

# Correlação e Regressão

Anderson Rodrigo da Silva

Instituto Federal Goiano

- 1 Covariância
- 2 Correlação de Pearson
- 3 Teste da correlação
- 4 Correlação de Spearman
- 5 Regressão linear simples
- 6 Regressão linear múltipla

- Associação linear entre duas variáveis resposta
- Exemplos: altura de planta e altura da espiga, teor de fósforo no solo e na folha, n° de lagartas por planta e área foliar, etc.


A covariância é uma medida de variabilidade conjunta, dada por:

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



**Tabela:** Dados referentes ao diâmetro (cm) e ao peso do colmo (kg) de 6 plantas de cana-de-açúcar, medidas em uma pesquisa.

Índice (i)	Diâmetro (X)	Peso (Y)	XY
1	3,04	14,60	44,38
2	2,85	14,02	39,96
3	2,90	14,23	41,27
4	3,03	14,45	43,78
5	2,90	14,34	41,73
6	2,95	14,35	42,33
Soma	17,68	85,99	253,45



## Correlação de Pearson ( $\rho$ )


- Também mede o grau de associação linear entre duas variáveis resposta
- É adimensional: não é afetado pela escala das variáveis

O coeficiente de correlação de Pearson é dado por:


$$Cor(X, Y) = \frac{Cov(X, Y)}{\sqrt{Var(X)Var(Y)}}$$

## Ilustrando $\rho$


(A)  $\rho \approx 0$




(B)  $\rho > 0$




(C)  $\rho = 1$



(D)  $\rho = -1$



(E)  $\rho < 0$



(F)  $\rho \approx 0$



## Teste da correlação

O teste da hipótese  $H_0 : \rho_{XY} = 0$  versus  $H_1 : \rho_{XY} \neq 0$  pode ser feito utilizando a estatística t-Student:

$$t = \frac{r\sqrt{n-2}}{\sqrt{1-r^2}} \sim t_{n-2}$$

desde que seja razoável admitir que  $X$  e  $Y$  tenham distribuição normal.

## Correlação de Spearman

- A correlação de Pearson é muito sensível à desvios da normalidade e assim como a média aritmética e a variância, também é sensível a valores discrepantes
- A correlação não paramétrica de Spearman é uma alternativa nesses casos
- É baseada nos ranks ou postos das observações
- É indicada quando a relação entre  $X$  e  $Y$  não é necessariamente linear
- O cálculo é feito usando a mesma equação do coeficiente de Pearson, substituindo os valores observados por seus ranks

## Regressão linear simples

- A correlação mede apenas o grau de associação entre duas variáveis, mas não nos informa nada sobre a relação de causa e efeito de uma variável sobre outra
- Na correlação, ambas as variáveis são supostas aleatórias (variáveis resposta)
- Exemplo: qual será o efeito na produção vegetal quando se aumentar em uma unidade a dose de um fertilizante?
- Exemplo 2: conhecendo-se a relação entre severidade de uma doença e tempo, a severidade pode ser predita num tempo específico
- A idéia consiste em ajustar um modelo para uma variável resposta ( $Y$ ) em função de uma variável explicativa ( $X$ )
- Admitindo que a relação entre ambas é linear, podemos ajustar o modelo:


$$y_i = \beta_0 + \beta_1 x_i + \epsilon_i$$

sendo  $\beta_0$  e  $\beta_1$  os parâmetros a serem estimados;  $\epsilon$  é o erro aleatório associado a observação  $y$

## Exemplo

**Tabela:** Amostra de  $n = 5$  parcelas experimentais nas quais foi avaliado o percentual de infestação por plantas daninhas monocotiledôneas após aplicação pós-emergencial de um herbicida seletivo.

Dose (L/ha)	0	1.5	3	4.5	6
Percentual	35	28	16	7.7	4



# Objetivos

- Ajustar um modelo para prever o grau de infestação ( $Y$ ) em função da dose aplicada ( $X$ )
- Para tal precisamos: 1) estimar os parâmetros  $\beta_0$  e  $\beta_1$ , 2) testar a significância dos parâmetros, 3) verificar o ajuste do modelo

## Estimação de parâmetros

- Método dos mínimos quadrados
- Método da máxima verossimilhança

## Mínimos Quadrados

O método consiste em obter estimativas para o vetor de parâmetros  $\beta = [\beta_0 \ \beta_1]^T$  que tornem mínima a função (notação matricial)

$$\epsilon^T \epsilon = (\mathbf{y} - \mathbf{X}\beta)^T (\mathbf{y} - \mathbf{X}\beta)$$

Igualando as derivadas parciais de  $\epsilon^T \epsilon$  em relação à  $\beta$ , obtemos:

$$\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$$

## Análise de variância da regressão

Admitindo que  $\epsilon \sim \text{Normal}(0, \sigma^2)$ , o teste da hipótese  $H_0 : \beta_1 = 0$  pode ser feito através do teste F da ANOVA

Tabela: ANOVA da regressão

FV	GL	SQ	QM	F
Regressão	$k$	$\hat{\beta}^T \mathbf{X}^T \mathbf{y} - C$		
Resíduo	$n - k - 1$	$\mathbf{y}^T \mathbf{y} - \hat{\beta}^T \mathbf{X}^T \mathbf{y}$		
Total	$n - 1$	$\mathbf{y}^T \mathbf{y} - C$		

sendo  $k$  o n° de regressores ("x") no modelo. No caso da regressão linear simples,  $k = 1$ .

Coeficiente de determinação simples ( $r^2$ )

O coeficiente de determinação é utilizado para medir o grau de ajuste do modelo de regressão linear simples.

$$r^2 = \frac{SQ_{reg}}{SQ_{total}} \in [0, 1]$$

quanto mais próximo da unidade, melhor o ajuste.

## Teste t para cada parâmetro

O teste F da ANOVA apenas indica se o modelo de regressão é significativo, como um todo, ou não. O teste individual, para cada parâmetro do modelo, é construído da seguinte forma

$$t = \frac{\hat{\beta}_j}{\sqrt{\text{Var}(\hat{\beta}_j)}} \sim t_{GLres}$$

sendo

$$\hat{\text{Var}}(\hat{\beta}_j) = (\mathbf{X}^T \mathbf{X})_{jj}^{-1} QMres$$

# Regressão linear múltipla

A idéia consiste em ajustar um modelo para uma variável resposta ( $Y$ ) em função de dois ou mais regressores ( $X_1, X_2, \dots$ )

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki} + \epsilon_i$$


sendo  $\beta_0, \beta_1, \dots, \beta_k$  os parâmetros a serem estimados;  $\epsilon_i$  é o erro aleatório associado a observação  $y_i$

**Exemplo:** modelar a produção vegetal em função das doses de N, P e K

## Exemplo 1

Tabela: Peso de mil grãos de feijão sob efeito de doses de gesso (kg/ha)

Dose	0	50	100	150	200	250	300
Peso	138.6	153.6	164.5	164.9	158.7	159.9	154.4



## Exercício 1

Ajuste um modelo de regressão aos dados de severidade de determinada doença em função da temperatura do ar. Depois, aplique o teste t para cada parâmetro do modelo.

Temperatura (°C)	2	1	5	5	20	20	23	10	30	25
Severidade (%)	1.9	3.1	3.3	4.8	5.3	6.1	6.4	7.6	9.8	12.4

Fonte: American Phytopathological Society (<http://www.apsnet.org/>)

## Exercício 2

Ajuste um modelo de regressão linear múltipla para  $y$  em função de  $x_1$  e  $x_2$ . Depois, aplique o teste t para cada parâmetro do modelo.

$y$	$x_1$	$x_2$
1.5	0	0
6.5	1	2
10	1	4
11	2	2
11.5	2	4
16.5	3	6