

# Variáveis aleatórias: Introdução e variáveis aleatórias discretas (parte 3)

Notas de Aula da Professora Verónica González-López, digitadas por Beatriz Cuyabano, Pós-Graduação IMECC/UNICAMP, com modificações do Prof. Caio Azevedo

# Modelos probabilísticos discretos especiais

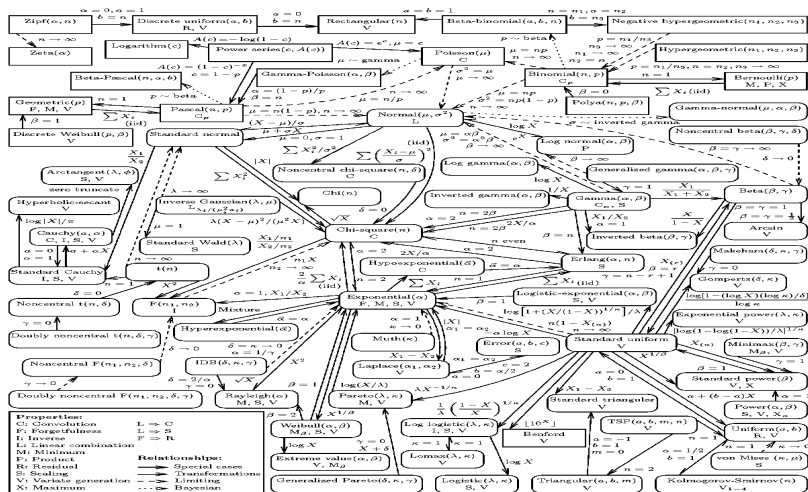
- Os exemplos visto [aqui](#) e [aqui](#), essencialmente, eram “toy examples” (“exemplos de brinquedo”) úteis para introduzir os conceitos necessários.
- Veremos agora modelos discretos especiais, no sentido de que eles foram motivados por problemas reais na Estatística, Probabilidade e, principalmente, em outras áreas.
- Apresentaremos os modelos mais básicos (conhecidos) e indicaremos onde encontrar outros modelos.

# Modelos probabilísticos discretos especiais

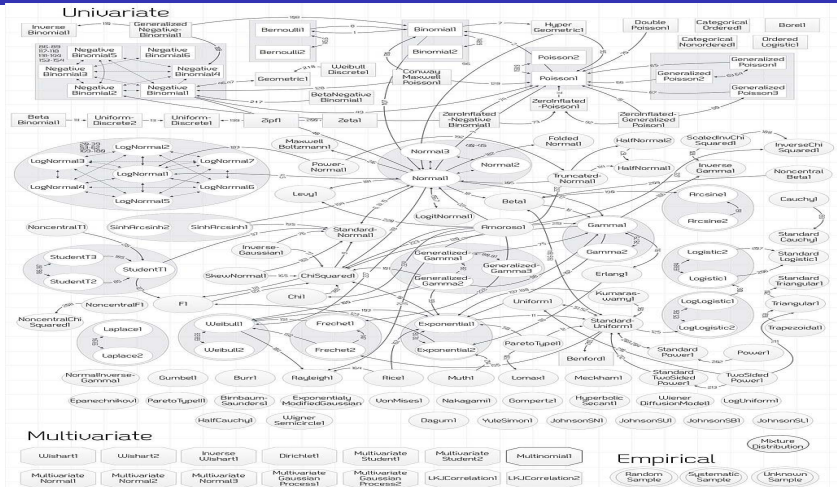
- É virtualmente impossível dar indicações de todos os modelos existentes também, porque regularmente, novos modelos são disponibilizados na literatura.
- Apresentaremos a concepção dos modelos (como surgiram) e suas principais características (em relação ao que apresentamos anteriormente).
- Adiante (no curso) apresentaremos outras características e propriedades.



# Exemplo de Modelos probabilísticos (e inter-relações)



# Exemplo de Modelos probabilísticos (e inter-relações)



# Modelos probabilísticos discretos especiais

- Apresentaremos um conceito importante, relativo à independência de variáveis aleatórias.
- No momento, por simplicidade, concentrar-nos-emos em vad's.
- Sejam  $X_1, X_2, \dots, X_n$  vad's com suportes (imagens) respectivamente em  $A_i \subset \mathcal{R}, i = 1, 2, \dots, n$ .
- Dizemos que elas são mutuamente independentes se, e somente se

$$\begin{aligned} & P(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n) \\ &= P((X_1 = x_1) \cap (X_2 = x_2) \cap \dots \cap (X_n = x_n)) \\ &= \prod_{i=1}^n P(X_i = x_i), \forall x_i \in A_i. \end{aligned}$$

# Modelo Uniforme

- Exemplo: Uma rifa tem 100 bilhetes numerados de 1 a 100. Tenho 5 bilhetes consecutivos numerados de 21 a 25, e um amigo tem outros 5 bilhetes, com os números 1, 11, 29, 68 e 93. Quem tem maior probabilidade de ser sorteado?
  - Espalhar os números é a melhor forma de ganhar o sorteio?
  - Assumindo honestidade da rifa, cada número tem a mesma probabilidade de ser sorteado, ou seja:  $\frac{1}{100}$ .
  - Como eu e meu amigo temos 5 bilhetes, temos a mesma probabilidade de ganhar a rifa:  $\frac{5}{100} = \frac{1}{20}$
  - Assim, a probabilidade de ganhar depende somente da quantidade de bilhetes que se tem na mão, independente da numeração.



# Modelo Uniforme

- Seja  $X$  é uma variável aleatória cujos possíveis valores são representados por  $A = \{x_1, x_2, \dots, x_k\}$ .
- Dizemos  $X$  segue o modelo uniforme discreto se é atribuído a mesma probabilidade  $\left(\frac{1}{k}\right)$  a cada um desses possíveis valores.
- Notação  $X \sim \text{uniforme}\{x_1, x_2, \dots, x_k\}$  ou  $X \sim U\{x_1, x_2, \dots, x_k\}$ .
- A fdp de  $X$  é dada por:

$$f_X(x) = P(X = x) = \frac{1}{k} \mathbb{1}_{\{x_1, x_2, \dots, x_k\}}(x).$$

# Modelo Uniforme

- Para o cálculo da fda de  $X$ , note que:

$$F_X(x) = \sum_{y \leq x} f_X(y) = \sum_{y=x_1}^{x_k} \frac{1}{k} = \frac{1}{k} \sum_{y=x_1}^x 1 = \frac{n(x)}{k},$$

em que  $n(x)$  é o número de elementos menores ou iguais à  $x$  (com probabilidade positiva). Logo

$$F_X(x) = P(X \leq x) = \frac{n(x)}{k} \mathbb{1}_{[x_1, x_k)}(x) + \mathbb{1}_{[x_k, \infty)}(x).$$

# Modelo Uniforme

- Por outro lado, a fds de  $X$  é dada por:

$$S_X(x) = P(X > x) = \mathbb{1}_{(-\infty, x_1)}(x) + \left(1 - \frac{n(x)}{k}\right) \mathbb{1}_{[x_1, x_k]}(x).$$

- Exercício: verifique que  $f_X$ ,  $F_X$  e  $S_X$  são, de fato, legítimas, fdp, fda e fds, respectivamente.
- Para o valor esperado, temos que:

$$\mathcal{E}(X) = \sum_{x=x_1}^{x_k} x f_X(x) = \frac{1}{k} \sum_{x=x_1}^{x_k} x.$$

# Modelo Uniforme

- Para o cálculo da variância, primeiramente, notemos que:

$$\mathcal{E}(X^2) = \sum_{x=x_1}^{x_k} x^2 f_X(x) = \frac{1}{k} \sum_{x=x_1}^{x_k} x^2.$$

- Logo:

$$\begin{aligned} \mathcal{V}(X) &= \mathcal{E}(X^2) - \mathcal{E}^2(X) = \frac{1}{k} \sum_{x=x_1}^{x_k} x^2 - \left( \frac{1}{k} \sum_{x=x_1}^{x_k} x \right)^2 \\ &= \frac{1}{k} \left[ \sum_{x=x_1}^{x_k} x^2 - \frac{1}{k} \left( \sum_{x=x_1}^{x_k} x \right)^2 \right]. \end{aligned}$$

- Exercício: calcular  $E(X)$  e  $Var(X)$  se  $x_i = i, i = 1, 2, \dots, k$ .

# Modelo Uniforme

- Exemplo: Seja  $X$  o resultado obtido no lançamento de um dado honesto. Temos que:

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

- $E(X) = \frac{1}{6} \times (1 + 2 + 3 + 4 + 5 + 6) = \frac{21}{6} = 3,5$
- $Var(X) = \frac{1}{6} [(1 + 4 + 9 + 16 + 25 + 36) - \frac{1}{6} \times (21)^2] = \frac{35}{2} = 17,5$
- Interpretação apropriada de  $E(X)$ : a cada 10 lançamentos espera-se que a soma das faces obtidas esteja em torno de 35.

# Modelo Uniforme

- Retomando o exemplo do dado:

- $F(2) = P(X \leq 2) = P(X = 1) + P(X = 2) = \frac{2}{6}$

- $F(2,5) = P(X \leq 2,5) = P(X = 1) + P(X = 2) = \frac{2}{6}$

# Simulação

- Representar de forma controlada (e.g., através de um programa de computador) uma situação real.
- Simular a amostragem de unidades de uma população, cuja característica de interesse possa ser modelada através de alguma distribuição de probabilidade.
- Simular a seleção de números ( $\{1, 2, \dots, k\}$ ), o lançamento de uma moeda ou dado etc.

# Simulação

- Em geral, a simulação de variáveis aleatórias (quaisquer) utiliza, pelo menos, um dos seguinte algoritmos:
  - Gerador de números pseudo aleatórios.
  - Gerador de uma variável aleatória uniforme contínua (veremos adiante)
- Um gerador de números pseudo aleatórios é um algoritmo que utiliza funções matemática para gerar números aproximadamente independentes entre si [veja aqui](#).



# Simulação

- Não nos estenderemos sobre a geração de números pseudo aleatórios.
- Apresentaremos adiante (no curso) a geração de números uniformes contínuos.
- Via de regra, números uniformes são gerados com base em números pseudo aleatórios.
- Denotaremos por  $u$  números uniformes no intervalo  $(0,1)$ . Essencialmente representa um número real gerado nesse intervalo, em que as probabilidades de ocorrência são as mesmas  $\forall u \in (0, 1)$ .
- Apresentaremos um algoritmo (há várias opções)

# Simulação de uma variável uniforme discreta

- Seja a fda (calculada anteriormente)

$x$	$x_1$	$x_2$	$x_3$	$\dots$	$x_{k-1}$	$x_k$
$F_X(x)$	$\frac{1}{k}$	$\frac{2}{k}$	$\frac{3}{k}$	$\dots$	$\frac{k-1}{k}$	1





- Algoritmo:

- 1 Simule  $u$ ,  $U \sim U(0, 1)$ .
- 2 Se  $\frac{r}{k} < u < \frac{r+1}{k}$ , então  $x = x_{r+1}$ ,  $r = 0, 1, 2, \dots, k-1$ .





# Simulação de uma variável uniforme discreta

- No programa R ([link](#)) ( $n$  é o tamanho da amostra a ser simulada, e vamos considerar  $x_i = i$ ,  $i=1,2,\dots,k$ ):
- Duas opções:
  - Opção 1:  
`sample(1:k,n)`
  - Opção 2 (tem que instalar e carregar o pacote “extraDistr”):  
`rdunif(n, 1, k)`





# fdp: uniforme



# valores simulados: uniforme



# fdp (azul) e valores simulados (vermelho): uniforme



# Modelo Bernoulli

- Consideremos um experimento  $E$  com espaço amostral  $\Omega$  e o evento  $A$ ,  $A \subset \Omega$ .
- Dizemos que ocorreu “sucesso” se o evento  $A$  aconteceu e fracasso, caso contrário.
- Exemplo: Experimento - lançar uma moeda e verificar se observamos cara ou coroa. Suponha que consideramos como sucesso a obtenção de cara.
- Esse tipo de experimento é chamado de ensaio de Bernoulli.

# Modelo Bernoulli

- Ensaios tipo Bernoulli: estamos interessados em modelar as probabilidades de ocorrência somente do um sucesso ou do fracasso.
- Outro exemplo: uma pessoa é escolhida ao acaso entre os moradores de uma certa cidade, e lhe é perguntado se concorda com um projeto. As possíveis respostas são apenas “Sim” ou “Não”.
- $\Omega = \{\text{Sim}, \text{Não}\}$ . De uma forma geral  $\Omega = \{\text{Fracasso}, \text{Sucesso}\}$ .
- Defina:  $X = \begin{cases} 1, & \text{evento de interesse ocorre (sucesso)} \\ 0, & \text{caso contrário (fracasso)} \end{cases}$



# Modelo Bernoulli

- $P(X = 1) = P(\text{sucesso}) = p \Rightarrow P(X = 0) = P(\text{fracasso}) = 1 - p$ .
- Homenagem ao matemático Suíço Jacob Bernoulli.
- Notação  $X \sim \text{Bernoulli}(p)$ , parâmetro  $p \in (0, 1)$ .
- Temos que a respectiva fdp é dada por:

$$f_X(x) = P(X = x) = p^x q^{1-x} \mathbb{1}_{\{0,1\}}(x),$$

em que  $q = 1 - p$ .

- Por outro lado, a fda é dada por:

$$F_X(x) = q \mathbb{1}_{[0,1)}(x) + \mathbb{1}_{[1,\infty)}(x).$$

# Modelo Bernoulli

- Além disso, a fds é dada por:

$$S_X(x) = \mathbf{1}_{(-\infty, 0)}(x) + p\mathbf{1}_{[0, 1]}(x).$$

- Valor esperado:

$$E(X) = \sum_{x=0}^1 xf_X(x) = 0 \times (1 - p) + 1 \times p = p.$$

# Modelo Bernoulli

- Para a variância, temos que:

$$E(X^2) = \sum_{x=0}^1 x^2 f_X(x) = 0^2 \times (1 - p) + 1^2 \times p = p.$$

- Logo

$$\text{Var}(X) = E(X^2) - [E(X)]^2 = p - p^2 = p(1 - p).$$

# Modelo Bernoulli

- Exemplo: lançamos um dado e consideramos como sucesso, a obtenção da face 5. Supondo que o dado é honesto:

$x$	0	1
$p(x)$	$\frac{5}{6}$	$\frac{1}{6}$





- $P(X = x) = p^x(1 - p)^{1-x} = \left(\frac{1}{6}\right)^x \left(\frac{5}{6}\right)^{1-x}$  em que  $x = 0, 1$
- $E(X) = \frac{1}{6}$ .
- $E(X^2) = \frac{1}{6}$ .
- $Var(X) = \frac{1}{6} - \frac{1}{36} = \frac{6-1}{36} = \frac{5}{36}$ .

# Simulação de uma variável Bernoulli





- Algoritmo:
  - 1 Simule  $u, U \sim U(0, 1)$ .
  - 2 Se  $u < p$ , então  $x= 1$ , caso contrário,  $x=0$ .
- No programa R ( $n$  é o tamanho da amostra a ser simulada)

```
rbinom(n,1,p)
```





# fdp: Bernoulli



# valores simulados: Bernoulli



# fdp (azul) e valores simulados (vermelho): Bernoulli





# Modelo Binomial

- Consideremos novamente um experimento  $E$  com espaço amostral  $\Omega$  e o evento  $A$ .
- Dizemos que ocorreu sucesso se o evento  $A$  for observado e fracasso, caso contrário.
- Repetimos o experimento (ensaios de Bernoulli)  $n$  vezes, de forma independente.
- $X$ =número de sucessos nos  $n$  experimentos.
- Exemplo: lançar uma moeda 3 vezes e verificar se se observa cara ou coroa. Consideramos como sucesso, a obtenção de cara.
- Os valores possíveis de  $X$  são  $\{0, 1, 2, 3\}$ .

# Modelo binomial

- A repetição de ensaios independentes de Bernoulli com a mesma probabilidade de sucesso dá origem a variável aleatória binomial.
- Exemplo: Sabe-se que a eficiência de uma vacina é de 80%. Um grupo de 3 indivíduos é sorteado, dentre a população vacinada, e cada um é submetido a testes para averiguar se está imunizado. Nesse caso, consideramos como sucesso, a imunização:
  - Defina  $X_i = \begin{cases} 1, & \text{indivíduo } i \text{ está imunizado} \\ 0, & \text{caso contrário} \end{cases}$
  - Pelo enunciado, sabe-se que  $P(X_i = 1) = p = 0,8$ .

# Modelo Binomial

- As variáveis aleatórias  $X_1$ ,  $X_2$  e  $X_3$  são independentes, com a mesma distribuição (mesma probabilidade de sucesso) de Bernoulli.
- Se o interesse está em estudar  $X$  o número de indivíduos imunizados no grupo, temos que  $\Omega = \{0, 1, 2, 3\}$ .
- Note que  $X = X_1 + X_2 + X_3$ .

# Modelo Binomial

evento	P(evento)	X
$X_1 = 0, X_2 = 0, X_3 = 0$	$(0,2)^3$	0
$X_1 = 1, X_2 = 0, X_3 = 0$	$0,8 \times (0,2)^2$	1
$X_1 = 0, X_2 = 1, X_3 = 0$	$0,8 \times (0,2)^2$	1
$X_1 = 0, X_2 = 0, X_3 = 1$	$0,8 \times (0,2)^2$	1
$X_1 = 1, X_2 = 1, X_3 = 0$	$(0,8)^2 \times 0,2$	2
$X_1 = 1, X_2 = 0, X_3 = 1$	$(0,8)^2 \times 0,2$	2
$X_1 = 0, X_2 = 1, X_3 = 1$	$(0,8)^2 \times 0,2$	2
$X_1 = 1, X_2 = 1, X_3 = 1$	$(0,8)^3$	3

# Modelo Binomial

- Assim, as probabilidades de cada valor possível de  $X$  são:

$x$	0	1	2	3
$P(X = x)$	$(0,2)^3$	$3 \times 0,8 \times (0,2)^2$	$3 \times (0,8)^2 \times 0,2$	$(0,8)^3$

- Além disso, o comportamento de  $X$  é completamente determinado pela função

$$P(X = x) = \binom{3}{x} (0,8)^x (0,2)^{3-x} \mathbb{1}_{\{0,1,2,3\}}(x).$$

# Modelo Binomial

- Modelo Geral: Considere a repetição de  $n$  ensaios  $X_i$  Bernoulli independentes e todos com a mesma probabilidade de sucesso  $p$ . A variável aleatória  $X = X_1 + \dots + X_n$  que representa o total de sucessos corresponde ao modelo binomial com parâmetros  $n$  e  $p$  ( $n \in \mathcal{N}^*$ ,  $p \in (0, 1)$ ).
- Notação:  $X \sim \text{bin}(n, p)$  ou  $X \sim \text{binomial}(n, p)$ .
- A respectiva fdp é dada por:

$$f_X(x) = P(X = x) = \binom{n}{x} p^x (1 - p)^{n-x} \mathbb{1}_{\{0,1,2,\dots,n\}}(x).$$

- O nome é devido aos coeficientes binomiais  $\binom{n}{x}$  que aparecem na fdp.

# Modelo Binomial

- Demonstração: para uma dada configuração de  $n$  ensaios, digamos  $\{S, S, F, S, \dots, F\}$  (em que  $S$  : sucesso e  $F$  : fracasso) temos que sua probabilidade de ocorrência é  $p^x q^{n-x}$ , sendo  $x$  o número de sucessos e  $n - x$  o número de fracassos.
- Contudo, temos um total de  $\binom{n}{x}$  configurações possíveis que levam ao mesmo número de sucessos e de fracassos.
- Como somente uma delas pode ocorrer, então

$$P(X = x) = P(C_1 \cup C_2 \cup \dots \cup C_{\binom{n}{x}}) = \sum_{i=1}^{\binom{n}{x}} p^x q^{n-x} = \binom{n}{x} p^x (1 - p)^{n-x},$$

em que  $C_i$  é a  $i$ -ésima configuração.

# Propriedades da Esperança e Variância

- Exercício: provar que  $f_X(\cdot)$  é, de fato, uma fdp.
- Obs: pode-se utilizar o fato de que

$$\sum_{i=0}^n \binom{n}{i} a^i b^{n-i} = (a + b)^n.$$

- Se  $n = 1$ , então  $X \sim \text{bin}(1, p) \equiv \text{Bernoulli}(p)$ .
- A fda de  $X$  é dada por

$$F_X(x) = \sum_{y \leq x} f_X(y) \mathbb{1}_{[0, n)}(x) + \mathbb{1}_{[n, \infty)}(x).$$



# Propriedades da Esperança e Variância

- A fds de  $X$  é dada por

$$S_X(x) = \mathbb{1}_{(-\infty, 0)}(x) + \sum_{y \leq x} f_X(y) \mathbb{1}_{[0, n]}(x).$$

- Valor esperado ( $y = x - 1$ ):

$$\begin{aligned} \mathcal{E}(X) &= \sum_{x=0}^n x \binom{n}{x} p^x q^{n-x} = \sum_{x=1}^n x \binom{n}{x} p^x q^{n-x} = \sum_{x-1=0}^n x \binom{n}{x} p^x q^{n-x} \\ &= np \sum_{x-1=0}^n \frac{(n-1)!}{(x-1)!(n-x)!} p^{x-1} q^{n-x} \\ &= np \sum_{y=0}^{n-1} \binom{n-1}{y} p^y q^{n-1-y} = np(p+q)^{n-1} = np. \end{aligned}$$

## Propriedades da Esperança e Variância

- Para calcular a variância, precisaremos da  $\mathcal{E}(X^2)$ . Contudo, é mais fácil calcular  $\mathcal{E}(X(X - 1))$ . De fato ( $y = x - 2$ )

$$\begin{aligned}\mathcal{E}(X(X - 1)) &= \sum_{x=0}^n x(x - 1) \binom{n}{x} p^x q^{n-x} \\ &= n(n - 1)p^2 \sum_{x=2}^n \frac{(n - 2)!}{(x - 2)!(n - x)!} p^{x-2} q^{n-x} \\ &= n(n - 1)p^2 \sum_{x-2=0}^n \binom{n - 2}{x - 2} p^{x-2} q^{n-x} \\ &= n(n - 1)p^2 \sum_{y=0}^{n-2} \binom{n - 2}{y} p^y q^{n-2-y} \\ &= n(n - 1)p^2,\end{aligned}$$

# Propriedades da Esperança e Variância

- (cont.) Portanto:

$$\mathcal{E}(X(X-1)) = n(n-1)p^2 = n^2p^2 - np^2$$

$$\rightarrow \mathcal{E}(X^2) = n^2p^2 - np^2 + \mathcal{E}(X) = n^2p^2 - np^2 + np$$

$$\rightarrow \mathcal{E}(X^2) = n^2p^2 + np(1-p).$$

- Logo

$$\mathcal{V}(X) = \mathcal{E}(X^2) - \mathcal{E}^2(X) = n^2p^2 + np(1-p) - n^2p^2 = np(1-p).$$

## Propriedades da Esperança e Variância

- Lembre que uma binomial( $n, p$ ) é uma soma de  $n$  vad's com mesma distribuição de Bernoulli's e mutuamente independentes (notação  $X_i \stackrel{iid}{\sim}$  Bernoulli( $p$ )).
- Devido a cada esperança existir, da propriedade vista [aqui](#), temos que

$$\begin{aligned}\mathcal{E}(X) &= \mathcal{E}(X_1 + X_2 + \dots + X_n) = \mathcal{E}(X_1) + \mathcal{E}(X_2) + \dots + \mathcal{E}(X_n) \\ &= p + p + \dots + p = np.\end{aligned}$$

# Modelo Binomial

- Como cada variância existe e as variáveis são independentes (vamos provar essa propriedade, adiante), temos que:

$$\begin{aligned}\mathcal{V}(X) &= \mathcal{V}(X_1 + X_2 + \dots + X_n) = \mathcal{V}(X_1) + \mathcal{V}(X_2) + \dots + \mathcal{V}(X_n) \\ &= p(1-p) + p(1-p) + \dots + p(1-p) = np(1-p).\end{aligned}$$

- No exemplo da vacina, temos então  $n = 3$  e  $p = 0,8$ .
  - $X \sim \text{bin}(3; 0,8)$ .
  - $E(X) = 3 \times 0,8 = 2,4$ .
  - $\text{Var}(X) = 3 \times 0,8 \times 0,2 = 0,48$ .

# Simulação de uma variável binomial

- Algoritmo:





- 1 Simule  $x_i, i = 1, 2, \dots, m$ , de forma iid de  $X \sim \text{Bernoulli}$ .

- 2 Faça  $x = x_1 + x_2 + \dots + x_m$ .





- No programa R ( $n$  é o tamanho da amostra a ser simulada, e vamos considerar que  $m$  é o número de ensaios de Bernoulli)

```
rbinom(n,m,p)
```

# fdp: binomial







# valores simulados: binomial





# fdp (azul) e valores simulados (vermelho): binomial



# Modelo de Poisson

- É apropriado para contagens sem um limite superior (no caso da binomial, por exemplo, a contagem está limitada por  $n$ ).
- Deprendido a partir do modelo binomial quando :
  - $n \rightarrow \infty$  (número de tentativas).
  - $p \rightarrow 0$  (probabilidade de sucesso).
  - $np \rightarrow \lambda$  (valor esperado).
- Notação  $X \sim \text{Poisson}(\lambda)$ ,  $\lambda > 0$ .
- Tem esse nome devido ao seu desenvolvedor, Siméon Denis Poisson.

# Modelo Poisson

- Demonstração: Temos que se  $X \sim \text{bin}(n, p)$ , então

$$\begin{aligned}P(X = x) &= \frac{n!}{x!(n-x)!} p^x (1-p)^{n-x} \\&= \frac{n(n-1)\dots(n-x+1)}{x! n^x} (pn)^x \left(1 - \frac{np}{n}\right)^n \left(1 - \frac{np}{n}\right)^{-x} \\&= \frac{1 \left(1 - \frac{1}{n}\right) \dots \left(1 - \frac{x}{n} + \frac{1}{n}\right)}{x!} (pn)^x \left(1 - \frac{np}{n}\right)^n \left(1 - \frac{np}{n}\right)^{-x},\end{aligned}$$

## Cont.

- Logo (lembrando que  $\lim_{n \rightarrow \infty} \left(1 + \frac{a}{n}\right)^n = e^a$ )

$$\begin{aligned}\lim_{n \rightarrow \infty} P(X = x) &= \lim_{n \rightarrow \infty} \frac{\left(1 - \frac{1}{n}\right) \dots \left(1 - \frac{x}{n} + \frac{1}{n}\right)}{x!} \\ &\times \lim_{n \rightarrow \infty} (pn)^x \underbrace{\lim_{n \rightarrow \infty} \left(1 - \frac{np}{n}\right)^n}_{e^{-\lambda}} \\ &\times \lim_{n \rightarrow \infty} \left(1 - \frac{np}{n}\right)^{-x} \\ &= \frac{1}{x!} \lambda^x e^{-\lambda}.\end{aligned}$$

# Distribuição de Poisson

- Uma variável aleatória  $X$  tem distribuição de Poisson com parâmetro  $\lambda > 0$ , se sua função de probabilidade é dada por:

$$f_X(x) = P(X = x) = \frac{e^{-\lambda} \lambda^x}{x!} \mathbb{1}_{\{0,1,2,\dots\}}(x) = \frac{e^{-\lambda} \lambda^x}{x!} \mathbb{1}_{\mathcal{N}}(x).$$

- $\lambda$  é chamado de taxa de ocorrência.
- Notação:  $X \sim P(\lambda)$  ou  $X \sim \text{Poisson}(\lambda)$ .

# Distribuição de Poisson

- Prove que  $f_X$  é, de fato, uma fdp. Você pode usar o fato de que:

$$e^\lambda = \sum_{x=0}^{\infty} \frac{\lambda^x}{x!},$$

que corresponde à expansão em séries de Taylor de  $e^\lambda$ , em torno do zero.

# Fda e fds

- Temos que a fda é dada por:

$$F_X(x) = P(X \leq x) = \sum_{y \leq x} \frac{e^{-\lambda} \lambda^y}{y!} = \sum_{y=0}^x \frac{e^{-\lambda} \lambda^y}{y!}.$$

- Logo

$$F_X(x) = \left( \sum_{y=0}^x \frac{e^{-\lambda} \lambda^y}{y!} \right) \mathbb{1}_{[0, \infty)}(x).$$

- Analogamente, temos que:

$$S_X(x) = P(X > x) = \mathbb{1}_{(-\infty, 0)}(x) + \left( \sum_{y=x+1}^{\infty} \frac{e^{-\lambda} \lambda^y}{y!} \right) \mathbb{1}_{[0, \infty)}(x).$$

# Distribuição de Poisson

- Para o valor esperado, temos que ( $y = x - 1$ ):

$$E(X) = \sum_{x=0}^{\infty} x \frac{e^{-\lambda} \lambda^x}{x!} = \sum_{x=1}^{\infty} x \frac{e^{-\lambda} \lambda^x}{x!} = \sum_{x=1}^{\infty} \frac{e^{-\lambda} \lambda^x}{(x-1)!} = \lambda \sum_{y=0}^{\infty} \frac{e^{-\lambda} \lambda^y}{y!} = \lambda.$$

- Assim como no caso da distribuição binomial, é mais fácil calcular  $\mathcal{E}(X(X-1))$  do que  $\mathcal{E}(X^2)$ . Com efeito ( $y = x - 2$ ):

$$\begin{aligned} E(X(X-1)) &= \sum_{x=0}^{\infty} x(x-1) \frac{e^{-\lambda} \lambda^x}{x!} = \sum_{x=2}^{\infty} x(x-1) \frac{e^{-\lambda} \lambda^x}{x!} \\ &= \sum_{x=2}^{\infty} \frac{e^{-\lambda} \lambda^x}{(x-2)!} = \lambda^2 \sum_{y=0}^{\infty} \frac{e^{-\lambda} \lambda^y}{y!} = \lambda^2, \end{aligned}$$



# Distribuição de Poisson

- (Cont.)

$$\begin{aligned}E(X(X - 1)) &= E(X^2 - X) \rightarrow E(X^2 - X) = \lambda^2 \\&\rightarrow E(X^2) = E(X) + \lambda^2 \\&\rightarrow E(X^2) = \lambda + \lambda^2.\end{aligned}$$

- Logo

$$V(X) = E(X^2) - E^2(X) = \lambda^2 + \lambda - \lambda^2 = \lambda.$$

# Distribuição de Poisson

- Exemplo: O Comportamento da emissão de partículas radioativas (de alguma fonte) são, em geral, modeladas através de uma distribuição de Poisson, com o valor do parâmetro dependendo da fonte utilizada. Supondo que o número de partículas  $\alpha$  emitidas por minuto é uma variável aleatória seguindo o modelo Poisson com parâmetro  $\lambda = 5$ , ou seja, a taxa de ocorrência é de 5 emissões a cada minuto, podemos estar interessados em calcular a probabilidade, por exemplo, de haver mais de duas emissões por minuto.

# Distribuição de Poisson

- $X \sim P(5)$ .

- $P(X > 2) = \sum_{x=3}^{\infty} \frac{e^{-5}5^x}{x!} = 1 - \sum_{x=0}^2 \frac{e^{-5}5^x}{x!} \approx 0,875$ .

- $E(X) = \lambda = 5$ .

- $Var(X) = \lambda = 5$ .

# Distribuição de Poisson

- Considerando a distribuição  $bin(n, p)$ , quando o valor de  $n$  é grande e  $p$  pequeno (mantendo-se o produto  $np$  constante), podemos usar a seguinte aproximação para a probabilidade:

$$P(X = x) = \binom{n}{x} p^x (1 - p)^{n-x} \approx \frac{e^{-np} (np)^x}{x!}, \quad \forall x = 0, 1, 2, \dots$$

- Geralmente considera-se o critério  $np \leq 7$  para usar essa aproximação.

# Distribuição de Poisson

- Exemplo:  $X \sim \text{bin}(100; 0,065)$ , deseja-se obter  $P(X = 10)$ .
  - $\lambda = np = 100 \times 0,065 = 6,5 \leq 7$ .
  - no modelo Binomial:  $P(X = 10) = \binom{100}{10}(0,065)^{10}(0,935)^{100-10} = 0,055$ .
  - no modelo Poisson:  $P(X = 10) = \frac{e^{-6,5}(6,5)^{10}}{10!} \approx 0,056$ .

# Simulação de uma variável Poisson





- Algoritmo:

- 1 O algoritmo usado pelo programa R encontra-se [aqui](#).





- No programa R ( $n$  é o tamanho da amostra a ser simulada)

```
rpois(n,lambda)
```

# fdp: Poisson







# valores simulados: Poisson





# fdp (azul) e valores simulados (vermelho): Poisson



# Modelo Geométrico

- Consideremos, novamente, um experimento  $E$  com espaço de resultados  $\Omega$  e o evento  $A, A \subset \Omega$ .
- Dizemos que ocorreu sucesso se o evento  $A$  foi observado e fracasso, caso contrário (como nos modelos Bernoulli e binomial).
- Repetimos o experimento até o primeiro sucesso ser observado.
- Defina  $X$ : o número de repetições necessárias até se obter o primeiro sucesso.
- Exemplo: lançar uma moeda repetidas vezes até observar-se a primeira cara.

# Modelo Geométrico

- Os valores possíveis de  $X$  são  $\{1, 2, 3, \dots\}$ .
- Repetimos ensaios de Bernoulli independentes e com a mesma probabilidade de sucesso ( $p$ ) até obtermos o primeiro sucesso.
- Ou seja,  $X$  é o número de ensaios Bernoulli até se obter o primeiro sucesso.

# Modelo Geométrico

- Notação:  $X \sim G(p)$ , ou  $X \sim \text{geométrica}(p)$ ,  $q = 1 - p$ .
- Função de probabilidade:

$$f_X(x) = P(X = x) = p(1 - p)^x \mathbb{1}_{\{1,2,3,\dots\}}(x) = p(1 - p)^x \mathbb{1}_{\mathcal{N}^*}(x).$$

- Demonstração:

$$P(Y = 1) = p$$

$$P(Y = 2) = (1 - p)p$$

$$P(Y = 3) = (1 - p)^2 p$$

$$\vdots$$

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

# Modelo Geométrico

- Prove que  $f_X(\cdot)$  é, de fato, uma legítima fdp (ver a fórmula da soma dos termos de uma pg finita).
- Em relação à fda, temos que:

$$\begin{aligned}F_X(x) &= P(X \leq x) = \sum_{y \leq x} (1 - p)^{y-1} p = p \sum_{y=1}^x (1 - p)^{y-1} p \\ &= p \frac{(q^x - 1)}{q - 1} = 1 - q^x.\end{aligned}$$

# Modelo geométrico

- Logo,

$$F_X(x) = (1 - q^x) \mathbb{1}_{[1, \infty)}(x).$$

- Analogamente,

$$S_X(x) = \mathbb{1}_{(-\infty, 1)}(x) + q^x \mathbb{1}_{[1, \infty)}(x).$$

# Modelo geométrico

- Para o valor esperado, temos que:

$$\begin{aligned} E(X) &= \sum_{x=1}^{\infty} x(1-p)^{x-1}p = p \sum_{x=1}^{\infty} \frac{dq^x}{dq} = p \frac{d}{dq} \sum_{x=1}^{\infty} q^x \\ &= p \frac{d}{dq} \left( \frac{q}{1-q} \right) = p \frac{1-q+q}{(1-q)^2} = p \frac{1}{p^2} = \frac{1}{p}. \end{aligned}$$

## Modelo geométrico

- Assim como para os modelos binomial e Poisson, é mais fácil calcular  $\mathcal{E}(X(X - 1))$  do que  $\mathcal{E}(X^2)$ , com efeito

$$\begin{aligned} E(X(X - 1)) &= (1 - p) \sum_{x=1}^{\infty} x(x - 1)(1 - p)^{x-2} p \\ &= (1 - p)p \sum_{x=1}^{\infty} \frac{d^2 q^x}{dq^2} = p(1 - p) \frac{d^2}{dq^2} \sum_{x=1}^{\infty} q^x \\ &= p(1 - p) \frac{d^2}{dq^2} \left( \frac{q}{1 - q} \right) = p(1 - p) \frac{d}{dq} \frac{1 - q + q}{(1 - q)^2} \\ &= p(1 - p) \frac{d}{dq} \frac{1}{(1 - q)^2} = (1 - p) \frac{2}{(1 - q)^2}. \end{aligned}$$



# Modelo geométrico

- (Cont.) Portanto

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

- Logo, temos que

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

# Modelo geométrico

- Em relação à fda, temos que (ver a fórmula da soma dos termos de uma pg finita):

$$\begin{aligned}F_X(x) &= P(X \leq x) = \sum_{y \leq x} (1-p)^{y-1} p = p \sum_{y=1}^x (1-p)^{y-1} p \\ &= p \frac{(q^x - 1)}{q - 1} = 1 - q^x.\end{aligned}$$

# Modelo geométrico

- Uma outra forma de se definir a distribuição é geométrica é através da  $Y$ , digamos,  $Y$  sendo o número de fracassos até se obter o primeiro sucesso.
- Prove que  $Y = X - 1$  e obtenha as respectivas fdp, fda, fds,  $\mathcal{E}(\cdot)$  e  $\mathcal{V}(\cdot)$  de  $Y$ .

# Simulação de uma variável geométrica

- Algoritmo:

- 1 O algoritmo usado pelo programa R encontra-se [aqui](#), pag. 480.





- Um algoritmo “ingênuo” seria:

- 1 Simule  $x$ ,  $X \sim \text{Bernoulli}$  até que  $x=1$ .





- No programa R ( $n$  é o tamanho da amostra a ser simulada)

```
rgeom(n,p)
```





# fdp: geométrica



# valores simulados: geométrica



# fdp (azul) e valores simulados (vermelho): geométrica



# Modelo binomial negativo

- Consideremos novamente um experimento  $E$  com espaço de resultados  $\Omega$  e o evento  $A, A \subset \Omega$ .
- Vamos dizer que ocorreu sucesso se o evento  $A$  aconteceu e fracasso, caso contrário.
- Repetimos o experimento até que  $r$  sucessos tenham ocorrido.
- Defina  $X$  o número de repetições até que observemos  $r$  sucessos.
- Exemplo: lançar uma moeda repetidas vezes até aparecerem 4 caras.



## modelo binomial negativo

- Os valores possíveis de  $X$  são  $\{r, r + 1, r + 2, \dots\}$ .
- Repetimos ensaios independentes de Bernoulli, com probabilidade ( $p$ ) de sucesso, até obtermos  $r$  sucessos.
- Seja  $X$  o número de ensaios Bernoulli até obtermos  $r$  sucessos.
- Assim  $X = X_1 + X_2 + \dots + X_r$ , em que  $X_i \stackrel{iid}{\sim}$  geométrica( $p$ ).
- Notações:  $X \sim$  binomial negativa( $r, p$ ),  $Y \sim \text{BN}(r, p)$ .
- Função de probabilidade:

$$f_X(x) = P(X = x) = \binom{x-1}{r-1} p^r (1-p)^{x-r} \mathbb{1}_{\{r, r+1, r+2, \dots\}}(x).$$

# Modelo binomial negativo

- Para uma dada sequência de “r” sucessos, temos que sua probabilidade de ocorrência é

$$P(X = r) = p^r$$

$$P(X = r + 1) = (1 - p)p^r$$

$$P(X = r + 2) = (1 - p)^2 p^r$$

⋮

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

# Modelo binomial negativo

- (Cont.) Contudo, para cada sequência de  $r$  sucessos e  $k$  repetições (a última repetição tem de ser sempre sucesso), temos um total de

$$\binom{k-1}{r-1},$$

possibilidades.

- Logo

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

- Exercício: prove que, de fato,  $f_X(\cdot)$  é uma legítima fdp.

# Modelo binomial negativo

- Pode-se usar o seguinte resultado (expansão em séries de Taylor da função  $f(x) = (1 - x)^{-r}$ , em torno do zero):

$$\begin{aligned}(1 - x)^{-r} &= \sum_{i=0}^{\infty} \binom{r+i-1}{i} x^i = \sum_{i+r=r}^{\infty} \binom{r+i-1}{i} x^i \\ &= \sum_{j=r}^{\infty} \binom{j-1}{j-r} x^{j-r} = x^{-r} \sum_{j=r}^{\infty} \binom{j-1}{r-1} x^j.\end{aligned}$$

# Modelo binomial negativo

- Notemos que

$$\begin{aligned}\binom{x-1}{r-1} &= \frac{(x-1)!}{(r-1)!(x-r)!} = \frac{(x-1) \times (x-2) \times \dots \times (x-r+1)}{(r-1)!} \\ &= (-1)^{r-1} \frac{(-x+1) \times (-x+2) \times \dots \times (-x+(r-1))}{(r-1)!} \\ &= (-1)^{r-1} \binom{-x}{r-1},\end{aligned}$$

por isso o nome binomial-negativa.

## Modelo binomial negativo

- A fda e a fds são dadas, respectivamente, por:

$$F_X(x) = P(X \leq x) = \left[ \left( \frac{1}{1-p} \right)^r \sum_{y \leq x} \binom{y-1}{r-1} (1-p)^y \right] \mathbb{1}_{[r, \infty)}(x).$$

$$\begin{aligned} S_X(x) &= P(X > x) = \mathbb{1}_{(\infty, r)}(x) \\ &+ \left[ 1 - \left( \frac{1}{1-p} \right)^r \sum_{y > x} \binom{y-1}{r-1} (1-p)^y \right] \mathbb{1}_{[r, \infty)}(x). \end{aligned}$$

# Modelo binomial negativo

- Para o valor esperado, temos que:

$$\begin{aligned}\mathcal{E}(X) &= \sum_{x=r}^{\infty} \binom{x-1}{r-1} x (1-p)^{x-r} p^r \\ &= -(1-p)^{1-r} p^r \sum_{x=r}^{\infty} \binom{x-1}{r-1} \frac{d}{dp} (1-p)^x \\ &= -(1-p)^{1-r} p^r \frac{d}{dp} \sum_{x=r}^{\infty} \binom{x-1}{r-1} (1-p)^x \\ &= -(1-p)^{1-r} p^r \frac{d}{dp} \left( \frac{1-p}{p} \right)^r \\ &= (1-p)^{1-r} p^r \frac{r(1-p)^r}{p^{r+1}(1-p)} = \frac{r}{p}.\end{aligned}$$

## Modelo binomial negativo

- Para a variância, temos que:

$$\begin{aligned}\mathcal{E}(X(X-1)) &= \sum_{x=r}^{\infty} \binom{x-1}{r-1} x(x-1)(1-p)^{x-r} p^r \\ &= (1-p)^{2-r} p^r \sum_{x=r}^{\infty} \binom{x-1}{r-1} \frac{d^2}{dp^2} (1-p)^x \\ &= (1-p)^{2-r} p^r \frac{d^2}{dp^2} \sum_{x=r}^{\infty} \binom{x-1}{r-1} (1-p)^x \\ &= (1-p)^{2-r} p^r \frac{d^2}{dp^2} \left( \frac{1-p}{p} \right)^r \\ &= -(1-p)^{2-r} p^r \frac{r(1-p)^r p^{-r-2} (2p-r-1)}{(1-p)^2} =\end{aligned}$$



# Modelo binomial negativo

- (Cont.) temos que:

$$\begin{aligned}\mathcal{E}(X(X-1)) &= -\frac{r(2p-r-1)}{p^2} \rightarrow \mathcal{E}(X^2) = -\frac{r(2p-r-1)}{p^2} + \mathcal{E}(X) \\ &= -\frac{r(2p-r-1)}{p^2} + \frac{r}{p} = \frac{-pr+r^2+r}{p^2}.\end{aligned}$$

- Logo,

$$\mathcal{V}(X) = \frac{-pr+r^2+r}{p^2} - \frac{r^2}{p^2} = \frac{r(1-p)}{p^2}.$$

# Modelo binomial negativo

- Lembre que uma  $\text{bn}(r, p)$  é uma soma de  $r$  vad's com mesma distribuição geométrica e mutuamente independentes (notação  $X_i \stackrel{iid}{\sim} G(p)$ ).
- Devido a cada esperança existir, da propriedade vista [aqui](#), temos que:

$$\mathcal{E}(X) = \mathcal{E}(X_1 + X_2 + \dots + X_r) = \mathcal{E}(X_1) + \mathcal{E}(X_2) + \dots + \mathcal{E}(X_r) = \frac{r}{p}.$$

# Modelo binomial negativo

- Como cada variância existe e as variáveis são independentes (vamos provar essa propriedade, adiante), temos que:

$$\begin{aligned}\mathcal{V}(X) &= \mathcal{V}(X_1 + X_2 + \dots + X_r) = \mathcal{V}(X_1) + \mathcal{V}(X_2) + \dots + \mathcal{V}(X_r) \\ &= \frac{1-p}{p^2} + \frac{1-p}{p^2} + \dots + \frac{1-p}{p^2} = \frac{r(1-p)}{p^2}.\end{aligned}$$

# Simulação de uma variável binomial negativa

- Algoritmo:

- 1 O algoritmo usado pelo programa R encontra-se [aqui](#), pag. 480.





- Um outro algoritmo seria:

- 1 Simule  $x_1, x_r, \dots, x_r, X_i \stackrel{iid}{\sim} G(p)$  e faça  $x = x_1 + x_2 + \dots + x_r$ .





- No programa R ( $n$  é o tamanho da amostra a ser simulada)

```
rnbinom(n,r,p)
```





# fdp: binomial negativa



# valores simulados: binomial negativa



# fdp (azul) e valores simulados (vermelho): BN



# Distribuição Hipergeométrica

- Suponha uma população dividida em dois grupos (duas características).
- Extrações casuais sem reposição.
- Detalhes:
  - $N$  objetos.
  - $r$  têm a característica A.
  - $N - r$  têm a característica B.
  - um grupo de  $n$  elementos é escolhido ao acaso, dentre os  $N$  possíveis, sem reposição.
- Objetivo: calcular a probabilidade de que este grupo de  $n$  elementos contenha exatamente  $x$  elementos com a característica A.



# Distribuição Hipergeométrica

- Note que  $n < r$  ou  $n \geq r$  e  $n < N - r$  ou  $n \geq N - r$ .
- Modelo Geral (princípios multiplicativo e aditivo da contagem, num espaço amostral equiprobabilístico):

$$P(X = x) = \frac{\binom{r}{x} \binom{N-r}{n-x}}{\binom{N}{n}} \mathbb{1}_{\{\max\{0, n-(N-r)\}, \min\{r, n\}\}}(x).$$

- $X$  registra o número de elementos dentre os  $n$  sorteados, que possuem a característica  $A$ .
- Notação:  $X \sim \text{HG}(N, n, r)$  ou  $X \sim \text{hipergeométrica}(N, n, r)$ .

# Distribuição Hipergeométrica

- Notação:  $X \sim \text{hip}(N, n, r)$  ou  $H \sim \text{hipergeométrica}(N, n, r)$ .
- $X$  tem distribuição Hipergeométrica com parâmetros  $N, n, r$ , então:
  - $E(X) = \frac{nr}{N}$ .
  - $\text{Var}(X) = \frac{nr}{N} \left(1 - \frac{r}{N}\right) \frac{(N-n)}{(N-1)}$ .
  - Pesquisar sobre como calcular a média e a variância e sobre como provar que  $f_X(\cdot)$  é uma legítima fdp.
  - Escrever a fda e a fds de  $X$ .
- Um resultado importante é:

$$\binom{m+n}{r} = \sum_{k=0}^r \binom{m}{k} \binom{n}{r-k}.$$

# Distribuição Hipergeométrica

- Uma outra identidade útil é dada por:

$$\binom{N}{n} = \frac{N}{n} \binom{N-1}{n-1}.$$

- Além disso, é possível provar que: (em que  $Y \sim HG(N-1, n-1, r-1)$ ):

$$\mathcal{E}(X^k) = \frac{nr}{N} \mathcal{E}((Y+1)^{k-1}).$$

- Obs: sem perda de generalidade, na demonstrações dos resultados, pode-se utilizar o conjunto  $A = \{0, 1, 2, \dots, n\}$  como suporte de  $X$ .

# Distribuição Hipergeométrica

- Aplicação: Controle da Qualidade- Suponha um lote com  $N = 100$  elementos a ser analisado. São escolhidas  $n = 5$  peças sem reposição. Sabendo que neste lote de 100 elementos,  $r = 10$  são defeituosos, a probabilidade de não se obter nenhuma peça defeituosa na amostra retirada é:

$$P(X = 0) = \frac{\binom{10}{0} \binom{100-10}{5-0}}{\binom{100}{5}} = \frac{\binom{90}{5}}{\binom{100}{5}} \approx 0,584.$$

# Distribuição Hipergeométrica

- A probabilidade de se obter pelo menos uma peça defeituosa é:

$$\sum_{i=1}^5 P(X = i) = 1 - P(X = 0) \approx 0,426.$$

- $E(X) = \frac{nr}{N} = \frac{5 \times 10}{100} = 0,5.$
- $Var(X) = \frac{nr}{N} \left(1 - \frac{r}{N}\right) \frac{(N-n)}{(N-1)} = \frac{5 \times 10}{100} \left(1 - \frac{10}{100}\right) \frac{(100-10)}{(100-1)} \approx 0,409.$

# Simulação de uma variável hipergeométrica





- Algoritmo:

- 1 O algoritmo usado pelo programa R encontra-se [aqui](#).





- No programa R ( $n$  é o tamanho da amostra a ser simulada)

```
rhyper(n, r, N-r, n)
```

# fdp: Hipergeométrica



# valores simulados: Hipergeométrica





# fdp (azul) e valores simulados (vermelho): Hipergeométrica

