



Análise de Regressão

Tópicos Avançados em Avaliação de Desempenho

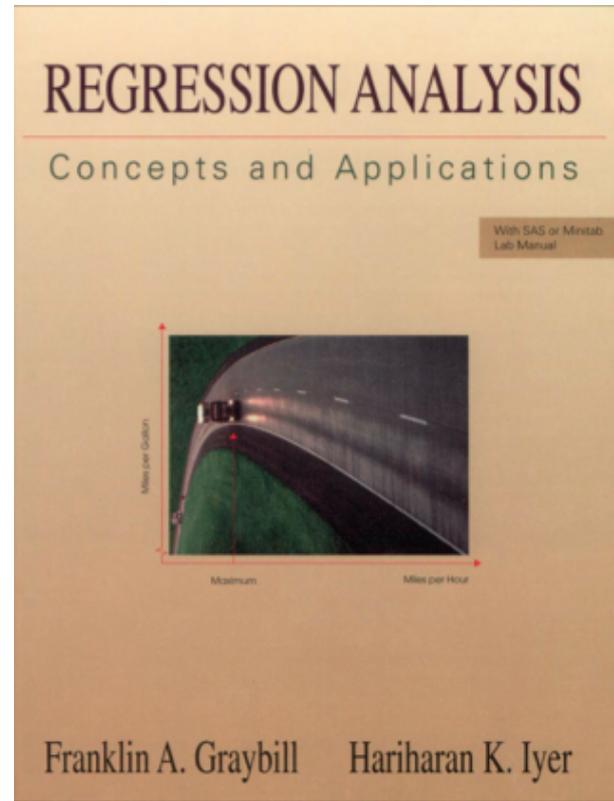
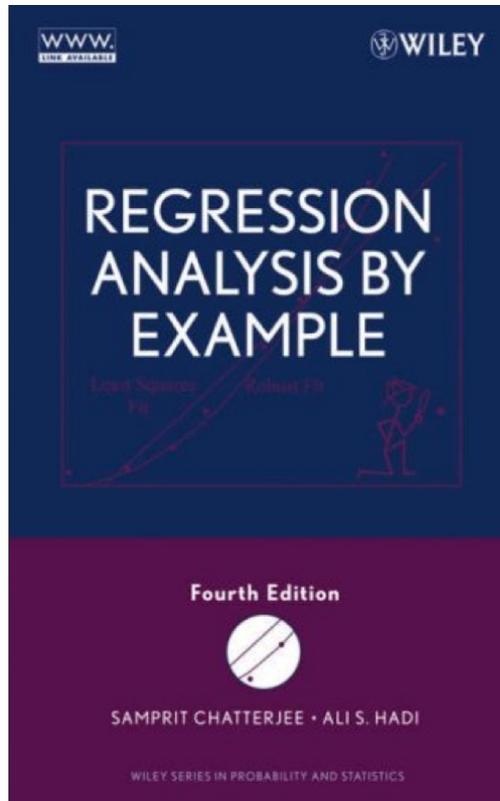
Cleber Moura

Edson Samuel Jr

Agenda

- Introdução
- Passos para Realização da Análise
- Modelos para Análise de Regressão
- Regressão Linear Simples
- Regressão Linear Múltipla

Referências



O que é Análise de Regressão?

(GRAYBILL & IYER, 1994, p. 1)

- Área da Estatística que lida com métodos para investigação da existência de associações entre várias quantidades observáveis e, se presente, a natureza das associações.

(CHATTERJEE & HADI, 2006, p. 1)

- É um método simples para investigação de relacionamentos funcionais entre variáveis.
- Exemplo: Podemos examinar como o consumo do cigarro está relacionado a diversas variáveis socioeconômicas e demográficas, como: idade, educação, salário e preço do cigarro.

Relação entre as variáveis

- O relacionamento entre as variáveis é expressado na forma de uma equação ou modelo, conectando a **variável de resposta** (ou dependente) com uma ou mais **variáveis preditoras** (ou explicativas).
- No exemplo anterior:
 - Variável de resposta: **consumo de cigarro**
 - Variáveis preditoras: **idade, educação, salário e preço do cigarro**

Áreas de aplicação

- Possui inúmeras áreas de aplicação, como:
 - economia, finanças, negócios, direito, meteorologia, medicina, biologia, química, engenharia, física, educação, esportes, história, sociologia, psicologia, dentre outras.
- A Análise de Regressão é uma das mais utilizadas ferramentas estatísticas, por que provê métodos simples para **estabelecer uma relação funcional entre variáveis** e para **predição da variável de resposta**.

Passos da Análise

- Definição do problema
- Seleção das variáveis potenciais e relevantes
- Coleta de dados
- Especificação do modelo
- Escolha do método e adequação do modelo
- Validação e análise crítica do modelo
- Uso dos modelos adotados para solucionar o problema exposto

Passo 1: Definição do problema

- Inicia com a formulação do problema e determinação das questões a serem tratadas pela análise
- É o primeiro e um dos mais importantes passos
- **Um problema mal definido ou questões mal formuladas podem levar a:**
 - desperdício de tempo/esforço;
 - seleção de variáveis irrelevantes; e
 - escolha de um método estatístico ou modelo de análise não apropriados.

Cenário 1

- Queremos determinar se uma empresa faz ou não discriminação entre os grupos de funcionários (homens e mulheres)
 - Os dados sobre salário, qualificações e sexo estão disponíveis nos registros da empresa.
- Para identificar ocorrência de discriminação, devemos responder:
 - Na média, as mulheres são menos pagas do que homens igualmente qualificados?
 - Na média, as mulheres são mais qualificadas do que homens igualmente pagos?

Passo 2: Seleção das variáveis

- Neste passo são selecionadas o conjunto de variáveis que explicam ou predizem a variável de resposta.
- A variável de resposta é indicada por Y e a variável preditora ou explicativa por X_1, X_2, \dots, X_p , onde p indica o número de variáveis predictoras.

Cenário 1

- Para responder a questão:
“Na média, as mulheres são menos pagas que homens igualmente qualificados?”

Escolhemos salário como variável de resposta, e **qualificação** e **sexo** como variáveis preditoras.

- Para questão:
“Na média, as mulheres são mais qualificadas que homens igualmente pagos?”

Escolhemos qualificação como variável de resposta, e **sexo** e **salário** como variáveis preditoras.

Passo 3: Coleta de dados

- Este passo consiste na observação de n "alvos" e cada uma das n observações consiste em medições para cada uma das variáveis relevantes;
- As variáveis podem ser qualitativas e quantitativas

Número da Observação	Resposta Y	Preditoras			
		X_1	X_2	...	X_p
1	Y_1	X_{11}	X_{12}	...	X_{1p}
2	Y_2	X_{21}	X_{22}	...	X_{2p}
3	Y_3	X_{31}	X_{32}	...	X_{3p}
...
n	Y_n	X_{n1}	X_{n2}	...	X_{np}

Passo 4: Especificação do Modelo

- Neste passo é definido o **modelo de regressão** que será **utilizado** para **relacionar a variável de resposta** ao conjunto de **variáveis preditoras**
- Regressão *Simple*s e *Múltipla*:
 - Determinado pelo número de variáveis preditoras
- Regressão *Univariável* e *Multivariável*
 - Determinado pelo número de variáveis de resposta

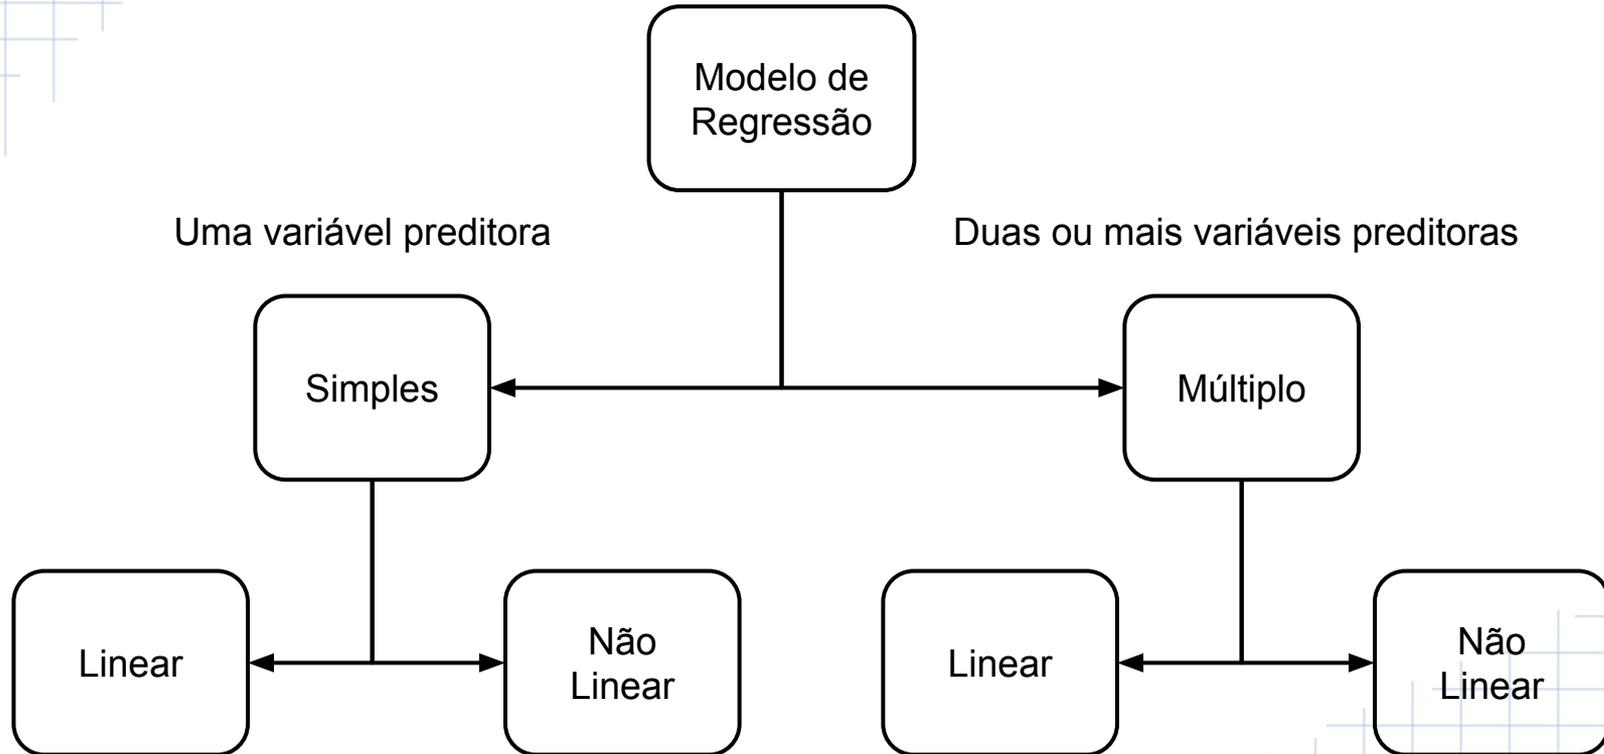
Passo 5: Adequação do modelo

- Com base no modelo definido e nos dados coletados, o próximo passo é estimar os parâmetros de regressão utilizando algum método de estimativa.
- O mais utilizado é o **método dos mínimos quadrados**.

Passo 6: Validação e Análise Crítica

- A validade do método estatístico depende de premissas feitas sobre os dados e modelo
- A análise de regressão é vista como um processo iterativo, onde as saídas são utilizadas para diagnosticar, validar, criticar, e possivelmente modificar as entradas
- O processo deve ser repetido até obter saídas satisfatórias

Modelos de Regressão Univariável



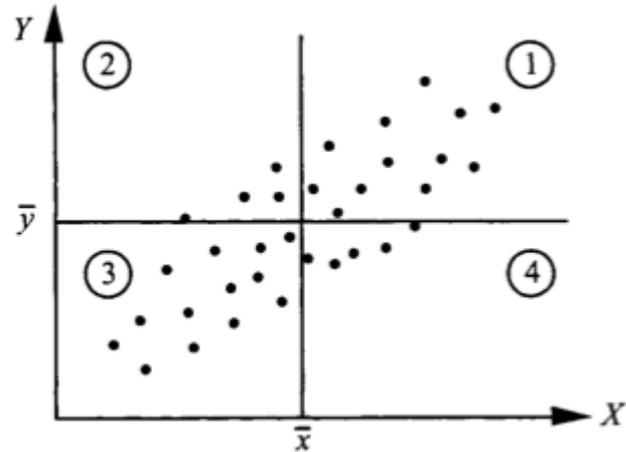
Regressão Linear Simples

- Envolve o estudo do relacionamento entre uma **variável de resposta** Y e uma **variável preditora** X_1
- X_1 passa a ser considerado apenas como X
- Também conhecida como *Straight Line Regression* (Regressão em Linha Reta) (GRAYBILL & IYER, 1994, p. 99)

Covariância e Correlação

- São métricas que avaliam a **direção** e **força** de uma relação linear entre duas variáveis X e Y.

Observation Number	Response Y	Predictor X
1	y_1	x_1
2	y_2	x_2
\vdots	\vdots	\vdots
n	y_n	x_n



$y_i - \bar{y}$ Desvio entre cada observação y e a média da variável de resposta

$x_i - \bar{x}$ Desvio entre cada observação x e a média da variável preditora

Covariância e Correlação

- Se a relação linear entre Y e X é positiva (quando X aumenta, Y também aumenta), temos mais pontos nos quadrantes 1 e 3;
- Quando é negativa (quando X aumenta, Y diminui), temos mais pontos nos quadrantes 2 e 4;
- Determina a direção da reta de regressão

Covariância

- Para determinar a covariância entre Y e X, temos:

$$\text{Cov}(Y, X) = \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{n - 1}$$

- Se $\text{Cov}(Y, X) > 0$, então temos um relacionamento positivo
- Se $\text{Cov}(Y, X) < 0$, então temos um relacionamento negativo

Correlação

- Para determinar a força da relação entre as variáveis Y e X, identificamos o **coeficiente de correlação** (valor entre -1 até 1):

$$\text{Cor}(Y, X) = \frac{1}{n-1} \sum_{i=1}^n \left(\frac{y_i - \bar{y}}{s_y} \right) \left(\frac{x_i - \bar{x}}{s_x} \right)$$

S_y = Desvio padrão de y

S_x = Desvio padrão de x

- Fórmula equivalente:

$$= \frac{\sum (y_i - \bar{y})(x_i - \bar{x})}{\sqrt{\sum (y_i - \bar{y})^2 \sum (x_i - \bar{x})^2}}$$

Exemplo

- Considerando uma empresa que vende e conserta computadores. Qual a relação entre o tempo de uma chamada de serviço e o número de componentes a serem substituídos ou consertados?
 - tempo de uma chamada de serviço (variável de resposta)
 - número de componentes reparados (variável preditora)

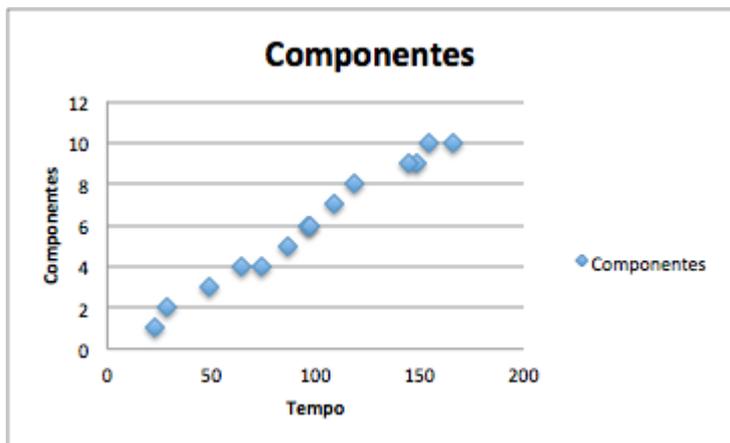
Dados coletados:

Table 2.5 Length of Service Calls (in Minutes) and Number of Units Repaired

Row	Minutes	Units	Row	Minutes	Units
1	23	1	8	97	6
2	29	2	9	109	7
3	49	3	10	119	8
4	64	4	11	149	9
5	74	4	12	145	9
6	87	5	13	154	10
7	96	6	14	166	10

Exemplo

Gráfico de dispersão:



Covariância:

$$\begin{aligned} \text{Cov}(Y, X) &= \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{n - 1} \\ &= \frac{1768}{13} \\ &= 136 \end{aligned}$$

Coefficiente de Correlação:

$$\begin{aligned} \text{Cor}(Y, X) &= \frac{\sum (y_i - \bar{y})(x_i - \bar{x})}{\sqrt{\sum (y_i - \bar{y})^2 \sum (x_i - \bar{x})^2}} \\ &= \frac{1768}{1779,2113} \\ &= 0,993698746 \end{aligned}$$

Modelo de Regressão Linear Simples

- O relacionamento entre a variável de resposta Y e a preditora X é estabelecido como um modelo linear:

$$Y = \beta_0 + \beta_1 X + \varepsilon$$

- Onde:
 - β_0 e β_1 são constantes chamadas de coeficientes de regressão ou parâmetros
 - ε é uma margem de erro

Modelo de Regressão Linear Simples

- β_0 -> intercepto
 - Valor previsto em Y quando $X = 0$.
- β_1 -> inclinação
 - Pode ser interpretada como a mudança ocorrida em Y para uma mudança de unidade em X.
- Cada observação pode ser escrita como:

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, \quad i = 1, 2, \dots, n$$

Modelo de Regressão Linear Simples

- Voltando ao exemplo:
 - Suponhamos que a empresa quer prever o número de engenheiros de serviço necessários ao longo dos próximos anos.
 - Um modo linear seria:

$$\text{Tempo}_i = \beta_0 + \beta_1 \text{Componentes}_i + \varepsilon_i$$

Modelo de Regressão Linear Simples

- A análise de regressão difere-se da análise de correlação em:
- Na correlação:
 - X e Y têm igual importância
 - O coeficiente de correlação é simétrico: $\text{Cor}(Y,X) = \text{Cor}(X,Y)$
- Na regressão:
 - A variável de resposta Y é de importância primordial
 - X tem habilidade de representar a variabilidade em Y

Estimativa de Parâmetros

- Com base nos dados disponíveis podemos estimar os parâmetros β_0 e β_1
- Equivale encontrar a linha reta que dá o melhor ajuste dos pontos no gráfico de dispersão para variável de resposta vs. preditora.
- Para isso, utilizamos o método dos mínimos quadrados
 - Estabelece a linha que minimiza a soma dos quadrados das distâncias verticais, a partir de cada ponto até a linha.
- As distâncias verticais representam os erros na variável resposta.

Estimativa de Parâmetros

- Os erros podem ser obtidos reescrevendo a fórmula:

$$\varepsilon_i = y_i - \beta_0 - \beta_1 x_i, \quad i = 1, 2, \dots, n.$$

- A soma dos quadrados das distâncias podem ser obtidas por:

$$S(\beta_0, \beta_1) = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2$$

Estimativa de Parâmetros

- Os valores ajustados de β_0 e β_1 que minimiza $S(\beta_0, \beta_1)$ é dado por:

$$\hat{\beta}_1 = \frac{\sum (y_i - \bar{y})(x_i - \bar{x})}{\sum (x_i - \bar{x})^2}$$

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$$

- Estes valores determinam a **intercepção** e a **inclinação** da linha com a menor soma possível dos quadrados das distâncias verticais de cada ponto para a linha.
- São chamados de linha de regressão dos mínimos quadrados

Estimativa de Parâmetros

- A linha de regressão dos mínimos quadrados é dada por:

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X$$

- Note que desprezamos o erro (ε) por já estarem considerados nos valores ajustados de (β_0 e β_1).
- Para encontrar os valores ajustados da variável de resposta, de cada observação, utilizamos:

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i, \quad i = 1, 2, \dots, n.$$

Estimativa de Parâmetros

- Para calcular a distância vertical, temos:

$$e_i = y_i - \hat{y}_i, \quad i = 1, 2, \dots, n$$

- Essa distância corresponde ao residual dos mínimos quadrados.

Exemplo

- Utilizando os dados do exemplo anterior, temos:

$$\hat{\beta}_1 = \frac{\sum (y_i - \bar{y})(x_i - \bar{x})}{\sum (x_i - \bar{x})^2}$$

$$= \frac{1768}{114}$$
$$= 15,50877193$$

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$$

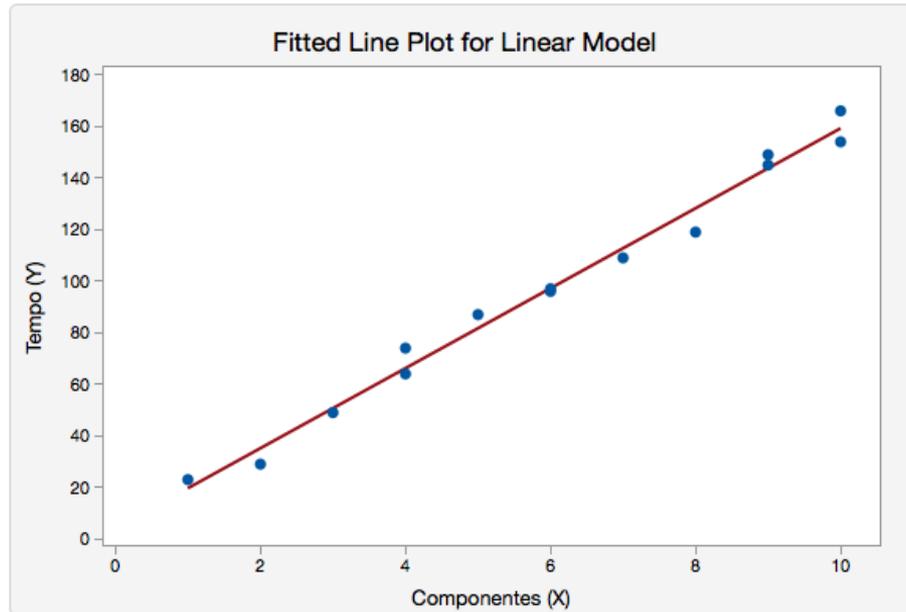
$$= 4,161654135$$

A equação da linha de regressão dos mínimos quadrados fica:

$$\text{Tempo} = 4.162 + 15.509 * \text{Componentes}$$

Exemplo

- Usando o minitab para Análise de Regressão Simples



Testes de Hipóteses

- É um método mais formal para medir a utilidade da variável X como uma preditora da variável Y, em comparação a análise do coeficiente de correlação e do gráfico de dispersão.
- Os testes de hipóteses são realizados para o parâmetro de regressão β_1

Testes de Hipóteses: Exemplo

- A empresa espera que o **aumento no tempo de serviço** para cada componente adicional a ser reparado seja de **12 minutos**.
 - Teremos:
 - $H_0 : \mu_1 = 12$ minutos
é chamada de **hipótese nula** e sempre abrange a igualdade.
 - $H_1 : \mu_1 \neq 12$ minutos
é chamada de **hipótese alternativa** e é sempre o oposto da hipótese nula, que será apoiada caso a H_0 seja rejeitada.
- Esse é um tipo de hipótese **bilateral**.

Testes de Hipóteses

- Em alguns casos podemos formular hipóteses **unilaterais**:

- $H_0 : \mu_1 = 12$ minutos

- $H_1 : \mu_1 > 12$ minutos

ou

- $H_0 : \mu_1 = 12$ minutos

- $H_1 : \mu_1 < 12$ minutos

Testes de Hipóteses: Erros

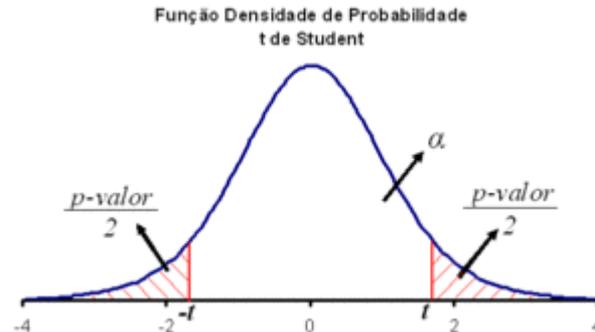
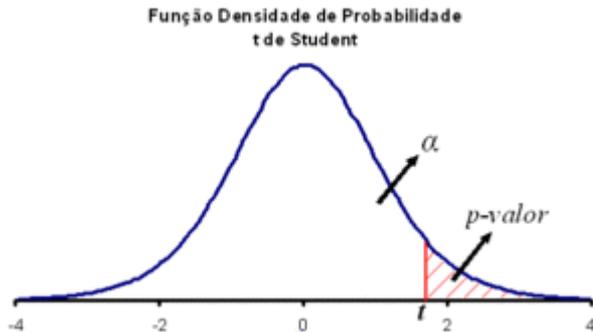
- **Erro do tipo I:**
 - Probabilidade de rejeitarmos a **hipótese nula** quando ela é efetivamente verdadeira (α - nível de significância).
- **Erro do tipo II:**
 - Probabilidade de rejeitarmos a **hipótese alternativa** quando ela é efetivamente verdadeira.

Testes de Hipóteses: Procedimentos

1. Avaliação do problema e escolha das hipóteses.
2. Decisão da estatística (estimador) p/ teste da hipótese nula (Propriedades: média, desvio padrão, distribuição estatística)
3. Estabelece um valor para Erro tipo I (α - nível de significância)
4. Construção da região crítica (RC) que servirá de regra para rejeição ou não a hipótese nula.
5. Retira-se uma amostra da população e executa-se os cálculos para determinação do valor da estatística de teste (t).
6. Se $t \notin RC$, estabelecida α , não rejeite a hipótese nula. Se pertencer, rejeite a hipótese nula.

Teste T de Student

- Um teste estatístico apropriado para testar a hipótese nula (H_0)
- O valor t é aplicado à função densidade de probabilidade da distribuição t para medir o tamanho da área abaixo dessa função para valores maiores ou iguais a t



Teste T de Student: Fórmulas

$$\hat{\sigma}^2 = \frac{\sum e_i^2}{n-2} = \frac{\sum (y_i - \hat{y}_i)^2}{n-2} = \frac{\text{SSE}}{n-2}$$

$$\text{s.e.}(\hat{\beta}_0) = \hat{\sigma} \sqrt{\frac{1}{n} + \frac{\bar{x}^2}{\sum (x_i - \bar{x})^2}}$$

$$t_1 = \frac{\hat{\beta}_1 - \beta_1^0}{\text{s.e.}(\hat{\beta}_1)}$$

$$\text{s.e.}(\hat{\beta}_1) = \frac{\hat{\sigma}}{\sqrt{\sum (x_i - \bar{x})^2}}$$

- β_1^0 = Constante escolhida pelo avaliador. No exemplo: 12.
- s.e. = Erro padrão da estimativa
- σ^2 = Param. desconhecido estimado dos dados
- $\hat{\sigma}$ = Raiz quadrada de σ^2
- SSE = Soma dos quadrados residuais

Teste T de Student

- Testando $H_0: \mu_1 = 12$ contra $H_1: \mu_1 \neq 12$

Tabela de Distribuição T de Student

- Com 12 graus de liberdade (n - 2)
- Nível de confiança de 95% bilateral
- Temos que:

$$t_1 = 6,948 \text{ é } > 2,179$$

**Resultado altamente
significante levando a
rejeição da hipótese nula**

Unilateral	75%	80%	85%	90%	95%	97,50%	99%	99,50%	99,75%	99,90%	99,95%
Bilateral	50%	60%	70%	80%	90%	95%	98%	99%	99,50%	99,80%	99,90%
1	1	1,376	1,963	3,078	6,314	12,71	31,82	63,66	127,3	318,3	636,6
2	0,816	1,061	1,386	1,886	2,92	4,03	6,965	9,925	14,09	22,33	31,6
3	0,765	0,978	1,25	1,638	2,353	3,082	4,541	5,841	7,453	10,21	12,92
4	0,741	0,941	1,19	1,533	2,132	2,76	3,747	4,604	5,598	7,173	8,61
5	0,727	0,92	1,156	1,476	2,015	2,571	3,365	4,032	4,773	5,893	6,869
6	0,718	0,906	1,134	1,44	1,943	2,447	3,143	3,707	4,317	5,208	5,959
7	0,711	0,896	1,119	1,415	1,895	2,365	2,998	3,499	4,029	4,785	5,408
8	0,706	0,889	1,108	1,397	1,86	2,306	2,896	3,355	3,833	4,501	5,041
9	0,703	0,883	1,1	1,383	1,833	2,262	2,821	3,25	3,69	4,297	4,781
10	0,7	0,879	1,093	1,372	1,812	2,228	2,764	3,169	3,581	4,144	4,587
11	0,697	0,876	1,088	1,363	1,796	2,191	2,718	3,106	3,497	4,025	4,437
12						2,179	2,681	3,055	3,428	3,93	4,318
13	0,694	0,87	1,079	1,35	1,771	2,16	2,65	3,012	3,372	3,852	4,221
14	0,692	0,868	1,076	1,345	1,761	2,145	2,624	2,977	3,326	3,787	4,14
15	0,691	0,866	1,074	1,341	1,753	2,131	2,602	2,947	3,286	3,733	4,073
16	0,69	0,865	1,071	1,337	1,746	2,12	2,583	2,921	3,252	3,686	4,015
17	0,689	0,863	1,069	1,333	1,74	2,11	2,567	2,898	3,222	3,646	3,965
18	0,688	0,862	1,067	1,33	1,734	2,101	2,552	2,878	3,197	3,61	3,922
19	0,688	0,861	1,066	1,328	1,729	2,093	2,539	2,861	3,174	3,579	3,883
20	0,687	0,86	1,064	1,325	1,725	2,086	2,528	2,845	3,153	3,552	3,85
21	0,686	0,859	1,063	1,323	1,721	2,08	2,518	2,831	3,135	3,527	3,819
22	0,686	0,858	1,061	1,321	1,717	2,074	2,508	2,819	3,119	3,505	3,792
23	0,685	0,858	1,06	1,319	1,714	2,069	2,5	2,807	3,104	3,485	3,767
24	0,685	0,857	1,059	1,318	1,711	2,064	2,492	2,797	3,091	3,467	3,745
25	0,684	0,856	1,058	1,316	1,708	2,06	2,485	2,787	3,078	3,45	3,725
26	0,684	0,856	1,058	1,315	1,706	2,056	2,479	2,779	3,067	3,435	3,707
27	0,684	0,855	1,057	1,314	1,703	2,052	2,473	2,771	3,057	3,421	3,69

Regressão Linear Múltipla

- Representa uma generalização da regressão linear simples
- Considera um **conjunto p de variáveis preditoras**, expandindo o potencial analítico da regressão para **múltiplos fatores** de influência
- Para cada valor das variáveis preditoras (X_p), o modelo expresso através de uma equação linear fornece uma aproximação aceitável da verdadeira relação entre o valor de Y e os valores de X

Regressão Linear Múltipla

- Desta forma, o relacionamento entre as variáveis passa a ser definido perante o seguinte modelo:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \epsilon$$

- $\beta_0, \beta_1, \beta_2, \dots, \beta_p$ são os coeficientes de regressão
- ϵ representa o fator de erro (perturbação aleatória)
- X_1, X_2, \dots, X_p são as variáveis preditoras

Regressão Linear Múltipla

- Em uma representação tabular para o modelo expresso na equação anterior...

Observation Number	Response Y	Predictors			
		X_1	X_2	...	X_p
1	y_1	x_{11}	x_{12}	...	x_{1p}
2	y_2	x_{21}	x_{22}	...	x_{2p}
3	y_3	x_{31}	x_{32}	...	x_{3p}
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
n	y_n	x_{n1}	x_{n2}	...	x_{np}

Estimativa de parâmetros

- Para efetuar a descoberta do valor para os parâmetros (coeficientes de regressão), é necessário **aplicar o método dos quadrados mínimos** (assim como na regressão linear simples)

$$\text{SSE} = \sum_{i=1}^n \varepsilon_i^2$$

- Neste caso, considerando a característica de múltiplas variáveis preditoras, temos:

$$\text{SSE} = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_{i1} - \dots - \beta_p x_{ip})^2$$

Interpretando coeficientes de regressão

- Utilizando soma dos quadrados mínimos (assim como na regressão linear simples, comparando cada preditora à variável de resposta)
- Resolvendo através de um sistema de equações e substituindo valores dos coeficientes
- Utilizando estratégia de equações normais (matrizes)

Exemplo

Uma pesquisa foi aplicada considerando a satisfação dos funcionários em relação aos seus supervisores em uma determinada empresa. Com base em um estudo exploratório, seis itens em um questionário foram escolhidos como possíveis variáveis preditoras:

- Recebe as queixas de insatisfação que o funcionário faz
- Não permite privilégios especiais
- Dá oportunidade ao aprendizado de coisas novas
- Cresce com base no desempenho
- É bastante crítico quanto a níveis de desempenho baixos

Exemplo

- Observações
 - As questões 1, 2, e 5 estão relacionadas ao relacionamento interpessoal entre o funcionário e o supervisor
 - As questões 3 e 4 são referentes à realização das atividades do trabalho como um todo
 - A questão 6 representa uma percepção do funcionário sobre o progresso do supervisor na empresa
 - As respostas para as questões variam em uma escala de 1 a 5, representando respectivamente de muito satisfeito para muito insatisfeito

Exemplo

- Definição de variáveis na pesquisa de desempenho do supervisor

X_1 Recebe as queixas de insatisfação que o funcionário faz

X_2 Não permite privilégios especiais

X_3 Dá oportunidade ao aprendizado de coisas novas

X_4 Cresce com base no desempenho

X_5 É bastante crítico quanto a níveis de desempenho baixos

X_6 Frequência com que avança para funções melhores

Y Taxa geral de trabalho sendo feito (satisfatoriamente) pelo supervisor

Exemplo

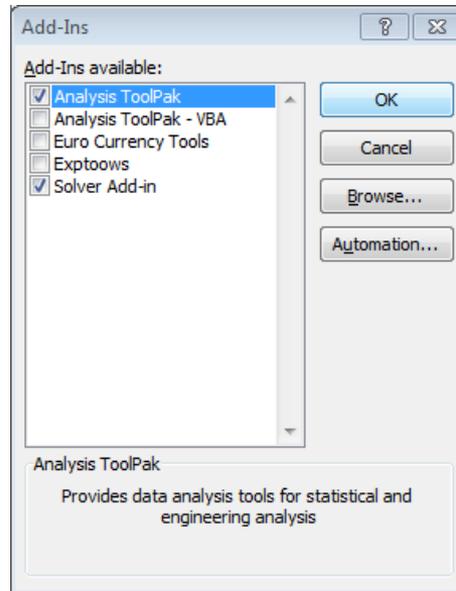
Row	Y	X_1	X_2	X_3	X_4	X_5	X_6
1	43	51	30	39	61	92	45
2	63	64	51	54	63	73	47
3	71	70	68	69	76	86	48
4	61	63	45	47	54	84	35
5	81	78	56	66	71	83	47
6	43	55	49	44	54	49	34
7	58	67	42	56	66	68	35
8	71	75	50	55	70	66	41
9	72	82	72	67	71	83	31
10	67	61	45	47	62	80	41

...

<http://www.ilr.cornell.edu/~hadi/RABE4/Data4/P056.txt>

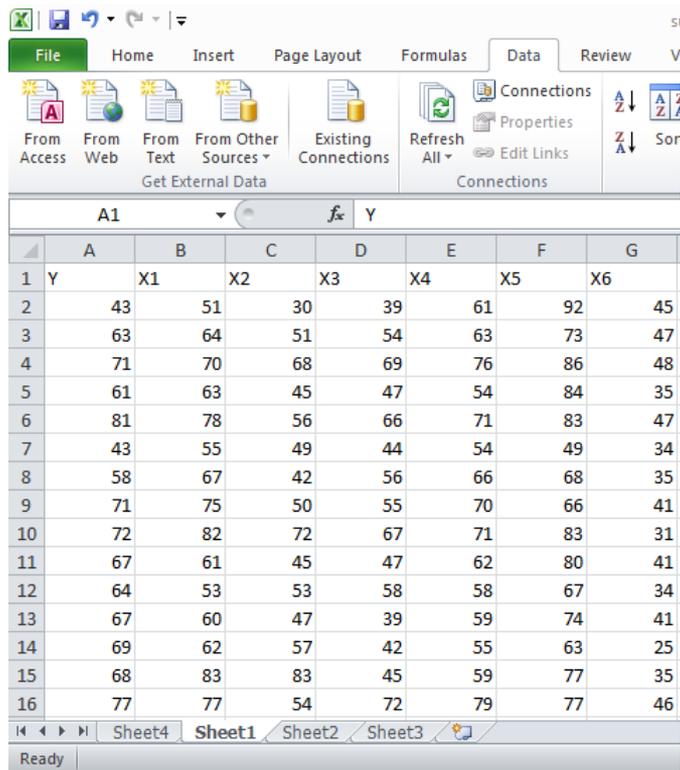
Exemplo

- Utilizando o Excel
 - Certificar que o Add-in de Análise de Dados está ativo



Exemplo

- Utilizando o Excel
 - Importar para



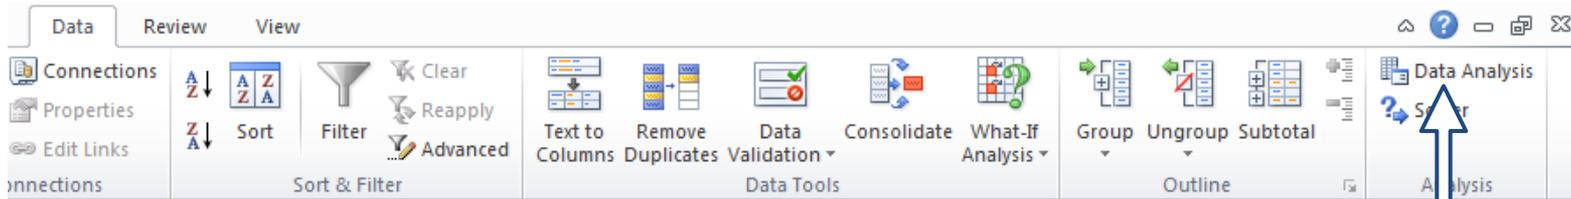
The screenshot shows the Microsoft Excel interface with the 'Data' tab selected in the ribbon. The ribbon includes options for 'Get External Data' (From Access, From Web, From Text, From Other Sources, Existing Connections) and 'Connections' (Refresh All, Edit Links). The spreadsheet below shows data imported from an external source, with columns labeled Y, X1, X2, X3, X4, X5, and X6. The data is organized in a grid with rows numbered 1 to 16.

	A	B	C	D	E	F	G
1	Y	X1	X2	X3	X4	X5	X6
2	43	51	30	39	61	92	45
3	63	64	51	54	63	73	47
4	71	70	68	69	76	86	48
5	61	63	45	47	54	84	35
6	81	78	56	66	71	83	47
7	43	55	49	44	54	49	34
8	58	67	42	56	66	68	35
9	71	75	50	55	70	66	41
10	72	82	72	67	71	83	31
11	67	61	45	47	62	80	41
12	64	53	53	58	58	67	34
13	67	60	47	39	59	74	41
14	69	62	57	42	55	63	25
15	68	83	83	45	59	77	35
16	77	77	54	72	79	77	46

dados
planilha

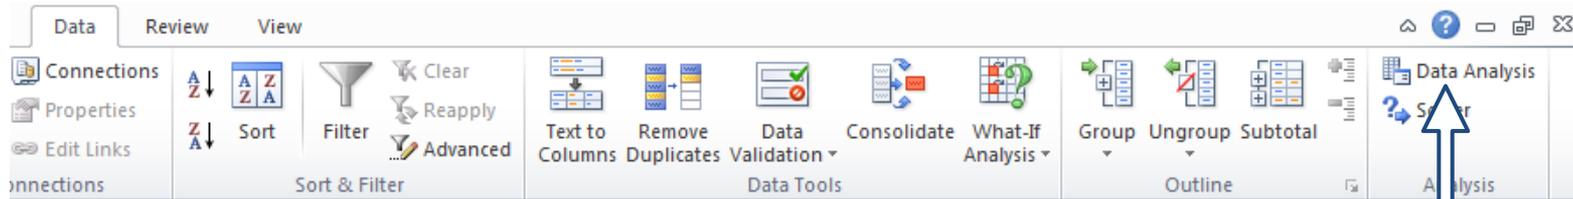
Exemplo

- Utilizando o Excel
 - Na guia “Dados” da faixa de opções, selecionar “Análise de Dados”



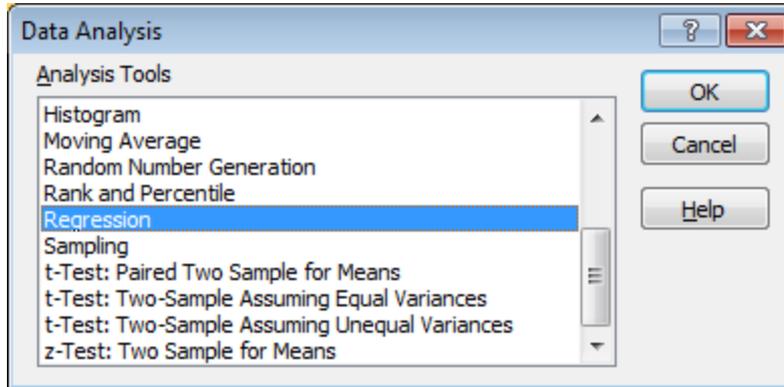
Exemplo

- Utilizando o Excel
 - Na guia “Dados” da faixa de opções, selecionar “Análise de Dados”



Exemplo

- Utilizando o Excel
 - Na janela do add-in de análise de dados, selecionar a opção “Regressão”



Exemplo

- Utilizando o Excel
 - Na janela de configuração para a ferramenta de Regressão, selecionar os dados para a coluna que representa a variável de resposta (Y)

The image shows an Excel spreadsheet with a data table and the 'Regression' dialog box open. The data table has a header row with 'A1' and 'A', and a column of values from row 1 to 16. The 'Regression' dialog box is configured with the following settings:

Input
Input Y Range: \$A\$1:\$A\$31
Input X Range: (empty)
<input checked="" type="checkbox"/> Labels
<input type="checkbox"/> Constant is Zero
<input type="checkbox"/> Confidence Level: 95 %

Output options:

- Output Range: (empty)
- New Worksheet Ply: (empty)
- New Workbook

Residuals:

- Residuals
- Residual Plots
- Standardized Residuals
- Line Fit Plots

Normal Probability:

- Normal Probability Plots

Exemplo

- Utilizando o Excel
 - Fazer o mesmo para as variáveis preditoras (X_p)

The image shows the 'Regression' dialog box in Microsoft Excel. The dialog is titled 'Regression' and has a question mark icon and a close icon in the top right corner. It is divided into several sections:

- Input:**
 - Input Y Range:** \$A\$1:\$A\$31
 - Input X Range:** \$B\$1:\$G\$31
 - L**abels
 - C**onstant is **Z**ero
 - C**onfidence Level: 95 %
- Output options:**
 - O**utput Range:
 - N**ew Worksheet **P**ly:
 - N**ew **W**orkbook
- Residuals:**
 - R**esiduals
 - S**tandardized Residuals
 - R**esidual **P**lots
 - L**ine **F**it **P**lots
- Normal Probability:**
 - N**ormal Probability **P**lots

Buttons for 'OK', 'Cancel', and 'Help' are located on the right side of the dialog.

Exemplo

SUMMARY OUTPUT

<i>Regression Statistics</i>	
Multiple R	0,855921721
R Square	0,732601993
Adjusted R Square	0,662845991
Standard Error	7,067993765
Observations	30

ANOVA

	<i>df</i>	<i>SS</i>	<i>MS</i>	<i>F</i>	<i>Significance F</i>
Regression	6	3147,966342	524,661057	10,50235065	0,000012404
Residual	23	1149,000325	49,95653586		
Total	29	4296,966667			

	<i>Coefficients</i>	<i>Standard Error</i>	<i>t Stat</i>	<i>P-value</i>	<i>Lower 95%</i>	<i>Upper 95%</i>
Intercept	10,78707639	11,58925724	0,930782375	0,361633721	-13,18712881	34,76128158
X1	0,613187608	0,160983115	3,809018158	0,000902868	0,280168662	0,946206554
X2	-0,073050143	0,13572469	-0,53822295	0,595593921	-0,353818056	0,20771777
X3	0,320332116	0,168520319	1,900851595	0,069925346	-0,028278723	0,668942956
X4	0,081732134	0,221477677	0,369031022	0,715480088	-0,376429349	0,539893616
X5	0,038381447	0,146995442	0,261106377	0,796334264	-0,265701793	0,342464688
X6	-0,217056682	0,178209471	-1,217986229	0,235577049	-0,58571106	0,151597697