



Universidade Federal de Mato Grosso

AULA 08 – Estatística

Prof. Lucas Bianchi

Cuiabá, 12 de setembro de 2016


Na aula de hoje, estudaremos:

- ✓ Variáveis aleatórias
- ✓ Correlação
- ✓ Regressão Linear

Introdução

Existem situações nas quais há interesse em estudar o comportamento conjunto de uma ou mais variáveis. Em muitos casos, a explicação de um fenômeno de interesse pode estar associado a outros fatores (variáveis) que contribuem de algum modo para a ocorrência deste fenômeno.

Classificação de variáveis



Qualitativa Nominal

Consistem apenas em nomes, rótulos ou categorias. Os dados não podem ser dispostos segundo um esquema ordenado.

Ex: Masculino, Feminino.

Quantitativa Discreta

Assume valores pertencentes a um conjunto finito ou enumerável. Geralmente, seus valores são resultados de um processo de contagem, razão pela qual seus valores são expressos através de números inteiros não-negativos.

Ex: Quantidade de membros por família.

Qualitativa Ordinal

Envolve dados que podem ser dispostos em alguma ordem, mas as diferenças entre os valores dos dados não podem ser determinadas ou não tem sentido.

Ex: Ens. Fundamental, médio e superior.

Quantitativa Contínua

Assume qualquer valor pertencente a um determinado intervalo do conjunto dos Reais. Pode-se dizer que a variável contínua resulta normalmente de mensurações.

Ex: Nota, Altura, Peso.

Associação entre variáveis Quantitativas

Quando as variáveis envolvidas são ambas do tipo quantitativo é possível utilizar procedimentos analíticos como:

- Gráfico de dispersão
- Correlação

Utilizamos o diagrama de dispersão entre duas variáveis para:

- Mostrar a relação entre duas variáveis quantitativas, medidas sobre os mesmos indivíduos;
- Os valores de uma variável aparecem no eixo horizontal, e os da outra, no eixo vertical.

Cada indivíduo aparece como o ponto do gráfico definido pelos valores de ambas as variáveis para aquele indivíduo

Alguns aspectos são importantes ao se analisar o gráfico de dispersão, são eles:

- Direção (crescente, decrescente)
- Forma (linear, não linear, aglomerados)
- Pontos discrepantes

Tabela 1: Anos de serviço (X) por Números de clientes (Y)

| Agente | Anos de serviço (X) | Número de clientes (Y) |
|--------|---------------------|------------------------|
| 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 |


Figura 1: Gráfico de dispersão para as variáveis anos de serviço e número de clientes

Tabela 2: Anos de serviço (X) por Números de clientes (Y)

| Variável | X | Y |
|----------|----|----|
| A | 3 | 44 |
| B | 10 | 19 |
| C | 4 | 40 |
| D | 9 | 42 |
| E | 1 | 17 |
| F | 4 | 20 |
| G | 7 | 26 |
| H | 10 | 20 |
| I | 4 | 25 |
| J | 4 | 31 |



Figura 2: Gráfico de dispersão para as variáveis anos de serviço e número de clientes

Tabela 3: Renda bruta mensal (X) e porcentagem da renda gasta em saúde (Y)

| Familia | X | Y |
|---------|----|-----|
| A | 12 | 7,2 |
| B | 16 | 7,4 |
| C | 18 | 7 |
| D | 20 | 6,5 |
| E | 28 | 6,6 |
| F | 30 | 6,7 |
| G | 40 | 6 |
| H | 48 | 5,6 |
| I | 50 | 6 |
| J | 54 | 5,5 |

Figura 3: Gráfico de dispersão para as variáveis X e Y




Correlação Linear Simples

Vimos que os gráficos ajudam a verificar, de forma rápida e fácil, a existência de possíveis associações. Entretanto, é muito difícil quantificar essa relação entre a variável X e Y apenas olhando o gráfico. Portanto, precisamos definir uma medida que quantifica essa associação.


A relação mais simples que podemos observar entre duas variáveis é a **relação linear**. Assim, teremos uma medida que quantifica o quanto os pontos se aproximam de uma reta.

Essa medida será definida de modo a variar num intervalo finito, especificamente, de -1 a +1.


Correlação Positiva Linear



Correlação Negativa Linear



Correlação Não Linear



Utilizamos a correlação linear entre duas variáveis para:

- Verificar se uma delas está, de alguma forma, relacionada com a outra;
- Analisar se a alteração no valor de uma variável (dita independente) provoca alterações no valor da outra variável (dita dependente)

Para fazer isso precisamos calcular

Tabela 4: Anos de serviço (X) por Números de clientes (Y)

| Agente | Anos (X) | Clientes (Y) | $(x - \bar{x})$ | $(y - \bar{y})$ | $(x - \bar{x})(y - \bar{y})$ | $(x - \bar{x})^2$ | $(y - \bar{y})^2$ |
|--------|----------|--------------|-----------------|-----------------|------------------------------|-------------------|-------------------|
| A | 2 | 48 | -3,70 | -8,50 | 31,45 | 13,69 | 72,25 |
| B | 3 | 50 | -2,70 | -6,50 | 17,55 | 7,29 | 42,25 |
| C | 4 | 56 | -1,70 | -0,50 | 0,85 | 2,89 | 0,25 |
| D | 5 | 52 | -0,70 | -4,50 | 3,15 | 0,49 | 20,25 |
| E | 4 | 43 | -1,70 | -13,50 | 22,95 | 2,89 | 182,25 |
| F | 6 | 60 | 0,30 | 3,50 | 1,05 | 0,09 | 12,25 |
| G | 7 | 62 | 1,30 | 5,50 | 7,15 | 1,69 | 30,25 |
| H | 8 | 58 | 2,30 | 1,50 | 3,45 | 5,29 | 2,25 |
| I | 8 | 64 | 2,30 | 7,50 | 17,25 | 5,29 | 56,25 |
| J | 10 | 72 | 4,30 | 15,50 | 66,65 | 18,49 | 240,25 |
| Total | 57 | 565 | | | 171,5 | 58,1 | 658,5 |

Até agora, fizemos cálculos necessários para obter o coeficiente de correlação entre as duas variáveis X e Y. A formula desse cálculo é dada por:

$$\text{corr}(X, Y) = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} = \frac{171,5}{\sqrt{58,1 * 658,5}} = 0,8767$$

Observa-se que temos todos os campos necessários para obtermos o valor da correlação, desta forma, basta fazer as substituições

Portanto, neste exemplo, o grau de correlação linear é de 87,67%, ou seja, há uma correlação positiva forte.

Tabela 5: Renda bruta mensal (X) e porcentagem da renda gasta em saúde (Y)

| Agente | Anos (X) | Cientes (Y) | $(x - \bar{x})$ | $(y - \bar{y})$ | $(x - \bar{x})(y - \bar{y})$ | $(x - \bar{x})^2$ | $(y - \bar{y})^2$ |
|--------|----------|-------------|-----------------|-----------------|------------------------------|-------------------|-------------------|
| A | 12 | 7,2 | -19,6 | 0,75 | -14,7 | 384,16 | 0,5625 |
| B | 16 | 7,4 | -15,6 | 0,95 | -14,82 | 243,36 | 0,9025 |
| C | 18 | 7 | -13,6 | 0,55 | -7,48 | 184,96 | 0,3025 |
| D | 20 | 6,5 | -11,6 | 0,05 | -0,58 | 134,56 | 0,0025 |
| E | 28 | 6,6 | -3,6 | 0,15 | -0,54 | 12,96 | 0,0225 |
| F | 30 | 6,7 | -1,6 | 0,25 | -0,4 | 2,56 | 0,0625 |
| G | 40 | 6 | 8,4 | -0,45 | -3,78 | 70,56 | 0,2025 |
| H | 48 | 5,6 | 16,4 | -0,85 | -13,94 | 268,96 | 0,7225 |
| I | 50 | 6 | 18,4 | -0,45 | -8,28 | 338,56 | 0,2025 |
| J | 54 | 5,5 | 22,4 | -0,95 | -21,28 | 501,76 | 0,9025 |
| Total | 316 | 64,5 | | | -85,8 | 2142,4 | 3,885 |

Uma vez feito os cálculos, vamos obter o grau de associação linear (correlação)

$$\text{corr}(X, Y) = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} = \frac{-85,5}{\sqrt{2142,4 * 3,885}} = -0,9404$$

Observa-se que temos todos os campos necessários para obtermos o valor da correlação, desta forma, basta fazer as substituições

Portanto, neste exemplo, o grau de correlação linear é de -94,04%, ou seja, há uma correlação linear negativa forte.

Atenção!!

As propriedades mais importantes do coeficiente de correlação são:

1. O coeficiente de correlação é uma medida adimensional, isto é, ele é independente das unidades de medida das variáveis X e Y .
2. Quanto mais próximo de $+1$ for “ r ”, maior o grau de relacionamento linear positivo entre X e Y , ou seja, se X varia em uma direção, Y variará na mesma direção.
3. Quanto mais próximo de -1 for “ r ”, maior o grau de relacionamento linear negativo entre X e Y , isto é, se X varia em um mesmo sentido Y , variará no sentido inverso.
4. Quanto mais próximo de zero estiver “ r ”, menor será o relacionamento linear entre X e Y .

Observação: R^2 , chamado de coeficiente de determinação é dado simplesmente pelo quadrado de R .

Propriedades:

- Se $R > 0$, então a relação linear é positiva.
- Se $R < 0$, então a relação linear é negativa.
- Se R^2 é próximo de 1, então dizemos que a relação linear é forte.
- Se R^2 é próximo de 0, então dizemos que a relação linear é fraca.
- Se R^2 for intermediário, a relação linear é intermediária.

Regressão Linear

Descreve a relação entre duas variáveis por meio de uma reta. Essa reta é chamada de **reta de regressão** e é dada por:

$$y = a + xb + e_i$$

Em que “*a*” (é o intercepto) e “*b*” (inclinação da reta) são parâmetros do modelo, ou seja, para encontrarmos a reta de regressão. Podemos utilizar o método de mínimos quadrados para calcular essas constantes.

Mínimos Quadrados

É uma técnica de otimização matemática que procura o melhor ajuste para um conjunto de dados, ou seja, procura-se encontrar a reta que mais se aproxima dos dados.

O objetivo deste método é encontrar os valores para “a” e “b” que minimizem a soma do quadrado dos resíduos. Os resíduos são as diferenças entre o valor estimado e o observado.

Podemos calcular esses parâmetros utilizando as expressões abaixo:




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

Exercício 1. (CAPES/2008) Considere as afirmações abaixo:

- I) O coeficiente de correlação linear de Pearson é necessariamente um número no intervalo $(-1,1)$.
 - II) O coeficiente de correlação linear de Pearson só pode ser calculado para variáveis quantitativas.
- a) As duas afirmações são verdadeiras, e a segunda é uma justificativa correta da primeira
 - b) As duas são verdadeiras, e a segunda não é uma justificativa correta da primeira.
 - c) A primeira é verdadeira e a segunda é falsa.
 - d) A primeira é falsa e a segunda é verdadeira.
 - e) Ambas são falsas.

Regressão não-linear


A relação entre as variáveis não pode ser descrita por uma função linear como demonstrado nas figuras abaixo.





Mas o que fazer quando o modelo de regressão linear não é apropriado?

Solução 1: Dividir o dado em partes suficientes para que a regressão linear seja adequada, exemplo:





Mas o que fazer quando o modelo de regressão linear não é apropriado?

Solução 2: Podemos utilizar um modelo de regressão não linear.

Solução 3: Aplicar uma linearização, ou seja, transformar os dados para que seja possível continuar usando a regressão linear.

Regressão linear múltipla

Regressão múltipla é uma coleção de técnicas estatísticas para construir modelos que descrevem de maneira razoável relações entre várias variáveis explicativas de um determinado processo.

A diferença entre a regressão linear simples e a múltipla é que na múltipla são tratadas duas ou mais variáveis explicativas.

Exercício 2: Recordemos o exemplo em que se pretende estudar a relação entre o volume de vendas (Y) efetuadas durante um dado período de tempo por um vendedor, os seus anos de experiência (X1) e o seu score num teste de inteligência (X2)

| Vendedor | Vendas (Y) | Anos de experiência (X1) | Score no teste de inteligência (X2) |
|----------|------------|--------------------------|-------------------------------------|
| 1 | 9 | 6 | 3 |
| 2 | 6 | 5 | 2 |
| 3 | 4 | 3 | 2 |
| 4 | 3 | 1 | 1 |
| 5 | 3 | 4 | 1 |

| Vendedor | Vendas (Y) | Anos de experiência (X1) | Score no teste de inteligência (X2) |
|----------|------------|--------------------------|-------------------------------------|
| 6 | 5 | 3 | 3 |
| 7 | 8 | 6 | 3 |
| 8 | 2 | 2 | 1 |
| 9 | 7 | 4 | 2 |
| 10 | 4 | 2 | 2 |

Exercício 1. Um pesquisador deseja verificar se um instrumento para medir a concentração de determinada substância no sangue está bem calibrado. Para isto, ele tomou 15 amostras de concentrações conhecidas (X) e determinou a respectiva concentração através do instrumento (Y), obtendo:

| | | | | | | | | | | | | | | | |
|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|------|------|------|
| X | 2,0 | 2,0 | 2,0 | 4,0 | 4,0 | 4,0 | 6,0 | 6,0 | 6,0 | 8,0 | 8,0 | 8,0 | 10,0 | 10,0 | 10,0 |
| Y | 2,1 | 1,8 | 1,9 | 4,5 | 4,2 | 4,0 | 6,2 | 6,0 | 6,5 | 8,2 | 7,8 | 7,7 | 9,6 | 10,0 | 10,1 |

- Construa o diagrama de dispersão para esses dados.
- Calcule o coeficiente de correlação entre as variáveis X e Y .
- Obtenha a reta de regressão da variável Y em função de X .

Gabarito – Exercício 1

$R = 0,9961$

$R^2 = 0,9922$

| X | Y | coluna 1 | coluna 2 | coluna 3 | coluna 4 | coluna 5 |
|----|------|----------|----------|----------|----------|----------|
| 2 | 2,1 | -4 | -3,94 | 15,76 | 16 | 15,5236 |
| 2 | 1,8 | -4 | -4,24 | 16,96 | 16 | 17,9776 |
| 2 | 1,9 | -4 | -4,14 | 16,56 | 16 | 17,1396 |
| 4 | 4,5 | -2 | -1,54 | 3,08 | 4 | 2,3716 |
| 4 | 4,2 | -2 | -1,84 | 3,68 | 4 | 3,3856 |
| 4 | 4 | -2 | -2,04 | 4,08 | 4 | 4,1616 |
| 6 | 6,2 | 0 | 0,16 | 0 | 0 | 0,0256 |
| 6 | 6 | 0 | -0,04 | 0 | 0 | 0,0016 |
| 6 | 6,5 | 0 | 0,46 | 0 | 0 | 0,2116 |
| 8 | 8,2 | 2 | 2,16 | 4,32 | 4 | 4,6656 |
| 8 | 7,8 | 2 | 1,76 | 3,52 | 4 | 3,0976 |
| 8 | 7,7 | 2 | 1,66 | 3,32 | 4 | 2,7556 |
| 10 | 9,6 | 4 | 3,56 | 14,24 | 16 | 12,6736 |
| 10 | 10 | 4 | 3,96 | 15,84 | 16 | 15,6816 |
| 10 | 10,1 | 4 | 4,06 | 16,24 | 16 | 16,4836 |
| | | | | 117,6 | 120 | 116,156 |