

Medidas Estatísticas

ASSOCIAÇÃO: COVARIÂNCIA E CORRELAÇÃO LINEAR SIMPLES

Análise de Correlação e medidas de associação

CET083 – PROBABILIDADE E ESTATÍSTICA

PROFESSOR JOSÉ CLÁUDIO FARIA

SETEMBRO DE 2014

IAGO FARIAS

Roteiro

Introdução

Diagramas de dispersão

Covariância

Exemplo

Interpretação de resultados

Grau de associação linear

Funções em R

Considerações

Bibliografia

Análise exploratória de dados

```
graph TD; A[Análise exploratória de dados] --> B[Medidas estatísticas]; B --> C[Associação];
```

The diagram consists of three stacked, rounded rectangular boxes with a gradient from dark orange at the top to light orange at the bottom. The top box contains the text 'Análise exploratória de dados'. A downward-pointing arrow connects the bottom right corner of the top box to the top right corner of the middle box. Another downward-pointing arrow connects the bottom right corner of the middle box to the top right corner of the bottom box.

Medidas estatísticas

Associação

Intro

Avaliar o grau de relacionamento linear entre duas ou mais variáveis


- Quanto uma variável interfere na outra? Qual a sua dependência?
- Técnicas de correlação

Grau de associação linear

Perfeita negativa

Não correlacionadas


Perfeita positiva



Diagramas de Dispersão

Coleção de pontos em que as coordenadas cartesianas (x,y) são valores de cada membro do par de dados

- Qual a necessidade de um diagrama?
 - Análise de tendências
 - Mudanças de espalhamento de uma variável em relação à outra
 - Análise de valores discrepantes



Covariância

Medida de relação linear entre duas variáveis:

$$\text{Cov}(X, Y) = E[(X - E(X))(Y - E(Y))];$$

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

Compreensão a partir de um exemplo

Duas variáveis aleatórias:

- M : rendimento acadêmico em matemática
- L : rendimento acadêmico em línguas

Tabela 1 – Rendimento acadêmico em matemática (M) e línguas (L) do curso X da Universidade Y - 2014

Obs	1	2	3	4	5	6	7	8
M	36	80	50	58	72	60	56	08
L	35	65	60	39	48	44	48	61

-
- $\sum m = 480$
 - $m(M) = 60$
 - $s(M) = 13,65$

- $\sum l = 400$
- $m(L) = 50$
- $s(L) = 10,93$




Figura 1 – Gráfico de dispersão entre M e L.

- Novo gráfico, com os eixos das médias m e l sobreposto




Figura 2 – Gráfico de dispersão entre M e L com médias transladadas.

-
- Grau de associação entre as duas variáveis aleatórias?
 - $\sum ml$
 - Onde $m = m_i - m(M)$ e $l = l_i - m(L)$

Tabela 2 – Cálculo do índice $\sum ml$

Obs	M	L	$m = (M_i - m(M))$	$l = (L_i - m(L))$	$m.l$
1	36	35	- 24	- 15	360
2	80	65	20	15	300
3	50	60	- 10	10	- 100
4	58	39	- 2	- 11	22
5	72	48	12	- 2	- 24
6	60	44	0	- 6	0
7	56	48	- 4	- 2	8
8	68	61	8	11	88
$m(M) = 60$ $s(M) = 13,65$		$m(L) = 50$ $s(L) = 10,93$		$\Sigma ml = 654$	

Interpretação de resultados

- Observações sobre o resultado de ml .

- $ml > 0$
- $ml < 0$
- $ml \cong 0$



- Observações sobre o resultado de $\sum ml$.

- $\sum ml > 0$
- $\sum ml < 0$
- $\sum ml \cong 0$

- Sinal representa a associação corretamente!
- E se a amostra tivesse o dobro do tamanho?
 - $2 * \sum ml$? A tendência também dobra?

$$\circ \frac{\sum ml}{n-1} = \frac{1}{n-1} [\sum (M_i - m(M)) \times (L_i - m(L))]$$

- Divisão pelo tamanho da amostra

- Nova medida: Correlação.

- Unidade de medidas das variáveis envolvidas? (pés e polegadas, metros e milhas)
 - Padronização de unidades -> Dividir m e l pelos seus respectivos desvios-padrões s(M) e s(L)

$$\circ \frac{1}{n-1} \sum \left(\frac{m}{s(M)} \right) \left(\frac{l}{s(L)} \right) = \frac{1}{n-1} \left[\sum \left(\frac{M_i - m(M)[un]}{s(M)[un]} \right) \left(\frac{L_i - m(L)[un]}{s(L)[un]} \right) \right],$$

$$\text{onde } s(M) = \sqrt{\sum_{i=1}^n \frac{(x_i - \bar{x})^2}{n-1}} \text{ e } s(L) = \sqrt{\sum_{i=1}^n \frac{(y_i - \bar{y})^2}{n-1}}$$

- $\frac{\sum ml}{n-1} = \frac{1}{n-1} [\sum (M_i - m(M)) \times (L_i - m(L))]$

- Divisão pelo tamanho da amostra

- Nova medida: Correlação.

- Unidade de medidas das variáveis envolvidas? (pés e polegadas, metros e milhas)
 - Padronização de unidades -> Dividir m e l pelos seus respectivos desvios-padrões s(M) e s(L)

- $\frac{1}{n-1} \sum \left(\frac{m}{s(M)} \right) \left(\frac{l}{s(L)} \right) = \frac{1}{n-1} \left[\sum \left(\frac{M_i - m(M)}{s(M)} \right) \left(\frac{L_i - m(L)}{s(L)} \right) \right],$

onde $s(M) = \sqrt{\sum_{i=1}^n \frac{(x_i - \bar{x})^2}{n-1}}$ e $s(L) = \sqrt{\sum_{i=1}^n \frac{(y_i - \bar{y})^2}{n-1}}$

- $r = \frac{cov(M,L)}{s(M)s(L)}$ -> Correlação de Pearson

-
- **Covariância:**
 - Não é influenciado pelo tamanho da amostra, entretanto influenciado pelas unidades de medida das variáveis
 - **Coefficiente de correlação:**
 - Não é influenciado nem pelo tamanho, nem pelas unidades de medida das variáveis
 - **Pressupõe-se da correlação que:**
 - Relacionamento linear
 - Variáveis aleatórias e intervalares ou proporcionais (nunca categóricas ou nominais)
 - Distribuição normal bivariada
 - **Teorema**
 - Se X e Y forem independentes, então não são correlacionadas, isto é,

$$p_{(x,y)} \rightarrow r_{(x,y)} = 0$$

- $cov(M, L) = \sum \frac{(M_i - m(M))(L_i - m(L))}{n-1} = \frac{654}{7} = 93,43$

- $r(M, L) = \frac{cov(M, L)}{s(M)s(L)} = \frac{93,43}{13,65 * 10,93} = 0,63$


- Obs.: $-1 \leq r \leq 1$

- $r^2 = 0,63^2 = 0,3922$


- $r^2 = 39,22\%$

- A variação observada em M é explicada pela variação em L, e vice-versa.
 - Interpretação dos resultados.


Coeficiente de Correlação	Correlação
$r = 1$	Perfeita positiva.
$0,8 \leq r < 1$	Forte positiva
$0,5 \leq r < 0,8$	Moderada positiva
$0,1 \leq r < 0,5$	Fraca positiva
$0 \leq r < 0,1$	Íntima positiva
$r = 0$	Nula
$0 \leq r < -0,1$	Íntima negativa
$-0,1 \leq r < -0,5$	Fraca negativa
$-0,5 \leq r < -0,8$	Moderada negativa
$-0,8 \leq r < -1$	Forte negativa.
$r = -1$	Perfeita negativa.




$r = 0,6$




$r = 1$




$$r = -0,8$$



$$r = -1$$



$$r = 0$$



$$r = 0$$

Obs.: existe relação, mas não é linear.

Funções em R

- `cov(x, y, na.rm, use, method, V)`

x

a numeric vector, matrix or data frame.

y

NULL (default) or a vector, matrix or data frame with compatible dimensions to x. The default is equivalent to `y = x` (but more efficient).

na.rm

logical. Should missing values be removed?

Use

an optional character string giving a method for computing covariances in the presence of missing values. This must be (an abbreviation of) one of the strings "everything", "all.obs", "complete.obs", "na.or.complete", or "pairwise.complete.obs".

Method

a character string indicating which correlation coefficient (or covariance) is to be computed. One of "pearson" (default), "kendall", or "spearman", can be abbreviated.

V

symmetric numeric matrix, usually positive definite such as a covariance matrix.

- `cor(x, y, na.rm, use, method, V)`

<code>x</code>	a numeric vector, matrix or data frame.
<code>y</code>	NULL (default) or a vector, matrix or data frame with compatible dimensions to <code>x</code> . The default is equivalent to <code>y = x</code> (but more efficient).
<code>na.rm</code>	logical. Should missing values be removed?
<code>use</code>	an optional character string giving a method for computing covariances in the presence of missing values. This must be (an abbreviation of) one of the strings "everything", "all.obs", "complete.obs", "na.or.complete", or "pairwise.complete.obs".
<code>method</code>	a character string indicating which correlation coefficient (or covariance) is to be computed. One of "pearson" (default), "kendall", or "spearman", can be abbreviated.
<code>V</code>	symmetric numeric matrix, usually positive definite such as a covariance matrix.

Considerações

- Predição e análise exploratória
- Pressupõe-se da correlação:
 - Relacionamento linear
 - Variáveis aleatórias medidas nas escalas intervalar ou proporcional (nunca categórica ou nominal)
 - Distribuição normal bivariada
- Análise da concordância, porém não estabelece relação causa-efeito, nem permite previsões
- Covariância fortemente influenciado por *outliers*
- Correlação é uma técnica menos poderosa que a análise de regressão

Referências

- GUIMARÃES, Paulo Ricardo B. ***Análise de Correlação e medidas de associação***. DEST/UFPR, 2013.
- BUSSAB, Wilton O & MORETTIN, Pedro A. **Estatística Básica**. São Paulo, Saraiva, 5 ed. 2004.
- Slides referentes a apresentação do grupo de 2014.1
- FARIA, José Cláudio. **Notas de aulas expandidas** – Ilhéus, UESC/DCET, 10 ed. 2009.