


PGE966 - Processos Estocásticos

Programa de Pós-graduação em Estatística da UFPE



REVISÃO DE PROBABILIDADE

Prof. Pablo M. Rodriguez

<https://www.pablo-rodriguez.org>



UNIVERSIDADE
FEDERAL
DE PERNAMBUCO

CCEN

CENTRO DE CIÊNCIAS EXATAS
E DA NATUREZA

Conteúdo

- ▶ Variáveis aleatórias discretas.
- ▶ Esperança matemática.
- ▶ Esperança condicional.



Tipos de variáveis aleatórias

Uma variável aleatória X é:

- ▶ **discreta** se $X(\omega) \in \mathcal{S} \subset \mathbb{R}$ para todo $\omega \in \Omega$, para algum conjunto \mathcal{S} finito ou enumerável. Neste caso

$$p(i) := P(X = i), i \in \mathcal{S},$$

é a função de probabilidade de X .

- ▶ **(absolutamente) contínua** se existe $f(x) \geq 0$ tal que

$$F(x) = P(X \leq x) = \int_{-\infty}^x f(t) dt, \quad \text{para todo } x \in \mathbb{R}.$$

Neste caso f é a função densidade de probabilidade de X .



Exemplo 1.1

Problema da coleção de cupons. *Existem n tipos de cupons e cada vez que um colecionador pega um cupom, este tem, independentemente das seleções anteriores, a mesma probabilidade de ser de qualquer um dos n tipos. Seja X o número de cupons que precisam ser recolhidos até obter uma coleção completa de pelo menos um cupom de cada tipo. Vamos encontrar $P(X = k)$.*

► *Note que*

$$\{X > k - 1\} = \{X = k\} \cup \{X > k\},$$

então

$$P(X = k) = P(X > k - 1) - P(X > k).$$



... *continuação do Exemplo 1.1.* Para encontrar $P(X > k)$, fixe k e considere os eventos:

$A_j =$ “nenhum cupom do tipo j está nos primeiros k cupons recolhidos”,

para $j \in \{1, \dots, n\}$. Note que

$$\begin{aligned} P(X > k) &= P\left(\bigcup_{i=1}^n A_i\right) \\ &= \sum_{i=1}^n P(A_i) - \sum_{1 \leq i < j \leq n} P(A_i \cap A_j) \\ &\quad + \sum_{1 \leq i < j < k \leq n} P(A_i \cap A_j \cap A_k) - \dots (-1)^{n+1} P\left(\bigcap_{i=1}^n A_i\right). \end{aligned}$$



... continuação do Exemplo 1.1. Mas

$$P(A_j) = \left(\frac{n-1}{n}\right)^k,$$

para todo $j \in \{1, \dots, n\}$. Da mesma forma,

$$P(A_i \cap A_j) = \left(\frac{n-2}{n}\right)^k,$$

para todo $i, j \in \{1, \dots, n\}$ com $i \neq j$ e, em geral

$$P(A_{i_1} \cap A_{i_2} \cap \dots \cap A_{i_\ell}) = \left(\frac{n-\ell}{n}\right)^k,$$

para $1 \leq i_1 < i_2 < \dots < i_\ell \leq n$. Logo,

$$P(X > k) = \sum_{i=1}^{n-1} \binom{n}{i} \left(\frac{n-i}{n}\right)^k (-1)^{i+1}.$$



Distribuição Bernoulli

X tem *distribuição de Bernoulli* com parâmetro $p \in (0, 1)$ se:

$$p(1) = p = 1 - p(0).$$

Notação: $X \sim \text{Bernoulli}(p)$.

Observação!

Um experimento com apenas dois resultados possíveis, sucesso ou fracasso, chama-se ensaio de Bernoulli.

Exemplo 1.2

Seja X a variável aleatória indicadora do evento A com $P(A) = p$:

$$X = \begin{cases} 1, & \text{se } A \text{ ocorre,} \\ 0, & \text{se } A \text{ não ocorre.} \end{cases}$$

Então $X \sim \text{Bernoulli}(p)$.



Distribuição Binomial

X tem *distribuição Binomial* com parâmetros $n \in \mathbb{N}$ e $p \in (0, 1)$ se:

$$p(i) = \binom{n}{i} p^i (1-p)^{n-i}, \text{ para } i \in \{0, 1, \dots, n\}.$$

Notação: $X \sim B(n, p)$.

Observação!

X pode ser interpretada como o número de sucessos obtidos quando n ensaios independentes de Bernoulli, com probabilidade de sucesso p , são realizados.

Observação!

Duas variáveis aleatórias X_1 e X_2 são independentes se para todo $B_1 \in \mathcal{B}$ e $B_2 \in \mathcal{B}$, os eventos aleatórios $\{X_1 \in B_1\}$ e $\{X_2 \in B_2\}$ são independentes.



Note que, para $i \in \{0, 1, \dots, n\}$, por exemplo a configuração

$$\sigma : \begin{array}{cccccccccccc} \checkmark & \times & \checkmark & \times & \checkmark & \dots & \times & \checkmark & \times & \checkmark \\ \hline 1 & 2 & 3 & 4 & 5 & & n-3 & n-2 & n-1 & n \end{array} \quad \begin{array}{l} i \text{ sucessos } (\checkmark) \\ n - i \text{ fracassos } (\times) \end{array}$$

é favorável para a ocorrência de $\{X = i\}$. Como temos $\binom{n}{i}$ formas diferentes de obter uma configuração destas e como

$$P(\sigma) = p^i (1-p)^{n-i}, \quad \text{por independência!}$$

concluímos que

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



Se $X \sim B(n, p)$ podemos escrever

$$X = \sum_{i=1}^n X_i,$$

em que X_1, \dots, X_n são i.i.d. com $X_1 \sim \text{Bernoulli}(p)$.

Observação!

A notação i.i.d. é usada para dizer que as variáveis são independentes e identicamente distribuídas.



Distribuição de Poisson

X tem *distribuição de Poisson* com parâmetro $\lambda \in (0, \infty)$ se:

$$p(i) = \frac{e^{-\lambda} \lambda^i}{i!}, \text{ para } i \in \{0, 1, \dots\}.$$

Notação: $X \sim \text{Poisson}(\lambda)$.

Observação!

X pode ser interpretada como uma aproximação para o número de sucessos obtidos quando n ensaios independentes de Bernoulli, com probabilidade de sucesso p , são realizados, assumindo valores grandes de n e pequenos de p .



Aproximação da Binomial para a Poisson

Seja $X \sim B(n, p)$, n grande, e seja $Y \sim Poisson(\lambda)$ com $\lambda = np$.

$$P(X = i) = \binom{n}{i} p^i (1-p)^{n-i} = \frac{n!}{(n-i)! i!} \left(\frac{\lambda}{n}\right)^i \left(1 - \frac{\lambda}{n}\right)^{n-i}$$

que podemos reescrever:

$$P(X = i) = \left\{ \frac{n(n-1)(n-2) \cdots (n - \{i-1\})}{n^i} \right\} \left(\frac{\lambda^i}{i!}\right) \frac{\left(1 - \frac{\lambda}{n}\right)^n}{\left(1 - \frac{\lambda}{n}\right)^i}.$$



Aproximação da Binomial para a Poisson

Como

$$1 - \frac{j}{n} \approx 1, \quad \left(1 - \frac{\lambda}{n}\right)^n \approx e^{-\lambda}, \quad \left(1 - \frac{\lambda}{n}\right)^i \approx 1,$$


concluimos que

$$P(X = i) \approx \frac{e^{-\lambda} \lambda^i}{i!} = P(Y = i).$$



Processo de Poisson de parâmetro λ

Um Processo de Poisson de parâmetro λ **unidimensional** pode ser representado como uma sequência de pontos ou marcas em \mathbb{R}^+ :



tais que, se

$N(B)$ = número de pontos contidos no intervalo $B \subset \mathbb{R}^+$, então:

- ▶ $N(B) \sim \text{Poisson}(\lambda|B|)$;
- ▶ $B_1, B_2 \subset \mathcal{B}(\mathbb{R}^+)$, $B_1 \cap B_2 = \emptyset$, então
... $N(B_1)$ e $N(B_2)$ são independentes.



Distribuição Geométrica

X tem *distribuição geométrica* com parâmetro $p \in (0, 1)$ se:

$$p(i) = p(1 - p)^{i-1}, \text{ para } i \in \mathbb{N}.$$

Notação: $X \sim \text{Geom}(p)$.

Observação!

X pode ser interpretada como o número de ensaios independentes de Bernoulli, com probabilidade de sucesso p , que devem ser realizados até obter o primeiro sucesso.



Pensando na interpretação de X , note que se

$$X_i = \begin{cases} 1, & \text{se o } i\text{-ésimo ensaio resulta em sucesso,} \\ 0, & \text{caso contrário,} \end{cases}$$

para todo $i \in \mathbb{N}$, então:

$$P(X = i) = P\left(\left\{\bigcap_{k=1}^{i-1} \{X_k = 0\}\right\} \cap \{X_i = 1\}\right) \stackrel{\text{por independência!}}{=} (1-p)^{i-1}p.$$



Problema da coleção de cupons

Se X é o número de cupons que precisam ser recolhidos até obter uma coleção completa de pelo menos um cupom de cada tipo, então:

$$X = \sum_{i=1}^n T_i,$$

em que T_1, T_2, \dots, T_n são variáveis aleatórias independentes com

$$T_i \sim \text{Geom} \left(\frac{n - i + 1}{n} \right),$$

para $i \in \{1, \dots, n\}$.



Independência

X e Y são independentes se, para quaisquer $A, B \subset \mathcal{B}$, vale que

$$P(X \in A, Y \in B) = P(X \in A)P(Y \in B).$$

Isto é, X e Y são independentes se para quaisquer $A, B \subset \mathcal{B}$ os eventos

$$\mathcal{E}_A := \{X \in A\}$$

e

$$\mathcal{E}_B := \{Y \in B\}$$

são independentes.



Independência

X e Y são independentes se, e somente se,

- ▶ $F(a, b) = F_X(a) \cdot F_Y(b)$, para todo a, b ;
- ▶ $p(x, y) = p_X(x) \cdot p_Y(y)$ para todo x, y (caso discreto);
- ▶ $f(x, y) = f_X(x) \cdot f_Y(y)$ para todo x, y (caso contínuo).



Critério de independência

Proposição 1.1

X e Y são independentes se, e somente se, existirem funções h e g, definidas nos reais, tais que

$$f(x, y) = h(x) \cdot g(y), \quad x, y \in \mathbb{R}, \quad (\text{se } X \text{ e } Y \text{ são contínuas}),$$

ou

$$p(x, y) = h(x) \cdot g(y), \quad x, y \in \mathbb{R}, \quad (\text{se } X \text{ e } Y \text{ são discretas}).$$



Em geral

Em geral, dadas X_1, X_2, \dots, X_n , variáveis aleatórias discretas, a função de probabilidades conjunta é dada por

$$p(x_1, x_2, x_3, \dots, x_n) := P(X_1 = x_1, X_2 = x_2, X_3 = x_3, \dots, X_n = x_n),$$

e a função de probabilidade marginal de X_i , para $i \in \{1, 2, \dots, n\}$, é obtida fazendo

$$p_{X_i}(x_i) := P(X_i = x_i) = \underbrace{\sum_{x_1} \sum_{x_2} \cdots \sum_{x_n}}_{x_j: j \neq i} p(x_1, x_2, \dots, x_i, \dots, x_n)$$



Esperança de uma v.a. discreta

A esperança de uma v.a. discreta X , com valores em \mathcal{S} e função de probabilidade $p(x)$, é dada por

$$E(X) := \sum_{x \in \mathcal{S}} x p(x) = \sum_{x \in \mathcal{S}: x < 0} x p(x) + \sum_{x \in \mathcal{S}: x \geq 0} x p(x),$$

... desde que pelo menos uma das somas seja finita. Caso contrário, dizemos que a esperança de X não existe.

Observação!

Note que ambas as somas são finitas se $\sum_{x \in \mathcal{S}} |x| p(x) < \infty$.




► Se $X \sim \text{Poisson}(\lambda)$ então

$$E(X) = \sum_{n=0}^{\infty} n \left\{ e^{-\lambda} \frac{\lambda^n}{n!} \right\} = \lambda e^{-\lambda} \sum_{n=1}^{\infty} \frac{\lambda^{n-1}}{(n-1)!} = \lambda e^{-\lambda} \sum_{k=0}^{\infty} \frac{\lambda^k}{k!} = \lambda.$$

Observação!

Considere um Processo de Poisson de parâmetro λ :



Qual o papel de λ ?

Lembre que $N(a, b) \sim \text{Poisson}(\lambda(b - a))$.



Exemplo 1.3

Seja X uma variável aleatória discreta com valores em $\mathbb{Z} \setminus \{0\}$ tal que

$$p(i) = \frac{C}{i^2}, \quad i \in \mathbb{Z} \setminus \{0\}, \quad \text{com } C = \left\{ \frac{1}{2} \sum_{i=1}^{\infty} \frac{1}{i^2} \right\}^{-1}.$$

Então $E(X)$ não existe pois:

$$- \sum_{i \in \mathbb{Z}_-} i p(i) = \sum_{i \in \mathbb{Z}_+} i p(i) = C \sum_{i=1}^{\infty} \frac{1}{i} = \infty$$



Observação!

No que segue, consideramos variáveis aleatórias tais que sua esperança existe.

1. Se $X = c$ então $E(X) = c$.
2. Se $X \leq Y$ então $E(X) \leq E(Y)$.
3. **Linearidade.**

$$E(cX + Y) = cE(X) + E(Y),$$


se c é uma constante, quando os termos à direita tem sentido.

Em geral, se X_1, \dots, X_n são v.a. e c_1, \dots, c_n são constantes, então:


$$E\left(\sum_{i=1}^n c_i X_i\right) = \sum_{i=1}^n c_i E(X_i).$$




O passeio aleatório em \mathbb{Z}




O passeio aleatório em \mathbb{Z}




O passeio aleatório em \mathbb{Z}



O passeio aleatório em \mathbb{Z}



O passeio aleatório em \mathbb{Z}



O passeio aleatório em \mathbb{Z}

Exemplo 1.4

A cada passo, independentemente, a partícula pula à direita com probabilidade p , ou à esquerda com probabilidade $1 - p$. Definimos:

$Y_n =$ posição da partícula logo após o n - ésimo salto,
para $n \in \{0, 1, 2, \dots\}$, e supomos que $Y_0 = 0$. Podemos escrever

$$Y_n = \sum_{i=1}^n X_i,$$

onde X_1, X_2, \dots são v.a. i.i.d. tais que

$$P(X_i = 1) = p = 1 - P(X_i = -1).$$



... *continuação do Exemplo 1.4.* Note que

$$E(Y_n) = E(X_1 + X_2 + \cdots + X_n) = n E(X_1) = n(2p - 1).$$

Logo,

$$\lim_{n \rightarrow \infty} E(Y_n) = \begin{cases} +\infty, & \text{se } p > 1/2; \\ 0, & \text{se } p = 1/2; \\ -\infty, & \text{se } p < 1/2. \end{cases}$$



Soma de variáveis aleatórias indicadoras e esperança

Proposição 1.2

Se A_1, \dots, A_n são eventos aleatórios, então $P\left(\bigcup_{i=1}^n A_i\right) \leq \sum_{i=1}^n P(A_i)$.

Prova. Para cada $i \in \{1, 2, \dots, n\}$ seja

$$X_i = \begin{cases} 1, & \text{se o evento } A_i \text{ ocorrer,} \\ 0, & \text{caso contrário.} \end{cases}$$

Seja $X = \sum_{i=1}^n X_i$. Então

$$E(X) = \sum_{i=1}^n E(X_i) = \sum_{i=1}^n P(A_i). \quad (1)$$



... continuação da prova da Prop.1.2. Por outro lado, se

$$Y = \begin{cases} 1, & \text{se } X \geq 1, \\ 0, & \text{caso contrário,} \end{cases}$$

então $P(X \geq Y) = 1$ e portanto

$$E(X) \geq E(Y). \quad (2)$$

Mas

$$E(Y) = P(Y = 1) = P(X \geq 1) = P\left(\bigcup_{i=1}^n A_i\right). \quad (3)$$

De (1), (2) e (3) obtemos o resultado.



Esperança condicional

Se X e Y são variáveis aleatórias em (Ω, \mathcal{F}, P) , a esperança condicional de X dado que $Y = y$, que denota-se como:

$$E(X|Y = y)$$

é a esperança da distribuição condicional de X dado que $Y = y$, se esta esperança existir.

- ▶ Se X é discreta:

$$E(X|Y = y) = \sum_x x P(X = x|Y = y).$$



Caso de variáveis aleatórias discretas

Exemplo 1.5

Sejam $X \sim B(n, p)$ e $Y \sim B(n, p)$ independentes. Vamos encontrar

$$E(X|X + Y = m).$$

Dado que $X + Y = m$, X toma valores em $\{0, 1, \dots, \min\{n, m\}\}$ e

$$P(X = k|X+Y = m) = \frac{P(X = k, X + Y = m)}{P(X + Y = m)} = \frac{P(X = k, Y = m - k)}{P(X + Y = m)},$$

mas $X + Y \sim B(2n, p)$.



... continuação do Exemplo 1.5. Temos que

$$P(X = k | X + Y = m) = \frac{\left\{ \binom{n}{k} p^k (1-p)^{n-k} \right\} \left\{ \binom{n}{m-k} p^{m-k} (1-p)^{n-m+k} \right\}}{\binom{2n}{m} p^m (1-p)^{n-m}}$$

isto é:

$$P(X = k | X + Y = m) = \frac{\binom{n}{k} \binom{n}{m-k}}{\binom{2n}{m}},$$

para $k \in \{0, 1, \dots, \min\{n, m\}\}$.



... *continuação do Exemplo 1.5.* A partir daqui temos duas opções:

- ▶ Calcular $E(X|X + Y = m) = \sum_k k P(X = k|X + Y = m)$,
- ▶ ou reconhecer que:

$$X|X + Y = m \sim H(m, 2n, n)$$

e portanto: $E(X|X + Y = m) = \frac{nm}{2n} = \frac{m}{2}$.



A esperança condicional como variável aleatória

Sejam X, Y duas variáveis aleatórias em (Ω, \mathcal{F}, P) . Se

$$\varphi(y) := E(X|Y = y)$$

então $\varphi(Y) = E(X|Y)$ é uma variável aleatória chamada **esperança condicional de X dada Y** .

Propriedade importante: $E(E(X|Y)) = E(X)$. Isto é, se Y é discreta:

$$E(X) = \sum_y E(X|Y = y)P(Y = y).$$



Propriedades da esperança condicional

Observação!

Na sequência Y é uma v.a. e X, X_1, X_2 são integráveis, todas em (Ω, \mathcal{F}, P) .

- ▶ Se $X = c$, com c uma constante, então $E(X|Y) = c$.
- ▶ Se $X_1 \leq X_2$ então $E(X_1|Y) \leq E(X_2|Y)$.
- ▶ **Linearidade.** $E(aX_1 + bX_2|Y) = aE(X_1|Y) + bE(X_2|Y)$.
- ▶ **Princípio da substituição.** Se $\varphi(X, Y)$ é integrável, então

$$E(\varphi(X, Y)|Y = y) = E(\varphi(X, y)|Y = y).$$

- ▶ Se X e Y são independentes então $E(X|Y) = E(X)$.



Esperança da soma de um # aleatório de variáveis aleatórias.

Seja X_1, X_2, \dots uma sequência de variáveis aleatórias *i.i.d* e N uma variável aleatória discreta com valores em \mathbb{N} , independente às X_i 's.

$$\text{Se } Y = \sum_{i=1}^N X_i \text{ então } E(Y) = E(X_1)E(N).$$

De fato, como

$$E(Y|N = n) = E\left(\sum_{i=1}^N X_i \mid N = n\right) = E\left(\sum_{i=1}^n X_i \mid N = n\right) = E\left(\sum_{i=1}^n X_i\right)$$

temos $E(Y|N = n) = n E(X_1)$ e portanto $E(Y|N) = N E(X_1)$. Logo:


$$E(Y) = E(E(Y|N)) = E(NE(X_1)) = E(X_1)E(N).$$




Processo de ramificação




Processo de ramificação



Processo de ramificação




Processo de ramificação




Pergunta: o processo continuara indefinidamente?

Processo de ramificação



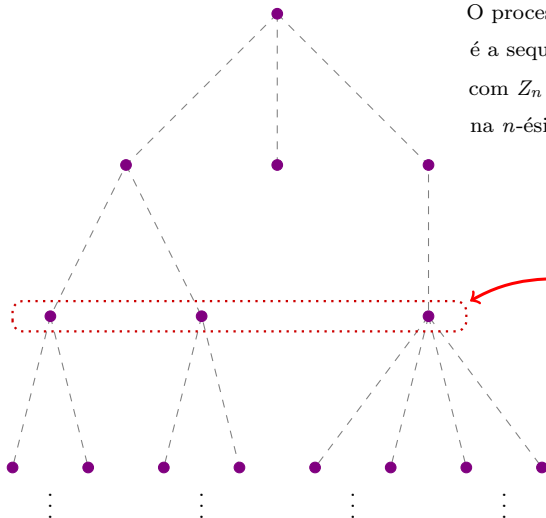
Processo de ramificação



O processo de ramificação
é a sequência $(Z_n)_{n \geq 0}$,
com $Z_n = \#$ de partículas
na n -ésima geração.



Processo de ramificação



O processo de ramificação
é a sequência $(Z_n)_{n \geq 0}$,
com $Z_n = \#$ de partículas
na n -ésima geração.

2da geração



Extinção do processo de ramificação

O evento $\mathcal{E} := \bigcup_{n=1}^{\infty} \{Z_n = 0\}$ chama-se **extinção** do processo.

Vamos provar que $m := E(X) < 1 \Rightarrow P(\mathcal{E}) = 1$.



Extinção do processo de ramificação

Suponha que $m < 1$. Para todo $n \geq 1$ temos que

$$Z_n = \sum_{i=1}^{Z_{n-1}} X_i,$$

onde as X_i 's são i.i.d. à variável aleatória X com $E(X) = m$. Então,

$$E(Z_n) = m E(Z_{n-1}),$$

para todo $n \in \mathbb{N}$, o que implica: $E(Z_n) = m^n$. Então,

$$P(\mathcal{E}^c) = P\left(\bigcap_{n=0}^{\infty} \{Z_n \geq 1\}\right) = \lim_{n \rightarrow \infty} P(Z_n \geq 1) \leq \lim_{n \rightarrow \infty} E(Z_n) = 0$$

$m < 1$

$\{Z_n \geq 1\} \searrow$ $P(Z_n \geq 1) \leq E(Z_n)$



Referências para a revisão de probabilidade




R. Schinazi. Classical and Spatial Stochastic Processes, Birkhäuser Boston, 1999. Ver também: Uma introdução aos processos estocásticos espaciais, IMPA, 1995.



Sheldon M. Ross. Introduction to Probability Models. 10th ed. Academic Press. 2010.





Bom estudo!

