

Estadística Aplicada II

▶ Correlação e Regressão

Aula de hoje

- ▶ **Tópicos**

- ▶ Correlação e Regressão

- ▶ **Referência**

- ▶ Barrow, M. Estatística para economia, contabilidade e administração. São Paulo: Ática, 2007, Cap. 7

Aula de hoje

Objetivos:

- ▶ **Analisar os movimentos simultâneos de variáveis:**
 - ▶ Entender o grau de relação linear entre elas através do cálculo do coeficiente de correlação
 - ▶ Entender a causalidade entre elas através da análise de regressão




Correlação



Exemplo: Renda familiar e gastos com alimentação (em % da renda)

- ▶ Como esperado, à medida em que aumenta a renda familiar, diminui o percentual da renda destinado à alimentação

Família	Renda Total	Gasto em Alimentação
A	12	7,2
B	16	7,4
C	18	7,0
D	20	6,5
E	28	6,6
F	30	6,7
G	40	6,0
H	48	5,6
I	50	6,0
L	60	5,0



Exemplo livro (Bussab-Morettin), p.81

- ▶ Consideremos as duas variáveis abaixo


Número de anos de serviço (X) por número de clientes de agentes de uma cia de seguros

Agente	Anos de serviço (X)	Número de clientes
A	2	48
B	3	50
C	4	56
D	5	52
E	4	43
F	6	60
G	7	62
H	8	58
I	8	64
J	10	72

-
- ▶ Dados hipotéticos

Exemplo livro (Bussab-Morettin), p.81

▶ Gráfico de Dispersão



▶ Dados hipotéticos

Covariância

- ▶ Dados n pares de valores $(x_1, y_1), \dots, (x_n, y_n)$, chamaremos de covariância entre as variáveis X e Y , na população:

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

- ▶ Para calcular a covariância na amostra, devemos dividir por $n-1$ e não por n
- ▶ É a média dos produtos dos valores centrados das variáveis
- ▶ Tendo esta definição, podemos escrever o coeficiente de correlação como:

$$\text{corr}(X, Y) = \frac{\text{cov}(X, Y)}{dp(X).dp(Y)}$$


Características da covariância

- ▶ Das expressões da covariância, população e amostra:
 - ▶ As duas variáveis devem ter o mesmo número de dados.
 - ▶ Os pares de dados ocorrem ao mesmo tempo, são pares casados. Embora possa parecer redundante, é importante observar que não se pode mudar a ordem de uma única variável; a mudança de ordem deverá ser realizada nas duas amostras sem descasar os pares de dados.


Características da covariância

- ▶ A covariância é:
 - ▶ No caso de população, a soma dos produtos dos desvios de duas variáveis dividida pela quantidade de dados das variáveis.
 - ▶ No caso de amostra, a soma dos produtos dos desvios de duas variáveis dividida pela quantidade de dados das variáveis menos um.
- ▶ Os numeradores das expressões da covariância para população e para amostra são iguais, o resultado da soma dos produtos dos desvios.



- A covariância pode ser nula, negativa ou positiva.
- A covariância é a medida do afastamento simultâneo das respectivas médias.
- Se as ambas variáveis aleatórias tendem a estar simultaneamente acima, ou abaixo, de suas respectivas médias, então a covariância tenderá a ser positiva e nos outros casos poderá ser negativa, como mostram os gráficos abaixo.



A maioria dos pares de valores tem os dois valores acima de sua média correspondente, provocando covariância positiva.



A maioria dos pares de valores tem um valor acima de sua média e outro abaixo da média correspondente, provocando covariância negativa.



O gráfico de dispersão da esquerda mostra uma relação direta ou positiva entre as variáveis X e Y , tendência destacada pela declividade positiva da elipse tracejada. Enquanto o gráfico de dispersão da direita mostra uma relação inversa ou negativa, tendência também destacada pela declividade negativa da elipse tracejada.

Características da covariância

- ▶ A covariância de uma variável e ela mesma é a própria variância da variável, seja no caso de população ou amostra. Como $Y = X$,

$$\sigma_{XX} = \frac{\sum_{i=1}^N (X_i - \mu_X) \times (X_i - \mu_X)}{N} = \frac{\sum_{i=1}^N (X_i - \mu_X)^2}{N} = \sigma_X^2$$

- ▶ A permutação das variáveis não altera o resultado da covariância, se os pares de valores não forem alterados

$$\sigma_{XY} = \sigma_{YX}$$

Características da covariância

- ▶ Da mesma forma que a variância, a covariância é afetada pelos valores extremos da variável, ela não é uma medida resistente.
- ▶ A unidade de medida é o resultado do produto das unidades dos valores das variáveis.

Coeficiente de correlação

- ▶ Para facilitar o entendimento da relação entre duas variáveis e evitar a influência da unidade de medida, foi definido o coeficiente de correlação r_{XY} .
- ▶ Os valores de r_{XY} estão limitados entre os valores -1 e $+1$, e sem nenhuma unidade de medida

Coeficiente de correlação

- ▶ O coeficiente de correlação busca auferir a direção da relação entre as variáveis, dentro de um intervalo determinado entre -1 e 1
- ▶ O objetivo do intervalo é discriminar a direção e a intensidade da relação:
 - ▶ valores próximos de zero indicam ausência de relação entre as variáveis
 - ▶ valores próximos de 1 indicam forte relação positiva
 - ▶ valores próximos de -1 indicam forte relação negativa



Coeficiente de correlação

- ▶ O coeficiente de correlação é a medida do grau de associação linear entre duas variáveis
- ▶ Fórmula do coeficiente de correlação:

$$\text{corr}(X, Y) = \frac{1}{n} \sum \left(\frac{x_i - \bar{x}}{dp(X)} \right) \left(\frac{y_i - \bar{y}}{dp(Y)} \right)$$



Cálculo do coeficiente de correlação

Agente	Anos de serviço (X)	Número de clientes	$x - \bar{x}$	$y - \bar{y}$	$\frac{x - \bar{x}}{dp(X)} = z_x$	$\frac{y - \bar{y}}{dp(Y)} = z_y$	$z_x \cdot z_y$
A	2	48	-3,7	-8,5	-1,54	-1,05	1,608
B	3	50	-2,7	-6,5	-1,12	-0,80	0,897
C	4	56	-1,7	-0,5	-0,71	-0,06	0,043
D	5	52	-0,7	-4,5	-0,29	-0,55	0,161
E	4	43	-1,7	-13,5	-0,71	-1,66	1,173
F	6	60	0,3	3,5	0,12	0,43	0,054
G	7	62	1,3	5,5	0,54	0,68	0,366
H	8	58	2,3	1,5	0,95	0,18	0,176
I	8	64	2,3	7,5	0,95	0,92	0,882
J	10	72	4,3	15,5	1,78	1,91	3,407

Para calcular o coeficiente de correlação, devemos dividir o somatório dos valores da última coluna (8,77) pelo número de observações (n=10)

$$\text{Então: } \text{Corr}(X,Y) = 8,77/10=0,877$$

Coeficiente de correlação

- ▶ O coeficiente de correlação pode ser escrito da seguinte forma:

$$\text{corr}(X, Y) = \frac{1}{n} \sum \left(\frac{x_i - \bar{x}}{dp(X)} \right) \left(\frac{y_i - \bar{y}}{dp(Y)} \right)$$

$$\text{corr}(X, Y) = \frac{\sum x_i y_i - n \bar{x} \bar{y}}{\sqrt{\left(\sum x_i^2 - n \bar{x}^2 \right) \left(\sum y_i^2 - n \bar{y}^2 \right)}}$$

Sendo que $-1 \leq \text{corr}(X, Y) \leq 1$

- ▶ Lembremos da **variância**, que usamos para observar a dispersão de uma só variável

$$\text{var}(X) = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}$$

Voltando ao coeficiente de correlação

- ▶ Da fórmula do coeficiente de correlação pode-se obter também a covariância das mesmas variáveis quando conhecidos os desvios padrões correspondentes:

$$\sigma_{XY} = r_{XY} \times \sigma_X \times \sigma_Y$$

Características de r


- ▶ Se a variável Y é a mesma variável X , então o coeficiente de correlação é igual a 1:

$$r_{XX} = \frac{\sigma_{XX}}{\sigma_X \times \sigma_X} = \frac{\sigma_X^2}{\sigma_X^2} = 1$$

- ▶ A permutação das variáveis não altera o resultado do coeficiente de correlação, se os mesmos pares de valores forem mantidos.

$$r_{XY} = r_{YX}$$


$$r = +1$$




$$r = -1$$

	A	B	C	D	E	F	G	H	I
13	Amostras perfeitamente correlacionadas em sentido negativo								
14		X	Y		r	-1,00			
15		25	0						
16		10	15						
17		30	-5						
18		5	20						
19		20	5						
20		0	25						
21		15	10						
22									


$$r = 0$$




Coefficiente de correlação = 1,00




Coefficiente de correlação = 0,32




Coefficiente de correlação = -0,01




Coeficiente de correlação = -0,32



Coeficiente de correlação = -0,85



Coeficiente de correlação = -1,00



Os resultados são significantes?

➤ $H_0: r = 0$

$H_1: r \neq 0$

➤ A estatística do teste é:

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

➤ A qual tem distribuição t com n-2 graus de liberdade

Teste de Hipótese


▶ As etapas do teste são:

1. Escrever as hipóteses alternativas e nulas
2. Escolher o nível de significância do teste α
3. Calcular a estatística t , conhecida como a **estatística do teste**
4. Calcular o **valor crítico** do teste t^* ,
5. Decidir: **Comparar a estatística do teste t com o valor crítico do teste t^* ,**


Regressão Linear Simples

- Modelo linear para explicar a variável Y , denominada variável dependente, explicada ou endógena como função da variável X , denominada variável independente, explicativa ou exógena

Regressão Linear Simples



Regressão Linear Simples



Regressão Linear Simples

- A relação entre valor observado de Y e valor previsto de Y pelo modelo é dada por:

$$Y = \hat{Y} + e$$

$$Y = a + bX + e$$

Regressão Linear Simples


➤ Os valores de a e b são dados pela minimização da soma do quadrado dos erros. Tem-se:

$$b = \frac{n \sum XY - \sum X \sum Y}{n \sum X^2 - (\sum X)^2}$$

e

$$a = \bar{Y} - b\bar{X}$$

Regressão Linear Simples



Regressão Linear Simples

➤ Mensuração da qualidade do ajuste:

$$R^2 = \frac{RSS}{TSS}$$

Em que:

$$TSS = \sum (Y - \bar{Y})^2 = \sum Y^2 - n\bar{Y}^2$$

$$ESS = \sum (Y - \hat{Y})^2$$