

Estatística Básica

MEDIDAS RESUMO

Renato Dourado Maia

Instituto de Ciências Agrárias

Universidade Federal de Minas Gerais



Motivação Básica

- Se você estivesse num ponto de ônibus e alguém perguntasse sobre o **quanto** um **determinado ônibus demora para passar**, o que você responderia?
 - Com certeza você **não apresentaria uma tabela de frequências** e tampouco **um modelo teórico** para a variável aleatória de interesse!
- Quem perguntou deseja uma **resposta breve** que **sintetize a informação** e não uma completa descrição completa dos dados coletados ou de uma modelagem que eventualmente foi feita.



Motivação Básica

- Nesta unidade serão apresentadas algumas **medidas** que **sumarizam as informações disponíveis** sobre o **comportamento** de uma **variável**, seja para um **conjunto de dados** – toda a **população** ou uma **amostra**, seja para **variáveis aleatórias**.
- Essencialmente, estudaremos medidas que representem **tendência central** e **dispersão**.



Medidas de Posição (Tendência Central)

- Seja uma variável X com observações x_1, x_2, \dots, x_n .
 - A **mediana** (md_{obs}) é o valor que ocupa a posição central dos dados ordenados.
 - A **moda** (mo_{obs}) é dada pelo valor mais frequente.
 - A **média** é dada pela soma das observações dividida pelo número de observações:

$$\bar{x}_{obs} = \frac{x_1 + x_2 + \dots + x_n}{n} = \frac{\sum_{i=1}^n x_i}{n} = \frac{n_1 x_1 + n_2 x_2 + \dots + n_k x_k}{n_1 + \dots + n_k} = \frac{\sum_{i=1}^k n_i x_i}{n} = \sum_{i=1}^k \frac{n_i}{n} x_i.$$

Tabela de Frequências



Exemplo 1

- Suponha que parafusos a serem utilizados em tomadas elétricas são embalados em caixas rotuladas como contendo 100 unidades. Em uma construção, 10 caixas de um lote tiveram o número de parafusos contados, fornecendo os valores 98, 102, 100, 100, 99, 97, 96, 95, 99, 100. Determine, para o **número de parafusos por caixa**, a **média**, a **moda** e a **mediana**.



Exemplo 1


- **Dados ordenados:** 95, 96, 97, 98, 99, 99, 100, 100, 100, 102.

$$\left\{ \begin{array}{l} \rightarrow md_{obs} = \frac{\text{quinto elemento} + \text{sexto elemento}}{2} = \frac{99 + 99}{2} = 99 \\ \rightarrow mo_{obs} = 100 \\ \rightarrow \bar{x}_{obs} = \frac{98 + 102 + \dots + 100}{10} = \frac{986}{10} = 98,6 \end{array} \right.$$



Pergunta

Quando utilizar
cada uma das
medidas de
posição?



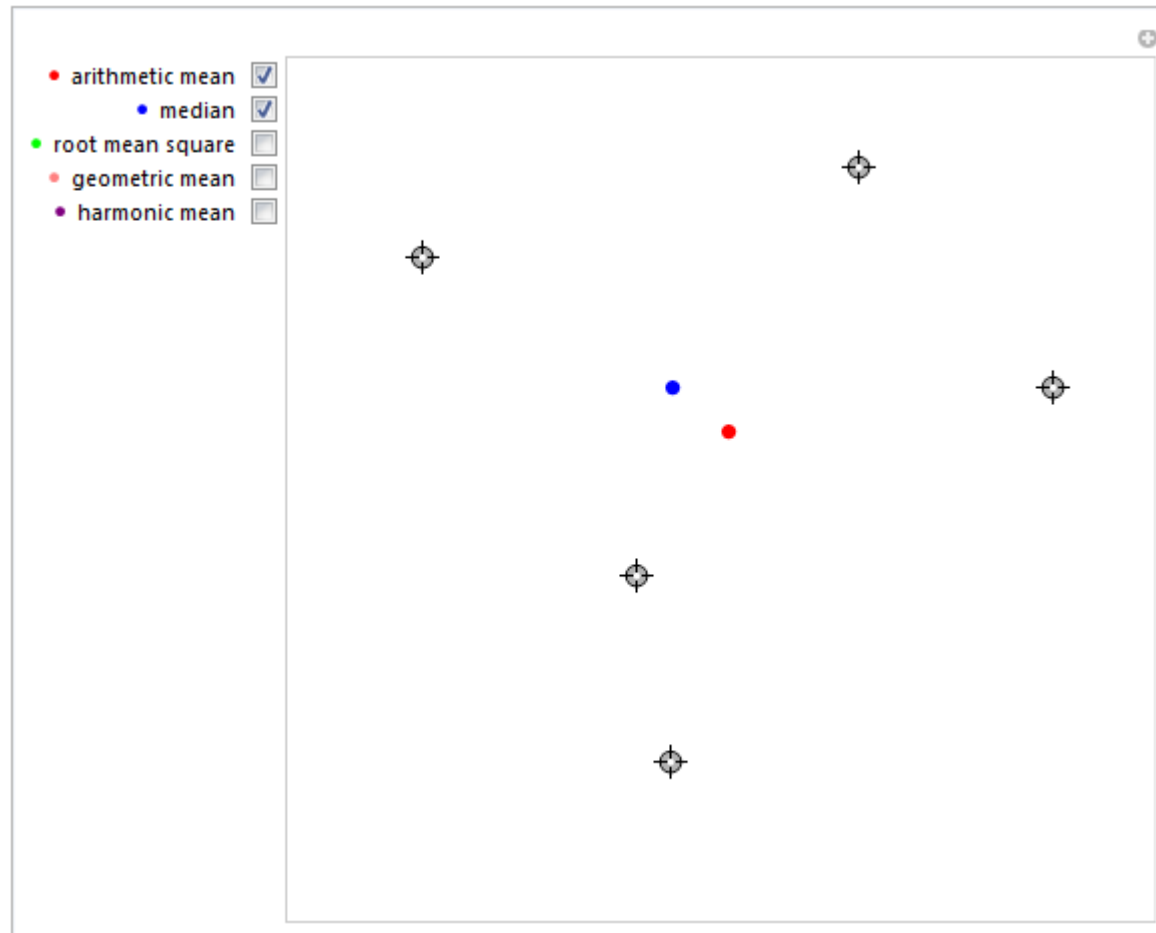
Medidas de Posição (Tendência Central)

- As **medidas de posição** podem ser utilizadas **em conjunto** para **auxiliar** na **análise** dos dados. Em determinadas situações, entretanto, **uma** pode ser **mais conveniente** do que as **outras**.
 - Se há valores **discrepantes**, a **mediana** é **menos afetada** do que a **média**.
 - Se há **muitas observações**, a mediana é mais **difícil** de ser calculada, mesmo considerando a utilização de **computadores**, pois o **processo de ordenação é custoso**.
 - Há distribuições **multimodais** – conjuntos de dados com **mais do que uma moda**.



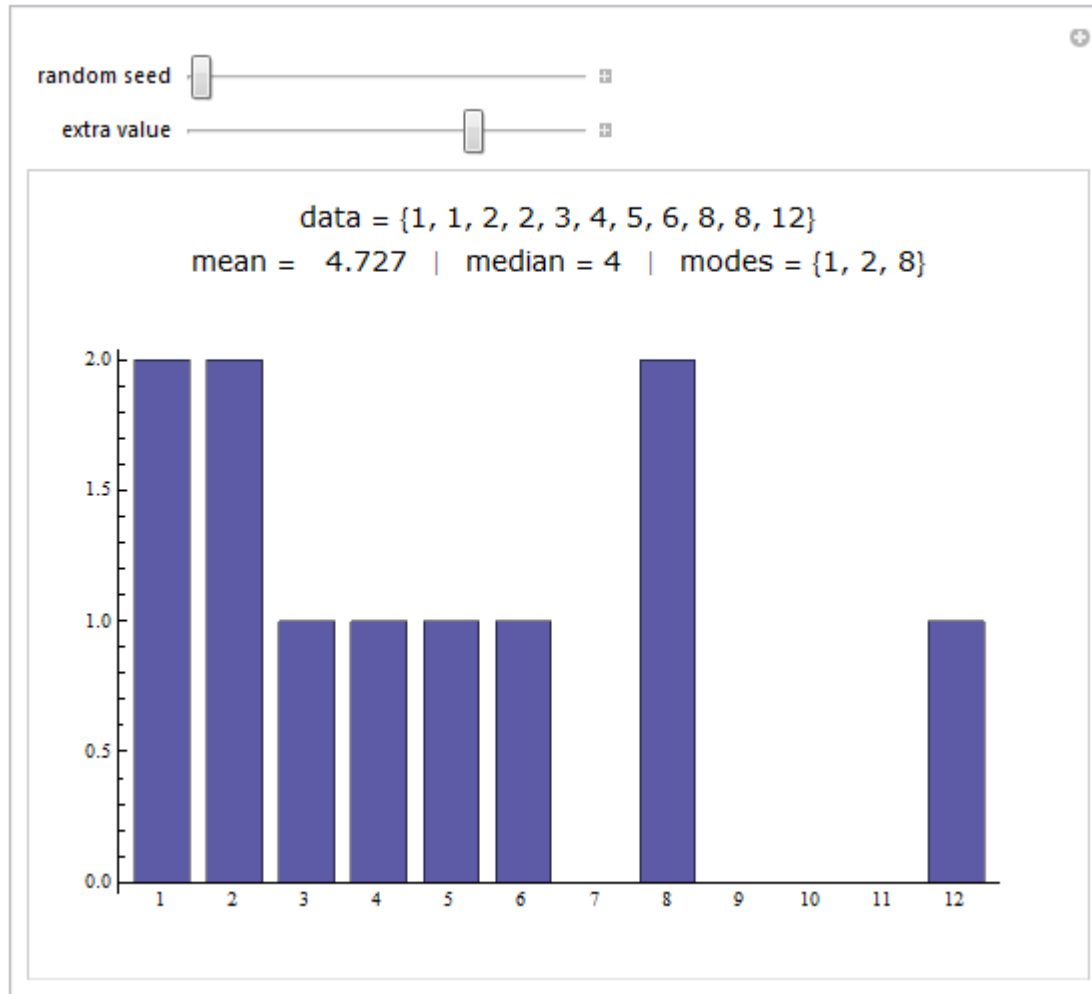
"Basic Statistics of Movable Points" from the Wolfram Demonstrations Project

<http://demonstrations.wolfram.com/BasicStatisticsOfMovablePoints>



"Mean, Median, Mode" from the Wolfram Demonstrations Project

<http://demonstrations.wolfram.com/MeanMedianMode/>



Medidas de Posição (Tendência Central)

- Seja uma VA X com possíveis valores x_1, x_2, \dots, x_k e correspondentes probabilidades p_1, p_2, \dots, p_k .
 - A **média, valor esperado** ou **esperança matemática** de X , denotada por $E(X)$, μ_X , ou simplesmente μ , é dada pela expressão:

$$E(X) = \sum_{i=1}^k x_i p_i.$$

- A **moda** (Mo) de X é(são) o(s) valor(es) da variável com **maior probabilidade**, ou seja:

$$P(X = Mo) = \max(p_1, p_2, \dots, p_k).$$



Medidas de Posição (Tendência Central)

- Seja uma VA X com possíveis valores x_1, x_2, \dots, x_k e correspondentes probabilidades p_1, p_2, \dots, p_k .
 - A **mediana** de X (Md) é o valor que satisfaz às seguintes condições:

$$P(X \geq Md) \geq 0,5 \quad e \quad P(X \leq Md) \geq 0,5.$$

- Em algumas situações, as desigualdades são satisfeitas por **qualquer valor num certo intervalo** e, nesse caso, **toma-se a mediana como o ponto médio do intervalo**.



Exemplo 2

- Determine a **média**, e **moda** e a **mediana** para a VA X com a **função discreta de probabilidade** apresentada na tabela a seguir.

| | | | | |
|-------|-----|-----|-----|-----|
| X | -5 | 10 | 15 | 20 |
| p_i | 0,3 | 0,2 | 0,4 | 0,1 |

$$\left\{ \begin{array}{l} \rightarrow \mu = \sum_{i=1}^4 x_i p_i = (-5) \times (0,3) + 10 \times 0,2 + 15 \times 0,4 + 20 \times 0,1 = 8,5 \\ \rightarrow Mo = 15 \\ \rightarrow Md \in [10, 15] \Rightarrow Md = 12,5 \end{array} \right.$$




Medidas de Posição (Tendência Central)

| | Conjunto de Dados | Variável Aleatória |
|---------|--|--|
| Valores | $ \begin{array}{ccccc} X & x_1 & x_2 & \dots & x_k \\ n_i & n_1 & n_2 & \dots & n_k \end{array} $ | $ \begin{array}{ccccc} X & x_1 & x_2 & \dots & x_k \\ p_i & p_1 & p_2 & \dots & p_k \end{array} $ |
| Média | $\bar{x}_{obs} = \frac{1}{n} \sum_{i=1}^k n_i x_i$ | $\mu = \sum_{i=1}^k x_i p_i$ |
| Mediana | $md_{obs} = \text{valor central}$ | $ \begin{array}{l} P(X \geq Md) \geq 0,5 \text{ e} \\ P(X \leq Md) \geq 0,5 \end{array} $ |
| Moda | $mo_{obs} = \text{valor com maior frequência}$ | $Mo = \text{valor com maior probabilidade}$ |



Pergunta

A **renda *per capita*** é **a-**
propriada para **compa-**
rar a **distribuição de**
renda de dois países?



Medidas de Dispersão

- As **medidas de posição** podem **esconder** valiosas **informações**, pois elas **não capturam a variabilidade** dos valores da variável em estudo.
 - **Diferentes** conjuntos de dados, por exemplo, podem ter **medidas de posição idênticas**.
 - Nesses casos, é provável que existam **diferenças** em relação à **dispersão dos dados**, isto é, quanto à **maneira como os valores de cada conjunto se espalham**.
- Para quantificar a **dispersão dos dados**, são utilizadas **medidas de dispersão**.



Medidas de Dispersão



**UM ESTATÍSTICO É AQUELE QUE,
TENDO A CABEÇA A ARDER E OS
PÉS ENTERRADOS NO GELO,
AINDA DIZ QUE NA MÉDIA
ESTÁ TUDO BEM!...**



Medidas de Dispersão – Conjunto de Dados

- A **amplitude** (Δ) é definida como a **diferença** entre o **maior** e o **menor** valor do conjunto de dados.
- **Desvio mediano:**

$$\text{desvio mediano} = \frac{1}{n} \sum_{i=1}^n |x_i - md_{obs}|.$$

- **Desvio médio:**

$$\text{desvio médio} = \frac{1}{n} \sum_{i=1}^n |x_i - \bar{x}_{obs}|.$$



Medidas de Dispersão – Conjunto de Dados

- Os **desvios mediano** e **médio** utilizam a **função módulo**, cuja derivada é **descontínua**, o que **dificulta** o tratamento matemático:
 - O que se pode dizer sobre a **derivada** da **função módulo**?
- Em função disso, é comum a utilização de uma **medida de dispersão** que tenha **propriedades matemáticas mais interessantes**.



Medidas de Dispersão – Conjunto de Dados

- A **variância** de uma variável X referente a um **conjunto de dados**, denotada por var_{obs} , pode ser calculada por meio da seguinte expressão:

$$var_{obs} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_{obs})^2.$$

- O **desvio-padrão** (dp_{obs}), que tem a **mesma unidade dos dados originais**, é definido como a **raiz quadrada positiva da variância**.



Medidas de Dispersão – Conjunto de Dados

- A expressão a seguir **facilita** o cálculo da **variância**:

$$var_{obs} = \left(\frac{1}{n} \sum_{i=1}^n x_i^2 \right) - \bar{x}_{obs}^2.$$

- Para o caso de os dados estarem disponíveis numa **tabela de frequências**, são utilizadas as seguintes expressões para o cálculo da **variância**:

$$var_{obs} = \frac{1}{n} \sum_{i=1}^k n_i (x_i - \bar{x}_{obs})^2 = \left(\frac{1}{n} \sum_{i=1}^k n_i x_i^2 \right) - \bar{x}_{obs}^2.$$



Medidas de Dispersão – Variável Aleatória

- Seja uma VA X com $P(X_i = x_i) = p_i$, $i = 1, 2, \dots, k$, e média μ . A **variância** de X é a **ponderação**, pelas respectivas **probabilidades**, dos **desvios relativos à média**, elevados ao quadrado, isto é,

$$\text{Var}(X) = \sum_{i=1}^k (x_i - \mu)^2 p_i.$$

- Normalmente, a **variância** por σ^2 e o **desvio-padrão** por σ .



Medidas de Dispersão – Variável Aleatória

- A **variância** de definida no *slide* anterior pode ainda ser considerada como o **valor esperado** de uma **nova variável aleatória**, o **desvio ao quadrado**, isto é,

$$\text{Var}(X) = E[(X - \mu)^2].$$

- Essa expressão pode ser **reescrita** da seguinte forma:

$$\text{Var}(X) = E(X^2) - \mu^2 = \sum_{i=1}^k p_i x_i^2 - \mu^2.$$



Medidas de Dispersão

| | Conjunto de Dados | Variável Aleatória |
|-----------|--|---|
| Valores | $ \begin{array}{cccccc} X & x_1 & x_2 & \dots & x_k \\ n_i & n_1 & n_2 & \dots & n_k \end{array} $ | $ \begin{array}{cccccc} X & x_1 & x_2 & \dots & x_k \\ p_i & p_1 & p_2 & \dots & p_k \end{array} $ |
| Variância | $ \begin{cases} var_{obs} = \frac{1}{n} \sum_{i=1}^k n_i (x_i - \bar{x}_{obs})^2 \\ var_{obs} = \left(\frac{1}{n} \sum_{i=1}^k n_i x_i^2 \right) - \bar{x}_{obs}^2 \end{cases} $ | $ \begin{cases} \sigma^2 = E[(X - \mu)^2] = \sum_{i=1}^k p_i (x_i - \mu)^2 \\ \sigma^2 = E(X^2) - \mu^2 = \sum_{i=1}^k p_i x_i^2 - \mu^2 \end{cases} $ |



Propriedades da Média e da Variância

| Conjunto de Dados | Variável Aleatória |
|---------------------------------------|-----------------------|
| $Y = aX + b$ | $Y = aX + b$ |
| $\bar{y}_{obs} = a \bar{x}_{obs} + b$ | $E(Y) = aE(X) + b$ |
| $var_{obs}(Y) = a^2 var_{obs}(X)$ | $Var(Y) = a^2 Var(X)$ |

Exercício interessante: demonstrar essas propriedades...



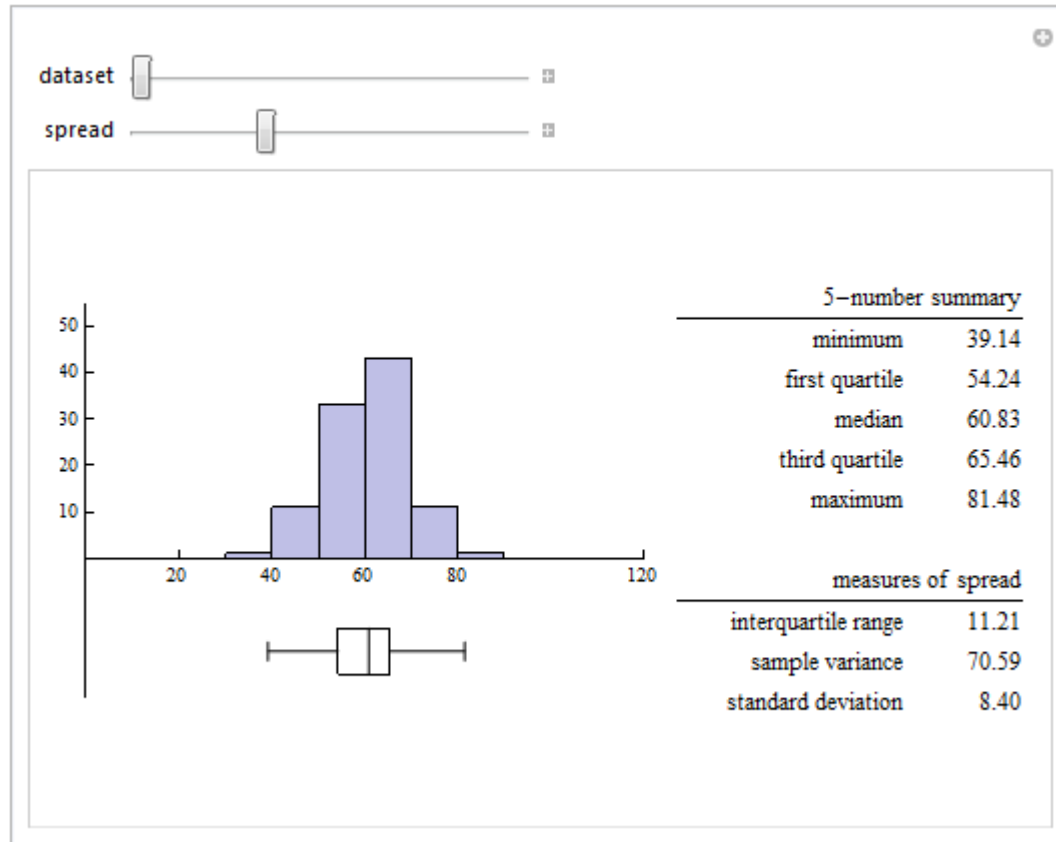
| Variável Discreta | Valor Esperado | Variância |
|--------------------------------|-----------------|---------------------------------|
| Uniforme $(1, k)$ | $\frac{1+k}{2}$ | $\frac{k^2-1}{12}$ |
| Bernoulli (p) | p | $p(1-p)$ |
| Binomial (n, p) | np | $np(1-p)$ |
| Geométrica (p) | $\frac{1-p}{p}$ | $\frac{1-p}{p^2}$ |
| Poisson (λ) | λ | λ |
| Hipergeométrica (n, m, r) | $\frac{rm}{n}$ | $\frac{rm(n-m)(n-r)}{n^2(n-1)}$ |

Exercício interessante: calcular...



"Descriptions of Univariate Data" from the Wolfram Demonstrations Project

<http://demonstrations.wolfram.com/DescriptionsOfUnivariateData>



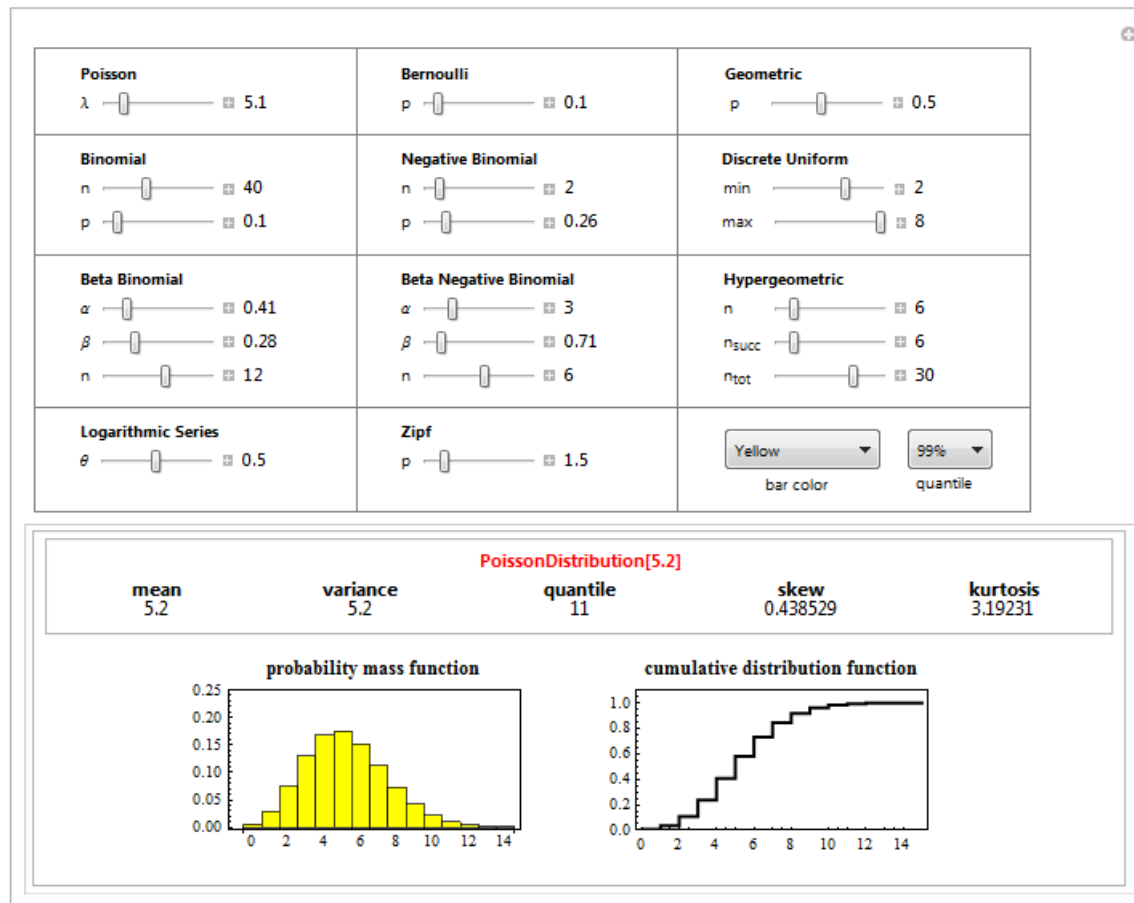
"Illustrating the Use of Discrete Distributions" from the Wolfram Demonstrations Project

<http://demonstrations.wolfram.com/IllustratingTheUseOfDiscreteDistributions>



"Mathematica 7's Discrete Distributions" from the Wolfram Demonstrations Project

<http://demonstrations.wolfram.com/Mathematica7sDiscreteDistributions/>



That's All Folks!



Próxima aula: exercícios do capítulo 4...

