



Universidade Estadual da Paraíba  
Centro de Ciências e Tecnologia  
Departamento de Estatística

**Dinércules Rodrigues da Silva**

**UMA REVISÃO DE ALGUMAS DISTRIBUIÇÕES  
DISCRETAS COM APLICAÇÕES EM R**

Campina Grande  
Outubro de 2016

Dinércules Rodrigues da Silva

**UMA REVISÃO DE ALGUMAS DISTRIBUIÇÕES  
DISCRETAS COM APLICAÇÕES EM R**

Trabalho de Conclusão de Curso apresentado ao curso de Bacharelado em Estatística do Departamento de Estatística do Centro de Ciências e Tecnologia da Universidade Estadual da Paraíba em cumprimento às exigências legais para obtenção do título de bacharel em Estatística.

Orientador:

Tiago Almeida de Oliveira

Campina Grande

Outubro de 2016

É expressamente proibida a comercialização deste documento, tanto na forma impressa como eletrônica. Sua reprodução total ou parcial é permitida exclusivamente para fins acadêmicos e científicos, desde que na reprodução figure a identificação do autor, título, instituição e ano da dissertação.

S586r Silva, Dinércules Rodrigues da.  
Uma revisão de algumas distribuições discreta com aplicações em R [manuscrito] / Dinércules Rodrigues da Silva. - 2016.  
38 p.

Digitado.

Trabalho de Conclusão de Curso (Graduação em Estatística) - Universidade Estadual da Paraíba, Centro de Ciências e Tecnologia, 2016.

"Orientação: Prof. Dr. Tiago Almeida de Oliveira, Departamento de Estatística".

1. Probabilidade. 2. Modelos discretos. 3. Software livre. 4. Software R. I. Título.

21. ed. CDD 519.2

Dinércules Rodrigues da Silva

**UMA REVISÃO DE ALGUMAS DISTRIBUIÇÕES  
DISCRETAS COM APLICAÇÕES EM R**

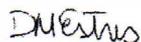
Trabalho de Conclusão de Curso apresentado ao curso de Bacharelado em Estatística do Departamento Estatística do Centro de Ciências e Tecnologia da Universidade Estadual da Paraíba em cumprimento às exigências legais para obtenção do título de bacharel em Estatística.

Aprovado em: 31/10/2016

**Banca Examinadora:**



Prof. Dr. Tiago Almeida de Oliveira  
Orientador



Prof.<sup>a</sup> Dr.<sup>a</sup> Divanilda Maia Esteves  
Universidade Estadual da Paraíba



Prof. Dr. Sílvio Fernando Alves Xavier  
Júnior  
Universidade Estadual da Paraíba

*“Se ressuscitastes com Cristo, buscai as coisas do alto, onde Cristo está entronizado à direita de Deus.”*

Col 3,1

*“É preciso amar as pessoas como se não houvesse amanhã!”*

Renato Russo

# Dedicatória

À minha família, em especial à minha esposa Elk e meus filhos Gabriel e Rafael, aos meus pais, Antonio (in memorian) e Lucia, aos meus irmãos Tony, Doridarnel, Denecler e Donglei e por fim ao Senhor de tudo e maestro da minha vida, Jesus Cristo.

# Agradecimentos

Nada mais justo que agradecer ao meu querido Jesus Cristo que é a razão do meu viver, meu tudo, meu mestre.

Ao professor Doutor Tiago Almeida pela paciência, apoio e orientação a este trabalho e pelo amor com que desempenha esta profissão tão difícil, mas que é uma arte, um dom ser educador, obrigado pelo exemplo.

Aos companheiros Gercino, Fagner, Tiago Almeida (aluno e Amigo), Mauro, Waleska, Tiago Diniz, Kleiton, Fagna e todos aqueles que compartilharam comigo tantos momentos na UEPB.

Gostaria de deixar o meu muito obrigado a todos os professores, funcionários e colegas que passaram ao decorrer do curso. A professora Núbia, ao professor João Gil por todo incentivo e em especial a professora Ruth por estar sempre presente, nos mostrando que somos capazes.

Por fim agradeço a minha esposa Elk aos meus filhos Gabriel e Rafael por todo amor, cumplicidade e força, elementos essenciais para vencer mais um etapa da vida. Aos meus pais, Antonio Rodrigues (in memoriam) e Lucia Emilia, aos meus irmãos Tony, Doridarnel, Denecler e Donglei, pelo incentivo e pela força quando pensei em desistir.

# Resumo

Nesta monografia apresentamos uma breve introdução sobre o estudo de probabilidades e variáveis aleatórias discretas com o uso de definições, lemas, teoremas e demonstrações. Apresentando ao leitor interessado, seja professor de ensino médio ou algum aluno que se depara com o estudo de estatística na universidade, os modelos probabilísticos discretos com aplicações no software R no contexto de Educação Estatística. O uso do software R como ferramenta estatística de aplicação, permitiu o entendimento dos exercícios propostos.

Palavras-chave: Probabilidade. Modelos discreto. Software Livre.

# Abstract

This monograph is a brief introduction to the study of probability and discrete random variables with the use of definitions, lemmas, theorems and proofs. Introducing the interested reader, is a high school teacher or a student who is faced with the statistical study at the university, the discrete probabilistic models with applications in R software in Statistics Education context. Use of R software and application of statistical tool, allowed the understanding of the proposed exercises.

Key words: Probabilities. discrete models. Free Software.

# Sumário

<b>1</b>	<b>Introdução</b>	p. 9
<b>2</b>	<b>Fundamentação Teórica</b>	p. 10
2.1	Ensino de Estatística . . . . .	p. 10
2.2	O <i>Software</i> R . . . . .	p. 11
2.3	Introdução a Probabilidade . . . . .	p. 11
2.3.1	Teoria das probabilidades . . . . .	p. 12
2.3.2	Espaço amostral e eventos . . . . .	p. 12
2.4	Variáveis aleatórias . . . . .	p. 13
2.5	Distribuição de probabilidade de variáveis aleatórias discreta . . . . .	p. 13
2.6	Algumas distribuições probabilísticas discretas . . . . .	p. 17
2.6.1	Distribuição uniforme discreta . . . . .	p. 17
2.6.2	Distribuição de Bernoulli . . . . .	p. 18
2.6.3	Distribuição Binomial . . . . .	p. 18
2.6.4	Distribuição Hipergeométrica . . . . .	p. 22
2.6.5	Distribuição Geométrica . . . . .	p. 24
2.6.6	Distribuição de Poisson . . . . .	p. 26
<b>3</b>	<b>Aplicação</b>	p. 30
<b>4</b>	<b>Conclusão</b>	p. 37
	<b>Referências</b>	p. 38

# 1 Introdução

De acordo com a descrição feita pela Escola Nacional de Ciências Estatísticas, o que modernamente se conhece como Ciências Estatísticas, ou simplesmente Estatística, é um conjunto de técnicas e métodos de pesquisa e análise de dados baseados em estudos probabilísticos que entre outros tópicos envolve o planejamento do experimento a ser realizado, a coleta qualificada dos dados, a inferência, o processamento, a análise e a disseminação das informações.

Atualmente existem muitos *softwares* para auxiliar os alunos na aprendizagem da estatística. O R é um *software* gratuito de códigos abertos, reproduzíveis e adaptáveis, desenvolvido para Windows, UNIX e MacOS, que dia após dia tem ganhado espaço na academia e no setor privado; Propõe um manual de utilização do *software* R, com o ensino de Estatística no ensino superior, permitindo aos alunos ter conhecimento de toda a parte gráfica e computacional imprescindível à aplicação da Estatística. Algumas vantagens de se usar o *software* R, De acordo com Muenchen (2011), são:

O R oferece um vasto conjunto de métodos de análise estatística; É constantemente atualizado; Tem uma vasta biblioteca de métodos implementada; É uma ferramenta flexível com gráficos que apresentam boa manipulação e resolução; Muito versátil para tratamento de dados; Permite desenvolver programas específicos e permite alterações nas funções disponíveis.

Existe um aumento do interesse dos professores do ciclo de Ensino Fundamental e do Médio no lecionamento da Estatística. Apesar de a aleatoriedade estar presente fortemente no dia a dia das pessoas, boa parte desses professores de tais níveis não foram e não estão sendo preparados para transmitir tais conhecimentos de forma consistente, dado que a maioria não teve em sua graduação um direcionamento adequado neste sentido.

O objetivo deste trabalho é apresentar alguns dos principais modelos probabilísticos discretos em conjunto com aplicações no software R, com intuito de auxiliar professores e estudantes de estatística.

## 2 Fundamentação Teórica

Este trabalho está estruturado em seções relativas conhecimento do R, Introdução a Probabilidade e variáveis aleatórias discretas e aplicações dos conceitos vistos com o *Software R*.

### 2.1 Ensino de Estatística

No ensino médio, a Proposta Curricular para o ensino de matemática permite certa flexibilidade no número de aulas semanais. Esta flexibilidade afeta o modo como o conteúdo é abordado. Nas escolas com grade curricular com duas ou três aulas semanais, não está previsto Estatística em quase nenhum momento. Apenas no 2º ano era previsto análise combinatória e probabilidade. No caso de escolas com 4 ou 5 aulas semanais de matemática pode ser incluído Matemática Financeira ou Estatística, ficando a critério da escola ou do professor.

Os conteúdos de Estatística, ministrados no ensino fundamental e médio, estão incluídos na disciplina de matemática. Cabe então ao professor conhecer o currículo da disciplina de matemática, assim como compreender a importância de se trabalhar estes elementos de Probabilidade e Estatística. Deste modo, não há como negar a grandeza desta contribuição, assim como a importância de que estes elementos de Estatística estejam inseridos adequadamente dentro deste currículo.

Assim, embora presente nos diversos níveis de ensino, a Estatística, na maioria das vezes é tratada apenas como uma disciplina (ou um conteúdo) a mais, focada em fórmulas e exercícios. Para Viali (2008), a Estatística ser abordada apenas como uma aplicação de fórmula, sem focar na análise e interpretação dos dados pode omitir sua significância. Então, a solução seria saber transmitir o conteúdo de forma adequada, porém Viali (2008) cita que muitas vezes os professores preferem não trabalhar com Estatística por falta de preparação com relação aos conteúdos dessa.

## 2.2 O *Software* R

A linguagem R foi criada originalmente por Robert Gentleman e Ross Ihaka do Departamento de Estatística da Universidade de Auckland em Nova Zelândia, mais conhecidos por “R & R”, apelido do qual originou-se o nome R do programa (MUENCHEN, 2011). O objetivo inicial de “R & R”, em 1991, era produzir um software para as suas aulas de laboratório baseado na já revolucionária linguagem S, utilizada pelo software comercial S-Plus criado por Jonh M. Chambers da AT & T que atualmente vem contribuindo para o aperfeiçoamento e ampliação das análises estatísticas do R.

Atualmente, o R vem tendo uma aceitação crescente nas universidades e empresas de todo mundo. Hoje em dia, *softwares* estatísticos semelhantes ou até inferiores em termos de análises realizadas, têm preços de aquisição muito elevados, principalmente para empresas de pequeno e médio porte que predominam em nosso país.

Este *software* contém uma linguagem de programação que permite a computação de uma grande variedade de métodos de estatísticos e técnicas gráficas. A maneira mais fácil de inserir dados em objetos no R é a leitura de arquivos. Ele pode ler arquivos de estruturas simples com as extensões .txt. Também é possível importar outros tipos de arquivos mais complexos como .xls mas nesse caso aconselha-se a salvá-lo como .txt. Quando se salva uma área de trabalho, guarda-se o nome e o conteúdo dos objetos. Todos os comandos executados e todos os resultados não armazenados em objetos são perdidos. Esta característica do R recomenda que se trabalhe no R em associação com um editor de texto da sua preferência.

## 2.3 Introdução a Probabilidade

O estudo das probabilidades teve sua origem na necessidade de quantificar os riscos dos seguros e de avaliar as chances de ganhar em jogos de azar. O surgimento dos seguros está associado ‘a perda de carga dos navios (por naufrágio ou roubo), há mais de 5 mil anos. Os estudos matemáticos sobre seguros aparecem no início do século XVI, relacionados a seguros de vida. Iniciados por Gerônimo Cardano (1501-1576) em 1570, não ganharam repercussão. Outra grande contribuição para o estudo de probabilidade está relacionada com jogos de azar, onde a probabilidade de ganhar ou perder depende exclusivamente do acaso, não importando o raciocínio ou habilidade do jogador. Havia a preocupação de enumerar as possibilidades de se obter certo resultado no jogo e os primeiros cálculos de

probabilidade em jogos de azar foram feitos com base em situações concretas. Diz-se que em 1654 Pascal recebeu de seu amigo Chevalier de Méré o desafio de resolver questões como esta.

Isso desencadeou uma série de correspondências entre ele e Fermat, o que estimulou os estudos de Huygens sobre o assunto. Desta forma, o seguro de navios e os jogos de azar foram a base para se chegar aos modelos de probabilidade que existem nos dias de hoje (DANTE, 2014).

### 2.3.1 Teoria das probabilidades

A teoria das probabilidades é um segmento da matemática que visa estudar e desenvolver modelos e analisar experimentos e/ou fenômenos aleatórios.

### 2.3.2 Espaço amostral e eventos

Considerando um experimento cujo resultado não se pode prever com certeza. Entretanto, embora o resultado do experimento não seja conhecido antecipadamente, supondo que o conjunto de todos os resultados possíveis sejam conhecidos, esse conjunto é conhecido como *espaço amostral* do experimento e é representado pela letra  $S$ .

**Exemplo:** Se o resultado de um experimento consiste na determinação de sexo de um bebê recém nascido, logo

$$\Omega = \{m, f\},$$

onde,  $m$  significa masculino e  $f$  feminino.

Qualquer subconjunto  $E$  do espaço amostral é conhecido como um evento. Se o resultado do experimento estiver contido em  $E$ , então dizemos que  $E$  ocorreu. No exemplo acima, se  $E = m$ , então  $E$  é o evento em que o bebê é do sexo masculino. (ROSS, 2009)

Suas propriedades pode-se obter algumas das probabilidades que aqui estão sendo estudadas. A probabilidade de um evento  $A$  deve ser um número maior que 0 e menor que 1. Isto é:

$$0 < P(A) < 1,$$

para qualquer evento  $A$ .

Será útil considerar o espaço todo  $\Omega$  e o conjunto vazio  $\emptyset$  como eventos. O primeiro é denominado evento certo e o segundo, evento impossível (BUSSAB; MORETTIN, 2010),

assim:

$$P(\Omega) = 1, \quad P(\emptyset) = 0$$

## 2.4 Variáveis aleatórias

**Definição 2.1** *Seja  $E$  um experimento e  $S$  um espaço amostral associado a  $E$ . A função  $X$  que associa a cada resultado  $s \in S$  um número real  $x = X(s)$  é chamada variável aleatória unidimensional (MEYER, 1970).*

**Exemplos 2.1** *Lançar duas moedas e observar as faces (cara- $\bar{c}$ , coroa- $c$ ) voltadas para cima (DANTAS, 2013).*

$$\Omega = \{cc, \bar{c}c, c\bar{c}, \bar{c}\bar{c}\}$$

$X$ : Número de caras obtidas no lançamento das duas moedas.

$$Rx = \{0, 1, 2\}$$

O espaço  $Rx$ , o conjunto de todos os resultados possíveis de  $X$ , é chamado de contradomínio.

## 2.5 Distribuição de probabilidade de variáveis aleatórias discretas

**Definição 2.2** *É a função que associa a cada valor assumido pela variável aleatória a probabilidade do evento correspondente (MORETTIN, 1999).*

**Exemplos 2.2** *Uma moeda é lançada duas vezes sobre uma superfície plana. Em cada um dos eventos pode ocorrer cara( $c$ ) ou coroa( $\bar{c}$ ), logo o espaço amostral é o conjunto: (DANTAS, 2013).*

$$\Omega = \{cc, c\bar{c}, \bar{c}c, \bar{c}\bar{c}\}$$

Por suposição obtém-se o número de caras em cada lançamento, assim:

Tabela 1: Ponto amostral e suas probabilidades no lançamento de duas moedas e obtenção do número de caras

Valor de $X$	Ponto Amostral	Probabilidades
0	$\bar{c}\bar{c}$	$\frac{1}{4}$
1	$c\bar{c}, \bar{c}c$	$\frac{1}{2}$
2	$cc$	$\frac{1}{4}$

Os valores das probabilidades são obtidas da seguinte forma:

$$P[X = 0] = P(\bar{c}\bar{c}) = \frac{1}{2} \cdot \frac{1}{2} = \frac{1}{4}.$$

$$\begin{aligned} P[X = 1] &= P(\bar{c}c) + P(c\bar{c}) = \frac{1}{2} \cdot \frac{1}{2} + \frac{1}{2} \cdot \frac{1}{2} \\ &= \frac{1}{2}. \end{aligned}$$

$$P[X = 2] = P(cc) = \frac{1}{2} \cdot \frac{1}{2} = \frac{1}{4}.$$

Desta forma define-se a função de probabilidade da variável aleatória discreta.

ou seja:

$$\left\{ \left( x_i, P(x_i) \right), i = 1, 2, \dots \right\}$$

Isto é,

$$p(x_i) = P(X = x_i) = p_i, i = 1, 2, \dots$$

Deduz-se do exposto que uma variável aleatória  $X$ , discreta, estará bem caracterizada se indicarmos os possíveis valores  $x_1, x_2, \dots, x_n$  que ela pode assumir e as respectivas probabilidades  $p(x_1), p(x_2), \dots, p(x_n), \dots$

**Definição 2.3** *A esperança matemática de uma variável aleatória discreta  $X$ , definida em um espaço amostral  $\Omega$  no qual está definida uma probabilidade  $P$  é dada por (DANTAS, 2013):*

$$E(X) = \sum_{w \in \Omega} X(w)P(w) = \sum_{i=1}^{\infty} x_i p(x_i)$$

Desde de que,

$$\sum_{w \in \Omega} |X(w)|P(w) < \infty$$

(DANTAS, 2013) afirma que A esperança matemática de uma variável aleatória  $X$  pode ser expressa por meio da distribuição de probabilidade de  $X$ .

Como na definição

$$E(X) = \sum_{w \in S} X(w)P(w)$$

Define-se a variância de uma variável aleatória  $X$  da seguinte forma:

**Definição 2.4** *Defini-se a Variância de uma variável aleatória  $X$  denotada por  $Var(X)$  ou  $\sigma^2(X)$ , da seguinte forma (DANTAS, 2013):*

$$\sigma^2(X) = E(X - E(X))^2$$

Para variáveis aleatórias discreta  $X$  a variância será dada por:

$$\sigma^2(X) = \sum_{i=1}^{\infty} (x_i - E(X))^2 P[X = x_i]$$

### Demonstração

Desenvolvendo  $E[X - E(X)]^2$ , obtêm-se

$$\begin{aligned} Var(X) &= E[X - E(X)]^2 \\ &= E\{X^2 - 2(X)E(X) + [E(X)]^2\} \\ &= E(X^2) - 2E(X)(X) + [E(X)]^2 \\ &= E(X^2) - [E(X)]^2 \end{aligned}$$

A variância de uma variável aleatória fornece uma medida de dispersão dos valores dessa variável em relação à sua esperança.

**Definição 2.5** *A raiz quadrada da variância de uma variável aleatória  $X$ , denotada  $\sigma(X)$ , denomina-se Desvio Padrão de  $X$  (DANTAS, 2013).*

**Exemplos 2.3** *O serviço de meteorologia classifica o tipo de céu que é visível, em termos de graus de nebulosidade. Uma escala de 11 categorias é empregada: 0, 1, 2, ..., 10, em que 0 representa um céu perfeitamente claro, 10 representa um céu completamente encoberto, enquanto os outros valores representam as diferentes condições intermediárias. Suponha-se que tal classificação seja feita em uma determinada estação meteorológica, em um*

determinado dia e hora. Seja  $X$  a variável aleatória que pode tomar um dos 11 valores acima. Admita-se que a distribuição de probabilidade de  $X$  seja (MEYER, 1970):

$$p_0 = p_{10} = 0,05; p_1 = p_2 = p_8 = p_9 = 0,15;$$

$$p_3 = p_4 = p_5 = p_6 = p_7 = 0,06.$$

Portanto,

$$\begin{aligned} E(X) &= 1(0,15) + 2(0,15) + 3(0,06) + 4(0,06) + 5(0,06) + 6(0,06) + 7(0,06) + 8(0,15) \\ &\quad + 9(0,15) + 10(0,05) \\ &= 5,0 \end{aligned}$$

A fim de calcular  $Var(X)$ , necessita-se calcular  $E(X^2)$ , que é

$$\begin{aligned} E(X^2) &= 1(0,15) + 4(0,15) + 9(0,06) + 16(0,06) + 25(0,06) + 36(0,06) + 49(0,06) \\ &\quad + 64(0,15) + 81(0,15) + 100(0,05) \\ &= 35,6. \end{aligned}$$

Portanto,

$$\begin{aligned} Var(X) &= E(X^2) - [E(X)]^2 \\ &= 35,6 - 25 \\ &= 10,6 \end{aligned}$$

e o desvio-padrão  $\sigma = 3,25$ .

A esperança de uma variável aleatória nos dá a ideia da posição da distribuição de probabilidade dessa variável aleatória e que a variância da dispersão dos valores da variável em torno da esperança. A esperança de  $X^2$  é denominada 2º momento da variável aleatória  $x$ , para  $k = 1, 2, 3, \dots$ . Para uma variável aleatória discreta  $X$  com distribuição de probabilidade que associa os valores  $x_1, x_2, \dots$  as probabilidades  $P[X = x_1], P[X = x_2], \dots$  o momento de ordem  $K$ , para  $K = 1, 2, \dots$  é dado por:

$$E(X^K) = \sum_{i=1}^{\infty} x_i^k P[X = x_i]$$

## 2.6 Algumas distribuições probabilísticas discretas

As distribuições de probabilidade de alguns dos principais modelos discretos serão apresentadas abaixo.

### 2.6.1 Distribuição uniforme discreta

**Definição 2.6** A Variável aleatória  $X$ , assumindo os valores distintos  $x_1, \dots, x_k$ , tem distribuição uniforme se, e somente se (BUSSAB; MORETTIN, 2010):

$$P(X = x_i) = p(x_i) = p = \frac{1}{K}$$

para todo  $i = 1, 2, \dots, k$

Verificamos que,

$$E(X) = \frac{1}{K} \sum_{i=1}^K x_i$$

e

$$Var(X) = \frac{1}{K} \left[ \sum X_i^2 - (\sum x_i)^2 \right]$$

**Exemplos 2.4** Seja  $X$  a v.a que indica o número de pontos marcados na face superior de um dado quando ele é lançado vejamos a distribuição de probabilidade de  $X$  pela tabela a seguir (BUSSAB; MORETTIN, 2010):

$x$	1	2	3	4	5	6	total
$P(x)$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	1

A esperança da V.a.u.d

$$E(X) = \frac{1}{6} \sum_{i=1}^6 x_i$$

$$E(X) = \frac{1}{6} (1 + 2 + 3 + 4 + 5 + 6) = \frac{21}{6}$$

A Variância

$$Var(X) = \frac{1}{6} (1 + 4 + 8 + \dots + 36) = \frac{(21)^2}{6} = \frac{35}{12}$$

## 2.6.2 Distribuição de Bernoulli

Suponha-se que o resultado de um experimento ou tentativa possa ser classificado como um sucesso ou fracasso seja realizado. Se  $X = 1$  para sucesso e  $X = 0$  para fracasso, então a função de probabilidade de  $X$  é dada por:

$$p(0) = P(X = 0) = 1 - p$$

$$p(1) = P(X = 1) = p$$

em que,  $p = \textit{sucesso}$  e  $q = 1 - p = \textit{fracasso}$ . Logo, uma variável aleatória  $X$  é chamada de variável aleatória de Bernoulli, se sua função de probabilidade for dada por essas equações (ROSS, 2009).

**Definição 2.7** *A esperança ou valor esperado da distribuição de Bernoulli é o resultado de sucesso, então*

$$E(X) = p$$

e

$$\begin{aligned} \text{Var}(X) &= p(1 - p) \\ &= p - p^2 \\ &= p \cdot q \end{aligned}$$

## 2.6.3 Distribuição Binomial

O que caracteriza este modelo? Se nós considerarmos um experimento em que estamos interessados em um dos seus eventos em particular e aí registrarmos a ocorrência ou não-ocorrência desse evento que denominaremos de sucesso ou fracasso consecutivamente, isto é, o que caracteriza este modelo, onde ao repetirmos o experimento, registramos o sucesso ou o fracasso do evento em observação (DANTAS, 2013).

**Exemplos 2.5** *Em uma prova de múltipla escolha, cada questão tem cinco alternativas da qual somente uma é correta. Para cada questão, escolher a alternativa correta corresponde a sucesso e uma das erradas, a falha (DANTAS, 2013).*

**Exemplos 2.6** *Uma moeda é lançada três vezes, qual a probabilidade de se obter duas caras? (BUSSAB; MORETTIN, 2010)*

**Exemplos 2.7** *Dez peças são extraídas ao acaso, com reposição, de um lote contendo 500 peças, qual a probabilidade de que todas sejam defeituosas, sabendo-se que 10% das peças do lote são defeituosas?*(BUSSAB; MORETTIN, 2010).

Analisados os exemplos acima, vamos agora introduzir uma sequência de ensaios para construir o modelo binomial, onde esses ensaios são denominados de Bernoulli.

Veremos agora as condições para definirmos uma sequência de *Ensaio de Bernoulli*:

i) Em cada ensaio considera-se somente a ocorrência ou não de um certo evento, ou seja, fracasso ou sucesso.

ii) Os ensaios são independentes.

iii) A probabilidade de sucesso, que denotaremos por  $p$ , é a mesma em cada ensaio, e a probabilidade de falha denotaremos por  $1 - p$ , ou seja, se repetirmos um ensaio de Bernoulli  $n$  vezes, ou, de maneira alternativa, obtemos uma amostra de tamanho  $n$  de uma distribuição de Bernoulli. Suponha ainda que as repetições sejam independentes, isto é, o resultado de um ensaio não tem influência nenhuma no resultado de qualquer outro ensaio.

Deste modo, uma amostra particular de ensaios de Bernoulli será constituída a partir de uma sequência de sucessos e fracassos; Repetindo um ensaio de Bernoulli cinco vezes ( $n = 5$ ). Supondo um particular resultado  $fssfs$  que será o mesmo que  $0, 1, 1, 0, 1$ , como temos  $p$  para sucesso e  $(1 - p)$  para fracasso, a probabilidade de tal amostra será (BUSSAB; MORETTIN, 2010):

$$(1 - p)pp(1 - p)p = p^3(1 - p)^2.$$

**Exemplos 2.8** *Consideremos a situação do Ex 2.6, supondo que a moeda seja “honestá”, isto é,  $P(\text{sucesso}) = P(\text{cara}) = \frac{1}{2}$  indiquemos o sucesso (cara) por  $s$  e fracasso (coroa), por  $f$  então, estamos interessados na probabilidade do evento  $A$ .*

$$A = \{SSF, SFS, FSS\}$$

ou

$$A = \{(1, 1, 0); (1, 0, 1); (0, 1, 1)\}$$

Logo,

$$P(A) = P(SSF) + P(SFS) + P(FSS),$$

como os eventos são independentes.

$$P(FSS) = P(SSF) = P(SFS) = \frac{1}{2} \cdot \frac{1}{2} \cdot \frac{1}{2},$$

e assim,

$$\begin{aligned} P(A) &= \frac{1}{8} + \frac{1}{8} + \frac{1}{8} \\ &= \frac{3}{8}. \end{aligned}$$

Pelas condições i) e ii) vemos que a probabilidade de um ponto amostral com sucesso nos  $k$  primeiros ensaios e falhas nos  $n - k$  ensaios seguintes é  $p^k(1 - p)^{n-k}$ , notemos que esta é a probabilidade de qualquer ponto com  $k$  sucessos e  $n - k$  falhas em posições fixadas.

Notemos que o evento  $\{X = k\}$  ocorre se observarmos um ponto amostral que tenha  $k$  sucesso e  $n - k$  falhas. O número de pontos do espaço amostral que satisfazem essa condição é igual ao número de maneiras com que podemos escolher  $k$  ensaios dentre os  $n$  para a ocorrência de sucesso, pois nos  $n - k$  restante deverão ocorrer falhas. Este número é igual ao número de combinações de  $n$  elementos tomados  $k$  a  $k$ , ou seja,  $\binom{n}{k}$ . Podemos definir a probabilidade de tomarmos  $n$  ensaios de Bernoulli e observarmos  $k$  sucessos.

**Definição 2.8** *A variável aleatória  $X$ , correspondente ao número de sucessos em  $n$  ensaios de Bernoulli independentes todos com probabilidade de sucesso  $p$  ( $0 < p < 1$ ) é definida por:*

$$P(X = k) = \binom{n}{k} p^k (1 - p)^{n-k}.$$

As variáveis aleatórias que assumem valor um (1) ou zero (0) conforme um dado evento pode ser representado por um modelo de urna. Consideremos uma urna com  $N$  bolas, das quais  $M$  são brancas e  $N - M$  são pretas. Retiram-se sucessivamente  $n$  bolas

da urna recolocando-se após cada retirada a bola selecionada. Vamos considerar sucesso a ocorrência de branca em uma retirada e falha a ocorrência de preta. Assim temos uma sequência de  $n$  ensaios de Bernoulli com probabilidade de sucesso igual a  $\frac{M}{N}$  e de falha  $1 - \frac{M}{N}$ , logo temos pela *defi. 2.8*, para  $k = 0, 1, 2, \dots, n$ ;

$$P(X = k) = \binom{n}{k} \left(\frac{M}{N}\right)^k \left(1 - \frac{M}{N}\right)^{n-k}. \quad (2.1)$$

As probabilidades também serão indicadas por  $b(k; n; p)$  e, quando a V.a.X tiver distribuição binomial com parâmetro  $n$  e  $p$  escreveremos(DANTAS, 2013).

$$X \sim b(n, p).$$

**Exemplos 2.9** *Considere um conjunto com  $n$  mulheres grávidas internadas em uma maternidade para dar a luz. O número de filhos do sexo feminino é uma variável aleatória com distribuição binomial, pois, cada nascimento pode ser considerado independente dos demais e a probabilidade de um nascimento do sexo feminino é aproximadamente  $\frac{1}{2}$  para  $n = 6$ . Denotando-se por  $X$  o número de filhos do sexo feminino, calculemos  $p(X = 2)$  usando a equação 2.1 temos(DANTAS, 2013):*

$$P(X = k) = \binom{n}{k} \left(\frac{M}{N}\right)^k \left(1 - \frac{M}{N}\right)^{n-k}$$

$$\begin{aligned} P(X = 2) &= \binom{6}{2} \left(\frac{1}{2}\right)^2 \left(\frac{1}{2}\right)^4 \\ &= 0,23. \end{aligned}$$

**Exemplos 2.10** *Usando o Ex 2.7 temos  $n = 10$  ensaios de bernoulli, cada um com  $P(s)=P(\text{peças defeituosas})=0,1$  se  $X$  indicar o número de peças defeituosas na amostra, queremos calcular  $P(X = 10) = b(10; 10; \frac{1}{10})$*

$$P(X = 10) = \binom{10}{10} \left(\frac{1}{10}\right)^{10} \left(\frac{9}{10}\right)^0$$

$$\begin{aligned}
&= \left(\frac{1}{10}\right)^{10} \\
&= \frac{1}{10^{10}}.
\end{aligned}$$

A esperança matemática de uma variável aleatória discreta  $X$  com distribuição Binomial, é dada por:

$$E(X) = n \cdot p$$

e,

$$Var(X) = np(1 - p)$$

**Exemplos 2.11** Considerando o Ex 2.7, onde temos  $n = 10$  ensaios de Bernoulli, cada um com  $P(S) = P(\text{peças defeituosas}) = p = 0,1$ . Se  $X$  indicar o número de peças defeituosas na amostra, queremos calcular  $P(X = 10) = b(10; 10; \frac{1}{10})$ , então:

$$E(X) = 10 \cdot \frac{1}{10} = 1$$

$$Var(X) = 10 \cdot \frac{1}{10} \cdot \frac{9}{10} = \frac{9}{10}.$$

## 2.6.4 Distribuição Hipergeométrica

Essa distribuição representa um modelo para amostragem sem reposição de uma população com número finito de elementos de uma população com  $N$  elementos, dos quais  $n$  de um tipo atributo  $A$  e  $N - n$  do atributo  $B$ , então poderemos representá-la por meio de uma urna que contenha, digamos,  $n$  bolas brancas e  $N - n$  bolas vermelhas. Retira-se da urna  $z$  bolas sem reposição, estamos interessados em calcular a probabilidade de que esse grupo contenha  $X$  elementos com atributo  $A$  (DANTAS, 2013).

Utilizando o princípio

$$P[X = k] = \frac{\binom{n}{k} \binom{N-n}{z-k}}{\binom{N}{z}}$$

**Exemplos 2.12** *Uma caixa contém 15 peças das quais quatro são defeituosas. Retira-se uma amostra de três(3) peças da caixa sem reposição. Calcular a probabilidade que haja duas ou três peças defeituosas na amostra(DANTAS, 2013).*

Deseja-se calcular  $P(X = 2) + P(X = 3)$ , assim:

$$\begin{aligned} P(X = 2) + P(X = 3) &= \frac{\binom{4}{2} \binom{11}{1}}{\binom{15}{3}} + \frac{\binom{4}{3} \binom{11}{0}}{\binom{15}{3}} \\ &= 0,153. \end{aligned}$$

A esperança matemática de uma variável aleatória  $X$  com distribuição de probabilidade hipergeométrica, é dada por:

$$E(X) = z \frac{n}{N}.$$

A variância da distribuição hipergeométrica é dada por,

$$\text{Var}(X) = z \frac{n}{N} \frac{N-n}{N} \left(1 - \frac{z-1}{N-1}\right)$$

**Exemplos 2.13** *Pequenos motores elétricos são expedidos em lotes de 50 unidades, antes que uma remessa seja aprovada, um inspetor escolhe cinco (5) desses motores e os inspeciona, se nenhum dos motores inspecionados for defeituoso, o lote é aprovado, se um ou mais forem verificados defeituosos, todos os motores da remessa são inspecionados. Suponha que existem de fato, três (3) motores defeituosos no lote. Qual é a probabilidade de que a inspeção 100% seja necessária(MORETTIN, 1999)?*

Para  $X = 0$  número de motores defeituosos

$$\begin{aligned} P(X \geq 1) &= 1 - P(X = 0) \\ &= 1 - \frac{\binom{3}{0} \binom{47}{5}}{\binom{50}{5}} \\ &= 0,2662. \end{aligned}$$

**Exemplos 2.14** *Foram impressos vinte exemplares de um boletim, em quatro exemplares falta uma página. Você escolhe cinco exemplares ao acaso entre os vinte.*

- a) Qual é a probabilidade que haja dois exemplares com a página faltando entre os cinco?  
 b) Qual é a probabilidade que pelo menos um tenha página faltando?  
 c) Qual é a média e a variância que dá o número de exemplares com a página faltando entre os cinco (DANTAS, 2013)?

Seja,  $X = A$  variável aleatória que dá o número de exemplares com a página faltando na amostra de cinco,  $N=20$ ;  $M=4$ ;  $n=5$ , logo

$$\text{a) } P(X = 2) = \frac{\binom{4}{2} \binom{16}{3}}{\binom{20}{5}} = 0,216$$

$$\text{b) } P(X = 1) \text{ ou } P(X = 2) \text{ ou } P(X = 3) \text{ ou } P(X = 4),$$

Então,

$$P(X = 1) + P(X = 2) + P(X = 3) + P(X = 4) = 1 - P(X = 0),$$

Assim,

$$\begin{aligned} P(X = 0) &= \frac{\binom{16}{5}}{\binom{20}{5}} \\ &= \frac{91}{323}, \end{aligned}$$

Então,

$$\begin{aligned} 1 - P(X = 0) &= 1 - \frac{91}{323} \\ &= \frac{232}{323}. \end{aligned}$$

$$\text{c) } E(X) = z \frac{n}{N} = 1.$$

$$\text{d) } \text{Var}(X)$$

$$\text{Var}(X) = z \frac{n}{N} \frac{N-n}{N} \left(1 - \frac{z-1}{N-1}\right) = \left(\frac{12}{19}\right).$$

### 2.6.5 Distribuição Geométrica

Consideremos uma sequência ilimitada de ensaios de Bernoulli, com probabilidade de sucesso  $p$  em cada ensaio. Designamos sucesso por  $S$  e falha  $F$ . Realizamos os ensaios até que ocorra o primeiro sucesso.

$$\Omega = \{S, FS, FFS, \dots, FF, \dots, FS, \dots\}.$$

Um elemento típico desse espaço amostral é uma sequência de comprimento  $n$  em que nas primeiras  $n - 1$  posições têm  $F$  e na  $n$ -ésima temos  $S$ . Aqui nos afastamos das hipóteses que levaram à distribuição binomial. Na distribuição Binomial, o número de repetições era pré-determinado, enquanto aqui é uma variável aleatória.

Define-se a variável aleatória  $X$  como o número de repetições necessárias para obter a primeira ocorrência de sucesso ( $S$ ), assim,  $X$  toma os valores possíveis  $1, 2, 3, \dots$ , como  $X = k$  se, e somente se, as primeiras  $(k-1)$  repetições derem resultado ( $F$ ), enquanto a  $k$ -ésima repetição dê o resultado ( $S$ ), teremos (DANTAS, 2013).  
Seja  $X$  a variável aleatória que fornece o número de falhas que precedem o primeiro sucesso,

$$P(X = k) = q^{k-1}p$$

,

$$n = 1, 2, \dots,$$

em que,

$$q = (1 - p)$$

logo,

$$P(X = k) = (1 - p)^{k-1}p.$$

O evento ( $X=k$ ) ocorre se, e somente se, ocorrer falhas nos  $k - 1$  primeiros ensaios e sucesso no  $k$ -ésimo ensaio.

A esperança matemática da distribuição geométrica é dada por

$$E(X) = \frac{1 - p}{p}$$

Para calcularmos a variância,

$$Var(X) = E(X^2) - [E(X)]^2$$

$$E(X^2) = \frac{1 - p^2}{p^2}$$

$$Var(X) = \frac{1 - p}{p^2}$$

**Exemplos 2.15** *Um banco de sangue necessita de sangue tipo O – RH negativo. Seja  $P$  a proporção de indivíduos na população com esse tipo de sangue. Suponha que as pessoas são escolhidas da população ao acaso para serem examinadas se tem esse tipo de sangue. O número de pessoas examinadas antes de se encontrar a primeira com esse tipo de sangue tem distribuição geométrica com parâmetro  $P$ . Calcule para  $p = 0,1$  a probabilidade de a primeira pessoa a ser encontrada com esse tipo de sangue ser a quinta, se  $X$  designa o número de pessoas examinadas antes de encontrar a primeira com tipo de sangue O – RH negativo. Queremos calcular  $P(X = 4)$  (DANTAS, 2013).*

$$P(X = 4) = (1 - p)^4 p = (0,9)^4 0,1 = 0,0656.$$

**Exemplos 2.16** *Se a probabilidade de um certo ensaio de reação positiva for igual a 0,4, qual será a probabilidade de que menos de 5 reações “negativas” ocorram antes da primeira positiva (MEYER, 1970)?*

Seja  $X$  o número de reações negativas antes da primeira positiva, com  $p = 0,4$  e  $q = 0,6$ .

$$P(X = k) = (0,6)^k (0,4)$$

$$P(X = k) = (1 - p)^k p,$$

em que,

$$(1 - p) = q \quad k = 0, 1, 2, \dots$$

$$P(X < 5) = \sum_{k=0}^4 (0,6)^k (0,4) = 0,92$$

## 2.6.6 Distribuição de Poisson

**Definição 2.9** *A variável aleatória  $X$  tem distribuição de Poisson com parâmetro  $\lambda$  se para  $k = 0, 1, 2, \dots$*

$$P(X = k) = \frac{e^{-\lambda} \lambda^k}{k!}$$

**Teorema 2.1** *Se  $X$  tiver distribuição de Poisson com parâmetro  $\lambda$ , então  $E(X) = \lambda$  e  $Var(X) = \lambda$  conforme (MEYER, 1970).*

A distribuição de Poisson tem grande importância tanto teórica como aplicada. Podemos introduzir essa distribuição como uma aproximação para a distribuição binomial quando

o número de ensaios de Bernoulli tende a infinito, porém de modo que o produto  $np_n = \lambda$  permanece constante.

Associado aos  $n$  ensaios de Bernoulli, definimos a variável aleatória  $X_n$  que é igual ao número de sucessos nesses  $n$  ensaios, então  $X_n$  tem distribuição binomial com parâmetro  $n$  e  $P_n$  então (DANTAS, 2013):

$$\begin{aligned} P(X_n = k) &= \binom{n}{k} P_n^k (1 - P_n)^{n-k} \\ &= \frac{n(n-1)\dots(n-(k-1))}{k!} \left(\frac{\lambda}{n}\right)^k \left(1 - \frac{\lambda}{n}\right)^n \left(1 - \frac{\lambda}{n}\right)^{-k} \\ &= 1 \left(1 - \frac{1}{n}\right) \dots \left(1 - \frac{k-1}{n}\right) \frac{1}{k!} (\lambda)^k \left(1 - \frac{\lambda}{n}\right)^n \left(1 - \frac{\lambda}{n}\right)^{-k} \end{aligned}$$

Como o primeiro termo do produto é 1 e os  $k-1$  seguintes são iguais a  $1 - \frac{1}{n}, 1 - \frac{2}{n}, \dots, 1 - \frac{(k-1)}{n}$ , respectivamente, que tendem a 1 quando  $n \mapsto \infty$

O termo  $\left(1 - \frac{\lambda}{n}\right)^{-k}$  também tende a 1, levando-se em conta que no cálculo mostra-se que (DANTAS, 2013):

$$\lim_{n \rightarrow \infty} \left(1 - \frac{\lambda}{n}\right)^n = e^{-\lambda}$$

Passando-se ao limite na expressão acima para  $n$  tendendo a infinito obtemos:

$$\lim_{n \rightarrow \infty} P(X_n = k) = \frac{e^{-\lambda} \lambda^k}{k!}.$$

Exemplificando agora de forma que compararemos os dois casos (binomial e Poisson) e daremos ênfase a definição acima, ou seja, a distribuição de Poisson pode ser visto como uma distribuição binomial quando o número de ensaios de Bernoulli tende a infinito; então veremos agora pelo seguinte exemplo:

**Exemplos 2.17** *Em um cruzamento de tráfego intenso, a probabilidade  $p$  de um carro sofrer um acidente é muito pequena, digamos  $p = 0,0001$ . Contudo, durante certa parte do dia, por exemplo das 16 às 18h00, um grande número de carros passam no cruzamento, um valor como  $n = 1000$ . Nessas condições, qual é a probabilidade de que dois ou mais acidentes ocorram durante aquele período (MEYER, 1970)?*

Adaptado de Meyer (1970) pode-se pensar que para resolver este problema deve-se fazer algumas hipóteses. Admita-se que  $p$  seja a mesma para cada carro. Também deve-se supor que o fato de um carro sofrer ou não acidentes seja um evento independente; Assim,

pode-se supor que se  $X$  for o número de acidentes entre os 1000 carros que chegam então  $X$  terá distribuição binomial com parâmetro  $p = 0.0001$  (Vale salientar que a hipótese que faz-se, não declarada explicitamente, é que  $n$ , o número de carros que passam no cruzamento durante o período em estudo, é pré-determinado, 1000 por exemplo. Obviamente, o próprio  $n$  é um “resultado aleatório”; se você fixa o tempo este  $n$  é aleatório, no entanto, basta fixar o  $n$  de acidentes em 1000 para que deixe de ser aleatório. Logo

$$\begin{aligned} P(X = k) &= \binom{n}{k} p^k (1 - p)^{n-k} \\ &= \binom{1000}{k} (0,0001)^k (0,9999)^{1000-k} \end{aligned}$$

E a probabilidade procurada é dada por:

$$\begin{aligned} \sum_{k=2}^{\infty} P(X = k) &= 1 - [P(X = 0) + P(X = 1)] \\ &= 1 - [(0,9999)^{1000} + 1000(0,0001)(0,9999)^{999}] \\ &= 0,00467 \end{aligned}$$

Aplicando-se a aproximação pela binomial, visto que  $n = 1000$  e  $p = 0,0001$  daí  $np = \lambda = 0,1$ , portanto:

$$\begin{aligned} P(X = k) &= \frac{e^{-\lambda} \lambda^k}{k!} \\ P(X = k) &= \frac{e^{-0,1} 0,1^k}{k!} \\ P(X \geq 2) &= 1 - e^{-0,1} (1 + 0,1) = 0,0048 \end{aligned}$$

**Exemplos 2.18** *Suponha-se que um processo de fabricação produza peças de tal maneira que uma determinada proporção (constante) das peças sejam defeituosas. Se uma partida de  $n$  dessas peças for obtida, a probabilidade de encontrar exatamente  $k$  peças pode ser calculada pela distribuição binomial como igual a  $p(X = k) = \binom{n}{k} p^k (1 - p)^{n-k}$ , onde  $X$  é o número de peças defeituosas na partida. Se  $n$  for grande e  $p$  pequeno (como é frequente o caso), poderemos aprox:*

$$P(X = k) = \frac{e^{-\lambda} \lambda^k}{k!}$$

Suponha-se que para cada 1000 peças uma seja defeituosa, isto é,  $p = 0,001$ , daí empregando a distribuição binomial, encontraremos que uma partida de 500 peças, a probabilidade de que nenhuma das peças sejam defeituosas será  $(0,999)^{500} = 0,609$ . Agora

aplicando a aproximação de Poisson, esta probabilidade poderá ser escrita como  $e^{-0,5} = 0,61$ . A probabilidade de encontrar (dois) ou mais peças defeituosas será, de acordo com a aproximação da binomial para a Poisson,  $P(X \geq 2) = 1 - e^{-0,5}(1 + 0,5) = 0,085$

**Exemplos 2.19** *Um PABX recebe em média, cinco chamadas por minuto. Supondo que a distribuição de Poisson seja adequada nessa situação, obter a probabilidade de que o PABX não receba chamadas durante um intervalo de um minuto (BUSSAB; MORETTIN, 2010):*

Utilizando a distribuição de Poisson para resolver esse problema sem a aproximação binomial, tem-se:

$$P(X = k) = \frac{e^{-\lambda} \lambda^k}{k!}$$

com  $\lambda = 5$ , então a probabilidade de não acontecer nenhuma chamada é:

$$\begin{aligned} P(X = 0) &= \frac{e^{-5} 5^0}{0!} \\ &= 0,0067 \end{aligned}$$

Supondo que queremos obter no máximo duas chamadas em quatro minutos, teremos  $\lambda = 20$  chamadas em quatro minutos, logo

$$P(X = k) = \frac{e^{-\lambda t} \lambda t^k}{k!}, k = 0, 1, 2, \dots$$

onde,  $\lambda$  representa o número médio de ocorrência naquele intervalo. Denotaremos uma v.a.  $X$  com distribuição de Poisson de parâmetro  $\lambda$  por,  $X \sim POIS(\lambda)$ .

## 3 Aplicação

Nesta seção serão apresentados as resoluções dos exemplos utilizando uma ferramenta computacional gratuita, o software R (TEAM, 2016). Este por se tratar de uma ferramenta de aprendizagem poderosa para visualizar e interpretar os dados possibilita que qualquer pessoa com o conhecimento técnico adequado chegue às conclusões probabilísticas de forma autônoma. Serão apresentados os exemplos relacionados as distribuições de probabilidade estudadas (Bernoulli, Binomial, Poisson, Hipergeométrica, Geométrica e Uniforme). Pretende-se que o leitor ao final desta aplicação tenha totais condições de utilizar o Software R e fazer o uso em Educação Estatística.

Início da aplicação em R.

O exemplo ( 2.1 ), é um exemplo de variáveis aleatórias, espaço amostral

Exemplo 2.1

```
S0 <- tosscoin(2, makespace = FALSE)
> S0
toss1 toss2
1     H     H
2     T     H
3     H     T
4     T     T
```

O exemplo ( 2.2 ) trata da distribuição de V.a Discreta do espaço amostral

Exemplo 2.2

```
S0 <- tosscoin(2, makespace = TRUE)
> S0
toss1 toss2 probs
1     H     H 0.25
2     T     H 0.25
3     H     T 0.25
4     T     T 0.25
```

O exemplo (2.3) é um exemplo da variância de uma variável aleatória

## Exemplo 2.3

```
> escala=seq(0,10,1)
> Prob=c(0.05,0.15,0.15,0.06,0.06,0.06,0.06,0.06,0.15,0.15,0.05)
> Ex=weighted.mean(escala,Prob)
> Ex
[1] 5
> Ex2=weighted.mean(escala^2, Prob)
> Varx=Ex2-Ex^2
> Varx
[1] 10.6
> sqrt(Varx)
[1] 3.255764
```

Exemplo ( 2.4 ) de variância de distribuição Uniforme

## Exemplo 2.4

```
U <- Unif(1,6)
> EU=E(U) ## uses explicit terms
> EU
[1] 3.5
>
> VU=var(U)
> VU
[1] 2.083333
```

Os exemplos (2.6), (2.9), (2.10) e (2.11), são exemplos da distribuição Binomial.

Exemplo 2.6 - Trata-se da obtenção de duas caras no lançamento de três moedas.

```
S <- tosscoin(3, makespace = TRUE)
> S
toss1 toss2 toss3 probs
1     H     H     H 0.125
2     T     H     H 0.125
3     H     T     H 0.125
4     T     T     H 0.125
5     H     H     T 0.125
6     T     H     T 0.125
7     H     T     T 0.125
8     T     T     T 0.125
>
> P_HH=S[2,4]+S[3,4]+S[5,4]
> P_HH
[1] 0.375
```

Exemplo 2.8

```
SSS <- tosscoin(3, makespace = TRUE)
> SSS
toss1 toss2 toss3 probs
1     H     H     H 0.125
2     T     H     H 0.125
3     H     T     H 0.125
4     T     T     H 0.125
5     H     H     T 0.125
6     T     H     T 0.125
7     H     T     T 0.125
8     T     T     T 0.125
>
> A=c(S[1,1,1],S[1,1,2],S[2,1,1])
> A
[1] 1 1 2
```

Exemplo 2.9 - Relacionado ao conjunto de Mulheres grávidas.

```
> Pb=dbinom(2,6,0.5)
> Pb
[1] 0.234375
```

Exemplo 2.10 - Peças defeituosas.

```
> Pb2=dbinom(10,10,0.1)
> Pb2
[1] 1e-10
```

O exemplo (2.11) é um exemplo de esperança de uma distribuição Binomial

Exemplo 2.11

```
> EB=10*0.1
> EB
[1] 1
```

O exemplo (2.13), (2.14) e (2.15) são exemplos referentes a distribuição Hipergeométrica

Exemplo 2.13

```
1-phyper(0, 5,47,3)
[1] 0.2662896
```

Exemplo 2.14

```
> #a
> p=dhyper(2,5,15,4)
> p
```

```
[1] 0.2167183
>
> #b
> phyper(0,5,15,4, lower.tail = F)
[1] 0.7182663
>
>
> #c
> mu=sum(0:5*dhyper(0:5,5,15,4))
> mu
[1] 1
>
> #d
> va=c(sum((0:5)^2*dhyper(0:5,5,15,4)))-mu^2
> va
[1] 0.6315789
```

Os exemplos de (2.15), (2.16) são referentes a distribuição Geométrica

Exemplo 2.15

```
> dgeom(4,0.1)
[1] 0.06561
```

Exemplo 2.16

```
> pgeom(4,0.4)
[1] 0.92224
```

Os exemplos (2.18) e (2.19) são referentes a distribuição de Poisson

Exemplo 2.18 - Fabricação de Peças

```
> 1-ppois(1,0.5)
[1] 0.09020401
```

Exemplo 2.19 - PABx

```
> dpois(0,5)
[1] 0.006737947
```

## 4 Conclusão

O estudo de algumas distribuições discretas é um tópico de grande relevância no estudo das probabilidades e suas aplicações. Neste trabalho, foi apresentada uma teoria das probabilidades e falado a respeito de espaço amostral caracterizando alguns exemplos, foi mostrado o que é uma variável aleatória e uma distribuição de probabilidades, trabalhou-se com algumas distribuições de probabilidade tais como Uniforme, Bernoulli, Binomial, Hipergeométrica, Geométrica e Poisson, todas estas distribuições discretas, fazendo sempre menção aos exemplos e deixando claro a aplicação dessas distribuições.

O uso do software R como ferramenta estatística de aplicação, permite a simplificação do entendimento dos exercícios propostos permitindo atingir o objetivo proposto neste trabalho de auxiliar professores e estudantes em seu uso na Educação Estatística, foi assim que aplicado o Software R se conseguiu realizar as soluções dos exemplos nesse trabalho de uma forma mais dinâmica.

# Referências

- BUSSAB, W. d. O.; MORETTIN, P. A. *Estatística básica*. [S.l.]: Saraiva, 2010.
- DANTAS, C. A. B. *Probabilidade: Um Curso Introdutório*. [S.l.]: Edusp, 2013.
- DANTE, L. R. Matemática: contexto e aplicações: Ensino médio são paulo: Ática, 2014. *Volume único*, 2014.
- MEYER, P. L. Probabilidade: aplicações à estatística. In: *Probabilidade: aplicações à estatística*. [S.l.]: Livro Técnico, 1970.
- MORETTIN, L. G. *Estatística Básica–Volume 1–Probabilidade–7ª edição*. [S.l.]: São Paulo: Pearson Makron Books, 1999.
- MUENCHEN, R. A. *R for SAS and SPSS users*. [S.l.]: Springer Science & Business Media, 2011.
- ROSS, S. *Probabilidade: um curso moderno com aplicações*. [S.l.]: Bookman Editora, 2009.
- TEAM, R. C. R: A language and environment for statistical computing. r foundation for statistical computing, vienna, austria. 2015. url h ttp. *www. R-project. org*, 2016.
- VIALI, L. O ensino de estatística e probabilidade nos cursos de licenciatura em matemática. *Simpósio Nacional de Probabilidade e Estatística*, v. 18, 2008.