2,9843	0,1669	17,88	0,000

S = 6,06961 R-Sq = 86,7% R-Sq(adj) = 86,2%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	2	11776,2	5888,1	159,83	0,000
Residual Error	49	1805,2	36,8		
Total	51	13581,4			

- Tamanho da amostra: 52



Intervalos com 95% de Confiança

- $t_{\alpha/2, (52-(2+1))} = 2,010$

- Do Parâmetro β_0 :

$$104,79 - (2,010)(6,483) \leq b_0 \leq 104,79 + (2,010)(6,483)$$
$$91,759 \leq b_0 \leq 117,821$$



Intervalos com 95% de Confiança

- Do Parâmetro β_1 :

$$-6,642 - (2,010)(3,191) \leq b_1 \leq -6,642 + (2,010)(3,191)$$
$$-13,056 \leq b_1 \leq -0,228$$

- Intervalo pouco informativo

- Redução de \$1 no preço acarreta um aumento da receita de \$ 228 a \$ 13.056.



Intervalos com 95% de Confiança

- Do Parâmetro β_2 :

$$2,984 - (2,010)(0,1669) \leq b_2 \leq 2,984 + (2,010)(0,1669)$$
$$2,649 \leq b_2 \leq 3,319$$

- Aumento de \$1.000 nas despesas com propaganda levam a um aumento da receita de \$ 2.649 a \$ 3.319.



Teste de Significância para Coeficiente Único

- Teste de significância do parâmetro β_j , $j = 0, 1, \dots, k$:

$H_0: \beta_j = 0$ vs regressão não é significativa

$H_1: \beta_j \neq 0$ regressão significativa

- Estatística de teste:

$$T = \frac{\hat{b}_j}{ep(\hat{b}_j)}$$

- Distribuição da estatística de teste: $T \sim t_{(n-(k+1))}$

☐

Inferência para Parâmetros – Caso Geral

- Teste de Hipóteses de parâmetro:

$H_0: \beta_j = \beta^0$ vs

$H_1: \beta_j \neq \beta^0$, $i = 0, \dots, k$

- Estatística de teste: $T = \frac{\hat{b}_j - b_j^0}{ep(\hat{b}_j)}$, $i = 0, \dots, k$

- Distribuição da estatística de teste: $T \sim t_{(n-(k+1))}$

☐

Regression Analysis: receita total versus preco, propaganda

The regression equation is
receita total = 105 - 6,64 preco + 2,98 propaganda

Predictor	Coef	SE Coef	T	P
Constant	104,786	6,483	16,163	0,000
preco	-6,642	3,191	-2,081	0,043
propaganda	2,9843	0,1669	17,881	0,000

S = 6,06961 R-Sq = 86,7% R-Sq(adj) = 86,2%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	2	11776,2	5888,1	159,83	0,000
Residual Error	49	1305,2	26,6		
Total	51	13581,4			

$$T_{b_0} = \frac{104,786}{6,483} = 16,163 \quad T_{b_1} = \frac{-6,642}{3,191} = -2,081 \quad T_{b_2} = \frac{2,9843}{0,1669} = 17,881$$

Rejeitamos H_0 se $|T| < 2,010$

☐

Teste de Elasticidade da Demanda

- Quer-se saber se:
 - √ $\beta_1 = 0$: demanda inelástica em relação ao preço
redução no preço ocasiona redução da receita
 - √ $\beta_1 < 0$: demanda elástica em relação ao preço
redução no preço ocasiona aumento da receita



Teste de Elasticidade da Demanda (2)

- Teste de Hipóteses de parâmetro:
 $H_0: \beta_1 = 0$ vs *elasticidade unitária ou inelástica*
 $H_1: \beta_1 < 0$ *demanda elástica*
- Estatística de teste: $T_b = \frac{-6,642}{3,191} = -2,081$
- Limite da região crítica: $t_{0,05; (52-(2+1))} = -1,68$
 $T = -2,081 < t_c = -1,68$

Há evidências para concluir que demanda elástica é mais compatível com os dados



Teste da Eficácia da Propaganda

- Quer-se saber se:
 - √ $\beta_2 = 1$: aumento de \$1.000 na propaganda ocasionará aumento inferior a \$1.000 na receita total
 - √ $\beta_2 > 1$: aumento na propaganda acarretará aumento maior na receita total



Teste de Elasticidade da Demanda (2)

- Teste de Hipóteses de parâmetro:

$$H_0: \beta_2 = 1 \quad \text{vs} \quad \text{propaganda ineficaz}$$

$$H_1: \beta_2 > 1 \quad \text{propaganda eficaz}$$

- Estatística de teste: $T_{b_2} = \frac{2,984 - 1}{0,1669} = 11,89$

- Limite da região crítica: $t_{0,05; (52 - (2+1))} = 1,68$

$$T = 11,89 > t_c = 1,68$$

Há evidências para concluir que a despesa com propaganda é justificada com aumento de receita



Qualidade do Ajuste e Teste de Significância

Coeficiente de Determinação (1)

$$R^2 = \frac{SQReg}{SQT} = \frac{\sum (\hat{y}_i - \bar{y})^2}{\sum (y_i - \bar{y})^2}$$
$$= 1 - \frac{SQRes}{SQT} = 1 - \frac{\sum \hat{e}_i^2}{\sum (y_i - \bar{y})^2}$$

- Medida da proporção da variável dependente que é explicada por todas as variáveis explicativas



Exemplo – Lei de Consumo

Regression Analysis: receita total versus preço; propaganda

The regression equation is
 receita total = 105 - 6,64 preço + 2,98 propaganda

Predictor	Coef	SE Coef	T	P
Constant	104,786	6,483	16,16	0,000
preço	-6,642	3,191	-2,08	0,043
propaganda	2,9843	0,1669	17,88	0,000

$R^2 = 6,06961$ $R\text{-Sq} = 86,74$ $R\text{-Sq(ajd)} = 86,28$

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	2	11776,2	5888,1	159,83	0,000
Residual Error	49	1805,2	36,9		
Total	51	13581,4			

Explicada
 Não explicada

$$R^2 = 1 - \frac{1.805,2}{13.581,4} = 0,867$$

R^2

- É o quadrado do coeficiente de correlação amostral entre o valor ajustado e o valor observado
- É um recurso descritivo para informação sobre o ajuste do modelo
- Dificuldade: É sempre possível aumentar o R^2 através da adição de novas variáveis no modelo

R^2 Ajustado

- Medida alternativa para a qualidade do ajustamento:

$$\bar{R}^2 = 1 - \frac{\frac{SQRes}{n - (k + 1)}}{\frac{SQT}{n - 1}}$$

- O R^2 ajustado penaliza a quantidade de variáveis

Regression Analysis: receita total versus preço; propaganda

The regression equation is
receita total = 105 + 6,64 preço + 2,98 propaganda

Predictor	Coef	SE Coef	T	P
Constant	104,786	6,483	16,16	0,000
preço	-6,642	3,191	-2,08	0,043
propaganda	2,9843	0,1669	17,88	0,000

R^2 Ajustado

S = 6,06961 R-Sq = 86,7% **R-Sq(adj) = 86,2%**

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	2	11776,2	5888,1	159,83	0,000
Residual Error	49	1805,2	36,8		
Total	51	13581,4			

$$\bar{R}^2 = 1 - \frac{1.805,2}{\frac{52 - (2+1)}{13.581,4}} = 0,862$$

☐

Considerações sobre R^2

- Não mede a adequação do modelo linear
- Para comparação entre modelos, é importante observar a variação do erro quadrático médio
- Sua grandeza depende também do intervalo de variação da variável regressora
valor grande de R^2 pode ser resultado de variação irrealista de x

☐

Abusos Comuns

- Deve-se tomar cuidado na forma do modelo e na seleção das variáveis que serão usadas.
 - √ Forte associação não implica relação causal entre variáveis
- Relações de regressão são válidas somente dentro da faixa dos dados originais de x .
 - √ Modelos de regressão não são necessariamente válidos para fins de extrapolação

☐

Teste de Significância Global do Modelo

- Hipóteses:

$$H_0: \mathbf{b}_1 = \mathbf{b}_2 = \dots = \mathbf{b}_k = 0 \quad H_1: \text{ pelo menos um } \neq 0$$

- Estatística de teste:

$$F = \frac{\frac{SQReg}{k}}{\frac{SQRes}{n - (k + 1)}}$$

Distribuição amostral de F :

$$F \sim F_{k, [n - (k + 1)]; \alpha}$$



Graus de Liberdade

- SQReg: k
- SQRes: $n - (k + 1)$
- SQT: $n - 1$



Análise de Variância do Modelo

Fonte de variação	gl	SQ	QM	Razão
Regressão	k	$SQReg$	$\frac{SQReg}{k}$	$F = \frac{QMReg}{QMRes}$
Erro	$n - (k + 1)$	$SQRes$	$\frac{SQRes}{n - (k + 1)}$	
Total	$n - 1$	SQT		



Exemplo – Lanchonetes

Regression Analysis: receita total versus preço; propaganda

The regression equation is
receita total = 105 - 6,64 preço + 2,98 propaganda

Predictor	Coef	SE Coef	T	P
Constant	104,786	6,483	16,16	0,000
preço	-6,642	3,191	-2,08	0,043
propaganda	2,9843	0,1669	17,88	0,000

S = 6,06961 R-Sq = 86,7% R-Sq(adj) = 86,2%

Estatística F

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	2	11776,2	5888,1	159,83	0,000
Residual Error	49	1305,2	26,6		
Total	51	13581,4			

$$F = \frac{\frac{11.776,2}{2}}{\frac{1.805,2}{52 - (2 + 1)}} = 159,825$$

☐

Teste de Significância Global

- Nível de significância de 5%
- Limite da região crítica:

$$F_{0,05; 2, [52-(2+1)]} = f_c = 3,18658$$

$$F = 159,83 > f_c = 3,187$$

Há evidências para concluir que a relação estimada é significativa, ou seja, ou o preço, ou a despesa com propaganda, ou ambos têm influência na receita total

☐

Relação entre Teste Conjunto e Testes Individuais

- Qual diferença entre testar os coeficientes conjuntamente ($\beta_2 = \beta_3 = 0$) ou testá-los separadamente ($\beta_2 = 0$ e $\beta_3 = 0$)?
- O teste F, além de abranger as duas hipóteses conjuntamente, considera a correlação entre os *EMQO*.
- Cada teste *t* não leva isto em conta, logo, eles não se equivalem.

☐

Conflito entre Teste t e Teste F

- É possível os testes t não indicarem coeficiente significativo, enquanto o teste F implica os coeficientes conjuntamente significativos
- Esta situação ocorre com frequência quando os dados são multicolineares



Modelo Restrito

- O teste F indicou que ou o preço ou a propaganda ou ambas explicam a Receita Total;
- Como saber se a mudança no preço não tem qualquer efeito sobre a receita, contornando o efeito dos testes t individuais?



- Vamos testar:

H_0 : *preço não tem efeito na receita*

H_1 : *preço tem algum efeito na receita*

Ou, de outra maneira:

H_0 : $RT_i = b_0 + b_2 a_i + e_i$

H_1 : $RT_i = b_0 + b_1 p_i + b_2 a_i + e_i$

- Se H_0 for verdadeira, esperamos uma pequena variação na soma dos quadrados dos resíduos dos dois modelos.



- Soma do quadrado dos resíduos:
 - ✓ $SQRes_R$: soma restrita de quadrados dos resíduos $SQRes$ de H_0
 - ✓ $SQRes_U$: soma não restrita quadrados resíduos $SQRes$ de H_1
- Tem-se sempre que: $SQRes_R - SQRes_U \geq 0$
- A estatística F para testar esta diferença é:

$$F = \frac{\frac{SQRes_R - SQRes_U}{J}}{\frac{SQRes_U}{n - (k + 1)}} \quad F \sim F_{J, [n - (k + 1)]; \alpha}$$

J: quantidade de restrições sob H_0

Teste F

- H_0 consiste em uma ou mais hipóteses (J) de igualdades (não pode incluir hipóteses do tipo: = ou =)
- H_1 : ao menos uma das igualdade não é verdadeira
- Estatística F: $F = \frac{(SQRes_R - SQRes_U) / J}{SQRes_U / [n - (k + 1)]}$
- Distribuição amostral da estatística $F \sim F_{J, [n - (k + 1)]; \alpha}$

Modelo Restrito

$$RT_i = b_0 + b_2 a_i + e_i$$

$$SQRes_R = 1.965$$

$$J = 1$$

Regression Analysis: receita total versus propaganda

The regression equation is
receita total = 91,8 + 2,95 propaganda

Predictor	Coeff	SE Coef	T	P
Constant	91,831	1,871	49,07	0,000
propaganda	2,9491	0,1725	17,19	0,000

S = 6,26858 R-Sq = 85,5% R-Sq(Adj) = 85,2%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	1	1327,7	1327,7	295,62	0,000
Residual Error	50	1365	27,3		
Total	51				

Modelo Irrestrito

$$RT_i = b_0 + b_1 p_i + b_2 a_i + e_i$$

$$SQRes_U = 1.805,2$$

Regression Analysis: receita total versus preço; propaganda

The regression equation is
receita total = 105 - 0,64 preço + 2,98 propaganda

Predictor	Coeff	SE Coef	T	P
Constant	104,795	6,483	16,16	0,000
preço	-0,642	3,191	-2,08	0,043
propaganda	2,9843	0,1669	17,88	0,000

S = 6,06961 R-Sq = 86,7% R-Sq(Adj) = 86,2%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	2	1805,2	902,6	588,1	159,83
Residual Error	49	36,8	0,75		
Total	51				

Teste F

- $\alpha = 5\%$
- Estatística de teste: $F = \frac{\frac{1.965 - 1.805,168}{1}}{\frac{1805,168}{52 - 3}} = 4,332$
- Limite da região crítica:

$$F_{0,05; 1, [52-(2+1)]} = f_c = 4,03839$$

$$F = 4,332 > f_c = 4,03839$$

Há evidências para concluir que o preço tem efeito significativo sobre a receita total



Modelo Ampliado

Questionamento

- A relação linear entre receita, preço e gastos com propaganda é uma boa aproximação da realidade?
- Modelo linear implica que crescimento de gastos com propaganda leva a crescimento proporcional da receita, independente do nível
- Aumento de gasto com propaganda não pode levar a retornos decrescentes?



Modelo Alternativo

$$RT_i = b_0 + b_1 p_i + b_2 a_i + b_3 a_i^2 + e_i$$

- O termo do quadrado dos gastos leva em conta a diminuição dos resultados em função dos gastos com propaganda
- A resposta de $E(RT_i)$ é:

$$\frac{\Delta E(RT)}{\Delta a_i}, p \text{ cte.} \quad \frac{\partial E(RT_i)}{\partial a_i} = b_2 + 2b_3 a_i$$

☐

Interpretação

$$\frac{\partial E(RT_i)}{\partial a_i} = b_2 + 2b_3 a_i$$

- Quando a_i aumenta de um unidade (\$1.000) e p_i é mantido constante, $E(RT_i)$ aumenta de $b_2 + 2b_3 a_i$
- Sinais esperados:
 - ✓ $b_2 > 0$: Positiva quando $a_i = 0$
 - ✓ $b_3 < 0$: Para o retorno cair quando a_i aumenta


☐

Estimação do Modelo Ampliado

- No Minitab, criamos uma coluna com os gastos da propaganda ao quadrado.
 - ✓ Em *Session, Editor > Enable Command*.

```
MTB > let 'propaganda^2' = 'propaganda'**2
```

Stat > Regression > Regression →



☐

Resultados

Regression Analysis: receita tota versus preço; propaganda; propaganda^2

The regression equation is
receita total = 105 - 6,58 preço + 2,95 propaganda + 0,0017 propaganda^2

Predictor	Coef	SE Coef	T	P
Constant	104,815	6,578	15,93	0,000
preço	-6,582	3,459	-1,90	0,063
propaganda	2,9475	0,7855	3,75	0,000
propaganda^2	0,00173	0,03609	0,05	0,962

S = 6,13236 R-Sq = 86,7% R-Sq(adj) = 85,9%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	3	11776,3	3925,4	104,38	0,000
Residual Error	48	1305,1	27,2		
Total	51	13581,4			

Comentários

- O coeficiente de a_1^2 não é significativo, ou seja, não há diminuição do retorno em relação à propaganda ou o coeficiente não foi estimado com precisão
- O preço se tornou não significativo
- Diferenças nas estimativas:

$$RT_i = 104,786 - 6,642p_i + 2,9843a_i \quad R^2 = 86,7\% \quad S^2 = 36,8$$

(6,483) (3,191) (0,1669)

$$RT_i = 104,815 - 6,582p_i + 2,9843a_i + 0,00173a_i^2 \quad R^2 = 86,7\%$$

(6,578) (3,459) (0,7855) $S^2 = 37,6$

Novos Dados

- Uma das soluções quando não há estimativa precisa de parâmetros econômicos é obter mais e melhores dados
- Neste caso, foram coletados dados de outras 26 semanas, disponíveis na planilha: *lancheonete_new*
- O nome das colunas têm o sufixo *_new*.
- Cria-se a coluna do quadrado dos gastos com propaganda.

Regression Analysis: receita_new versus preço_new; propaganda_new; ...

The regression equation is
 $receita_new = 110 - 10,2 \text{ preço_new} + 3,36 \text{ propaganda_new} - 0,0268 \text{ propaganda_new}^2$

Predictor	Coef	SE Coef	T	P
Constant	110,464	3,741	29,52	0,000
preço_new	-10,198	1,582	-6,45	0,000
propaganda_new	3,3610	0,4217	7,97	0,000
propaganda_new^2	-0,02675	0,01589	-1,68	0,096

S = 5,91871 R-Sq = 87,9% R-Sq(adj) = 87,4%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	3	18752,0	6250,7	178,43	0,000
Residual Error	74	2592,3	35,0		
Total	77	21344,3			

Teste de Significância Unilateral

- $H_0: \beta_3 = 0$ vs $H_1: \beta_3 < 0$
- Nível de significância de 5%
- Limite crítico: $t_{0,05; [78-(3+1)]} = f_c = -1,66571$

$$t = -1,68 < t_c = -1,67$$

Os dados de que dispomos são compatíveis com a hipótese da diminuição do retorno em função da despesa

Comentários

- Comparação com o ajuste anterior:
 $RT_i = 104,815 - 6,582p_i + 2,9843a_i + 0,00173a_i^2$ $\bar{R}^2 = 85,9\%$
(6,578) (3,459) (0,7855) (0,03609) $\hat{s}^2 = 37,6$
 $RT_i^* = 110,464 - 10,198p_i^* + 3,3610a_i^* - 0,02675a_i^{*2}$ $\bar{R}^2 = 87,4\%$
(3,741) (1,582) (0,4217) (0,01589) $\hat{s}^2 = 35,0$

- Houve aumento da precisão (menor erro-padrão)
- O termo a_i^2 tem o sinal esperado

Modelo Restrito

Regression Analysis: receita_new versus preço_new

The regression equation is
receita_new = 112 + 5,06 preço_new

Predictor	Coef	SE Coef	T	P
Constant	111,713	8,854	12,62	0,000
preço_new	5,057	4,012	1,26	0,211

S = 16,5860 R-Sq = 2,0% R-Sq(adj) = 0,8%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	1	436,9	436,9	1,59	0,211
Residual Error	76	2097,3	275,1		
Total	77	2534,2			

Referências

Bibliografia Recomendada

- Hill, R. C., Griffiths, W. E. e Judge, G. (Saraiva)
Econometria
- Gujarati, D. N. (Pearson)
Econometria Básica
- Maddala, G. S. (LTC)
Introdução à econometria
