

# Processos Estocásticos e Aplicações

José Pedro Gaivão

May 3, 2019

# Contents

|          |   |           |
|----------|---|-----------|
| <b>1</b> | <b>Noções gerais de teoria de probabilidades</b>          | <b>3</b>  |
| 1.1      | Espaços de probabilidade e variáveis aleatórias . . . . . | 3         |
| 1.2      | Esperança Condicional . . . . .                           | 6         |
| 1.2.1    | Esperança condicional: caso discreto . . . . .            | 7         |
| 1.2.2    | Esperança condicional: caso contínuo . . . . .            | 8         |
| 1.2.3    | Esperança condicional: caso vectorial . . . . .           | 9         |
| 1.2.4    | Propriedades . . . . .                                    | 9         |
| <b>2</b> | <b>Noções gerais de processos estocásticos</b>            | <b>11</b> |
| 2.1      | Noções gerais . . . . .                                   | 11        |
| 2.2      | Processos iid . . . . .                                   | 13        |
| 2.3      | Estacionariedade . . . . .                                | 14        |
| <b>3</b> | <b>Cadeias de Markov</b>                                  | <b>17</b> |
| 3.1      | Probabilidades de transição . . . . .                     | 17        |
| 3.2      | Recorrência . . . . .                                     | 26        |
| 3.3      | Exercícios . . . . .                                      | 34        |
| 3.4      | Periodicidade . . . . .                                   | 34        |
| 3.5      | Classes de equivalência . . . . .                         | 36        |
| 3.6      | Exercícios . . . . .                                      | 40        |
| 3.7      | Distribuição estacionária . . . . .                       | 41        |
| 3.8      | Exercícios . . . . .                                      | 48        |
| 3.9      | Estados absorventes e probabilidade de absorção . . . . . | 49        |
| 3.10     | Exercícios . . . . .                                      | 52        |
| <b>4</b> | <b>Processo de Poisson</b>                                | <b>54</b> |
| 4.1      | Definição do processo de Poisson . . . . .                | 55        |
| 4.2      | Construção do processo de Poisson . . . . .               | 57        |
| 4.3      | Caracterização . . . . .                                  | 58        |
| 4.4      | Relação com a distribuição Binomial . . . . .             | 60        |
| 4.5      | Processo de Poisson não homogéneo . . . . .               | 60        |

|          |   |           |
|----------|---|-----------|
| 4.6      | Exercícios . . . . .                                      | 61        |
| 4.7      | Processo de Poisson composto . . . . .                    | 62        |
| <b>5</b> | <b>Processos de Markov em tempo contínuo</b>              | <b>65</b> |
| 5.1      | Construção do Processo de Markov . . . . .                | 68        |
| 5.2      | Equações Regressivas/Progressivas de Kolmogorov . . . . . | 69        |
| 5.3      | Distribuição estacionária . . . . .                       | 73        |
| 5.4      | Exercícios . . . . .                                      | 77        |
| 5.5      | Filas de Espera . . . . .                                 | 78        |
| 5.6      | Exercícios . . . . .                                      | 82        |
| <b>6</b> | <b>Martingalas</b>  | <b>84</b> |
| 6.1      | Estratégias . . . . .                                     | 86        |
| 6.2      | Tempos de paragem . . . . .                               | 89        |
| 6.3      | Teorema de paragem opcional . . . . .                     | 90        |
| 6.4      | Convergência de martingalas . . . . .                     | 93        |
| 6.5      | Exercícios . . . . .                                      | 95        |
| <b>7</b> | <b>Movimento Browniano</b>                                | <b>97</b> |
| 7.1      | Propriedades . . . . .                                    | 99        |
| 7.2      | Exercícios . . . . .                                      | 101       |

# Chapter 1

## Noções gerais de teoria de probabilidades

Antes de iniciarmos o nosso estudo dos processos estocásticos convém relembrar alguns conceitos elementares de teoria de probabilidades.

### 1.1 Espaços de probabilidade e variáveis aleatórias

Seja  $\Omega$  um conjunto. Designamos por  $\Omega$  o **espaço dos resultados**. Uma colecção  $\mathcal{F}$  de subconjuntos de  $\Omega$  é uma  $\sigma$ -**álgebra** se as seguintes 3 condições se verificarem:

1.  $\emptyset \in \mathcal{F}$ ,
2.  $A \in \mathcal{F}$  sse  $A^c \in \mathcal{F}$ ,
3.  $\bigcup_n A_n \in \mathcal{F}$  para quaisquer  $A_1, A_2, \dots \in \mathcal{F}$ .

Os elementos de uma  $\sigma$ -álgebra  $\mathcal{F}$  designam-se por **eventos**. Uma **medida de probabilidade** é uma função  $\mathbb{P}: \mathcal{F} \rightarrow [0, 1]$  tal que

$$\mathbb{P}(\emptyset) = 0 \quad \text{e} \quad \mathbb{P}\left(\bigcup_n A_n\right) = \sum_{n=1}^{\infty} \mathbb{P}(A_n),$$

para quaisquer eventos  $A_1, A_2, \dots \in \mathcal{F}$  disjuntos entre si. Ao triplo  $(\Omega, \mathcal{F}, \mathbb{P})$  designamos por **espaço de probabilidade**. Os axiomas que definem um espaço de probabilidade foram introduzidos por Andrey Kolmogorov<sup>1</sup>.

---

<sup>1</sup>Andrey Kolmogorov (1903-1987) foi um matemático russo que fez inúmeras contribuições fundamentais em diversas áreas da matemática

| Variável discreta | $X(\Omega)$          | Distribuição de probabilidade  |
|-------------------|----------------------|--|
| Bernoulli         | $\{0, 1\}$           | $\mathbb{P}(X = 1) = p, \quad p \in [0, 1]$                                |
| Binomial          | $\{0, \dots, n\}$    | $\mathbb{P}(X = k) = C_k^n p^k (1 - p)^{n-k}$                              |
| Poisson           | $\{0, 1, 2, \dots\}$ | $\mathbb{P}(X = k) = e^{-\lambda} \frac{\lambda^k}{k!}, \quad \lambda > 0$ |

Table 1.1: Exemplos de variáveis aleatórias discretas

Uma **variável aleatória** é uma função  $\mathcal{F}$ -mensurável  $X : \Omega \rightarrow \mathbb{R}$ . Ser  **$\mathcal{F}$ -mensurável** significa que a pré-imagem (ou imagem inversa) de qualquer conjunto aberto é um evento de  $\mathcal{F}$ , i.e.,  $X^{-1}(]a, b[) \in \mathcal{F}$  para quaisquer reais  $a < b$ .

A **função de distribuição de probabilidade**<sup>2</sup> de  $X$  é a função  $F_X : \mathbb{R} \rightarrow \mathbb{R}$  definida por

$$F_X(x) = \mathbb{P}(X \leq x).$$

Há duas classes particulares de variáveis aleatórias: discretas e contínuas. Uma variável aleatória diz-se **discreta** se tomar um conjunto contável (finito ou infinito) de valores, isto é,  $X(\Omega) = \{x_1, x_2, \dots\}$ . Uma variável aleatória diz-se **contínua** se  $\mathbb{P}(X = x) = 0$ , ou seja,  $F_X$  é uma função contínua<sup>3</sup>. Se  $F_X$  for continuamente diferenciável, então

$$F_X(x) = \int_{-\infty}^x f_X(u) du,$$

onde  $f_X = F_X'$  é a **densidade de probabilidade** de  $X$ . Nesta disciplina vamos apenas considerar variáveis aleatórias discretas ou contínuas com densidade de probabilidade, também conhecidas por **absolutamente contínuas**. Ver Tabelas 1.1 e 1.2.

Se  $X$  é integrável relativamente a  $\mathbb{P}$  então definimos o **valor esperado** de  $X$  como

$$E(X) = \int_{\Omega} X d\mathbb{P}.$$

No caso de  $X$  ser discreta ou contínua temos que

$$E(X) = \sum_n x_n \mathbb{P}(X = x_n) \quad \text{ou} \quad E(X) = \int_{-\infty}^{\infty} x f_X(x) dx.$$

<sup>2</sup>Relembrar que  $F_X$  é uma função monótona crescente, contínua à direita,  $\lim_{x \rightarrow -\infty} F_X(x) = 0$  e  $\lim_{x \rightarrow \infty} F_X(x) = 1$

<sup>3</sup>Uma vez que  $\mathbb{P}(X = x) = F_X(x) - F_X(x^-)$ .

| Variável contínua | $X(\Omega)$    | Distribuição de probabilidade  |
|-------------------|----------------|--|
| Uniforme          | $[a, b]$       | $f_X(x) = \begin{cases} 1/(b-a) & a \leq x \leq b \\ 0 & \text{caso contrário} \end{cases}$                                      |
| Gaussiana         | $\mathbb{R}$   | $f_X(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}, \quad \sigma > 0, \mu \in \mathbb{R}$ |
| Exponencial       | $[0, +\infty[$ | $f_X(x) = \begin{cases} \lambda e^{-\lambda x} & x \geq 0 \\ 0 & \text{caso contrário} \end{cases}, \quad \lambda > 0$           |

Table 1.2: Exemplos de variáveis aleatórias contínuas

Em geral, definimos o **momento de ordem**  $n$  de  $X$  como  $E(X^n)$  e o **momento central de ordem**  $n$  de  $X$  como  $E((X - \mu)^n)$  onde  $\mu = E(X)$ . Ao momento central de segunda ordem chamamos **variância** de  $X$ ,

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

Da linearidade do valor esperado segue que

$$V(X) = E(X^2) - (E(X))^2.$$

Dado um vector de variáveis aleatórias  $(X_1, \dots, X_n) : \Omega \rightarrow \mathbb{R}^n$  designa-se por  $F_{X_1, \dots, X_n}$  a sua **distribuição de probabilidade conjunta**,

$$F_{X_1, \dots, X_n}(x_1, \dots, x_n) = \mathbb{P}(X_1 \leq x_1, \dots, X_n \leq x_n).$$

Recordar, que duas variáveis aleatórias  $X$  e  $Y$  são **independentes** sse

$$F_{X,Y}(x, y) = F_X(x)F_Y(y).$$

Definimos a covariância de variáveis aleatórias  $X$  e  $Y$  como

$$\text{cov}(X, Y) = E[(X - E(X))(Y - E(Y))].$$

Se  $X$  e  $Y$  são independentes, então  $\text{cov}(X, Y) = 0$ .

**Exercício 1.** Seja  $X$  uma variável aleatória contínua em  $[0, +\infty[$ . Mostre que

$$E(X) = \int_0^\infty \mathbb{P}(X > x) dx$$

**Exercício 2.** Sejam  $X$  e  $Y$  duas variáveis aleatórias independentes com densidade de probabilidade  $f_X$  e  $f_Y$ , respectivamente. Mostre que a densidade de probabilidade de  $Z = X + Y$  é

$$f_Z(z) = \int_{-\infty}^{+\infty} f_X(z - \eta) f_Y(\eta) d\eta$$

## 1.2 Esperança Condicional

A esperança condicional é um conceito central em teoria de probabilidades, em particular no estudo de processos estocásticos. Considere uma variável aleatória  $X : \Omega \rightarrow \mathbb{R}$  definida num espaço de probabilidade  $(\Omega, \mathcal{F}, \mathbb{P})$ . Suponha que desejamos obter a melhor "aproximação" de  $X$  dado que conhecemos alguma informação de  $\mathcal{F}$  (alguns dos seus eventos). A melhor aproximação de  $X$  é num certo sentido dada pela esperança condicional.

**Definição 1.2.1.** Seja  $\mathcal{G}$  uma sub- $\sigma$ -álgebra de  $\mathcal{F}$ , i.e.,  $\mathcal{G} \subset \mathcal{F}$ . A esperança condicional  $E(X|\mathcal{G}) : \Omega \rightarrow \mathbb{R}$  é uma variável aleatória que satisfaz:

1.  $E(X|\mathcal{G})$  é  $\mathcal{G}$ -mensurável,
2. Para todo o evento  $A \in \mathcal{G}$ ,

$$\int_A E(X|\mathcal{G}) d\mathbb{P} = \int_A X d\mathbb{P}.$$

**Observação 1.2.1.** A  $\sigma$ -álgebra  $\mathcal{G}$  representa alguma informação que é conhecida da experiência aleatória. Na definição está implícito que  $X$  é integrável, ou seja,  $E(X) < \infty$ . A existência da esperança condicional é consequência do teorema de Radon-Nikodym.

Usando a definição geral de esperança condicional podemos condicionar  $X$  numa outra variável aleatória  $Y : \Omega \rightarrow \mathbb{R}$ . Chamamos à seguinte coleção de eventos a informação de  $Y$ ,

$$\sigma(Y) = \{Y^{-1}(B) : B \text{ é Boreliano}\}.$$

É fácil verificar que  $\sigma(Y)$  é uma  $\sigma$ -álgebra de  $\Omega$ . De facto, é a menor  $\sigma$ -álgebra que torna  $Y$  mensurável. Assim, define-se a **esperança condicional de  $X$  dado  $Y$**  como

$$E(X|Y) = E(X|\sigma(Y)).$$

Note-se que  $E(X|Y)$  é  $\sigma(Y)$ -mensurável. Portanto,  $E(X|Y)$  é constante nos eventos  $\{Y = y\}$ . Logo, existe uma função  $E(X|Y = y)$  de variável independente  $y$  tal que

$$E(X|Y = y) = E(X|Y)(\omega), \quad \forall \omega \in \{Y = y\}.$$

Vejamos como calcular  $E(X|Y = y)$  quando  $X$  e  $Y$  são discretas ou absolutamente contínuas.

### 1.2.1 Esperança condicional: caso discreto

Seja  $Y : \Omega \rightarrow \mathbb{R}$  uma variável aleatória discreta. Suponha que  $Y(\Omega) = \{y_1, y_2, \dots\}$  e que  $P(Y = y_n) > 0$  para todo o  $n \geq 1$ . A esperança condicional de  $X$  dado  $Y$  é calculada da seguinte forma,

$$E(X|Y = y) = \begin{cases} E(X|Y = y_1), & y = y_1 \\ E(X|Y = y_2), & y = y_2 \\ \vdots \end{cases}$$

onde

$$E(X|Y = y_n) = \frac{1}{\mathbb{P}(Y = y_n)} \int_{\{Y=y_n\}} X d\mathbb{P}.$$

**Exemplo 1.2.2.** Considere duas moedas de 20 e 50 centavos. Lançam-se as moedas ao ar e somam-se os montantes das moedas que ficaram com a face voltada para cima. Esse montante é o valor da variável aleatória  $X$ . Seja  $Y$  a variável aleatória que retorna o montante da primeira moeda, de 20 centavos, caso esta se encontre de face voltada para cima. Caso contrário tem o valor zero. Note-se que

$$\{Y = 0\} = \{EF, EE\} \quad \text{e} \quad \{Y = 20\} = \{FF, FE\},$$

onde  $E$  simboliza escudo e  $F$  face. Então

$$E(X|Y = 0) = 25 \quad \text{e} \quad E(X|Y = 20) = 45.$$

Logo,

$$E(X|Y = y) = \begin{cases} 25 & \text{se } y = 0 \\ 45 & \text{se } y = 20 \end{cases}$$

Suponhamos, tal como no exemplo anterior, que  $X$  é uma variável aleatória discreta (tal como  $Y$ ). Então neste caso definimos a **função de massa de probabilidade condicionada** de  $X$  dado  $Y$ ,

$$p_{X|Y}(x|y) = \frac{\mathbb{P}(X = x, Y = y)}{\mathbb{P}(Y = y)}, \quad \text{se } \mathbb{P}(Y = y) > 0.$$

É usual também escrever-se

$$\mathbb{P}(X = x|Y = y) = p_{X|Y}(x|y).$$

Com esta definição expressa-se  $E(X|Y = y)$  através da fórmula

$$E(X|Y = y) = \sum_n x_n p_{X|Y}(x_n|y).$$

Usando a **lei de probabilidade total**,

$$\mathbb{P}(X = x) = \sum_n p_{X|Y}(x|y_n)\mathbb{P}(Y = y_n)$$

obtemos a seguinte proposição.

**Proposição 1.2.3** (Lei de probabilidade total para a esperança condicional).  
*Sejam  $X$  e  $Y$  duas variáveis aleatórias discretas. Então*

$$E(X) = \sum_n E(X|Y = y_n)\mathbb{P}(Y = y_n)$$

*Demonstração.* Exercício. □

## 1.2.2 Esperança condicional: caso contínuo

Suponhamos agora que  $X$  e  $Y$  são duas variáveis aleatórias absolutamente contínuas com função densidade de probabilidade  $f_X$  e  $f_Y$ , respectivamente. A **função de densidade de probabilidade condicional de  $X$  dado  $Y$**  é definida por

$$f_{X|Y}(x|y) = \frac{f_{X,Y}(x,y)}{f_Y(y)}.$$

A esperança condicional  $E(X|Y = y)$  é calculada da seguinte maneira,

$$E(X|Y = y) = \int_{-\infty}^{+\infty} x f_{X|Y}(x|y) dx.$$

Usando a lei de probabilidade total

$$f_X(x) = \int_{-\infty}^{+\infty} f_{X|Y}(x|y)f_Y(y) dy$$

obtem-se a seguinte proposição.

**Proposição 1.2.4.** *Sejam  $X$  e  $Y$  duas variável aleatória contínuas com função densidade de probabilidade  $f_X$  e  $f_Y$ . Então*

$$E(X) = \int_{-\infty}^{+\infty} E(X|Y = y)f_Y(y) dy$$

**Exemplo 1.2.5.** Suponha que  $X$  e  $Y$  têm a função de distribuição de densidade conjunta

$$f_{X,Y}(x, y) = 1/ye^{-\frac{x}{y}-y}. \quad x, y > 0.$$

Então

$$f_Y(y) = \int_0^{\infty} f_{X,Y}(x, y) dx = e^{-y}.$$

Logo

$$f_{X|Y}(x|y) = 1/ye^{-x/y}.$$

Portanto, a variável aleatória  $X$  condicionada a  $Y = y$  tem distribuição exponencial com parâmetro  $1/y$ . Logo  $E(X|Y = y) = y$ .

### 1.2.3 Esperança condicional: caso vectorial

Dado um vector aleatório  $(Y_1, \dots, Y_n)$  define-se de forma análoga a esperança condicional no caso de discreto,

$$E(X|Y_1 = y_1, \dots, Y_n = y_n) = \sum_k x_k p_{X|Y_1, \dots, Y_n}(x_k|y_1, \dots, y_n),$$

onde

$$p_{X|Y_1, \dots, Y_n}(x|y_1, \dots, y_n) = \frac{\mathbb{P}(X = x, Y_1 = y_1, \dots, Y_n = y_n)}{\mathbb{P}(Y_1 = y_1, \dots, Y_n = y_n)},$$

e no caso contínuo

$$E(X|Y_1 = y_1, \dots, Y_n = y_n) = \int_{-\infty}^{+\infty} x f_{X|Y_1, \dots, Y_n}(x|y_1, \dots, y_n) dx$$

onde

$$f_{X|Y_1, \dots, Y_n}(x|y_1, \dots, y_n) = \frac{f_{X, Y_1, \dots, Y_n}(x, y_1, \dots, y_n)}{f_{Y_1, \dots, Y_n}(y_1, \dots, y_n)}$$

### 1.2.4 Propriedades

A seguinte proposição reúne a principais propriedades da esperança condicional.

**Proposição 1.2.6.** *Sejam  $X, X_1, X_2, Y$  variáveis aleatórias com valor esperado finito e  $g, h : \mathbb{R} \rightarrow \mathbb{R}$  duas funções mensuráveis. A esperança condicional satisfaz as seguintes propriedades:*

1.  $E(\alpha_1 X_1 + \alpha_2 X_2 | \mathcal{G}) = \alpha_1 E(X_1 | \mathcal{G}) + \alpha_2 E(X_2 | \mathcal{G})$ ,
2.  $E(X | \mathcal{G}) \geq 0$  se  $X \geq 0$
3.  $E(g(Y)X | Y = y) = g(y)E(X | Y = y)$
4.  $E(h(X) | Y = y) = E(h(X))$  se  $X$  e  $Y$  forem independentes
5. Se  $\mathcal{H} \subset \mathcal{G} \subset \mathcal{F}$ , então  $E(X | \mathcal{H}) = E(E(X | \mathcal{G}) | \mathcal{H})$ .

*Demonstração.* Procurar na bibliografia. □

Note-se que da propriedade (3) obtém-se

$$E(XY | Y = y) = yE(X | Y = y).$$

No caso de  $X$  e  $Y$  serem independentes, então (4) implica

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

Ou seja, a esperança condicional é uma constante e não depende de  $y$ .

**Exercício 3.** Uma empresa produz diariamente  $N$  componentes electrónicas, onde  $N$  é uma variável aleatória com distribuição de Poisson e parâmetro  $\lambda > 0$ . Cada componente pode ter um defeito, independentemente das restantes, com probabilidade  $p$ . Supomos também que o defeito de cada componente é independente do número  $N$  de componentes electrónicas. Seja  $D$  o número diário de componentes electrónicas com defeito. Determine:

1.  $E(D | N = n)$
2.  $E(D)$
3.  $E(N | D = d)$

# Chapter 2

## Noções gerais de processos estocásticos

### 2.1 Noções gerais

Seja  $(\Omega, \mathcal{F}, \mathbb{P})$  um espaço de probabilidade.

**Definição 2.1.1.** Um **processo estocástico**  $X$  é uma colecção  $X = \{X_t : t \in T\}$  de variáveis aleatórias  $X_t : \Omega \rightarrow \mathbb{R}$  indexadas por um parâmetro  $t \in T \subset \mathbb{R}$ .

Quando o **conjunto dos parâmetros**  $T$  é um conjunto contável, tipicamente  $T = \{0, 1, 2, \dots\}$  ou  $T = \mathbb{Z}$ , então o processo estocástico é de **tempo discreto**. Neste contexto, uma sucessão de variáveis aleatórias  $X_1, X_2, \dots$  é um processo estocástico de tempo discreto.

Quando  $T$  é um intervalo, tipicamente  $T = [0, \infty[$  ou  $T = \mathbb{R}$ , então o processo estocástico é de **tempo contínuo**. Neste contexto, é usual escrever-se  $X(t)$  quando o processo é de tempo contínuo.

Ao conjunto dos valores que as variáveis aleatórias  $X_t$  podem tomar designa-se por  $E$ , o **conjunto dos estados do processo estocástico**. Quando o conjunto dos estados  $E$  é contável (finito ou infinito) então o processo estocástico diz-se **discreto**, caso contrário diz-se **contínuo**.

Para cada  $\omega \in \Omega$  a função

$$T \ni t \mapsto X_t(\omega)$$

é designada por **trajectória** ou **realização** do processo. Uma trajectória de um processo referente a um período limitado de tempo é designada por **série temporal**. Ver Figuras 2.1 e 2.2.

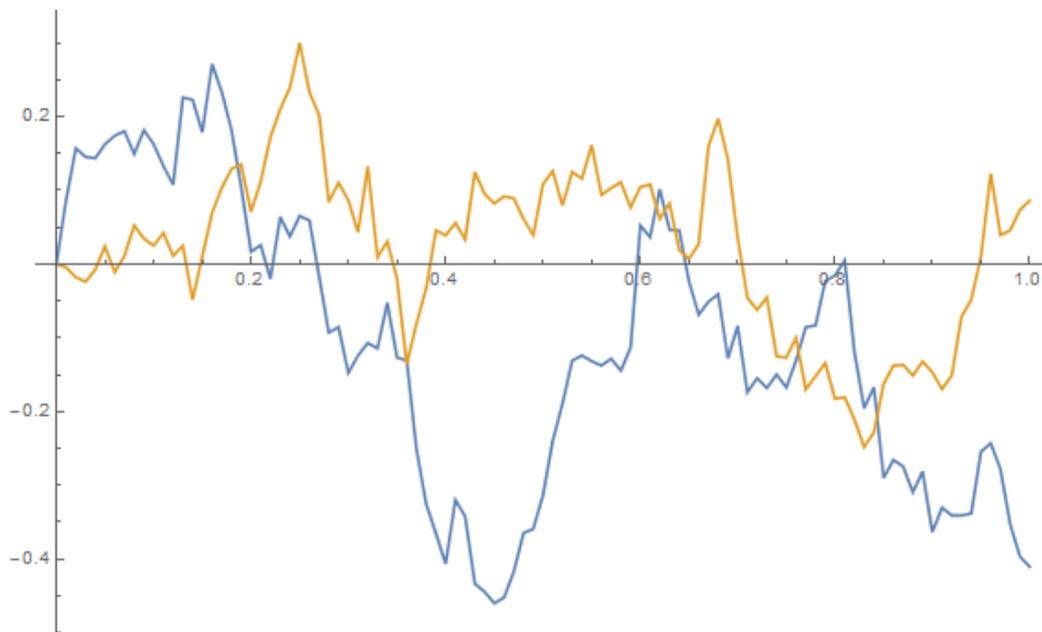


Figure 2.1: Duas realizações de um processo estocástico a tempo contínuo

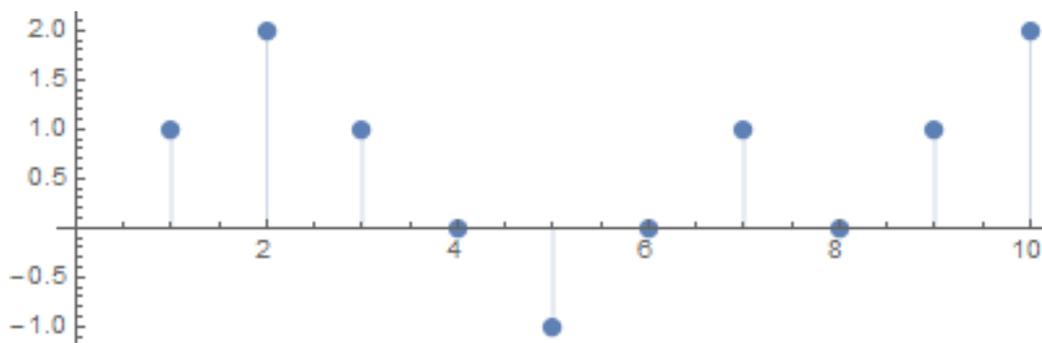


Figure 2.2: Realização de um passeio aleatório

A **lei de probabilidade** do processo estocástico é dada por todas as distribuições de probabilidade conjuntas de um número finito de variáveis aleatórias  $(X_{t_1}, \dots, X_{t_n})$ . Portanto, a lei de probabilidade do processo consiste na família de funções de distribuição de probabilidade conjuntas,

$$F_{X_{t_1}, \dots, X_{t_n}}(x_1, \dots, x_n) = P(X_{t_1} \leq x_1, \dots, X_{t_n} \leq x_n),$$

onde  $t_1, \dots, t_n$  são quaisquer conjunto finito de índices pertencentes a  $T$  e  $n \geq 1$ .

## 2.2 Processos iid

**Definição 2.2.1.** Um processo estocástico  $X = \{X_t : t \in T\}$  é **iid (independente e identicamente distribuído)** se

1. Para todo o conjunto finito de índices  $t_1, \dots, t_n \in T$  com  $n \in \mathbb{N}$ , as variáveis  $X_{t_1}, \dots, X_{t_n}$  são independentes, i.e.,

$$F_{X_{t_1}, \dots, X_{t_n}} = F_{X_{t_1}} \cdots F_{X_{t_n}}$$

2. As variáveis aleatórias são identicamente distribuídas, i.e.,

$$F_{X_t} = F_{X_s}, \quad \forall s, t \in T.$$

**Exemplo 2.2.1** (Passeio aleatório simétrico). Considere a sucessão  $(X_n)_{n \geq 1}$  de variáveis aleatórias independentes e identicamente distribuídas (iid) com distribuição

$$\mathbb{P}(X_n = -1) = \mathbb{P}(X_n = 1) = \frac{1}{2}.$$

Seja

$$S_n = X_1 + \cdots + X_n.$$

O processo estocástico de tempo discreto  $S = \{S_n : n \in \mathbb{N}\}$  é designado por **passeio aleatório simétrico**. Ver Figura 2.2. A variável aleatória  $S_n$  por ser interpretada como o deslocamento até ao instante  $n$ , podendo ser escrita

$$S_n = S_{n-1} + X_n.$$

**Definição 2.2.2.** Dois processos estocásticos  $X = \{X_t : t \in T\}$  e  $Y = \{Y_t : t \in T\}$  dizem-se **identicamente distribuídos** sse tiverem a mesma família de funções de distribuição de probabilidade conjuntas, ou seja,

$$F_{X_{t_1}, \dots, X_{t_n}} = F_{Y_{t_1}, \dots, Y_{t_n}}$$

para todo o conjunto finito de índices  $t_1, \dots, t_n \in T$ .

**Definição 2.2.3.** Dois processos estocásticos  $X = \{X_t : t \in T\}$  e  $Y = \{Y_t : t \in T\}$  dizem-se **independentes** sse os vectores aleatórios

$$(X_{t_1}, \dots, X_{t_n}) \quad \text{e} \quad (Y_{t_1}, \dots, Y_{t_n})$$

são independentes para quaisquer  $t_1, \dots, t_n \in T$  e  $n \in \mathbb{N}$ .

## 2.3 Estacionariedade

Em termos gerais, um processo estacionário é um processo cujas características de aleatoriedade não se alteram ao longo do tempo. Existem diversas definições de estacionariedade.

**Definição 2.3.1.** Um processo  $X_t$  diz-se **estacionário em média** sse

$$E(X_t) = \mu, \quad \forall t \in T.$$

Num processo estacionário em média o seu valor esperado não evolui ao longo do tempo.

**Definição 2.3.2.** Um processo  $X_t$  diz-se de **covariâncias estacionárias** sse

1. Os momentos de segunda ordem são finitos, isto é

$$E(X_t^2) < \infty, \quad \forall t \in T,$$

2. Existe uma função  $\gamma : T \rightarrow \mathbb{R}$  tal que

$$\text{Cov}(X_s, X_t) = \gamma(t - s), \quad \forall s \leq t.$$

**Observação 2.3.1.** Num processo  $X_t$  com covariâncias estacionárias tem-se

$$\text{Var}(X_t) = \gamma(0).$$

Ou seja, a variância do processo não se altera ao longo do tempo.

**Definição 2.3.3.** Um processo  $X_t$  diz-se **estacionário até à segunda ordem** sse for estacionário em média e tiver covariâncias estacionárias.

Uma definição de estacionariedade mais forte que as anteriores é a seguinte.

**Definição 2.3.4.** Um processo  $X_t$  diz-se **fortemente ou estritamente estacionário de ordem**  $k \in \mathbb{N}$  sse para quaisquer instantes  $t_1, \dots, t_k \in T$  e qualquer  $h$  tal que  $t_i + h \in T$ ,  $i = 1, \dots, k$ , os vectores aleatórios  $(X_{t_1}, \dots, X_{t_k})$  e  $(X_{t_1+h}, \dots, X_{t_k+h})$  são identicamente distribuídos.

Chegamos assim à definição de estacionariedade mais forte.

**Definição 2.3.5.** Um processo é **fortemente ou estritamente estacionário** sse for fortemente estacionário de ordem  $k$  para qualquer  $k \in \mathbb{N}$ .

Esta definição de estacionariedade implica todas as outras. Adicionalmente, num processo fortemente estacionário todas as variáveis aleatórias  $X_t$  tem a mesma distribuição. Analogamente, todos os pares  $(X_t, X_s)$  são identicamente distribuídos desde os instantes estejam igualmente espaçados no tempo.

**Exemplo 2.3.2** (Processo de Bernoulli). Sejam  $(X_n)_{n \geq 1}$  variáveis aleatórias iid com distribuição

$$\mathbb{P}(X_n = 1) = p, \quad \mathbb{P}(X_n = 0) = 1 - p$$

onde  $p \in [0, 1]$ . O processo de Bernoulli é fortemente estacionário.

**Exemplo 2.3.3.** Qualquer sucessão de variáveis aleatórias iid é um processo fortemente estacionário.

**Exemplo 2.3.4.** Considere um processo estocástico  $\{X_n : n = 1, 2, \dots\}$  tal que  $E(X_n) = 0$  e  $\text{Var}(X_n) = \sigma^2$  para todo  $n \geq 1$  e  $\text{Cov}(X_n, X_m) = 0$  para  $n \neq m$ . Este processo é estacionário até à segunda ordem, sendo usualmente designado por **ruído branco**.

**Exercício 4.** Seja  $\Omega = \{0, 1, 2\}$  e considere a família de variáveis aleatórias  $X_t : \Omega \rightarrow \mathbb{R}$ ,

$$X_t(\omega) = \omega t, \quad t \geq 0.$$

1. Classifique o processo estocástico  $\{X_t : t \geq 0\}$  indicando o conjunto dos parâmetros  $T$  e o conjuntos dos estados  $E$ .
2. Determine todas as realizações do processo.
3. Calcule  $\mathbb{P}(X_1 = 1, X_2 = 1)$  e  $\mathbb{P}(X_2 = 2 | X_1 = 1)$ .

**Exercício 5.** Seja  $(\xi_n)_{n \geq 1}$  uma sucessão de variáveis aleatórias de Bernoulli independentes e

$$X_n = \min\{k \geq 1 : \xi_1 + \dots + \xi_k = n\}, \quad n \geq 1.$$

1. Supondo que  $\xi_n$  representa o resultado (sucesso ou insucesso) de uma experiência aleatória, descreva o significado da variável aleatória  $X_n$ . Que valores pode tomar?

2. Classifique o processo estocástico  $\{X_n : n \geq 1\}$  indicativo o conjunto dos parâmetros  $T$  e o conjunto dos estados  $E$ .
3. Determine a distribuição de probabilidade de  $X_n$ .
4. Calcule  $\mathbb{P}(X_3 = x_3 | X_2 = x_2)$ .

**Exercício 6.** Seja  $(X_n)_{n \geq 1}$  uma sucessão de variáveis aleatórias iid,  $\theta \in \mathbb{R}$  e  $Y_n = X_n - \theta X_{n-1}$ . Mostre que o processo estocástico  $Y = \{Y_n : n \in \mathbb{N}\}$ , usualmente designado por processo de médias móveis de primeira ordem MA(1), é estacionário até à segunda ordem.

# Chapter 3

## Cadeias de Markov

Seja  $S$  um conjunto contável (finito ou infinito) e  $(\Omega, \mathcal{F}, \mathbb{P})$  um espaço de probabilidade. É frequente tomar  $S = \{0, 1, 2, \dots\}$ .

**Definição 3.0.1.** Uma sucessão de variáveis aleatórias  $(X_n)_{n \geq 0}$  é uma **cadeia de Markov com valores em  $S$**  se

1.  $X_n(\Omega) \subseteq S$  para todo  $n \geq 0$ .
2. Para quaisquer  $j, i_0, \dots, i_n \in S$  e  $n \geq 0$ ,

$$\mathbb{P}(X_{n+1} = j | X_0 = i_0, X_1 = i_1, \dots, X_n = i_n) = \mathbb{P}(X_{n+1} = j | X_n = i_n).$$

Note-se que as variáveis aleatórias  $X_n$  são discretas e as probabilidades condicionadas são calculadas de acordo com as expressões da secção anterior.

A equação da definição anterior é conhecida como a **propriedade de Markov**. Uma cadeia de Markov não tem memória do passado. A probabilidade de um estado futuro depende exclusivamente do estado presente.

### 3.1 Probabilidades de transição

A probabilidade de  $X_{n+1}$  estar no estado  $j$  dado que  $X_n$  está no estado  $i$  é conhecida como a probabilidade de transição a 1 passo,

$$P_{i,j}^n = \mathbb{P}(X_{n+1} = j | X_n = i), \quad i, j \in S.$$

**Definição 3.1.1.** Uma cadeia de Markov diz-se homogénea se  $P_{i,j}^n$  não depende de  $n$ .

Vamos apenas considerar cadeias de Markov homogêneas. Neste caso escrevemos  $P_{i,j}$  para denotar as probabilidades de transição e definimos a **matriz de probabilidades de transição**:

$$P = (P_{i,j})_{i,j \in S}.$$

**Proposição 3.1.1.** *A matriz de probabilidades de transição  $P$  satisfaz as seguintes propriedades:*

1.  $P_{i,j} \geq 0$  para quaisquer  $i, j \in S$ ,
2. A soma das linhas de  $P$  é igual a 1, ou seja,

$$\sum_{j \in S} P_{i,j} = 1.$$

*Demonstração.* A propriedade (1) é óbvia. Para demonstrar (2) note-se que

$$\begin{aligned} \sum_{j \in S} P_{i,j} &= \sum_{j \in S} \mathbb{P}(X_{n+1} = j | X_n = i) \\ &= \frac{1}{\mathbb{P}(X_n = i)} \sum_{j \in S} \mathbb{P}(X_{n+1} = j, X_n = i) \\ &= 1 \end{aligned}$$

□

Uma matriz que satisfaz (1) e (2) da proposição anterior diz-se **estocástica**.

Suponhamos que  $p_{i_0} = \mathbb{P}(X_0 = i_0)$ . Dados estados  $i_1, \dots, i_n \in S$ , como calcular as distribuições conjuntas

$$\mathbb{P}(X_0 = i_0, X_1 = i_1, \dots, X_n = i_n) \quad ?$$

Usando a definição de probabilidade condicionada,

$$\begin{aligned} \mathbb{P}(X_0 = i_0, \dots, X_n = i_n) &= \mathbb{P}(X_n = i_n | X_0 = i_0, \dots, X_{n-1} = i_{n-1}) \\ &\quad \times \mathbb{P}(X_0 = i_0, \dots, X_{n-1} = i_{n-1}). \end{aligned}$$

Pela propriedade de Markov,

$$\mathbb{P}(X_n = i_n | X_0 = i_0, \dots, X_{n-1} = i_{n-1}) = \mathbb{P}(X_n = i_n | X_{n-1} = i_{n-1}) = P_{i_{n-1}, i_n}.$$

Logo,

$$\mathbb{P}(X_0 = i_0, \dots, X_n = i_n) = P_{i_{n-1}, i_n} \mathbb{P}(X_0 = i_0, \dots, X_{n-1} = i_{n-1}).$$

Iterando esta equação obtemos a seguinte proposição.

**Proposição 3.1.2.**

$$\mathbb{P}(X_0 = i_0, X_1 = i_1, \dots, X_n = i_n) = p_{i_0} P_{i_1, i_2} \cdots P_{i_{n-1}, i_n}.$$

Esta proposição demonstra que todas as distribuições finitas da cadeia de Markov são determinadas pelas probabilidades de transição da matriz  $P$ .

**Exemplo 3.1.3.** Considere uma cadeia de Markov com três estados  $S = \{0, 1, 2\}$  e com a seguinte matriz de transição

$$P = \begin{pmatrix} 1/4 & 1/4 & 1/2 \\ 9/10 & 1/10 & 0 \\ 1/3 & 1/3 & 1/3 \end{pmatrix}.$$

Considere a distribuição inicial  $\pi_0 = (p_0, p_1, p_2)$  onde

$$p_0 = \mathbb{P}(X_0 = 0) = 3/10, \quad p_1 = \mathbb{P}(X_0 = 1) = 2/5 \quad \text{e} \quad p_2 = \mathbb{P}(X_0 = 2) = 3/10.$$

Logo,

$$\mathbb{P}(X_0 = 0, X_1 = 1, X_2 = 2) = p_0 P_{0,1} P_{1,2} = 0,$$

e

$$\mathbb{P}(X_1 = 1, X_2 = 1 | X_0 = 2) = P_{2,1} P_{1,1} = 1/30.$$

**Exemplo 3.1.4** (Passeio Aleatório). Considere a sucessão  $(\xi_n)_{n \geq 0}$  de variáveis aleatórias iid com distribuição

$$\mathbb{P}(\xi_n = 1) = p \quad \text{e} \quad \mathbb{P}(\xi_n = -1) = 1 - p,$$

onde  $0 < p < 1$ . Seja

$$X_n = \xi_0 + \cdots + \xi_n.$$

O processo estocástico de tempo discreto  $X = \{X_n : n \in \mathbb{N}\}$  é designado por **passeio aleatório**. Vamos mostrar que  $(X_n)_{n \geq 0}$  é uma cadeia de Markov homogênea. Em primeiro lugar, o espaço dos estados é  $S = \mathbb{Z}$ . Verifiquemos agora a propriedade de Markov:

$$\begin{aligned} \mathbb{P}(X_{n+1} = j | X_0 = i_0, \dots, X_n = i_n) &= \mathbb{P}(X_n + \xi_{n+1} = j | X_0 = i_0, \dots, X_n = i_n) \\ &= \mathbb{P}(\xi_{n+1} = j - i_n | X_0 = i_0, \dots, X_n = i_n) \\ &= \mathbb{P}(\xi_{n+1} = j - i_n). \end{aligned}$$

Por outro lado,

$$\begin{aligned} \mathbb{P}(X_{n+1} = j | X_n = i_n) &= \mathbb{P}(X_n + \xi_{n+1} = j | X_n = i_n) \\ &= \mathbb{P}(\xi_{n+1} = j - i_n | X_n = i_n) \\ &= \mathbb{P}(\xi_{n+1} = j - i_n). \end{aligned}$$

Logo,

$$\mathbb{P}(X_{n+1} = j | X_0 = i_0, \dots, X_n = i_n) = \mathbb{P}(X_{n+1} = j | X_n = i_n).$$

Assim, temos as seguintes probabilidades de transição:

$$P_{i,j} = \mathbb{P}(X_{n+1} = j | X_n = i) = \begin{cases} p & \text{se } j = i + 1 \\ 1 - p & \text{se } j = i - 1 \\ 0 & \text{caso contrário} \end{cases}$$

**Exemplo 3.1.5** (Incrementos iid). Generalizando o exemplo anterior, é possível demonstrar que qualquer sucessão de variáveis aleatórias discretas  $(X_n)_{n \geq 0}$  com incrementos iid, isto é:

1. As variáveis aleatórias  $X_{n+1} - X_n$ ,  $n \geq 0$  são independentes;
2. As variáveis aleatórias  $X_{n+1} - X_n$  têm todas a mesma distribuição de probabilidade;

então  $(X_n)_{n \geq 0}$  é uma cadeia de Markov homogênea.

Importante no estudo das cadeias de Markov são as probabilidades de transição a  $n$  passos,

$$P_{i,j}^{(n)} = \mathbb{P}(X_n = j | X_0 = i).$$

**Proposição 3.1.6** (Equação de Chapman-Kolmogorov).

$$P_{i,j}^{(n)} = \sum_{k \in S} P_{i,k} P_{k,j}^{(n-1)},$$

onde

$$P_{i,j}^{(0)} = \begin{cases} 1, & i = j, \\ 0, & i \neq j \end{cases}$$

*Demonstração.*

$$\begin{aligned}
P_{i,j}^{(n)} &= \mathbb{P}(X_n = j | X_0 = i) \\
&= \sum_{k \in S} \mathbb{P}(X_n = j, X_1 = k | X_0 = i) \\
&= \sum_{k \in S} \mathbb{P}(X_n = j | X_1 = k, X_0 = i) \mathbb{P}(X_1 = k | X_0 = i) \\
&= \sum_{k \in S} \mathbb{P}(X_n = j | X_1 = k) \mathbb{P}(X_1 = k | X_0 = i) \\
&= \sum_{k \in S} \mathbb{P}(X_{n-1} = j | X_0 = k) \mathbb{P}(X_1 = k | X_0 = i) \\
&= \sum_{k \in S} P_{i,k} P_{k,j}^{(n-1)}
\end{aligned}$$

□

Definindo a **matriz de transição a  $n$  passos**

$$P^{(n)} = (P_{i,j}^{(n)})_{i,j \in S}$$

as equação de Chapman-Kolmogorov pode ser escrita de forma matricial,

$$P^{(n)} = P \dots P$$

como o produto de  $n$  cópias da matriz  $P$ .

**Proposição 3.1.7.** *Suponha que  $X_0$  tem distribuição  $\pi_0 = (\pi_{0,i})_{i \in S}$  onde  $\pi_{0,i} = \mathbb{P}(X_0 = i)$ . Então a distribuição  $\pi_n$  de  $X_n$  é*

$$\pi_n = \pi_0 P^{(n)}$$

*Demonstração.*

$$\mathbb{P}(X_n = j) = \sum_i \mathbb{P}(X_n = j | X_0 = i) \mathbb{P}(X_0 = i) = \sum_i \pi_{0,i} P_{i,j}^{(n)}$$

Logo,

$$\pi_n = \pi_0 P^{(n)}$$

onde  $\pi_n = (\pi_{n,j})_{j \in S}$  e  $\pi_{n,j} = \mathbb{P}(X_n = j)$ .

□

**Exemplo 3.1.8.** Usando a matriz de transição do Exemplo 3.1.3 podemos calcular, usando a Proposição 3.1.7, a distribuição de  $X_1$  sabendo a distribuição de  $X_0$ . Suponhamos que a distribuição de  $X_0$  é

$$\pi_0 = (4/9 \quad 5/9 \quad 0).$$

Então  $X_1$  tem distribuição,

$$\begin{aligned} \pi_1 = \pi_0 P &= (4/9 \quad 5/9 \quad 0) \begin{pmatrix} 1/4 & 1/4 & 1/2 \\ 9/10 & 1/10 & 0 \\ 1/3 & 1/3 & 1/3 \end{pmatrix} \\ &= (11/18 \quad 1/6 \quad 2/9) \end{aligned}$$

**Exemplo 3.1.9.** Considere a seguinte matriz estocástica

$$P = \begin{pmatrix} 1/2 & 1/2 \\ 1 & 0 \end{pmatrix},$$

associada a uma cadeia de Markov com dois estados  $S = \{0, 1\}$ . Então

$$P^2 = \begin{pmatrix} 3/4 & 1/4 \\ 1/2 & 1/2 \end{pmatrix} \quad \text{e} \quad P^3 = \begin{pmatrix} 5/8 & 3/8 \\ 3/4 & 1/4 \end{pmatrix}.$$

Note-se que  $\mathbb{P}(X_1 = 1 | X_0 = 1) = 0$ , mas  $\mathbb{P}(X_n = 1 | X_0 = 1) > 0$  para  $n = 2, 3$ . Pode-se calcular, por exemplo diagonalizando a matriz  $P$ , a potência

$$P^n = \begin{pmatrix} \frac{2}{3} - \frac{1}{3}(-1)^{n+1}2^{-n} & \frac{1}{3} + \frac{1}{3}(-1)^{n+1}2^{-n} \\ \frac{2}{3} - \frac{1}{3}(-1)^n 2^{1-n} & \frac{1}{3} + \frac{1}{3}(-1)^n 2^{1-n} \end{pmatrix}.$$

Concluimos que

$$\lim_{n \rightarrow +\infty} \mathbb{P}(X_n = 0 | X_0 = 0) = \frac{2}{3} \quad \text{e} \quad \lim_{n \rightarrow +\infty} \mathbb{P}(X_n = 1 | X_0 = 0) = \frac{1}{3}.$$

**Exercício 7.** Seja  $0 < p < 1$ . Considere  $X_0 = 0$  e

$$X_n = X_{n-1} + \xi_n, \quad n = 1, 2, \dots$$

onde  $(\xi_n)_{n \geq 1}$  é uma sucessão iid de variáveis aleatórias com distribuição

$$\mathbb{P}(\xi_n = 1) = p, \quad \mathbb{P}(\xi_n = 0) = 1 - p.$$

1. Mostre que  $(X_n)_{n \geq 0}$  é uma cadeia de Markov.

2. Determine a matriz de transição da cadeia.
3. Desenhe o diagrama da cadeia.
4. Calcule  $\mathbb{P}(X_2 = 1)$ .
5. Mostre usando indução que

$$\mathbb{P}(X_n = j | X_0 = 0) = C_j^n p^j (1-p)^{n-j}.$$

**Exemplo 3.1.10** (Aplicação: Modelo de provisionamento). Considere um determinado artigo que é provisionado de modo a satisfazer determinada procura. Assumimos que a reposição do artigo é realizado no final de cada período  $n = 0, 1, 2, \dots$ , e que a procura total do produto em cada período é uma variável aleatória  $\xi_n$  com distribuição de probabilidade,

$$\mathbb{P}(\xi_n = k) = a_k, \quad k = 0, 1, 2, \dots$$

Claro que  $a_k \geq 0$  e  $\sum_k a_k = 1$ . Assumimos também que as procuras nos diversos períodos são independentes, ou seja, as variáveis  $\xi_n$  são independentes.

O nível de stock do artigo é examinado no final de cada período. Suponhamos que o nível de stock máximo é  $m > 0$ . A reposição do artigo é feita de acordo com um valor crítico não-negativo  $s < m$ . Seja  $X_n$  a quantidade de artigos no final do período  $n$ . Então a reposição segue a regra,

$$X_{n+1} = \begin{cases} X_n - \xi_{n+1} & \text{se } s < X_n \\ m - \xi_{n+1} & \text{se } X_n \leq s \end{cases}.$$

Note-se que os estados do processo são

$$S = \{\dots, -3, -2, -1, 0, 1, \dots, m-1, m\}.$$

É fácil verificar que  $(X_n)_{n \geq 0}$  satisfaz a propriedade de Markov. Portanto,  $(X_n)_{n \geq 0}$  é uma cadeia de Markov em  $S$ . As probabilidades de transição podem ser calculadas explicitamente,

$$\begin{aligned} P_{i,j} = \mathbb{P}(X_{n+1} = j | X_n = i) &= \begin{cases} \mathbb{P}(X_n - \xi_{n+1} = j | X_n = i) & \text{se } X_n > s \\ \mathbb{P}(m - \xi_{n+1} = j | X_n = i) & \text{se } X_n \leq s \end{cases} \\ &= \begin{cases} \mathbb{P}(\xi_{n+1} = i - j) & \text{se } i > s \\ \mathbb{P}(\xi_{n+1} = m - j) & \text{se } i \leq s \end{cases} \\ &= \begin{cases} a_{i-j} & \text{se } i > s \\ a_{m-j} & \text{se } i \leq s \end{cases} \end{aligned}$$

Quantidades relevantes num modelo de aprovisionamento são a probabilidade de a procura exceder a oferta no longo prazo,

$$\lim_{n \rightarrow \infty} \sum_{j < 0} \mathbb{P}(X_n = j),$$

e o nível médio do stock no longo prazo,

$$\lim_{n \rightarrow \infty} \sum_{j > 0} j \mathbb{P}(X_n = j).$$

Estas questões mostram que é importante estudar o comportamento assimp-tótico da distribuição de  $X_n$ .

**Exemplo 3.1.11** (Aplicação: Filas de espera). Considere um serviço onde os clientes chegam e tomam o seu lugar numa fila de espera. Durante cada período  $n = 0, 1, 2, \dots$ , um único cliente é servido, desde que haja clientes na fila de espera para serem servidos. Durante cada período em que é realizado um serviço novos clientes chegam e tomam o seu lugar na fila de espera. Suponhamos que o número de clientes que chega no período  $n$  é uma variável aleatória com distribuição,

$$\mathbb{P}(\xi_n = k) = a_k, \quad k = 0, 1, 2, \dots$$

Claro que  $a_k \geq 0$  e  $\sum_k a_k = 1$ . Supomos também que as variáveis  $\xi_n$  são independentes. Se  $X_n$  é o número de clientes na fila de espera no início do período  $n$ , então

$$X_{n+1} = \begin{cases} X_n - 1 + \xi_n & \text{se } X_n \geq 1 \\ \xi_n & \text{se } X_n = 0 \end{cases}.$$

É fácil verificar que  $(X_n)_{n \geq 0}$  é uma cadeia de Markov no espaço de estados  $S = \{0, 1, 2, \dots\}$ . As probabilidades de transição podem ser calculadas explicitamente,

$$\begin{aligned} P_{i,j} = \mathbb{P}(X_{n+1} = j | X_n = i) &= \begin{cases} \mathbb{P}(X_n - 1 + \xi_n = j | X_n = i) & \text{se } X_n \geq 1 \\ \mathbb{P}(\xi_n = j | X_n = i) & \text{se } X_n = 0 \end{cases} \\ &= \begin{cases} \mathbb{P}(\xi_n = j + 1 - i) & \text{se } i \geq 1 \\ \mathbb{P}(\xi_n = j) & \text{se } i = 0 \end{cases} \\ &= \begin{cases} a_{j+1-i} & \text{se } i \geq 1 \\ a_j & \text{se } i = 0 \end{cases} \end{aligned}$$

Colocando as probabilidades de transição numa matriz estocástica obtemos,

$$P = \begin{pmatrix} a_0 & a_1 & a_2 & a_3 & \cdots \\ a_0 & a_1 & a_2 & a_3 & \cdots \\ 0 & a_0 & a_1 & a_2 & \cdots \\ 0 & 0 & a_0 & a_1 & \cdots \\ \vdots & \vdots & \vdots & \vdots & \ddots \end{pmatrix}.$$

É intuitivamente claro que se o valor esperado do número de novos clientes que chegam à fila de espera for maior que 1, isto é,

$$E(\xi_n) = \sum_{k=0}^{\infty} k a_k > 1,$$

então com o passar do tempo o número de clientes na fila de espera cresce sem limite. No entanto, se  $E(\xi_n) < 1$ , então as probabilidades de transição a  $n$  passos convergem para uma distribuição limite,

$$\lim_{n \rightarrow \infty} \mathbb{P}(X_n = k | X_0 = j) = \pi_k > 0, \quad k = 0, 1, 2, \dots$$

independente de  $j$ . Quantidades relevantes no estudo de filas de espera são a probabilidade de a longo prazo não haver clientes na fila de espera,  $\pi_0$ , e o tempo médio, a longo prazo, que um cliente espera na fila,

$$\sum_{k=0}^{\infty} (1+k)\pi_k.$$

**Exercício 8.** Uma cadeia de Markov  $(X_n)_{n \geq 0}$  com estados  $S = \{0, 1, 2\}$  tem a seguinte matriz de transição

$$P = \begin{pmatrix} 0.1 & 0.1 & 0.8 \\ 0.2 & 0.2 & 0.6 \\ 0.3 & 0.3 & 0.4 \end{pmatrix}.$$

Calcule:

1.  $\mathbb{P}(X_3 = 1 | X_1 = 0)$
2.  $\mathbb{P}(X_2 = 1 | X_0 = 0)$
3.  $\mathbb{P}(X_3 = 1, X_2 = 1, X_1 = 0)$

**Exercício 9.** Considere um modelo de provisionamento (descrito no Exemplo 3.1.10) onde apenas 0, 1, ou 2 artigos são procurados em cada período ( $a_k = 0$  para  $k \geq 3$ ) com probabilidade

$$\mathbb{P}(\xi_n = 0) = \frac{1}{2}, \quad \mathbb{P}(\xi_n = 1) = \frac{2}{5} \quad \text{e} \quad \mathbb{P}(\xi_n = 2) = \frac{1}{10}.$$

Suponha que  $s = 0$  e  $m = 2$ .

1. Determine a matriz de transição de probabilidades  $P$  para a cadeia de Markov  $(X_n)_{n \geq 0}$  onde  $X_n$  é o número de artigos em stock no fim do período  $n$ . (Dica:  $S = \{2, 1, 0, -1\}$ .)
2. Calcule  $\mathbb{P}(X_2 = 1, X_1 = 2 | X_0 = 0)$ .
3. Calcule  $\mathbb{P}(X_3 = 0 | X_1 = 1)$ .

## 3.2 Recorrência

Seja  $(X_n)_{n \geq 0}$  uma cadeia de Markov homogênea com espaço de estados  $S$ .

**Definição 3.2.1.** Um estado  $i \in S$  diz-se **recorrente** se a cadeia  $X_n$  eventualmente regressa a  $i$  partindo de  $i$ , ou seja,

$$r_i := \mathbb{P}(X_n = i \text{ para algum } n \geq 1 | X_0 = i) = 1.$$

Um estado não recorrente diz-se **transiente**. Note-se que  $r_i$  é a probabilidade de a cadeia **reentrar** no estado  $i$  algures no futuro.

Considere a seguinte variável aleatória

$$T_i = \min\{n \geq 1 : X_n = i\}.$$

A variável aleatória  $T_i : \Omega \rightarrow \mathbb{N} \cup \{+\infty\}$  devolve o tempo que a cadeia demora até visitar o estado  $i$  independentemente do estado de partida. A variável  $T_i$  é conhecida por **tempo de paragem** ou **primeiro tempo de retorno a  $i$** . Podemos calcular a sua distribuição de probabilidade:

$$\mathbb{P}(T_i = n) = \mathbb{P}(X_1 \neq i, \dots, X_{n-1} \neq i, X_n = i)$$

e

$$\mathbb{P}(T_i = +\infty) = \mathbb{P}(X_1 \neq i, X_2 \neq i, X_3 \neq i, \dots).$$

Da igualdade dos eventos,

$$\{X_n = i \text{ para algum } n \geq 1\} = \bigcup_{n \geq 1} \{X_1 \neq i, \dots, X_{n-1} \neq i, X_n = i\},$$

concluimos que a probabilidade de a cadeia reentrar no estado  $i$  é dada por

$$r_i = \sum_{n=1}^{\infty} \mathbb{P}(T_i = n | X_0 = i).$$

Assim, obtemos o seguinte critério para a recorrência.

**Proposição 3.2.1.** *Um estado  $i \in S$  é recorrente sse*

$$\mathbb{P}(T_i < +\infty | X_0 = i) = 1.$$

Portanto, um estado  $i \in S$  é recorrente se a probabilidade de a cadeia demorar tempo infinito para regressar a  $i$  é igual a zero, ou seja,

$$\mathbb{P}(T_i = +\infty | X_0 = i) = 0.$$

Na prática há um critério mais simples para determinar se um estado é recorrente ou transiente. Esse critério, baseado nas probabilidades de transição  $P_{i,i}^{(n)}$  a  $n$  passos, é obtido da seguinte forma.

Seja  $N_i$  a variável aleatória que conta o número de visitas ao estado  $i$ , ou seja,

$$N_i = \sum_{n=0}^{\infty} \chi_{\{X_n=i\}} = \chi_{\{X_0=i\}} + \chi_{\{X_1=i\}} + \dots$$

onde  $\chi_{\{X_n=i\}}$  é uma variável aleatória (função indicadora) que toma valor 1 se  $X_n = i$  ou valor 0 caso contrário.

**Lemma 3.2.2** (Valor médio do número de reentradas em  $i$ ).

$$E(N_i | X_0 = i) = \frac{1}{1 - r_i}.$$

*Demonstração.* A probabilidade de a cadeia reentrar exactamente  $n$  vezes no estado  $i$  é

$$\mathbb{P}(N_i = n | X_0 = i) = r_i^{n-1}(1 - r_i).$$

Logo,

$$\begin{aligned}
E(N_i|X_0 = i) &= \sum_{n=1}^{\infty} n\mathbb{P}(N_i = n|X_0 = i) \\
&= \sum_{n=1}^{\infty} nr_i^{n-1}(1 - r_i) \\
&= (1 - r_i) \sum_{n=1}^{\infty} nr_i^{n-1} \\
&= (1 - r_i) \frac{1}{(1 - r_i)^2} \\
&= \frac{1}{1 - r_i}.
\end{aligned}$$

A soma da série anterior pode ser obtida derivando em ordem a  $x$  ambos os lados da igualdade,

$$\frac{1}{1 - x} = \sum_{n=0}^{\infty} x^n, \quad |x| < 1.$$

□

Usando o lemma anterior obtemos o seguinte critério para determinar se um estado é recorrente ou transiente.

**Teorema 3.2.3.** *Um estado  $i \in S$  é recorrente sse*

$$\sum_{n=1}^{\infty} P_{i,i}^{(n)} = +\infty.$$

*Demonstração.* Note-se que  $E(\chi_{\{X_n=i\}}) = \mathbb{P}(X_n = i)$ . Logo, segue da definição da variável  $N_i$  que

$$\begin{aligned}
E(N_i|X_0 = i) &= \sum_{n=0}^{\infty} E(\chi_{\{X_n=i\}}|X_0 = i) \\
&= \sum_{n=0}^{\infty} \mathbb{P}(X_n = i|X_0 = i) \\
&= \sum_{n=0}^{\infty} P_{i,i}^{(n)}.
\end{aligned}$$

Portanto, do lemma anterior concluímos que

$$\sum_{n=0}^{\infty} P_{i,i}^{(n)} = \frac{1}{1 - r_i}.$$

Assim,  $r_1 = 1$  (estado  $i$  recorrente) se e só se  $\sum_n P_{i,i}^{(n)} = +\infty$ . □

Note-se que  $i \in S$  é transiente se e só se

$$E(N_i | X_0 = i) = \sum_{n=1}^{\infty} P_{i,i}^{(n)} < +\infty.$$

Portanto, se  $i \in S$  é transiente, então  $\lim_{n \rightarrow +\infty} P_{i,i}^{(n)} = 0$ . Por outro lado, o valor médio do número de reentradas em  $i$  é finito, portanto

$$\mathbb{P}(X_n = i \text{ para uma infinidade de } n \geq 1 | X_0 = i) = 0.$$

Concluimos que uma cadeia de Markov entra apenas um número finito de vezes em qualquer estado transiente<sup>1</sup>.

Usando os mesmos argumentos da prova do Teorema 3.2.3 obtemos a seguinte condição necessária para um estado ser transiente (ou suficiente para ser recorrente).

**Corolário 3.2.4.** *Se  $j \in S$  é transiente, então*

$$\sum_{n=1}^{\infty} P_{i,j}^{(n)} < +\infty, \quad \forall i \in S.$$

*Demonstração.* Por um lado temos,

$$E(N_j | X_0 = i) = \sum_{n=1}^{\infty} P_{i,j}^{(n)}.$$

Por outro lado,

$$E(N_j | X_0 = i) \leq \frac{1}{1 - r_j}.$$

Logo, se  $r_j < 1$  ( $j$  transiente), então  $\sum_n P_{i,j}^{(n)} < +\infty$ . □

**Exemplo 3.2.5.** Considere uma cadeia de Markov com dois estados  $\{0, 1\}$  e matriz de transição

$$P = \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix}.$$

---

<sup>1</sup>É possível mostrar que se  $i$  é recorrente então  $\mathbb{P}(X_n = i \text{ para uma infinidade de } n \geq 1 | X_0 = i) = 1$ . No entanto, a demonstração é bastante complicada.

Então

$$P^n = \begin{cases} P, & \text{se } n \text{ é ímpar} \\ I, & \text{se } n \text{ é par} \end{cases}$$

onde  $I$  é a matriz identidade. Logo,

$$\sum_{n=1}^{\infty} P_{0,0}^{(n)} = +\infty \quad \text{e} \quad \sum_{n=1}^{\infty} P_{1,1}^{(n)} = +\infty.$$

Portanto, os dois estados são recorrentes.

**Exemplo 3.2.6.** Considere uma cadeia de Markov com dois estados  $\{0, 1\}$  e matriz de transição

$$P = \begin{pmatrix} \frac{1}{2} & \frac{1}{2} \\ 0 & 1 \end{pmatrix}.$$

Então

$$P^n = \begin{pmatrix} \frac{1}{2^n} & 1 - \frac{1}{2^n} \\ 0 & 1 \end{pmatrix}$$

Assim,

$$\sum_{n=1}^{\infty} P_{0,0}^{(n)} = 1 \quad \text{e} \quad \sum_{n=1}^{\infty} P_{1,1}^{(n)} = +\infty.$$

Portanto, 0 é transiente e 1 é recorrente.

É fácil ver que se o espaço de estados é finito, ou seja, a cadeia de Markov contém apenas um número finito de estados, então existe sempre um estado recorrente.

**Proposição 3.2.7.** *Se o espaço de estados  $S$  é finito, então existe um estado  $i \in S$  que é recorrente.*

*Demonstração.* Suponhamos por absurdo que todos os estados  $j \in S$  da cadeia de Markov são transientes, ou seja, usando o Corolário 3.2.4,

$$\sum_{n=1}^{\infty} P_{i,j}^{(n)} < +\infty, \quad \forall i \in S.$$

Logo,

$$\sum_{j \in S} \sum_{n=1}^{\infty} P_{i,j}^{(n)} < +\infty.$$

No entanto,

$$\sum_{j \in S} \sum_{n=1}^{\infty} P_{i,j}^{(n)} = \sum_{n=1}^{\infty} \sum_{j \in S} P_{i,j}^{(n)} = \sum_{n=1}^{\infty} 1 = +\infty,$$

o que é absurdo. □

**Exemplo 3.2.8.** Considere uma cadeia de Markov com espaço de estados contável (infinito)  $S = \{0, 1, 2, \dots\}$  e matriz de transição

$$P = \begin{pmatrix} a_{0,0} & a_{0,1} & a_{0,2} & a_{0,3} & a_{0,4} & \cdots \\ 0 & a_{1,1} & a_{1,2} & a_{1,3} & a_{1,4} & \cdots \\ 0 & 0 & a_{2,2} & a_{2,3} & a_{2,4} & \cdots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \ddots \end{pmatrix},$$

onde  $0 < a_{i,j} < 1$ . Uma vez que  $P$  é triangular superior, é fácil calcular as probabilidades de transição  $P_{i,i}^{(n)}$  a  $n$  passos,

$$P_{i,i}^{(n)} = a_{i,i}^n, \quad i = 0, 1, 2, \dots$$

Assim,

$$\sum_{n=1}^{\infty} P_{i,i}^{(n)} = \sum_{n=1}^{\infty} a_{i,i}^n = \frac{a_{i,i}}{1 - a_{i,i}} < +\infty.$$

Logo, todos os estados da cadeia de Markov são transientes, ou seja, não há estados recorrentes!

**Exemplo 3.2.9** (Assimétrico). Considere o passeio aleatório assimétrico. Trata-se de uma cadeia de Markov com espaço de estados  $S = \mathbb{Z}$  e probabilidades de transição

$$P_{i,j} = \begin{cases} p, & \text{se } j = i + 1 \\ 1 - p, & \text{se } j = i - 1 \\ 0, & \text{caso contrário} \end{cases}$$

onde  $p \neq \frac{1}{2}$ . É fácil calcular a probabilidade de transição  $P_{i,i}^{(n)}$ . No caso em que  $n$  é par,  $n = 2k$ , obtemos,

$$\begin{aligned} P_{i,i}^{(2k)} &= \mathbb{P}(X_{2k} = i | X_0 = i) = C_k^{2k} p^k (1-p)^k \\ &= \frac{(2k)!}{(k!)^2} p^k (1-p)^k \end{aligned}$$

e no caso em que  $n$  é ímpar obtemos  $P_{i,i}^{(2k+1)} = 0$ . Logo, como  $p \neq \frac{1}{2}$ , a série converge,

$$\sum_{n=1}^{\infty} P_{i,i}^{(n)} = \sum_{k=1}^{\infty} \frac{(2k)!}{(k!)^2} p^k (1-p)^k < +\infty$$

pelo critério d'Alembert (ou critério da razão) para séries,

$$\frac{P_{i,i}^{(2k+2)}}{P_{i,i}^{(2k)}} = \frac{(2k+2)(2k+1)}{(k+1)^2} p(1-p) \xrightarrow{k \rightarrow \infty} 4p(1-p) < 1$$

porque  $p \neq \frac{1}{2}$ . Assim, concluímos que todos os estados do passeio aleatório assimétrico são transientes. O caso simétrico  $p = \frac{1}{2}$  tem de ser analisado separadamente.

Os estados recorrentes dividem-se em dois tipos: os estados recorrentes com tempo finito de retorno e os estados recorrentes com tempo infinito de retorno. Os primeiros designam-se por **recorrentes positivos**.

**Definição 3.2.2.** Um estado recorrente  $i \in S$  é **recorrente positivo** se o tempo médio de reentrada é finito,

$$m_i := E(T_i | X_0 = i) < +\infty.$$

Caso contrário dizemos que  $i$  é **recorrente nulo**.

Note-se que

$$m_i = \left( \sum_{n=1}^{\infty} n \mathbb{P}(T_i = n | X_0 = i) \right) + \infty \cdot \mathbb{P}(T_i = +\infty | X_0 = i).$$

Logo, se  $i$  é transiente, ou seja,  $\mathbb{P}(T_i = +\infty | X_0 = i) > 0$ , então  $m_i = +\infty$ . Portanto, se o tempo médio de reentrada é finito então o estado é recorrente.

O seguinte resultado estabelece um critério para decidir se um estado é recorrente nulo.

**Teorema 3.2.10.** *Um estado  $i \in S$  recorrente nulo se e só se*

$$\lim_{n \rightarrow +\infty} P_{i,i}^{(n)} = 0.$$

*Demonstração.* Procurar na bibliografia da disciplina. □

Tal como na Proposição 3.2.7, quando o espaço de estados é finito, todos os estados recorrentes são positivos.

**Proposição 3.2.11.** *Se o espaço de estados é finito, então todos os estados recorrentes são positivos.*

*Demonstração.* Suponhamos por absurdo que existe um estado  $i \in S$  tal que  $i$  é recorrente nulo. Ou seja,  $\lim_{n \rightarrow \infty} P_{i,i}^{(n)} = 0$ . Então para todo  $j \in S$  temos que<sup>2</sup>  $\lim_{n \rightarrow \infty} P_{i,j}^{(n)} = 0$ . Mas,

$$\sum_{j \in S} P_{i,j}^{(n)} = 1,$$

---

<sup>2</sup>Este facto não é trivial, mas pode ser demonstrado com recurso à equação de Chapman-Kolmogorov e usando a noção de classes de comunicação que será introduzida posteriormente. Pode também encontrar uma demonstração na bibliografia da disciplina

contradizendo o facto de  $\lim_n P_{i,j}^{(n)} = 0$  (porque  $S$  é finito).  $\square$

**Exemplo 3.2.12.** Os estados recorrentes dos exemplos 3.2.5 e 3.2.6 são todos recorrentes positivos. No primeiro exemplo a sucessão  $P_{i,i}^{(n)}$  tem dois pontos de acumulação, portanto não é convergente para zero. No segundo exemplo  $P_{1,1}^{(n)} = 1$  para todo  $n \geq 1$ .

**Exemplo 3.2.13** (Simétrico). Considere o passeio aleatório simétrico. As probabilidades de transição são

$$P_{i,j} = \begin{cases} \frac{1}{2}, & \text{se } j = i + 1 \\ \frac{1}{2}, & \text{se } j = i - 1 \\ 0, & \text{caso contrário} \end{cases}$$

Tal como no passeio aleatório assimétrico temos,

$$P_{i,i}^{(n)} = \mathbb{P}(X_n = i | X_0 = i) = \begin{cases} \frac{n!}{((n/2)!)^2 2^n} & \text{se } n \text{ é par} \\ 0 & \text{se } n \text{ é ímpar} \end{cases}$$

Seja  $a_k = \frac{(2k)!}{(k!)^2 2^{2k}}$ . Queremos determinar se a série  $\sum_k a_k$  converge ou diverge. O critério d'Alembert é inconclusivo porque o limite da razão  $\frac{a_{k+1}}{a_k}$  é igual a 1 (ver exemplo do passeio aleatório assimétrico). Portanto, vamos usar a conhecida aproximação de Stirling<sup>3</sup>,

$$k! \sim \sqrt{2\pi k} \left(\frac{k}{e}\right)^k$$

para estimar  $a_k$ . Assim,

$$a_k \sim \frac{\sqrt{4\pi k} \left(\frac{2k}{e}\right)^{2k}}{2\pi k \left(\frac{k}{e}\right)^{2k}} \frac{1}{2^{2k}} = \frac{1}{\sqrt{\pi k}}.$$

Logo,

$$\sum_{n=1}^{\infty} P_{i,i}^{(n)} = \sum_{k=1}^{\infty} a_k \sim \sum_{k=1}^{\infty} \frac{1}{\sqrt{\pi k}} = +\infty$$

Portanto, todos os estados do passeio aleatório simétrico são recorrentes! Mais, como

$$\lim_{n \rightarrow +\infty} P_{i,i}^{(n)} = \lim_{k \rightarrow +\infty} \frac{1}{\sqrt{\pi k}} = 0,$$

concluimos que todos os estados são recorrentes nulos. Ou seja, apesar dos estados serem recorrentes, o tempo médio de reentrada é infinito.

<sup>3</sup>ver wikipedia

### 3.3 Exercícios

**Exercício 10.** Considere uma cadeia de Markov homogénea com estados  $S = \{0, 1\}$  e matriz de transição:

$$P = \begin{pmatrix} 1-p & p \\ q & 1-q \end{pmatrix}, \quad 0 < p < 1, \quad 0 < q < 1.$$

1. Mostre por indução que

$$P^n = \frac{1}{p+q} \left( \begin{pmatrix} q & p \\ q & p \end{pmatrix} + (1-p-q)^n \begin{pmatrix} p & -p \\ -q & q \end{pmatrix} \right), \quad n \geq 1.$$

2. Determine se os estados são recorrentes ou transientes.

3. Calcule

$$\pi_i = \lim_{n \rightarrow \infty} \mathbb{P}(X_n = i | X_0 = 0), \quad i \in \{0, 1\}.$$

4. Mostre que

$$\pi = \pi P$$

onde  $\pi$  é o vector linha formado por  $\pi_0$  e  $\pi_1$  calculados na alínea anterior.

**Exercício 11.** Uma urna contém inicialmente duas bolas, uma branca e outra preta. Uma bola é retirada ao acaso e substituída por uma bola de cor oposta. O processo é repetido um número infinito de vezes. Seja  $X_n$  o número de bolas brancas na urna no instante  $n \geq 0$ .

1. Mostre que  $X_n$  é uma cadeia de Markov homogénea e determine a matriz de transição  $P$ .

2. Calcule  $P^n$ .

3. Suponhamos que inicialmente a urna contém duas bolas brancas. No passo seguinte, uma bola branca é substituída por uma preta e por aí adiante. Determine a probabilidade de reencontrar ao longo do processo duas bolas brancas na urna.

### 3.4 Periodicidade

**Definição 3.4.1.** O período de um estado  $i \in S$  é o máximo divisor comum dos inteiros positivos  $n \in \mathbb{N}$  tais que  $P_{i,i}^{(n)} > 0$ , isto é,

$$Per(i) = \text{mdc}\{n \geq 1: P_{i,i}^{(n)} > 0\}.$$

Dizemos que o estado  $i$  é **periódico** se  $Per(i) \geq 2$ . Caso contrário, dizemos que  $i$  é **aperiódico**.

Algumas observações a reter:

1. se  $P_{i,i}^{(n)} > 0$  para todo  $n \geq 1$ , então o estado  $i$  é aperiódico;
2. se  $n$  não é um múltiplo de  $Per(i)$ , então  $P_{i,i}^{(n)} = 0$ .

**Definição 3.4.2.** Um estado  $i \in S$  que é recorrente positivo e aperiódico diz-se que é **ergódico**.

**Exemplo 3.4.1.** Considere a cadeia de Markov do Exemplo 3.2.5. Temos para qualquer  $i \in \{0, 1\}$  que

$$P_{i,i}^{(n)} = \begin{cases} 0 & \text{se } n \text{ é ímpar} \\ 1 & \text{se } n \text{ é par} \end{cases}$$

Logo,

$$Per(i) = \text{mdc}\{n \geq 1: P_{i,i}^{(n)} > 0\} = \text{mdc}\{2, 4, 6, 8, \dots\} = 2.$$

Portanto, todos os estados da cadeia são periódicos com período 2.

**Exemplo 3.4.2.** Considere o passeio aleatório simétrico do Exemplo 3.2.13. Tal como no exemplo anterior,  $P_{i,i}^{(n)} > 0$  se  $n$  é par 2 e  $P_{i,i}^{(n)} = 0$  se  $n$  é ímpar. Assim, todos os estados da cadeia são periódicos com período 2.

**Exemplo 3.4.3.** Considere a cadeia de Markov do Exercício 10. Como para todo  $n \geq 1$ ,  $P_{i,i}^{(n)} > 0$  temos que todos os estados  $i$  da cadeia são aperiódicos. Como também são recorrentes positivos então os estados da cadeia são ergódicos.

**Exemplo 3.4.4.** Considere a seguinte cadeia de Markov homogénea com estados  $S = \{0, 1, 2, 3\}$  e matriz de transição

$$P = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 \end{pmatrix}.$$

Fazendo o diagrama da cadeia de Markov é fácil verificar que  $P_{0,0}^{(n)} = 1$  para todo  $n \geq 1$  e para os restantes estados  $i \in \{1, 2, 3\}$ ,

$$P_{i,i}^{(n)} = \begin{cases} 1 & \text{se } n \text{ é múltiplo de } 3 \\ 0 & \text{caso contrário} \end{cases}$$

Portanto, todos os estados são recorrentes positivos. O estado 0 é aperiódico e os restantes têm período 3. Logo, o estado 0 é ergódico.

### 3.5 Classes de equivalência

**Definição 3.5.1.** Dizemos que um estado  $i$  **comunica** com um estado  $j$  se existir uma probabilidade de transitar de  $i$  para  $j$ , isto é, se existir  $n \geq 0$  tal que

$$P_{i,j}^{(n)} = \mathbb{P}(X_n = j | X_0 = i) > 0.$$

Se  $i$  comunicar com  $j$  escrevemos

$$i \rightarrow j$$

Se  $i \rightarrow j$  e  $j \rightarrow i$  então  $i$  e  $j$  **comunicam entre si** e escrevemos

$$i \leftrightarrow j$$

**Lemma 3.5.1.** *A relação de intercomunicação  $\leftrightarrow$  é uma relação de equivalência, isto é, satisfaz as seguintes propriedades:*

1.  $i \leftrightarrow i$
2. se  $i \leftrightarrow j$  então  $j \leftrightarrow i$
3. se  $i \leftrightarrow j$  e  $j \leftrightarrow k$  então  $i \leftrightarrow k$ .

*Demonstração.*

1.  $i \leftrightarrow i$  vem do facto que  $P_{i,i}^0 = 1 > 0$ .
2.  $i \leftrightarrow j$  é equivalente a  $P_{i,j}^{(n)} > 0$  e  $P_{j,i}^{(m)} > 0$  para algum  $n, m \geq 0$ . Logo  $j \leftrightarrow i$ .
3. Supondo que  $P_{i,j}^{(n)} > 0$  ( $i \rightarrow j$ ) e  $P_{j,k}^{(m)} > 0$  ( $j \rightarrow k$ ) usando a equação de Chapman-Kolmogorov,

$$P_{i,k}^{n+m} = \sum_{j \in S} P_{i,j}^{(n)} P_{j,k}^{(m)} \geq P_{i,j}^{(n)} P_{j,k}^{(m)} > 0.$$

Logo,  $i \rightarrow k$ . De forma análoga mostramos que  $k \rightarrow i$ .

□

Vamos de seguida introduzir algumas definições para particionar o espaço dos estados em subconjuntos que partilham propriedades comuns.

**Definição 3.5.2.** Ao conjunto  $C(i)$  formado por todos os estados da cadeia que intercomunicam com o estado  $i$  designamos por **classe de comunicação de  $i$** ,

$$C(i) = \{j \in S : i \leftrightarrow j\}$$

Um subconjunto de estados diz-se **irreduzível** se todos os estados nesse subconjunto comunicam entre si. Neste sentido, as classes de comunicação são irreduzíveis. De facto,  $C(i)$  é o maior conjunto irreduzível contendo o estado  $i$ . Se todos os estados da cadeia comunicam entre si (existe apenas uma única classe de comunicação) então dizemos que a cadeia é **irreduzível**.

**Proposição 3.5.2.** *Se  $j \in C(i)$ , então*

1.  $i$  e  $j$  têm o mesmo período.
2.  $i$  é recorrente sse  $j$  é recorrente.
3.  $i$  é recorrente positivo sse  $j$  é recorrente positivo.
4.  $i$  é ergódico sse  $j$  é ergódico.

*Demonstração.*

1. Procurar a prova na bibliografia da disciplina.
2. Como  $i \leftrightarrow j$ , temos que  $P_{i,j}^{(n)} > 0$  e  $P_{j,i}^{(m)} > 0$  para algum  $n, m \geq 0$ . Seja  $\epsilon = P_{i,j}^{(n)} P_{j,i}^{(m)} > 0$ . Usando sucessivamente a equação de Chapman-Kolmogorov,

$$\begin{aligned} P_{i,i}^{n+r+m} &= \sum_{k \in S} P_{i,k}^{(n)} P_{k,i}^{(r+m)} \\ &\geq P_{i,j}^{(n)} P_{j,i}^{(r+m)} \\ &= P_{i,j}^{(n)} \sum_{s \in S} P_{j,s}^{(r)} P_{s,i}^{(m)} \\ &\geq P_{i,j}^{(n)} P_{j,j}^{(r)} P_{j,i}^{(m)}. \end{aligned}$$

Assim,

$$P_{i,i}^{n+r+m} \geq \epsilon P_{j,j}^{(r)}.$$

Portanto,  $\sum_{r=1}^{\infty} P_{j,j}^{(r)} = +\infty$  implica que  $\sum_{r=1}^{\infty} P_{i,i}^{(r)} = +\infty$ , ou seja, se  $j$  é recorrente, então  $i$  também é recorrente. Trocando os papéis de  $i$  e  $j$  obtemos que a propriedade de recorrência é preservada nas classe de comunicação.

3. O mesmo se verifica com a recorrência positiva usando a desigualdade anterior.
4. Segue do (1) e do (3).

□

Portanto, recorrência positiva (ou nula) e periodicidade são propriedades partilhadas por todos os estados da mesma classe de comunicação. Assim, dizemos que a cadeia é aperiódica quando todos os estados são aperiódicos, recorrente quando todos os estados são recorrentes, etc.

**Definição 3.5.3.** Dizemos que um subconjunto  $C \subset S$  de estados é **fechado** se para todo  $i \in C$  e  $j \notin C$  tem-se  $P_{i,j} = 0$ . Ou seja, um subconjunto  $C$  de estados é fechado se a probabilidade de sair de  $C$  é zero.

**Proposição 3.5.3.** *Se  $i$  é recorrente, então  $C(i)$  é fechado.*

*Demonstração.* Suponhamos por absurdo que  $C(i)$  não é fechado. Então existe um estado  $s \in C(i)$  recorrente e  $j \notin C(i)$  tal que  $P_{s,j} > 0$ . Ou seja,  $s \rightarrow j$  mas  $j \not\rightarrow s$ , caso contrário  $j$  estaria em  $C(i)$ . Assim,

$$\begin{aligned} \mathbb{P}(T_s = +\infty | X_0 = s) &= \mathbb{P}(X_1 \neq s, X_2 \neq s, \dots | X_0 = s) \\ &\geq \mathbb{P}(X_1 = j, X_2 \neq s, \dots | X_0 = s) \\ &= \mathbb{P}(X_1 = j | X_0 = s) = P_{s,j} > 0, \end{aligned}$$

uma vez que  $j \not\rightarrow s$ . Portanto, da desigualdade anterior concluímos que  $s$  é transiente. Absurdo. □

Chegamos assim a um resultado central que estabelece uma decomposição dos estados de uma cadeia de Markov homogénea.

**Teorema 3.5.4** (Decomposição dos estados). *Qualquer espaço de estados de uma cadeia de Markov homogénea pode ser decomposto numa união (disjunta e contável) de estados transientes  $T$  e subconjuntos fechados e irredutíveis  $C_1, C_2, \dots$  de estados recorrentes, isto é,*

$$S = T \cup C_1 \cup C_2 \cup \dots$$

*Demonstração.* Seja  $R = S \setminus T$  o conjunto dos estados recorrentes da cadeia de Markov. Para cada  $i \in R$ , a respectiva classe de comunicação  $C(i)$  é irredutível e contém apenas estados recorrentes. Segue da proposição anterior que é fechada. Assim, existem  $i_1, i_2, \dots \in R$ , tal que o conjunto dos

estados recorrentes  $R$  pode ser escrito como uma união disjunta de classes de comunicação  $C(i_1), C(i_2), \dots$  fechadas e irredutíveis. Portanto,

$$S = T \cup C(i_1) \cup C(i_2) \cup \dots$$

□

**Observação 3.5.5.** Se o espaço de estados é finito, então existe pelo menos um conjunto fechado irredutível e não-vazio  $C_i$  de estados recorrentes na decomposição do teorema anterior. Adicionalmente, pela Proposição 3.2.11, todos os estados recorrentes são positivos.

**Observação 3.5.6.** Se uma classe de comunicação  $C(i)$  não é fechada, então segue da Proposição 3.5.3 que todos os estados da classe  $C(i)$  são transientes.

**Exemplo 3.5.7.** Considere uma cadeia de Markov homogênea com estados  $S = \{0, 1, 2, 3, 4, 5\}$  e matriz de transição

$$P = \begin{pmatrix} \frac{1}{2} & \frac{1}{2} & 0 & 0 & 0 & 0 \\ \frac{1}{4} & \frac{3}{4} & 0 & 0 & 0 & 0 \\ \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & 0 & 0 \\ \frac{1}{4} & 0 & \frac{1}{4} & \frac{1}{4} & 0 & \frac{1}{4} \\ 0 & 0 & 0 & 0 & \frac{1}{2} & \frac{1}{2} \\ 0 & 0 & 0 & 0 & \frac{1}{2} & \frac{1}{2} \end{pmatrix}$$

É fácil verificar que

$$0 \leftrightarrow 1, \quad 2 \leftrightarrow 3 \quad \text{e} \quad 4 \leftrightarrow 5.$$

Estas são as únicas relação de intercomunicação. Assim, temos três classes de comunicação

$$C(0) = \{0, 1\}, \quad C(2) = \{2, 3\} \quad \text{e} \quad C(4) = \{4, 5\}.$$

Para determinar os estados recorrentes, basta verificar se as classes de comunicação são fechadas ou não. Como as classes  $C(0)$  e  $C(4)$  são fechadas, contêm apenas estados recorrentes. A classe  $C(2)$  não é fechada, logo é formada por estados transientes. Quanto à periodicidade, podemos concluir que todos os estados  $i \in S$  são aperiódicos ( $Per(i) = 1$ ) porque  $P_{i,i} > 0$ , logo  $P_{i,i}^{(n)} > 0$  para todo  $n \geq 1$ . Relativamente à distribuição dos tempos de paragem  $T_i$ , podemos calcular sem dificuldade,

$$\mathbb{P}(T_0 = n | X_0 = 0) = \begin{cases} \frac{1}{2} & \text{se } n = 1 \\ P_{0,1} P_{1,1}^{n-2} P_{1,0} & \text{se } n \geq 2 \end{cases}$$

Expressões equivalentes podem ser obtidas para as distribuições dos restantes tempos de paragem. Logo,

$$\begin{aligned}
 m_0 = E(T_0|X_0 = 0) &= \sum_{n=1}^{\infty} n\mathbb{P}(T_0 = n|X_0 = 0) \\
 &= \frac{1}{2} + \sum_{n=2}^{\infty} n\frac{1}{2} \left(\frac{3}{4}\right)^{n-2} \frac{1}{4} \\
 &= \frac{1}{2} + \frac{1}{6} \left( \sum_{n=1}^{\infty} n \left(\frac{3}{4}\right)^{n-1} - 1 \right) \\
 &= \frac{1}{2} + \frac{1}{6} \left( \frac{1}{\left(1 - \frac{3}{4}\right)^2} - 1 \right) \\
 &= 3
 \end{aligned}$$

Portanto, o estado 0 é recorrente positivo. Um facto que já sabíamos pela Proposição 3.2.11.

### 3.6 Exercícios

**Exercício 12.** Construa uma cadeia de Markov homogénea onde  $P_{i,i}^{(Per(i))} = 0$  para algum estado  $i$  da cadeia. (Dica: considere a cadeia de Markov do Exercício 10 e escolha  $p$  e  $q$  adequadamente)

**Exercício 13.** Mostre que se  $P_{i,i} > 0$ , então o estado  $i$  é aperiódico.

**Exercício 14.** Mostre que se  $i \leftrightarrow j$ , então  $Per(i) = Per(j)$ .

**Exercício 15.** É possível construir uma cadeia de Markov homogénea com espaço de estados finito e um estado recorrente nulo? e todos os estados transientes? Justifique.

**Exercício 16.** Determine a decomposição dos estados  $S = \{0, 1, 2, 3, 4, 5\}$  da cadeia de Markov homogénea com a seguinte matriz de transição e calcule  $m_i = E(T_i|X_0 = i)$  para todo  $i \in S$ ,

$$P = \begin{pmatrix} \frac{1}{3} & 0 & \frac{1}{3} & 0 & 0 & \frac{1}{3} \\ \frac{1}{2} & \frac{1}{4} & \frac{1}{4} & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & 0 & 0 & \frac{1}{4} \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{pmatrix}$$

**Exercício 17.** Determine e classifique todas as classes de comunicação e período de cada classe para a cadeia de Markov homogênea com estados  $S = \{0, 1, 2, 3, 4, 5\}$  e matriz de transição:

$$\begin{pmatrix} \frac{1}{2} & 0 & 0 & 0 & \frac{1}{2} & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & \frac{1}{3} & \frac{1}{3} & 0 & \frac{1}{3} \end{pmatrix}$$

Calcule  $m_5 = E(T_5 | X_0 = 5)$ .

### 3.7 Distribuição estacionária

Seja  $(X_n)_{n \geq 0}$  uma cadeia de Markov estacionária com espaço de estados (finito ou infinito)  $S$  e matriz de transição  $P$ .

Dada uma distribuição de probabilidade inicial  $\pi_0$  de  $X_0$ , usando a Proposição 3.1.7 a distribuição de  $X_n$  é dada por  $\pi_n = \pi_0 P^n$ . Um caso especial é quando  $\pi_n = \pi_0$  para todo  $n \geq 0$ .

**Definição 3.7.1.** Uma distribuição de probabilidade<sup>4</sup>  $\pi$  em  $S$  diz-se **estacionária** se

$$\pi = \pi P.$$

**Observação 3.7.1.** A equação  $\pi = \pi P$  determina os vectores próprios associados ao valor próprio 1 da matriz transposta de  $P$ . Portanto, se  $P$  não tiver valor próprio<sup>5</sup> 1, então a cadeia não tem distribuição estacionária.

**Observação 3.7.2.** Se a cadeia de Markov tem duas distribuições estacionárias distintas, então tem uma infinidade de distribuições estacionárias. De facto, sejam  $\pi$  e  $\nu$  duas distribuições estacionárias. Então a combinação convexa

$$\mu = \lambda\pi + (1 - \lambda)\nu, \quad \lambda \in [0, 1]$$

é também uma distribuição estacionária:

$$\mu P = \lambda\pi P + (1 - \lambda)\nu P = \lambda\pi + (1 - \lambda)\nu = \mu$$

e

$$\sum_{i \in S} \mu_i = \sum_{i \in S} \lambda\pi_i + (1 - \lambda)\nu_i = \lambda \sum_{i \in S} \pi_i + (1 - \lambda) \sum_{i \in S} \nu_i = 1.$$

<sup>4</sup>Uma distribuição de probabilidade é um vector linha  $\pi = (\pi_i : i \in S)$  tal que  $\sum_{i \in S} \pi_i = 1$  e  $\pi_i \geq 0$  para todo  $i \in S$ .

<sup>5</sup>A matriz  $P$  e a sua transposta têm os mesmos valores próprios.

No caso em que a cadeia de Markov admite uma distribuição estacionária  $\pi$ , se  $X_0$  tiver distribuição  $\pi$  então todas as variáveis  $X_n$  têm a mesma distribuição  $\pi$ . Segue que a cadeia de Markov é um **processo estacionário**, ou seja,

$$(X_{n_1}, \dots, X_{n_k}) \stackrel{d}{=} (X_{n_1+m}, \dots, X_{n_k+m})$$

para quaisquer  $0 \leq n_1 < \dots < n_k$  e  $m \geq 0$ . De facto,

$$\begin{aligned} \mathbb{P}(X_{n_1+m} = i_1, \dots, X_{n_k+m} = i_k) &= \pi_{i_1} P_{i_1, i_2}^{(n_2-n_1)} \dots P_{i_{k-1}, i_k}^{(n_k-n_{k-1})} \\ &= \mathbb{P}(X_{n_1} = i_1, \dots, X_{n_k} = i_k) \end{aligned}$$

**Exemplo 3.7.3** (existência e unicidade). Considere a cadeia de Markov com matriz de transição

$$P = \begin{pmatrix} \frac{1}{2} & \frac{1}{2} \\ \frac{1}{2} & \frac{1}{2} \end{pmatrix}$$

Seja  $\pi = (\pi_0, \pi_1)$ . Então  $\pi = \pi P$  é equivalente a

$$\begin{aligned} \pi_0 &= \frac{1}{2}\pi_0 + \frac{1}{2}\pi_1 \\ \pi_1 &= \frac{1}{2}\pi_0 + \frac{1}{2}\pi_1 \end{aligned}$$

Destas equações concluímos que  $\pi_0 = \pi_1$ . Como  $\pi_0 + \pi_1 = 1$  concluímos que  $\pi_0 = \pi_1 = \frac{1}{2}$  é a distribuição estacionária e é única.

**Exemplo 3.7.4** (existência e não unicidade). Considere a cadeia de Markov com matriz de transição

$$P = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

Então  $\pi = \pi P = \pi$  porque  $P$  é a matriz identidade. Ou seja, qualquer distribuição de probabilidade é estacionária.

**Exemplo 3.7.5** (inexistência). Considere a cadeia de Markov com estados  $S = \{0, 1, 2, \dots\}$  e matriz de transição

$$P = \begin{pmatrix} \frac{1}{2} & \frac{1}{4} & \frac{1}{8} & \frac{1}{16} & \frac{1}{32} & \dots \\ 0 & \frac{1}{2} & \frac{1}{4} & \frac{1}{8} & \frac{1}{16} & \dots \\ 0 & 0 & \frac{1}{2} & \frac{1}{4} & \frac{1}{8} & \dots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \ddots \end{pmatrix}.$$

A equação  $\pi = \pi P$  é equivalente ao sistema de equações (em número infinito)

$$\begin{aligned}\pi_0 &= \frac{1}{2}\pi_0 \\ \pi_1 &= \frac{1}{4}\pi_0 + \frac{1}{2}\pi_1 \\ \pi_2 &= \frac{1}{8}\pi_0 + \frac{1}{4}\pi_1 + \frac{1}{2}\pi_2 \\ &\vdots\end{aligned}$$

A solução do sistema é  $\pi_i = 0$  para todo  $i \in \{0, 1, 2, \dots\}$ . No entanto, o vector nulo  $\pi = 0$  não é uma distribuição de probabilidade. Logo, a cadeia não tem distribuição estacionária. De facto, a matriz  $P$  é triangular superior com um unico valor proprio igual a  $1/2$ . Repare que todos os estados da cadeia são transientes! Compare com o Exemplo 3.2.8.

O próximo resultado mostra que os estados transientes não têm peso na distribuição estacionária.

**Proposição 3.7.6.** *Seja  $\pi = (\pi_j: j \in S)$  uma distribuição estacionária da cadeia de Markov. Se  $j \in S$  é um estado transiente, então  $\pi_j = 0$ .*

*Demonstração.* Como  $j$  é transiente,  $\lim_{n \rightarrow \infty} P_{i,j}^{(n)} = 0$  para todo  $i \in S$  (ver Corolário 3.2.4). Então

$$\pi_j = \sum_{i \in S} P_{i,j}^{(n)} \pi_i \xrightarrow{n \rightarrow \infty} 0.$$

□

**Exemplo 3.7.7.** Considere a cadeia de Markov do Exemplo 3.2.6. Recorde-se que tem matriz de transição

$$P = \begin{pmatrix} \frac{1}{2} & \frac{1}{2} \\ 0 & 1 \end{pmatrix}$$

Como 0 é um estado transiente, obtemos que  $\pi_0 = 0$ . De facto, a distribuição estacionária é  $\pi = (0, 1)$ .

O resultado seguinte relaciona os estados recorrentes com a distribuição estacionária e mostra que toda a cadeia de Markov com pelo menos um estado recorrente positivo admite pelo menos uma distribuição estacionária que é única no caso de existir uma única classe de comunicação entre estados recorrentes.

**Teorema 3.7.8.** *Toda a cadeia de Markov admite uma distribuição estacionária se e só se tiver pelo menos um estado recorrente positivo. Mais, a distribuição estacionária é única se e só se todos os estados recorrentes comunicam entre si. Nesse caso, a distribuição estacionária  $\pi = (\pi_j : j \in S)$  é dada por*

$$\pi_j = \frac{1}{m_j},$$

onde  $m_j$  é o tempo médio de reentrada no estado  $j$ , ou seja,  $m_j = E(T_j | X_0 = j)$ .

*Demonstração.* Procurar na bibliografia. □

**Observação 3.7.9.** Se o espaço de estados é finito, então sabemos das Proposições 3.2.7 e 3.2.11 que toda a cadeia de Markov tem pelo menos um estado recorrente positivo. Logo, admite distribuições estacionárias. A distribuição é única se tiver uma única classe de comunicação de estados recorrentes.

**Exemplo 3.7.10.** Considere a cadeia de Markov do Exemplo 3.2.5. A matriz de transição é

$$P = \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix}.$$

A cadeia de Markov é irredutível e todos os estados são recorrentes. É fácil calcular a distribuição estacionária  $\pi = (\frac{1}{2}, \frac{1}{2})$  que é única. Concluimos também que os tempos médios de reentrada são  $m_1 = m_2 = 2$ .

**Exemplo 3.7.11.** O passeio aleatório (simétrico ou assimétrico) não tem estados recorrentes positivos, portanto não admite distribuições estacionárias.

De seguida iremos relacionar a distribuição limite das probabilidades de transição de uma cadeia de Markov com as distribuições estacionárias. O próximo resultado mostra que se o limite das probabilidades de transição existir e for independente do estado de partida, então definem uma distribuição estacionária que é única.

**Proposição 3.7.12.** *Se para quaisquer  $i, j \in S$ , o seguinte limite é convergente e independente de  $i$ ,*

$$\pi_j := \lim_{n \rightarrow \infty} P_{i,j}^{(n)} < +\infty$$

*e  $\pi := (\pi_j : j \in S) \neq 0$  ou  $S$  é finito, então  $\pi$  é a única distribuição estacionária da cadeia de Markov.*

*Demonstração.* Para simplificar a demonstração consideremos o caso de  $S$  finito<sup>6</sup>. Pela equação de Chapman-Kolmogorov,

$$\pi_j = \lim_{n \rightarrow \infty} P_{i,j}^{(n)} = \lim_{n \rightarrow \infty} \sum_{k \in S} P_{i,k}^{(n-1)} P_{k,j} = \sum_{k \in S} \lim_{n \rightarrow \infty} P_{i,k}^{(n-1)} P_{k,j} = \sum_{k \in S} \pi_k P_{k,j}$$

e

$$\sum_{j \in S} \pi_j = \sum_{j \in S} \lim_{n \rightarrow \infty} P_{i,j}^{(n)} = \lim_{n \rightarrow \infty} \sum_{j \in S} P_{i,j}^{(n)} = \lim_{n \rightarrow \infty} 1 = 1.$$

Logo,  $\pi = \pi P$  e  $\sum_j \pi_j = 1$ , ou seja,  $\pi$  é uma distribuição estacionária. Para mostrar a sua unicidade, suponhamos que  $\nu$  é outra distribuição estacionária. Como  $\nu = \nu P^n$  temos que

$$\nu_j = \sum_{i \in S} P_{i,j}^{(n)} \nu_i \xrightarrow{n \rightarrow \infty} \sum_{i \in S} \pi_j \nu_i = \pi_j.$$

□

A distribuição  $\pi$  obtida pelo limite das probabilidade de transição é conhecida por **distribuição limite**.

**Observação 3.7.13.** A distribuição limite de  $X_n$  não depende do estado inicial da cadeia,

$$\lim_{n \rightarrow \infty} \mathbb{P}(X_n = j) = \lim_{n \rightarrow \infty} \sum_{i \in S} P_{i,j}^{(n)} \mathbb{P}(X_0 = i) = \pi_j.$$

O próximo resultado complementa a Proposição 3.7.12. Estabelece uma condição suficiente para a convergência das probabilidades de transição, definindo no limite uma única distribuição estacionária.

**Teorema 3.7.14** (Teorema Ergódico). *Se a cadeia de Markov é irredutível e aperiódica, então*

$$\lim_{n \rightarrow \infty} P_{i,j}^{(n)} = \frac{1}{m_j}.$$

*Demonstração.* Procurar na bibliografia. □

Quando o conjunto dos estados  $S$  é finito obtemos o seguinte corolário.

**Corolário 3.7.15.** *Considere uma cadeia de Markov com espaço de estados  $S$  finito. Se a cadeia de Markov é irredutível e aperiódica, então admite uma única distribuição estacionária  $\pi = (\pi_j : j \in S)$  dada por*

$$\pi_j := \lim_{n \rightarrow \infty} P_{i,j}^{(n)} = \frac{1}{m_j}.$$

<sup>6</sup>O caso  $S$  infinito é tecnicamente mais sofisticado.

*Demonstração.* Segue da Proposição 3.7.12 e do Teorema 3.7.14.  $\square$

**Observação 3.7.16.** A razão  $\pi_j = 1/m_j$  representa a fração de tempo passado no estado  $j$ .

**Observação 3.7.17.** Se  $(X_n)_{n \geq 0}$  é uma cadeia de Markov irreduzível com período  $d$  então  $(X_{nd})_{n \geq 0}$  é uma cadeia aperiódica. Logo,

$$\lim_{n \rightarrow \infty} P_{i,j}^{(nd)} = \frac{d}{m_j}.$$

**Exemplo 3.7.18.** Considere a cadeia do Exercício 10. É irreduzível e aperiódica. Tem uma única distribuição estacionária dada por,

$$\pi = \left( \frac{q}{p+q}, \frac{p}{p+q} \right).$$

**Exemplo 3.7.19.** Considere a cadeia de Markov do Exemplo 3.5.7. Recorde-se a matriz de transição:

$$P = \begin{pmatrix} \frac{1}{2} & \frac{1}{2} & 0 & 0 & 0 & 0 \\ \frac{1}{4} & \frac{3}{4} & 0 & 0 & 0 & 0 \\ \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & 0 & 0 \\ \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & 0 & \frac{1}{4} \\ \frac{1}{4} & 0 & \frac{1}{4} & \frac{1}{4} & 0 & \frac{1}{4} \\ 0 & 0 & 0 & 0 & \frac{1}{2} & \frac{1}{2} \\ 0 & 0 & 0 & 0 & \frac{1}{2} & \frac{1}{2} \end{pmatrix}.$$

Existem duas classes de comunicação recorrentes  $C(0)$  e  $C(4)$ . Cada classe de comunicação define uma cadeia de Markov a dois estados irreduzível e aperiódica. Logo, todas as distribuições estacionárias da cadeia são uma combinação convexa das distribuições,

$$\nu = \left( \frac{1}{3}, \frac{2}{3}, 0, 0, 0, 0 \right) \quad \text{e} \quad \mu = \left( 0, 0, 0, 0, \frac{1}{2}, \frac{1}{2} \right).$$

**Exemplo 3.7.20** (Aplicação: Modelo de Aproveitamento). Considere o modelo de aproveitamento descrito no Exemplo 3.1.10, onde apenas 0, 1, ou 2 artigos são procurados em cada período ( $a_k = 0$  para  $k \geq 3$ ) com probabilidade

$$\mathbb{P}(\xi_n = 0) = \frac{1}{2}, \quad \mathbb{P}(\xi_n = 1) = \frac{2}{5} \quad \text{e} \quad \mathbb{P}(\xi_n = 2) = \frac{1}{10}.$$

Suponha que  $s = 0$  e  $m = 2$ . O espaço de estados da cadeia é  $S = \{2, 1, 0, -1\}$  e a matriz de transição

$$P = \begin{pmatrix} 1/2 & 2/5 & 1/10 & 0 \\ 0 & 1/2 & 2/5 & 1/10 \\ 1/2 & 2/5 & 1/10 & 0 \\ 1/2 & 2/5 & 1/10 & 0 \end{pmatrix}.$$

É fácil verificar que todos os estados da cadeia comunicam entre si. Portanto, a cadeia é irredutível. Como  $P_{2,2} > 0$ , concluímos que o estado 2 é aperiódico, logo a cadeia também é. Pelo Corolário 3.7.15, a cadeia admite uma única distribuição estacionária. Podemos determinar a distribuição resolvendo o sistema  $\pi = \pi P$  onde  $\pi = (\pi_2, \pi_1, \pi_0, \pi_{-1})$ ,

$$\begin{aligned} \pi_2 &= \frac{1}{2}\pi_2 + \frac{1}{2}\pi_0 + \frac{1}{2}\pi_{-1} \\ \pi_1 &= \frac{2}{5}\pi_2 + \frac{1}{2}\pi_1 + \frac{2}{5}\pi_0 + \frac{2}{5}\pi_{-1} \\ \pi_0 &= \frac{1}{10}\pi_2 + \frac{2}{5}\pi_1 + \frac{1}{10}\pi_0 + \frac{1}{10}\pi_{-1} \\ \pi_{-1} &= \frac{1}{10}\pi_1 \end{aligned}$$

Resolvendo este sistema determinamos os coeficientes da distribuição estacionária

$$\pi = \left( \frac{5}{18}, \frac{4}{9}, \frac{7}{30}, \frac{2}{45} \right).$$

Como exemplo, concluímos que o tempo médio de reentrada da cadeia no estado 2 é  $18/5$ . Mais, a probabilidade de a procura exceder a oferta a longo prazo é

$$\lim_{n \rightarrow \infty} \sum_{j < 0} \mathbb{P}(X_n = j) = \frac{2}{45}$$

e o nível médio de stock a longo prazo é

$$\lim_{n \rightarrow \infty} \sum_{j > 0} j \mathbb{P}(X_n = j) = 2 \times \frac{5}{18} + 1 \times \frac{4}{9} = 1.$$

**Exemplo 3.7.21** (PageRank do Google). O motor de busca na internet mais famoso do mundo lista os seus resultados de acordo com a probabilidade com que um utilizador entrando aleatoriamente em links chega a uma determinada pagina na internet.

Podemos representar a internet como um grafo  $G = (V, E)$  onde os vértices correspondem às páginas e as arestas aos links ligando as diversas páginas. Designamos por  $n = \#V$  o número de páginas que existem na internet e  $L(i)$  o número distinto de links existentes na página  $i \in V$ . Um utilizador "aleatório" situado numa página  $i \in V$  entra numa página  $j \in V$  com probabilidade

$$\hat{P}_{i,j} = \begin{cases} \frac{1}{n} & \text{se } L(i) = 0 \\ \frac{1}{L(i)} & \text{se } L(i) > 0 \text{ e } (i, j) \in E \\ 0 & \text{se } L(i) > 0 \text{ e } (i, j) \notin E \end{cases}$$

A matriz  $\hat{P} = (\hat{P}_{i,j})_{i,j \in V}$  é estocástica. Para garantir que a cadeia de Markov associada é irredutível e aperiódica fazemos uma pequena transformação,

$$P_{i,j} = (1 - \epsilon)\hat{P}_{i,j} + \frac{\epsilon}{n}$$

onde  $\epsilon \in [0, 1[$  é um pequeno parâmetro. Assim,  $P_{i,j} > 0$  para quaisquer  $i, j \in V$  garantindo que a cadeia de Markov com matriz de transição  $P = (P_{i,j})_{i,j \in V}$  é irredutível e aperiódica. Pelo Corolário 3.7.15, a cadeia admite uma única distribuição estacionária,

$$\pi = \pi P$$

Se  $\pi_i > \pi_j$ , então a página  $i$  é mais relevante que a página  $j$ . Um dos segredos do Google reside num método numérico eficiente e uma grande capacidade computacional para calcular as maiores entradas da distribuição estacionária  $\pi$ .

### 3.8 Exercícios

**Exercício 18.** Determine as distribuições estacionárias das cadeias de Markov com matrizes de transição:

$$\begin{pmatrix} \frac{1}{3} & 0 & \frac{1}{3} & 0 & 0 & \frac{1}{3} \\ \frac{1}{2} & \frac{1}{4} & \frac{1}{4} & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & 0 & 0 & \frac{1}{4} \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{pmatrix} \quad \text{e} \quad \begin{pmatrix} \frac{1}{2} & 0 & 0 & 0 & \frac{1}{2} & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & \frac{1}{3} & \frac{1}{3} & 0 & \frac{1}{3} \end{pmatrix}.$$

**Exercício 19.** Determine a distribuição limite da cadeia de Markov com

matriz transição

$$P = \begin{pmatrix} q & p & 0 & 0 & 0 \\ q & 0 & p & 0 & 0 \\ q & 0 & 0 & p & 0 \\ q & 0 & 0 & 0 & p \\ 1 & 0 & 0 & 0 & 0 \end{pmatrix}, \quad 0 < p, q < 1, \quad p + q = 1.$$

**Exercício 20.** Considere a cadeia de Markov com estados  $S = \{0, 1, 2, 3\}$  e matriz transição,

$$P = \begin{pmatrix} 0 & 1 & 0 & 0 \\ \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & \frac{1}{4} \\ \frac{1}{8} & \frac{1}{8} & \frac{1}{2} & \frac{1}{4} \\ \frac{1}{4} & \frac{1}{4} & \frac{1}{2} & 0 \end{pmatrix}$$

Determine:

1. A distribuição limite da cadeia de Markov.
2. Calcule  $E(T_0 | X_0 = 1)$ . (Dica: observe que a cadeia passa sempre do estado 0 para o estado 1)

### 3.9 Estados absorventes e probabilidade de absorção

Seja  $(X_n)_{n \geq 0}$  uma cadeia de Markov homogênea com espaço de estados  $S$  (finito ou infinito).

Um tipo particular de estados recorrentes são os estados absorventes.

**Definição 3.9.1.** Um estado  $i \in S$  é **absorvente** se e só se  $P_{i,i} = 1$ .

Ou seja, uma cadeia de Markov que esteja num estado absorvente  $i$  tem probabilidade zero de sair do mesmo, isto é,  $P_{i,j} = 0$  para todo  $j \neq i$ .

**Observação 3.9.1.**

1. Se  $i$  é absorvente então  $C(i) = \{i\}$ , isto é, a classe de comunicação de  $i$  é o próprio  $i$ .
2. Se  $C \subset S$  é um conjunto de estados fechado contendo apenas um estado  $i$ , então  $i$  é absorvente.

3. Estados absorventes são ergódicos. De facto, pela equação de Chapman-Kolmogorov,

$$P_{i,i}^{(n)} = \sum_{j \in S} P_{i,j} P_{j,i}^{(n-1)} = P_{i,i} P_{i,i}^{(n-1)} = P_{i,i}^{(n-1)}.$$

Logo,  $P_{i,i}^{(n)} = 1$  para todo  $n \geq 1$ , e  $Per(i) = 1$ .

**Exemplo 3.9.2.** Considere a seguinte matriz estocástica associada a uma cadeia de Markov homogénea  $(X_n)_{n \geq 0}$  com estados  $S = \{0, 1, 2\}$ ,

$$P = \begin{pmatrix} 1 & 0 & 0 \\ \alpha & \beta & \gamma \\ 0 & 0 & 1 \end{pmatrix}, \quad \alpha + \beta + \gamma = 1, \quad \alpha, \beta, \gamma > 0.$$

Os estados 0 e 2 são absorventes enquanto o estado 1 é transiente.

Seja  $A \subset S$  um conjunto de estados fechado<sup>7</sup>. Em aplicações é importante calcular a **probabilidade de absorção em  $A$** ,

$$h_i := \mathbb{P}(T < \infty | X_0 = i), \quad i \in S$$

onde  $T = \min\{n \geq 0: X_n \in A\}$  é o primeiro tempo de retorno ao conjunto  $A$ . Designamos por **tempo médio de absorção** ao valor esperado

$$t_i := E(T | X_0 = i).$$

É fácil determinar  $h_i$  e  $t_i$  para certos estados  $i \in S$ . Note-se que se  $i \in A$  então

$$h_i = 1 \quad e \quad t_i = 0.$$

Por outro lado, se  $i$  é um estado absorvente mas não pertence a  $A$  então<sup>8</sup>

$$h_i = 0 \quad e \quad t_i = \infty.$$

De seguida vamos deduzir umas equações que permitem calcular  $h_i$  e  $t_i$  para qualquer estado  $i \in S$ .

**Proposição 3.9.3.** *O vector de probabilidades de absorção em  $A$ ,  $h = (h_i: i \in S)$ , é solução do seguinte sistema de equações lineares,*

$$\begin{cases} h_i = 1, & \text{se } i \in A \\ h_i = \sum_{j \in S} P_{i,j} h_j & \text{se } i \notin A \end{cases}$$

<sup>7</sup>O conjunto  $A$  pode ser formado por estados absorventes ou mais geral por classes de comunicação recorrentes.

<sup>8</sup>Mais geral, se  $i \nrightarrow j$  para todo  $j \in A$ , então  $h_i = 0$  e  $t_i = \infty$ .

*Demonstração.* Já vimos que se  $i \in A$ , então  $h_i = 1$ . Suponhamos que  $i \notin A$ . Então  $T \geq 1$ . Logo, usando a propriedade de Markov e a homogeneidade da cadeia,

$$\begin{aligned} h_i &= \mathbb{P}(T < \infty | X_0 = i) \\ &= \sum_{j \in S} \mathbb{P}(T < \infty | X_1 = j, X_0 = i) \mathbb{P}(X_1 = j | X_0 = i) \\ &= \sum_{j \in S} \mathbb{P}(T < \infty | X_1 = j) P_{i,j} \\ &= \sum_{j \in S} h_j P_{i,j} \end{aligned}$$

□

**Observação 3.9.4.** Seja  $\hat{P}$  a matriz que se obtém removendo as linhas  $i \in A$  de  $P$ . Analogamente, seja  $\hat{h}$  o vector coluna que se obtém removendo as entradas  $i \in A$  do vector  $h$ . Então

$$\hat{h} = \hat{P}h.$$

Compare com a equação que define uma distribuição estacionária.

**Exemplo 3.9.5.** Considere a cadeia de Markov do Exemplo 3.9.2. Seja  $A = \{0\}$  o conjunto formado pelo estado absorvente 0. Aplicando a proposição anterior obtemos,

$$\begin{aligned} h_0 &= 1 \\ h_1 &= \alpha + \beta h_1 + \gamma h_2 \\ h_2 &= 0. \end{aligned}$$

Note-se que o estado 2 é absorvente. Portanto  $h_2 = 0$ . Assim, concluímos que

$$h_1 = \frac{\alpha}{1 - \beta} = \frac{\alpha}{\alpha + \gamma}.$$

Ou seja, a probabilidade de absorção no estado 0 partindo do estado 1 é  $\frac{\alpha}{\alpha + \gamma}$ .

**Proposição 3.9.6.** Se o vector de tempos médios de absorção em  $A$ ,  $t = (t_i : i \in S)$  for finito<sup>9</sup>, então  $t$  é solução do seguinte sistema de equações lineares,

$$\begin{cases} t_i = 0, & \text{se } i \in A \\ t_i = 1 + \sum_{j \in S} P_{i,j} t_j & \text{se } i \notin A \end{cases}$$

---

<sup>9</sup> $t_i < \infty$  para todo  $i \in S$

*Demonstração.* Análoga à prova da proposição anterior. Procurar na bibliografia.  $\square$

**Exemplo 3.9.7.** Continuando o exemplo anterior, vamos agora calcular os tempos médios de absorção em  $A = \{0, 2\}$ . Note-se que  $t_0 = t_2 = 0$ . Para calcular  $t_1$  aplicamos a proposição anterior,

$$t_1 = 1 + \alpha t_0 + \beta t_1 + \gamma t_2$$

Portanto,

$$t_1 = \frac{1}{1 - \beta} = \frac{1}{\alpha + \gamma}.$$

Ou seja, o tempo médio de absorção partindo do estado 1 é  $\frac{1}{\alpha + \gamma}$ .

### 3.10 Exercícios

**Exercício 21.** Considere uma cadeia de Markov com estados  $S = \{0, 1, 2, 3\}$  e matriz de transição

$$P = \begin{pmatrix} \frac{1}{3} & \frac{1}{6} & \frac{1}{6} & \frac{1}{3} \\ 0 & \frac{1}{5} & \frac{1}{5} & \frac{1}{5} \\ 0 & 0 & \frac{1}{2} & \frac{1}{2} \\ 0 & 0 & 0 & 1 \end{pmatrix}.$$

Determine os tempos médios de absorção no estado 3.

**Exercício 22.** Considere uma cadeia de Markov com estados  $S = \{0, 1, 2, 3\}$  e matriz de transição

$$\begin{pmatrix} 1 & 0 & 0 & 0 \\ \frac{1}{3} & \frac{1}{6} & \frac{1}{6} & \frac{1}{3} \\ \frac{1}{4} & \frac{1}{8} & \frac{1}{2} & \frac{1}{8} \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

1. Partindo do estado 1, determine a probabilidade de a cadeia ser absorvida pelo estado 0.
2. Determine o tempo médio de absorção em  $A = \{0, 3\}$ .

**Exercício 23.** Considere o seguinte jogo. Uma moeda perfeita é lançada sucessivamente ao ar até que apareçam duas caras sucessivas.

1. Modele o jogo usando uma cadeia de Markov. Determine a matriz de transição e o diagrama da cadeia. (Dica:  $S = \{0, 1, 2\}$ )

2. Determine a decomposição do espaço dos estados da cadeia.
3. Calcule o tempo médio de duração do jogo supondo que começa o jogo com duas coroas.

# Chapter 4

## Processo de Poisson

Processos de Poisson são usados para contar o número de ocorrências "aleatoriamente" espaçadas entre si ao longo do tempo. Por exemplo, o número de partículas emitidas por um material radioativo ou o número de chamadas telefônicas que chegam a uma central. Antes de introduzir o Processo de Poisson vamos relembrar as propriedades da distribuição exponencial.

**Definição 4.0.1.** Uma variável aleatória  $T$  com valores em  $[0, +\infty[$  tem **distribuição exponencial** com parâmetro  $\lambda > 0$  se

$$\mathbb{P}(T \leq t) = 1 - e^{-\lambda t}, \quad t \geq 0.$$

A função densidade de probabilidade  $f_T(t)$  é

$$f_T(t) = \begin{cases} \lambda e^{-\lambda t}, & t \geq 0 \\ 0, & t < 0 \end{cases}$$

Facilmente determinamos que  $E(T) = 1/\lambda$  e  $V(T) = 2/\lambda^2$ .

A distribuição exponencial tem a propriedade de **não possuir memória**, ou seja,

$$\mathbb{P}(T > t + s | T > t) = \mathbb{P}(T > s).$$

De facto,

$$\begin{aligned} \mathbb{P}(T > t + s | T > t) &= \frac{\mathbb{P}(T > t + s, T > t)}{\mathbb{P}(T > t)} \\ &= \frac{\mathbb{P}(T > t + s)}{\mathbb{P}(T > t)} \\ &= \frac{e^{-\lambda(t+s)}}{e^{-\lambda t}} \\ &= \mathbb{P}(T > s). \end{aligned}$$

Como demonstra o próximo resultado, a soma de variáveis aleatórias independentes com distribuição exponencial tem **distribuição gamma**.

**Proposição 4.0.1.** *Sejam  $T_1, \dots, T_n$ ,  $n \geq 1$  variáveis aleatórias independentes com distribuição exponencial com parâmetro  $\lambda$  e  $W_n = T_1 + \dots + T_n$ . Então  $W_n$  tem distribuição gamma com parâmetros  $n$  e  $\lambda$ ,*

$$f_{W_n}(t) = \lambda e^{-\lambda t} \frac{(\lambda t)^{n-1}}{(n-1)!}, \quad t \geq 0.$$

*Demonstração.* A prova é por indução em  $n$ . Para  $n = 1$  temos  $W_1 = T_1$  que tem distribuição exponencial  $f_{W_1}(t) = f_{T_1}(t) = \lambda e^{-\lambda t}$ . Suponhamos que a proposição é verdadeira para  $n$ . Vamos mostrar o mesmo para  $n + 1$ . Usando o facto<sup>1</sup>  $W_{n+1} = W_n + T_{n+1}$  e a independência dos  $T_i$ 's temos que

$$f_{W_{n+1}}(t) = \int_0^t f_{W_n}(s) f_{T_{n+1}}(t-s) ds.$$

Usando a hipótese de indução,

$$\begin{aligned} f_{W_{n+1}}(t) &= \int_0^t \lambda e^{-\lambda s} \frac{(\lambda s)^{n-1}}{(n-1)!} \lambda e^{-\lambda(t-s)} ds \\ &= \lambda e^{-\lambda t} \lambda^n \int_0^t \frac{s^{n-1}}{(n-1)!} ds \\ &= \lambda e^{-\lambda t} \lambda^n \frac{t^n}{n!}. \end{aligned}$$

□

## 4.1 Definição do processo de Poisson

**Definição 4.1.1.** Uma variável aleatória  $X$  tem **distribuição de Poisson** com parâmetro  $\lambda > 0$  se

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

<sup>1</sup>Dadas duas variáveis aleatórias  $X$  e  $Y$  independentes com densidade  $f_X$  e  $f_Y$ , então a densidade da soma  $Z = X + Y$  é a convolução das densidades  $f_X$  e  $f_Y$ , ou seja,

$$f_Z(z) = \int_{-\infty}^{+\infty} f_X(x) f_Y(z-x) dx.$$

É fácil verificar que  $E(X) = V(X) = \lambda$ . Outra propriedade a reter é a soma de variáveis aleatórias independentes com distribuição de Poisson tem também distribuição de Poisson.

**Proposição 4.1.1.** *Sejam  $X_1, \dots, X_k$  variáveis aleatórias independentes com distribuição de Poisson de parâmetro  $\lambda_1, \dots, \lambda_k$ , respectivamente. Então a soma  $X_1 + \dots + X_k$  tem distribuição de Poisson com parâmetro  $\lambda_1 + \dots + \lambda_k$ .*

*Demonstração.* Exercício. □

A distribuição de Poisson surge considerando o limite da distribuição Binomial quando a probabilidade do evento é  $\lambda/n$  e  $n \rightarrow \infty$ . Esta aproximação é conhecida por **lei dos eventos raros**. Suponhamos que  $\lambda$  representa o número médio de eventos que se observam num intervalo de tempo (ou espaço). Divida-se o intervalo em  $n$  subintervalos de comprimento igual tal que  $n > \lambda$ . Então  $\lambda/n$  representa a proporção de eventos que se observam em cada subintervalo. Assumimos que a ocorrência de um evento num subintervalo é uma variável aleatória com **distribuição de Bernoulli** com parâmetro  $\lambda/n$ . Assim, o número de eventos no intervalo inicial é uma **distribuição Binomial** com parâmetros  $n$  e  $\lambda/n$ , ou seja, a probabilidade de observar  $k$  eventos é

$$\frac{n!}{(n-k)!k!} \left(\frac{\lambda}{n}\right)^k \left(1 - \frac{\lambda}{n}\right)^{n-k}.$$

Reescrevendo obtemos

$$\frac{n(n-1)\cdots(n-k+1)}{n^k} \frac{\lambda^k}{k!} \left(1 - \frac{\lambda}{n}\right)^n \left(1 - \frac{\lambda}{n}\right)^{-k}$$

Tomando o limite  $n \rightarrow \infty$ , é fácil verificar que o 1º termo do produto tem limite 1, o 2º não depende de  $n$ , o 3º tem limite  $e^{-\lambda}$  e o 4º tem limite 1. Portanto,

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

Vamos agora definir o processo de Poisson.

**Definição 4.1.2** (Processo de Poisson).  $\{N(t), t \geq 0\}$  é um **processo de Poisson** com parâmetro  $\lambda > 0$  se

1.  $N(0) = 0$ ,
2. os incrementos  $N(t+s) - N(s)$  têm distribuição de Poisson com parâmetro  $\lambda t$ ,

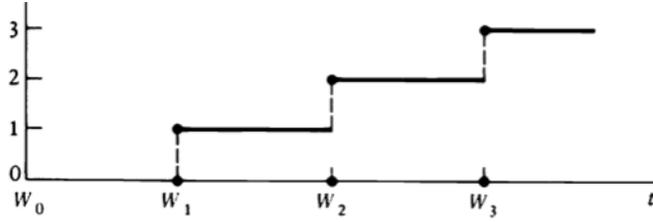


Figure 4.1: Realização de  $N(t)$

3.  $N(t)$  tem incrementos independentes, isto é, se  $t_0 < t_1 < \dots < t_n$  então

$$N(t_1) - N(t_0), \dots, N(t_n) - N(t_{n-1}) \quad \text{são independentes.}$$

O Processo de Poisson  $N(t)$  conta o número de eventos que ocorreram até ao instante  $t$ . É portanto um processo de contagem. Como têm incrementos estacionários e independentes, pertence a uma classe mais geral de processos que são as cadeias de Markov a tempo contínuo.

## 4.2 Construção do processo de Poisson

**Definição 4.2.1.** Sejam  $T_1, \dots, T_n$  variáveis aleatórias independentes com distribuição exponencial de parâmetro  $\lambda$ . Considere-se a soma  $W_n = T_1 + \dots + T_n$  com  $W_0 = 0$  e

$$N(t) := \max\{n \geq 0 : W_n \leq t\}.$$

Mostremos agora que  $N(t)$  é um processo de Poisson.

**Lemma 4.2.1.**  $N(t)$  tem distribuição de Poisson com parâmetro  $\lambda t$ .

*Demonstração.* Note-se que  $N(t) = n$  se e só se  $W_n \leq t < W_{n+1}$ . Portanto,

$$\begin{aligned} \mathbb{P}(N(t) = n) &= \mathbb{P}(W_n \leq t < W_{n+1}) \\ &= \int_0^t \mathbb{P}(W_n \leq t < W_{n+1} | W_n = s) f_{W_n}(s) ds \\ &= \int_0^t \mathbb{P}(T_{n+1} > t - W_n | W_n = s) f_{W_n}(s) ds \\ &= \int_0^t \mathbb{P}(T_{n+1} > t - s) f_{W_n}(s) ds. \end{aligned}$$

Segue da Proposição 4.0.1 que

$$\mathbb{P}(N(t) = n) = \int_0^t e^{-\lambda(t-s)} \lambda e^{-\lambda s} \frac{(\lambda s)^{n-1}}{(n-1)!} ds = e^{-\lambda t} \frac{(\lambda t)^n}{n!}.$$

□

**Lemma 4.2.2.**  $N(t+s) - N(s)$  tem distribuição de Poisson com parâmetro  $\lambda t$  e é independente de  $N(r)$  para  $0 \leq r \leq s$ .

*Demonstração.* Para fixar ideias, suponhamos que até ao instante  $s$  exactamente 3 eventos ocorreram nos instantes  $w_1, w_2$  e  $w_3$  (ver Figura 4.1). O tempo de espera até quarto evento é  $T_4$  que por hipótese  $s < w_3 + T_4$  (caso contrário 4 eventos teriam ocorrido). Como a distribuição exponencial não tem memória temos que,

$$\mathbb{P}(T_4 > s - w_3 + t | T_4 > s - w_3) = \mathbb{P}(T_4 > t).$$

Isto mostra que a distribuição do tempo de espera até ao primeiro evento depois de  $s$  é exponencial com parâmetro  $\lambda$  e independente de  $T_1, T_2$  e  $T_3$ . Logo,  $N(t+s) - N(s)$  tem a mesma distribuição de  $N(t)$  e é independente de  $N(r)$  com  $0 \leq r \leq s$ . □

**Lemma 4.2.3.**  $N(t)$  tem incrementos independentes.

*Demonstração.* O lemma anterior mostra que  $N(t_n) - N(t_{n-1})$  é independente de  $N(r)$  com  $r \leq t_{n-1}$ . Logo é independente de  $N(t_{n-1}) - N(t_{n-2})$ . O resultado segue usando indução. □

Mostrámos assim o seguinte teorema.

**Teorema 4.2.4.**  $N(t)$  é um processo de Poisson.

### 4.3 Caracterização

Descrevemos agora uma outra forma equivalente para caracterizar um processo de Poisson. Escrevemos  $o(h)$  para designar uma função que satisfaz  $\lim_{h \rightarrow 0} o(h)/h = 0$ .

**Teorema 4.3.1.** Seja  $\{N(t) : t \geq 0\}$  um processo estocástico tal que  $N(0) = 0$  e  $N(t) \in \{0, 1, 2, \dots\}$  para todo  $t \geq 0$ . O processo  $N(t)$  é Poisson se e só se

1.  $N(t)$  tem incrementos independentes
2.  $\mathbb{P}(N(t+h) - N(t) = 1) = \lambda h + o(h)$  quando  $h \rightarrow 0$
3.  $\mathbb{P}(N(t+h) - N(t) = 0) = 1 - \lambda h + o(h)$  quando  $h \rightarrow 0$

*Demonstração.* Se  $N(t)$  é um processo de Poisson, então  $N(t+h) - N(t)$  tem distribuição Poisson com parâmetro  $\lambda h$ . Portanto,

$$\mathbb{P}(N(t+h) - N(t) = 0) = e^{-\lambda h} \quad \text{e} \quad \mathbb{P}(N(t+h) - N(t) = 1) = \lambda h e^{-\lambda h}.$$

Logo,

$$\mathbb{P}(N(t+h) - N(t) = 0) = e^{-\lambda h} = 1 - \lambda h + o(h)$$

e

$$\mathbb{P}(N(t+h) - N(t) = 1) = \lambda h(1 - \lambda h + o(h)) = \lambda h + o(h)$$

Suponhamos agora que (1)-(3) se verificam e queremos mostrar que  $N(t+s) - N(s)$  tem distribuição de Poisson com parâmetro  $\lambda t$ . Consideremos o caso  $s = 0$  uma vez que o caso  $s > 0$  é análogo. Seja

$$p_n(t) = \mathbb{P}(N(t) = n).$$

Note-se que

$$\begin{aligned} p_n(t+h) &= \mathbb{P}(N(t) = n, N(t+h) - N(t) = 0) \\ &\quad + \mathbb{P}(N(t) = n, N(t+h) - N(t) = 1) \\ &\quad + \mathbb{P}(N(t) = n, N(t+h) - N(t) \geq 2) \end{aligned}$$

Segue de (1), (2) e (3) que

$$p_n(t+h) = p_n(t)p_0(h) + p_{n-1}(t)p_1(h) + o(h)$$

e

$$p_0(h) = 1 - \lambda h + o(h), \quad p_1(h) = \lambda h + o(h)$$

Logo,

$$p_n(t+h) - p_n(t) = -\lambda h p_n(t) + \lambda h p_{n-1}(t) + o(h)$$

Dividindo ambos os termos da equação por  $h$  e tomando o limite  $h \rightarrow 0$  temos que

$$p'_n(t) = -\lambda p_n(t) + \lambda p_{n-1}(t).$$

Note-se que  $p_{-1}(t) = 0$ . Temos de resolver este sistema de equações diferenciais com condição inicial

$$p_n(0) = \mathbb{P}(N(0) = n) = \begin{cases} 1 & n = 0 \\ 0 & n \geq 1 \end{cases}$$

Quando  $n = 0$  temos

$$p_0'(t) = -\lambda p_0(t) \quad \text{com} \quad p_0(t) = 1.$$

A solução é  $p_0(t) = e^{-\lambda t}$ . Usando indução é resolver as restantes equações e obter solução

$$p_n(t) = e^{-\lambda t} \frac{(\lambda t)^n}{n!}.$$

□

## 4.4 Relação com a distribuição Binomial

**Proposição 4.4.1.** *Sejam  $s < t$  e  $m \leq n$ . Então*

$$\mathbb{P}(N(s) = m | N(t) = n) = \frac{n!}{m!(n-m)!} \left(\frac{s}{t}\right)^m \left(1 - \frac{s}{t}\right)^{n-m}$$

*Demonstração.* Exercício.

□

## 4.5 Processo de Poisson não homogêneo

Uma extensão do processo de Poisson considera intensidades que variam ao longo do tempo.

**Definição 4.5.1.** Um processo  $\{N(t) : t \geq 0\}$  é um processo de Poisson com intensidade  $\lambda(t)$  se

1.  $N(0) = 0$
2.  $N(t)$  tem incrementos independentes
3.  $N(t) - N(s)$  tem distribuição de Poisson com parâmetro  $\int_s^t \lambda(r) dr$

É possível caracterizar um processo de Poisson não homogêneo através das aproximações de primeira ordem dos incrementos.

**Teorema 4.5.1.** *Um processo  $\{N(t) : t \geq 0\}$  é um processo de Poisson com intensidade  $\lambda(t)$  sse*

1. *Tem incrementos independentes*
2.  $\mathbb{P}(N(t+h) - N(t) = 1) = \lambda(t)h + o(h)$

$$3. \mathbb{P}(N(t+h) - N(t) = 0) = 1 - \lambda(t)h + o(h)$$

*Demonstração.* Procurar na bibliografia. □

**Exemplo 4.5.2.** Suponha que a procura de um produto numa loja entre as 9h e as 13h segue um processo de Poisson com taxa

$$\lambda(t) = \begin{cases} 2t, & 0 \leq t < 1 \\ 2, & 1 \leq t < 2 \\ 4 - t, & 2 \leq t \leq 4 \end{cases}$$

Vamos determinar a probabilidade da procura nas primeiras 2h ser igual a 2 artigos. Para tal, calculamos a taxa média entre  $t = 0$  e  $t = 2$ , portanto

$$\mu = \int_0^2 \lambda(t) dt = \int_0^1 2t dt + \int_1^2 2 dt = 1 + 2 = 3.$$

Assim,

$$\mathbb{P}(N(2) = 2) = e^{-3} \frac{3^2}{2!}.$$

No entanto, se quisermos determinar a probabilidade da procura ser igual a 2 artigos entre as 11h e as 13h, então

$$\mu = \int_2^4 \lambda(t) dt = \int_2^4 4 - t dt = 2,$$

e

$$\mathbb{P}(N(4) - N(2) = 2) = e^{-2} \frac{2^2}{2!}.$$

## 4.6 Exercícios

**Exercício 24.** Um autocarro chega a uma determinada paragem de 10 em 10 minutos. Suponha que o número de autocarros que chegam à paragem segue um processo de Poisson.

1. Qual é a probabilidade de o intervalo entre chegadas sucessivas ser superior a 20 minutos?
2. Após perder um autocarro, quanto tempo tem um passageiro de esperar para apanhar o autocarro seguinte com probabilidade de 0.5?
3. Dado que na última hora não chegou nenhum autocarro qual é a probabilidade esperar mais uma hora?

**Exercício 25.** Seja  $T$  uma variável aleatória com distribuição de probabilidade contínua. Mostre que  $T$  tem distribuição exponencial se e só se  $T$  não tem memória, isto é,

$$\mathbb{P}(T > x + y | T > x) = \mathbb{P}(T > y).$$

**Exercício 26.** A chegada de passageiros a uma paragem de autocarro segue um processo de Poisson com intensidade  $\lambda_1$ . Seja  $T$  o tempo de chegada de um autocarro que é independente do processo de Poisson. Quando  $t = 0$  não existem passageiros na paragem. Supondo que  $T$  segue uma distribuição exponencial com intensidade  $\lambda_2$ , calcule o número médio de pessoas na paragem no instante  $T$ .

**Exercício 27.** Suponha que  $N_1$  e  $N_2$  são processos de Poisson independentes com intensidades  $\lambda_1$  e  $\lambda_2$ , respectivamente. Mostre que  $N_1 + N_2$  é um processo de Poisson com intensidade  $\lambda_1 + \lambda_2$ .

## 4.7 Processo de Poisson composto

Dado um processo de Poisson  $N(t)$  com intensidade  $\lambda > 0$  e uma sucessão  $(X_n)_{n \geq 1}$  de variáveis aleatórias iid, e independentes do processo  $N(t)$ , designamos por  $Z(t)$  o **processo de Poisson composto** definido por

$$Z(t) = \sum_{n=1}^{N(t)} X_n$$

### Exemplo 4.7.1.

1. Em teoria do risco,  $N(t)$  representa o número de sinistros observados até ao instante  $t$ ,  $X_n$  a indemnização do  $n$ -ésimo sinistro, e  $Z(t)$  a indemnização agregada até ao instante  $t$ .
2. Outro exemplo, em matemática financeira, usa o processo de Poisson composto para descrever a evolução do preço de um activo financeiro. Suponhamos que transações de um certo activo ocorrem segundo um processo de Poisson com intensidade  $\lambda > 0$ . A variável  $X_k$  representa a variação do preço do activo entre a  $k - 1$  e a  $k$ -ésima transação. Supomos também que as variações são independentes entre si. Sob estas condições,  $Z(t)$  representa a variação total do preço do activo até ao instante  $t$ .

A distribuição do processo de Poisson composto pode ser calculada explicitamente fazendo a convolução das distribuições dos incrementos do processo (ver Exercício 2). Suponhamos que as variáveis aleatórias  $X_n$  são contínuas e admitem densidade de probabilidade  $f(x)$  (uma vez que são iid). Seja  $f^{(n)}(x)$  a densidade de probabilidade de  $X_1 + \dots + X_n$ , i.e.,

$$f^{(n)}(x) = f_{X_1+\dots+X_n}(x).$$

Usando o Exercício 2, temos que

$$f^{(n)}(x) = \int_{-\infty}^{+\infty} f^{(n-1)}(x-y)f(y) dy, \quad n = 2, 3, \dots$$

Assim,

$$\begin{aligned} F^{(n)}(x) &= \mathbb{P}(X_1 + \dots + X_n \leq x) \\ &= \int_{-\infty}^x \int_{-\infty}^{+\infty} f^{(n-1)}(z-y)f(y) dy dz \\ &= \int_{-\infty}^{+\infty} \left( \int_{-\infty}^x f^{(n-1)}(z-y) dz \right) f(y) dy \\ &= \int_{-\infty}^{+\infty} F^{(n-1)}(x-y)f(y) dy \end{aligned}$$

Então

$$\begin{aligned} \mathbb{P}(Z(t) \leq x) &= \mathbb{P}\left(\sum_{k=1}^{N(t)} X_k \leq x\right) \\ &= \sum_{n=0}^{\infty} \mathbb{P}(X_1 + \dots + X_n \leq x | N(t) = n) \mathbb{P}(N(t) = n) \\ &= \sum_{n=0}^{\infty} \mathbb{P}(X_1 + \dots + X_n \leq x) \mathbb{P}(N(t) = n) \\ &= \sum_{n=0}^{\infty} F^{(n)}(x) \frac{(\lambda t)^n}{n!} e^{-\lambda t} \end{aligned}$$

Fórmulas para os momentos de primeira e segunda ordem podem ser obtidas analogamente.

**Exercício 28.** Mostre que

$$E(Z(t)) = \lambda\mu t \quad \text{e} \quad V(Z(t)) = \lambda(\nu^2 + \mu^2)t$$

onde  $\mu = E(X_1)$  e  $\nu^2 = V(X_1)$ .

Expressões idênticas podem ser deduzidas quando as variáveis  $X_n$  são discretas. Neste caso, o integral é substituído por uma soma. Compare com o Exercício 3.

**Exercício 29.** Considere um sistema sujeito a impactos. Em média observa-se  $\lambda$  impactos por unidade de tempo. Seja  $N(t)$  o número de impactos observados até instante  $t$ . Cada impacto provoca um estrago mensurável  $X_n$  no sistema. Supomos que as variáveis  $X_n$  são exponencialmente distribuídas com intensidade  $\mu > 0$ . O sistema permanece em funcionamento enquanto o estrago total não exceder um valor crítico  $a > 0$ . Usando o processo de Poisson composto para descrever o estrago total do sistema determine:

1. A distribuição de probabilidade do tempo de falha do sistema, i.e.,

$$T = \min \{t \geq 1: Z(t) \geq a\}$$

2. O tempo médio de funcionamento  $E(T)$ .

# Chapter 5

## Processos de Markov em tempo contínuo

Seja  $\{X(t): t \geq 0\}$  um processo estocástico a tempo contínuo com espaço de estados  $E = \{0, 1, 2, 3 \dots\}$ .

**Definição 5.0.1.** Dizemos que  $\{X(t): t \geq 0\}$  é um **processo (ou cadeia) de Markov a tempo contínuo** sse

$$\begin{aligned} \mathbb{P}(X(t+s) = j | X(s) = i, X(s_n) = i_n \dots, X(s_0) = i_0) \\ = \mathbb{P}(X(t+s) = j | X(s) = i) \end{aligned}$$

para todo  $t > 0, s > s_n > \dots > s_0 > 0$  e  $j, i, i_n, \dots, i_0 \in E$ .

**Exemplo 5.0.1.** Uma classe especial de processos de Markov são os processos com incrementos estacionários e independentes. Suponhamos que  $X(0) = 0$ . O processo  $X(t)$  tem **incrementos estacionários e independentes** sse

1.  $X(t) - X(s) \stackrel{d}{=} X(t-s)$  para  $t > s$ ;
2. As variáveis aleatórias são independentes

$$X(t_n) - X(t_{n-1}), \dots, X(t_1) - X(t_0)$$

para quaisquer  $t_0 < t_1 < \dots < t_n$ .

Um processo com incrementos estacionários e independentes tem uma expressão simples para a evolução da média e da covariância do processo. Sejam  $m(t) = E(X(t))$  e  $c(s, t) = \text{Cov}(X(s), X(t))$ . Então<sup>1</sup> existem  $\mu \in \mathbb{R}$  e  $\sigma > 0$  tal que

$$m(t) = \mu t \quad \text{e} \quad c(s, t) = \sigma^2 \min\{s, t\}.$$

---

<sup>1</sup>Prova-se usando o lemma de Cauchy. Ver [https://en.wikipedia.org/wiki/Cauchy%27s\\_functional\\_equation](https://en.wikipedia.org/wiki/Cauchy%27s_functional_equation)

O processo de Markov é **homogêneo** se as probabilidades de transição não dependerem de  $s$ , ou seja,

$$\mathbb{P}(X(t+s) = j | X(s) = i) = \mathbb{P}(X(t) = j | X(0) = i).$$

Neste curso tratamos apenas dos processos homogêneos. Defina-se

$$p_{i,j}(t) = \mathbb{P}(X(t) = j | X(0) = i).$$

É claro que

$$p_{i,j}(0) = \begin{cases} 0, & i \neq j \\ 1, & i = j \end{cases}.$$

As equações de Chapman-Kolmogorov podem ser obtidas de forma equivalente ao caso discreto (cadeias de Markov).

**Proposição 5.0.2** (Equações de Chapman-Kolmogorov).

$$p_{i,j}(t+s) = \sum_{k \in E} p_{i,k}(t) p_{k,j}(s).$$

*Demonstração.* Exercício. □

Suponhamos que as probabilidades de transição  $p_{i,j}(t)$  são funções bem comportadas, ou seja, que podemos tomar o limite

$$q_{i,j} = \lim_{t \rightarrow 0^+} \frac{p_{i,j}(t)}{t}, \quad i \neq j.$$

No caso em que o limite existe designamos por  $q_{i,j}$  a **intensidade do salto de  $i$  para  $j$** . Note-se que  $q_{i,j} = p'_{i,j}(0)$ . Da igualdade,

$$p_{i,i}(t) = 1 - \sum_{j \neq i} p_{i,j}(t),$$

segue que

$$q_{i,i} := \lim_{t \rightarrow 0^+} \frac{p_{i,i}(t) - 1}{t} = - \sum_{j \neq i} q_{i,j}.$$

Note-se que  $q_{i,i} = p'_{i,i}(0)$ . A matriz formada pelas intensidades dos saltos é conhecida por **matriz de intensidades** do processo,

$$Q = (q_{i,j})_{i,j \in E}.$$

Uma matriz de intensidades  $Q$  tem a soma das linhas igual a zero e as entradas da diagonal sempre não-positivas.

Veremos de seguida que é possível construir um processo de Markov a partir de uma matriz de intensidades. Mais, a matriz de intensidades especifica a lei de probabilidade do processo, ou seja, é possível determinar a distribuição de probabilidade do processo a partir da matriz de intensidades. Antes de prosseguir, vejamos alguns exemplos.

**Exemplo 5.0.3.** O processo de Poisson tem incrementos estacionários e independentes, logo é um processo de Markov. Por outro lado, das equações que caracterizam o processo

$$\begin{aligned}\mathbb{P}(N(t+h) - N(t) = 1) &= \lambda h + o(h) \\ \mathbb{P}(N(t+h) - N(t) = 0) &= 1 - \lambda h + o(h)\end{aligned}$$

obtemos

$$p_{i,j}(t) = \begin{cases} 1 - \lambda t + o(t), & j = i \\ \lambda t + o(t), & j = i + 1 \\ 0, & \text{caso contrário} \end{cases}.$$

Assim,

$$q_{i,j} = \begin{cases} -\lambda, & j = i \\ \lambda, & j = i + 1 \\ 0, & \text{caso contrário} \end{cases}$$

com matriz de intensidades

$$Q = \begin{pmatrix} -\lambda & \lambda & 0 & 0 & \dots \\ 0 & -\lambda & \lambda & 0 & \dots \\ 0 & 0 & -\lambda & \lambda & \dots \\ \vdots & \vdots & \vdots & \vdots & \ddots \end{pmatrix}$$

**Exemplo 5.0.4.** Os **Processos de Nascimento e Morte** são processos de Markov a tempo contínuo que generalizam os processos de Poisson, no sentido em que são permitidos decrementos do processo. O processo de nascimento e morte é caracterizado por,

1.  $p_{i,i+1}(t) = \lambda_i t + o(t)$ ,  $i = 0, 1, \dots$
2.  $p_{i,i-1}(t) = \mu_i t + o(t)$ ,  $i = 1, 2, \dots$
3.  $p_{i,i}(t) = 1 - (\lambda_i + \mu_i)t + o(t)$ ,  $i = 0, 1, \dots$
4.  $p_{i,j}(t) = \begin{cases} 1, & i = j \\ 0, & i \neq j \end{cases}$

5.  $\mu_0 = 0$ ,  $\lambda_0 > 0$  e  $\lambda_i, \mu_i > 0$  para  $i = 1, 2, \dots$

É fácil verificar que o processo tem a seguinte matriz de intensidades

$$Q = \begin{pmatrix} -\lambda_0 & \lambda_0 & 0 & 0 & \cdots \\ \mu_1 & -(\lambda_1 + \mu_1) & \lambda_1 & 0 & \cdots \\ 0 & \mu_2 & -(\lambda_2 + \mu_2) & \lambda_2 & \cdots \\ \vdots & \vdots & \vdots & \vdots & \ddots \end{pmatrix}$$

**Exemplo 5.0.5. O Processo de Ramificação** modela a evolução de uma população onde cada indivíduo nasce a uma taxa  $\lambda > 0$  e morre a uma taxa  $\mu > 0$ . Assim

$$q_{i,i+1} = \lambda i \quad \text{e} \quad q_{i,i-1} = \mu i.$$

Quando  $\mu = 0$  obtém-se o **Processo de Yule**.

**Exemplo 5.0.6.** Numa fila de espera do tipo  $(M/M/s)$  com  $s$  servidores temos

$$q_{i,i+1} = \lambda \quad \text{e} \quad q_{i,i-1} = \begin{cases} i\mu, & 0 \leq i \leq s \\ s\mu, & i > s \end{cases}$$

onde  $\lambda$  é a taxa de chegada de novos clientes à fila e  $\mu$  a taxa de serviço de cada servidor. Filas de espera serão tratadas com maior detalhe na secção 5.5.

## 5.1 Construção do Processo de Markov

Dada uma matriz de intensidades  $Q$  vamos de seguida construir um processo de Markov  $X(t)$  com intensidades  $Q$ . Seja

$$\lambda_i = \sum_{i \neq j} q_{i,j}$$

a intensidade com que o processo deixa o estado  $i \in E$ . Vamos supor que  $0 \leq \lambda_i < \infty$ . Define-se

$$r_{i,j} = \frac{q_{i,j}}{\lambda_i}, \quad i \neq j,$$

que corresponde à "probabilidade" do processo entrar em  $j$  uma vez que saiu de  $i$ . Quando  $\lambda_i = 0$  então o processo é constante no estado  $i$  e definimos  $r_{i,i} = 1$ . Usando as probabilidades  $r_{i,j}$  definimos uma cadeia de Markov  $(Y_n)_{n \geq 0}$  com matriz de transição  $R = (r_{i,j})$ . As variáveis  $Y_n$  representarão

a  $n$ -ésima ocorrência do processo de Markov. Sejam  $\tau_0, \tau_1, \tau_2, \dots$  variáveis aleatórias iid com distribuição exponencial de parâmetro 1 e

$$T_n = \frac{\tau_{n-1}}{\lambda_{Y_{n-1}}} \quad \text{e} \quad W_n = T_1 + \dots + T_n, \quad n = 1, 2, \dots$$

Convenientemente definimos  $W_0 = 0$ . Finalmente, definimos o processo de Markov como

$$X(t) = Y_n, \quad W_n \leq t < W_{n+1}.$$

Os tempos  $T_n$  são independentes e têm distribuição exponencial de parâmetro  $\lambda_{Y_{n-1}}$ . Correspondem aos tempos entre ocorrências com intensidade  $\lambda_{Y_{n-1}}$  de transitar do estado  $Y_{n-1}$  para o estado  $Y_n$ . Os tempos  $W_n$  são os tempos de espera até ocorrer  $Y_n$ .

Esta construção do processo fornece um algoritmo para simular um processo de Markov a partir da matriz de intensidades  $Q$ .

## 5.2 Equações Regressivas/Progressivas de Kolmogorov

A partir da matriz  $Q$  podemos determinar a distribuição do processo de Markov. Iremos de seguida deduzir umas equações diferenciais que relacionam as probabilidades de transição  $p_{i,j}(t)$ . Usando a equação de Chapman-Kolmogorov,

$$\begin{aligned} p_{i,j}(t+h) - p_{i,j}(t) &= \sum_k p_{i,k}(h)p_{k,j}(t) - p_{i,j}(t) \\ &= \sum_{k \neq i} p_{i,k}(h)p_{k,j}(t) + (p_{i,i}(h) - 1)p_{i,j}(t). \end{aligned}$$

Dividindo todos os termos por  $h$  e tomando o limite obtemos as **equações regressivas de Kolmogorov**,

$$p'_{i,j}(t) = \sum_{k \neq i} q_{i,k}p_{k,j}(t) - \lambda_i p_{i,j}(t),$$

uma vez que

$$\lim_{h \rightarrow 0} \frac{p_{i,i}(h) - 1}{h} = - \lim_{h \rightarrow 0} \sum_{k \neq i} \frac{p_{i,k}(h)}{h} = - \sum_{k \neq i} q_{i,k} = -\lambda_i.$$

Podemos escrever as equações regressivas de Kolmogorov em forma matricial,

$$P'(t) = QP(t),$$

onde  $P(t) = (p_{i,j}(t))_{i,j \in E}$  é a matriz das probabilidades de transição. A equação diferencial tem de ser resolvida usando a condicional inicial  $P(0) = I$ , ou seja,

$$p_{i,j}(0) = \begin{cases} 1, & i = j \\ 0, & i \neq j \end{cases}$$

A solução da equação é dada a partir da matriz exponencial

$$P(t) = e^{tQ} \stackrel{\text{def}}{=} \sum_{n=0}^{\infty} \frac{(tQ)^n}{n!}.$$

Note-se que  $\frac{d}{dt}e^{tQ} = Qe^{tQ}$ . Uma forma de calcular a matriz exponencial é diagonalizando a matriz  $Q$ . Se a matriz  $Q$  for diagonalizável<sup>2</sup>, então existe uma matriz invertível  $U$ , formada pelos vectores próprios de  $Q$ , tal que

$$\Delta = U^{-1}QU$$

é uma matriz diagonal, ou seja, todas as entradas fora da diagonal são zero. Suponhamos que  $a_1, a_2, \dots$  são os elementos da diagonal de  $\Delta$ . Então  $e^{t\Delta}$  é a matriz diagonal com elementos  $e^{a_1 t}, e^{a_2 t}, \dots$ . Assim,

$$e^{tQ} = Ue^{t\Delta}U^{-1}.$$

Na dedução das equações regressivas de Kolmogorov partimos o intervalo  $[0, t+h]$  da forma  $[0, h] \cup [h, t+h]$ . Usando a partição  $[0, t] \cup [t, t+h]$  e repetindo a dedução obtêm-se as **equações progressivas de Kolmogorov**,

$$p'_{i,j}(t) = \sum_{k \neq j} p_{i,k}(t)q_{k,j} - \lambda_j p_{i,j}(t),$$

que reescritas na formal matricial,

$$P'(t) = P(t)Q.$$

Note-se que

$$P(t)Q = QP(t).$$

**Exemplo 5.2.1** (Processo de nascimento). Suponhamos que o processo de nascimento começa em zero, i.e.,  $X(0) = 0$ . Definimos

$$p_n(t) := \mathbb{P}(X(t) = n | X(0) = 0)$$

---

<sup>2</sup>Uma condição suficiente para  $Q$  ser diagonalizável é ter os seus valores próprios todos distintos.

Note-se que

$$p_n(0) = \begin{cases} 1, & n = 0 \\ 0, & n > 0 \end{cases}$$

Escrevendo as equações progressivas para o processo de nascimento obtemos o seguinte sistema para calcular  $p_n(t)$ ,

$$\begin{aligned} p_0'(t) &= -\lambda_0 p_0(t) \\ p_n'(t) &= -\lambda_n p_n(t) + \lambda_{n-1} p_{n-1}(t), \quad n \geq 1 \end{aligned}$$

Da primeira equação obtém-se

$$p_0(t) = e^{-\lambda_0 t}$$

As restantes equações podem ser resolvidas recursivamente, ou seja, sabendo  $p_{n-1}(t)$ , podemos calcular  $p_n(t)$  integrando a equação diferencial usando, por exemplo, o método de variação dos parâmetros. Obtém-se assim,

$$p_n(t) = \lambda_{n-1} e^{-\lambda_n t} \int_0^t e^{\lambda_n s} p_{n-1}(s) ds, \quad n = 1, 2, \dots$$

Para que a solução  $(p_n(t))_{n \geq 0}$  obtida seja uma distribuição de probabilidade é necessário que

$$\sum_{n=0}^{\infty} p_n(t) = 1 \quad \text{e} \quad p_n(t) \geq 0, \quad \forall n \geq 0.$$

A segunda condição é trivialmente satisfeita. No entanto, pode-se demonstrar que a primeira condição é satisfeita se e só se

$$\sum_{n=0}^{\infty} \frac{1}{\lambda_n} = \infty,$$

ou seja, é necessário um tempo médio infinito para que a população seja infinita.

Quando as intensidades  $\lambda_n$  são todas distintas, então podemos escrever expressões relativamente simples para as probabilidades  $p_n(t)$ ,

$$p_n(t) = \lambda_0 \cdots \lambda_{n-1} \sum_{k=0}^n \left( \prod_{j=0, j \neq k}^n \frac{1}{\lambda_j - \lambda_k} \right) e^{-\lambda_k t}, \quad n = 1, 2, \dots$$

Em particular,

$$p_1(t) = \lambda_0 \left( \frac{1}{\lambda_1 - \lambda_0} e^{-\lambda_0 t} + \frac{1}{\lambda_0 - \lambda_1} e^{-\lambda_1 t} \right)$$

e

$$p_2(t) = \lambda_0 \lambda_1 \left( \frac{1}{(\lambda_1 - \lambda_0)(\lambda_2 - \lambda_0)} e^{-\lambda_0 t} + \frac{1}{(\lambda_0 - \lambda_1)(\lambda_2 - \lambda_1)} e^{-\lambda_1 t} + \frac{1}{(\lambda_0 - \lambda_2)(\lambda_1 - \lambda_2)} e^{-\lambda_2 t} \right)$$

**Exemplo 5.2.2** (Processo de Markov com 2 estados). Considere um processo de Markov com estados  $\{0, 1\}$  e matriz de intensidade

$$Q = \begin{pmatrix} -\lambda & \mu \\ \mu & -\lambda \end{pmatrix}$$

onde  $\lambda, \mu > 0$ . As equações regressivas de Kolmogorov são,

$$\begin{pmatrix} p'_{0,0}(t) & p'_{0,1}(t) \\ p'_{1,0}(t) & p'_{1,1}(t) \end{pmatrix} = \begin{pmatrix} -\lambda & \mu \\ \mu & -\lambda \end{pmatrix} \begin{pmatrix} p_{0,0}(t) & p_{0,1}(t) \\ p_{1,0}(t) & p_{1,1}(t) \end{pmatrix}$$

Como  $p_{i,1} = 1 - p_{i,0}$  vamos determinar primeiro  $p_{i,0}$ . As equações para  $p_{i,0}$  são

$$\begin{aligned} p'_{0,0}(t) &= \lambda p_{1,0}(t) - \lambda p_{0,0}(t) \\ p'_{1,0}(t) &= \mu p_{0,0}(t) - \mu p_{1,0}(t) \end{aligned}$$

Fazendo a diferença obtém-se a seguinte equação diferencial linear,

$$\frac{d}{dt} (p_{0,0}(t) - p_{1,0}(t)) = -(\lambda + \mu) (p_{0,0}(t) - p_{1,0}(t)),$$

com condição inicial  $p_{0,0}(0) - p_{1,0}(0) = 1 - 0 = 1$ . Logo,

$$p_{0,0}(t) - p_{1,0}(t) = e^{-(\lambda+\mu)t}.$$

Como  $p'_{0,0}(t) = -\lambda e^{-(\lambda+\mu)t}$  segue que

$$p_{0,0}(t) = 1 - \int_0^t \lambda e^{-(\lambda+\mu)t} = \frac{\mu}{\lambda + \mu} + \frac{\lambda}{\lambda + \mu} e^{-(\lambda+\mu)t}.$$

De forma análoga determinam-se as restantes probabilidades de transição.

Assim

$$P(t) = \begin{pmatrix} \frac{\mu}{\lambda+\mu} + \frac{\lambda}{\lambda+\mu} e^{-(\lambda+\mu)t} & \frac{\lambda}{\lambda+\mu} - \frac{\lambda}{\lambda+\mu} e^{-(\lambda+\mu)t} \\ \frac{\mu}{\lambda+\mu} - \frac{\mu}{\lambda+\mu} e^{-(\lambda+\mu)t} & \frac{\lambda}{\lambda+\mu} + \frac{\mu}{\lambda+\mu} e^{-(\lambda+\mu)t} \end{pmatrix}$$

Note-se que a distribuição limite

$$\lim_{t \rightarrow \infty} p_{i,j}(t) = \begin{cases} \frac{\mu}{\lambda + \mu}, & j = 0 \\ \frac{\lambda}{\lambda + \mu}, & j = 1 \end{cases},$$

não depende do estado de partida  $i$ .

### 5.3 Distribuição estacionária

Dada uma distribuição inicial  $\pi(0)$  para  $X(0)$ , a distribuição  $\pi(t)$  de  $X(t)$  é obtida da seguinte forma,

$$\pi(t) = \pi(0)P(t).$$

Um caso especial é quando  $\pi(t)$  é constante e independente de  $t$ . Nesse caso  $\pi(t) = \pi(0)$  para todo  $t \geq 0$ . Este facto motiva a seguinte definição (compare com as cadeias de Markov).

**Definição 5.3.1.** Uma distribuição  $\pi$  é estacionária sse  $\pi P(t) = \pi$  para todo  $t \geq 0$ .

Se um processo de Markov admite uma distribuição estacionária  $\pi$ , então o processo é estacionário com distribuição inicial  $\pi$ .

**Lemma 5.3.1.**  $\pi$  é uma distribuição estacionária sse  $\pi Q = 0$ .

*Demonstração.* Se  $\pi P(t) = \pi$ , então

$$0 = \frac{d}{dt} \pi P(t) = \pi P'(t) = \pi P(t)Q = \pi Q.$$

Por outro lado, se  $\pi Q = 0$ , então

$$\frac{d}{dt} \pi P(t) = \pi P'(t) = \pi Q P(t) = 0.$$

Logo,  $\pi P(t)$  é constante para todo  $t \geq 0$ . Em particular,  $\pi P(t) = \pi P(0) = \pi$ .  $\square$

De seguida vamos relacionar a distribuição estacionária com a distribuição limite do processo.

**Definição 5.3.2.** Um processo de Markov é **irredutível** se para todo  $i, j \in E$  existe uma sequência de estados  $i = k_0, k_1, \dots, k_n = j$  tal que

$$q_{k_{m-1}, k_m} > 0, \quad m = 1, \dots, n.$$

**Teorema 5.3.2.** *Se o processo de Markov é irredutível e admite uma distribuição estacionária  $\pi$ , então*

$$\pi_j = \lim_{t \rightarrow \infty} p_{i,j}(t).$$

*Demonstração.* Ver na bibliografia. □

**Exemplo 5.3.3.** Considere o seguinte modelo simplificado para prever o tempo numa região. O processo é composto por três estados 0 = sol, 1 = nublado e 2 = chuva. Sabe-se que

1. Permanece sol durante um período de 3 dias até ficar nublado;
2. Permanece nublado durante um período de 4 dias até começar a chover;
3. Após 1 dia de chuva regressa o sol.

A matriz de intensidades do processo é

$$Q = \begin{pmatrix} -1/3 & 1/3 & 0 \\ 0 & -1/4 & 1/4 \\ 1 & 0 & -1 \end{pmatrix}.$$

Para determinar a distribuição estacionária vamos resolver o sistema  $\pi Q = 0$ , ou seja,

$$\begin{aligned} -\frac{1}{3}\pi_1 + \pi_3 &= 0 \\ \frac{1}{3}\pi_1 - \frac{1}{4}\pi_2 &= 0 \\ \frac{1}{4}\pi_2 - \pi_3 &= 0 \end{aligned}$$

Usando  $\pi_1 + \pi_2 + \pi_3 = 1$  determinamos a solução

$$\pi = \left( \frac{3}{8}, \frac{1}{2}, \frac{1}{8} \right).$$

Como o processo é irredutível (todos os estados comunicam entre si), sabemos que

$$\lim_{t \rightarrow \infty} p_{j,0}(t) = \frac{3}{8}.$$

Ou seja, a longo prazo, 3 em cada 8 dias vão ser dias de sol.

**Exemplo 5.3.4.** Considere um processo de nascimento e morte com parâmetros  $\lambda_n > 0$  e  $\mu_n > 0$ . Recorde que a matriz de intensidades,

$$Q = \begin{pmatrix} -\lambda_0 & \lambda_0 & 0 & 0 & \cdots \\ \mu_1 & -(\lambda_1 + \mu_1) & \lambda_1 & 0 & \cdots \\ 0 & \mu_2 & -(\lambda_2 + \mu_2) & \lambda_2 & \cdots \\ \vdots & \vdots & \vdots & \vdots & \ddots \end{pmatrix}$$

Vamos determinar as distribuições estacionárias do processo, i.e.,  $\pi Q = 0$ . Temos de resolver o sistema

$$\begin{cases} -\lambda_0\pi_0 + \mu_1\pi_1 = 0 \\ \lambda_{n-1}\pi_{n-1} - (\lambda_n + \mu_n)\pi_n + \mu_{n+1}\pi_{n+1} = 0, \quad n = 1, 2, \dots \end{cases}$$

Definimos  $\theta_0 = 1$  e

$$\theta_n = \frac{\lambda_0 \cdots \lambda_{n-1}}{\mu_1 \cdots \mu_n}, \quad n = 1, 2, \dots$$

Usando indução mostramos que

$$\pi_n = \theta_n \pi_0$$

De facto, o caso  $n = 0$  verifica-se. Supondo a hipótese de indução temos que

$$\begin{aligned} \pi_{n+1} &= \frac{(\lambda_n + \mu_n)\pi_n - \lambda_{n-1}\pi_{n-1}}{\mu_{n+1}} \\ &= \frac{(\lambda_n + \mu_n)\theta_n - \lambda_{n-1}\theta_{n-1}}{\mu_{n+1}} \pi_0 \\ &= \frac{\lambda_n\theta_n}{\mu_{n+1}} \pi_0 + \frac{\mu_n\theta_n - \lambda_{n-1}\theta_{n-1}}{\mu_{n+1}} \pi_0 \\ &= \theta_{n+1} \pi_0 \end{aligned}$$

uma vez que  $\mu_{n+1}\theta_{n+1} = \lambda_n\theta_n$ . Assim,

$$1 = \sum_{n=0}^{\infty} \pi_n = \pi_0 \sum_{n=0}^{\infty} \theta_n.$$

Desta equação determinamos  $\pi_0$  e conseqüentemente  $\pi_n$ . Logo, supondo que

$$\sum_{n=0}^{\infty} \theta_n < \infty \tag{5.3.1}$$

o processo de nascimento e morte tem uma única distribuição estacionária dada por,

$$\pi_n = \frac{\theta_n}{\sum_{n=0}^{\infty} \theta_n}, \quad n = 0, 1, 2, \dots$$

Segue do Teorema 5.3.2, que sob a condição (5.3.1), a distribuição estacionária é a distribuição limite do processo.

**Exemplo 5.3.5.** O processo de nascimento e morte pode ser usado para descrever o crescimento linear de uma população  $X(t)$  sujeita com imigração,

$$\lambda_n = n\lambda + a \quad \text{e} \quad \mu_n = n\mu$$

onde  $a > 0$  é uma taxa de imigração constante. Suponhamos que  $\lambda < \mu$ , ou seja, que a intensidade de nascimento per capita é menor que a intensidade de morte. Nestas condições o processo tem uma distribuição estacionária. Calculamos,

$$\begin{aligned} \theta_n &= \frac{a(a + \lambda) \cdots (a + (n - 1)\lambda)}{\mu^n n!} \\ &= \left(\frac{\lambda}{\mu}\right)^n \frac{(a/\lambda)(a/\lambda + 1) \cdots (a/\lambda + (n - 1))}{n!} \\ &= C_n^{\alpha+n-1} \left(\frac{\lambda}{\mu}\right)^n \end{aligned}$$

onde  $\alpha = a/\lambda$ . Assim<sup>3</sup>,

$$\sum_{n=0}^{\infty} \theta_n = \sum_{n=0}^{\infty} C_n^{\alpha+n-1} \left(\frac{\lambda}{\mu}\right)^n = \left(1 - \frac{\lambda}{\mu}\right)^{-\alpha}$$

uma vez que  $\lambda/\mu < 1$ . Portanto,

$$\pi_n = C_n^{\alpha+n-1} \left(\frac{\lambda}{\mu}\right)^n \left(1 - \frac{\lambda}{\mu}\right)^{\alpha}$$

Usando a distribuição estacionária, podemos calcular o valor médio (no limite) da população,

$$\lim_{t \rightarrow \infty} E(X(t)) = \sum_{n=0}^{\infty} n\pi_n = \frac{a}{\mu - \lambda}.$$

---

3

$$(1 - x)^{-\alpha} = \sum_{n=0}^{\infty} C_n^{\alpha+n-1} x^n, \quad |x| < 1$$

## 5.4 Exercícios

**Exercício 30.** Considere o crescimento linear com imigração do Exemplo 5.3.5. Mostre que o valor médio (no limite) da população é  $a/(\mu - \lambda)$  quando  $\lambda < \mu$ .

**Exercício 31.** Seja  $(Y_n)_{n \geq 0}$  uma cadeia de Markov com estados  $\{0, 1\}$  e matriz de transição

$$P = \begin{pmatrix} 0 & 1 \\ 1 - \alpha & \alpha \end{pmatrix}, \quad \alpha > 0.$$

Considere um processo de Poisson  $N(t)$  com parâmetro  $\lambda > 0$ . Mostre que

$$X(t) = Y_{N(t)}$$

é um processo de nascimento e morte com dois estados  $\{0, 1\}$ . Determine os parâmetros do processo  $\lambda_0$  e  $\mu_1$  em função de  $\alpha$  e  $\lambda$ .

**Exercício 32.** Considere um processo  $X(t)$  de nascimento (sem morte) com parâmetros  $\lambda_0 = 1$ ,  $\lambda_1 = 3$  e  $\lambda_2 = 2$ . Supondo que  $X(0) = 0$ , determine  $\mathbb{P}(X(t) = j)$  para  $j = 0, 1, 2$ .

**Exercício 33.** Considere um processo de nascimento e morte com parâmetros  $\lambda_n = \lambda$  e  $\mu_n = \mu n$  para  $n = 0, 1, 2, \dots$ . Verifique que as probabilidades

$$p_{0,j}(t) = \frac{(\lambda p)^j e^{-\lambda p}}{j!}, \quad \text{onde } p = \frac{1 - e^{-\mu t}}{\mu}$$

satisfazem as equações progressivas de Kolmogorov ( $i = 0$ ).

**Exercício 34.** Um camião viaja entre Lisboa, Castelo Branco e Porto com a seguinte matriz de intensidades (número de viagens por mês)

$$Q = \begin{pmatrix} -4 & 2 & 2 \\ 3 & -4 & 1 \\ 5 & 0 & -5 \end{pmatrix}$$

Determine:

1. A fracção de tempo (a longo prazo) que o camião permanece em cada cidade.
2. O número médio de viagens por ano de Castelo Branco para Lisboa.

**Exercício 35.** Seja  $X(t)$  um processo de nascimento e morte com estados  $\{0, 1, \dots, N\}$  e parâmetros  $\lambda_n = \alpha(N - n)$  e  $\mu_n = \beta n$  onde  $\alpha, \beta > 0$ . Determine a distribuição estacionária.

**Exercício 36.** Uma fábrica tem 2 máquinas e um técnico responsável pela sua manutenção. Suponha que cada máquina trabalha durante um tempo médio de 12 dias até necessitar de manutenção e o técnico demora em média 2 dias para realizar a respectiva manutenção.

1. Supondo que a intensidade de avaria é proporcional ao número de máquinas em funcionamento, use um processo de nascimento e morte para modelar o número de máquinas em activo. Determine a matriz de intensidades que caracteriza o processo.
2. Sabendo que  $p_{0,0}(t) = \frac{6}{25}e^{-\frac{5t}{6}} + \frac{18}{25}e^{-\frac{5t}{12}} + \frac{1}{25}$  calcule as probabilidades de transição  $p_{1,0}(t)$  e  $p_{2,0}(t)$  do processo.
3. Determine a distribuição estacionária.
4. Qual é fracção de tempo (longo prazo) de funcionamento simultâneo das máquinas.

## 5.5 Filas de Espera

Uma fila de espera consiste num sistema em que clientes chegam aleatoriamente e esperam para ser servidos. Uma fila de espera é caracterizada por:

- Um processo de chegada
- Uma distribuição do tempo de serviço
- Disciplina de serviço: número de servidores e política de serviço.

Iremos considerar filas de espera onde o processo de chegada é o processo de Poisson, os tempos de serviço são distribuídos exponencialmente, e a política de serviço é *first in first out* (FIFO).

Eis algumas medidas (assimptóticas) que são importantes no estudo de uma fila de espera:

- a distribuição limite do número de clientes na fila
- taxa de utilização dos servidores
- comprimento médio do número de pessoas no sistema e em fila de espera
- tempo médio de espera até ser servido

Usaremos a notação de Kendall para designar um tipo de fila de espera

$$A/B/s$$

onde  $A$  representa o tipo de distribuição dos tempos entre chegadas,  $B$  o tempo de serviço de cada servidor, e  $s$  o número de servidores existentes no sistema. Usualmente,  $A$  e  $B$  são do tipo

- $G$ , distribuição geral
- $M$ , distribuição sem memória
- $E_k$ , de Erlang, distribuição gamma de ordem  $k$

De seguida iremos estudar as filas de espera

$$M/M/s$$

onde os tempos entre chegada/serviço são exponencialmente distribuídos. Seja  $X(t)$  o número de clientes no sistema no instante  $t$ , i.e., o número de clientes em fila de espera mais o número de clientes a serem servidos. Não é difícil verificar que  $\{X(t): t \geq 0\}$  é um processo de nascimento e morte. Vejamos o caso  $s = 1$ .

### Fila de Espera $M/M/1$

Numa fila de espera do tipo  $M/M/1$  temos um processo de nascimento e morte com parâmetros,

$$\lambda_n = \lambda \quad \text{e} \quad \mu_n = \mu$$

onde  $\lambda$  é a intensidade de chegadas (o número médio de clientes que chegam à fila de espera por unidade de tempo) e  $\mu$  a intensidade de serviço (o número médio de clientes que cada servidor consegue servir por unidade de tempo). Queremos calcular a distribuição limite

$$\pi_n = \lim_{t \rightarrow \infty} \mathbb{P}(X(t) = n), \quad n = 0, 1, 2, \dots$$

Como o processo é irredutível, basta calcular a distribuição estacionária do processo (ver Exemplo 5.3.4). Temos que

$$\theta_n = \left(\frac{\lambda}{\mu}\right)^n \quad \text{e} \quad \sum_{n=0}^{\infty} \theta_n = \begin{cases} \infty, & \lambda \geq \mu \\ \frac{\mu}{\mu-\lambda}, & \lambda < \mu \end{cases}.$$

Seja

$$\rho = \frac{\lambda}{\mu}$$

a **intensidade de tráfego** no sistema. Portanto, se  $\rho < 1$  então o sistema tem uma única distribuição estacionária dada por

$$\pi_n = \frac{\theta_n}{\sum \theta_n} = (1 - \rho)\rho^n, \quad n \geq 0.$$

Note-se que  $\pi_n$  é a distribuição geométrica onde  $\rho$  é a probabilidade do insucesso. A probabilidade de uma pessoa ser servida imediatamente quando chega à fila de espera é,

$$\pi_0 = 1 - \rho,$$

ou seja,  $1 - \rho$  representa a taxa de desocupação do servidor, ou a proporção de tempo em que o servidor se encontra inactivo. Usando a distribuição estacionária podemos calcular o número médio de pessoas no sistema

$$L = \sum_{n=0}^{\infty} n\pi_n = \frac{\rho}{1 - \rho}.$$

Note-se que  $L$  cresce de forma ilimitada à medida que  $\rho$  se aproxima de 1. De forma análoga, podemos calcular o número médio de pessoas em fila de espera (excepto aquela que se encontra a ser servida),

$$L_0 = \sum_{n=1}^{\infty} (n - 1)\pi_n = \frac{\rho^2}{1 - \rho}.$$

Para determinar o tempo médio de espera definimos a variável aleatória  $T$  que representa o tempo de espera de uma pessoa para sair do sistema e a variável aleatória  $T_n$  que é o tempo de espera  $T$  de uma pessoa dado que existem  $n$  pessoas no sistema à frente desta. Note-se que  $T_n$  é a soma de  $n + 1$  variáveis aleatórias independentes com distribuição exponencial de parâmetro  $\mu$ . Portanto,  $T_n$  tem distribuição gama com parâmetros  $n + 1$  e  $\mu$ . Assim,

$$\begin{aligned} \mathbb{P}(T \leq t) &= \sum_{n=0}^{\infty} \mathbb{P}(T_n \leq t)\pi_n \\ &= \sum_{n=0}^{\infty} \left( \int_0^t \frac{\mu^{n+1} x^n e^{-\mu s}}{n!} ds \right) (1 - \rho)\rho^n \\ &= \mu(1 - \rho) \int_0^t e^{-\mu s} \sum_{n=0}^{\infty} \frac{(\lambda x)^n}{n!} ds \\ &= \mu(1 - \rho) \int_0^t e^{-\mu(1-\rho)s} ds \\ &= 1 - e^{(\mu-\lambda)t} \end{aligned}$$

Logo,  $T$  tem distribuição exponencial de parâmetro  $\mu - \lambda$ . Assim, o tempo médio de espera (desde que entra até que sai) de uma pessoa no sistema é

$$W = E(T) = \frac{1}{\mu - \lambda}.$$

Verificamos que

$$L = \lambda W$$

conhecida como a **equação fundamental** das filas de espera. Se excluirmos o tempo de serviço, então podemos calcular de forma análoga o tempo médio de espera  $W_0$  de uma pessoa na fila de espera. Também se verifica a equação fundamental,

$$L_0 = \lambda W_0.$$

### Fila de Espera $M/M/s$

No caso geral, uma fila de espera com  $s$  servidores pode ser estudado usando um processo de nascimento e morte com parâmetros,

$$\lambda_n = \lambda \quad \text{e} \quad \mu_n = \begin{cases} n\mu, & n = 0, 1, 2, \dots, s-1 \\ s\mu, & n \geq s \end{cases},$$

onde  $\mu$  é a intensidade de serviço individual de cada servidor. Portanto, a intensidade de serviço  $\mu_n$  é igual à intensidade agregada dos servidores em funcionamento. Como temos  $s$  servidores,

$$\mu_n = \min\{n, s\}\mu, \quad n \geq 0.$$

No caso geral, definimos

$$\rho = \frac{\lambda}{s\mu}$$

e verifica-se que

$$\theta_n = \begin{cases} \frac{s^n}{n!} \rho^n, & n = 0, 1, 2, \dots, s-1 \\ \frac{s^s}{s!} \rho^n, & n \geq s \end{cases}$$

Assim

$$\sum_{n=0}^{\infty} \theta_n = \begin{cases} \frac{s^s}{s!} \frac{\rho^s}{1-\rho} + \sum_{n=0}^{s-1} \frac{s^n}{n!} \rho^n, & \rho < 1 \\ \infty, & \rho \geq 1 \end{cases}$$

Portanto, supondo que

$$\rho < 1$$

concluimos que o sistema tem uma única distribuição estacionária,

$$\pi_n = \theta_n \pi_0, \quad n \geq 0,$$

onde

$$\pi_0 = \left( \frac{s^s \rho^s}{s! (1 - \rho)} + \sum_{n=0}^{s-1} \frac{s^n}{n!} \rho^n \right)^{-1}.$$

Usando a distribuição estacionária podemos calcular as seguintes medidas de desempenho do sistema:

$$\begin{aligned} L &= \lambda W \\ W &= W_0 + \frac{1}{\mu} \\ L_0 &= \sum_{n=s}^{\infty} (n - s) \pi_n = \frac{s^s \rho^{s+1}}{s! (1 - \rho)^2} \pi_0 \\ W_0 &= \frac{L_0}{\lambda} \end{aligned}$$

## 5.6 Exercícios

**Exercício 37.** Clientes chegam a uma mercearia com uma intensidade de 5 por hora. O empregado demora em média 10 minutos a atender cada cliente. Determine a probabilidade de encontrar, a longo prazo, 2 ou mais clientes na mercearia.

**Exercício 38.** Para uma fila de espera  $M/M/1$  faça o gráfico a taxa de utilização do servidor  $1 - \pi_0$  e do número médio  $L$  de pessoas no sistema como funções da intensidade de tráfego  $\rho < 1$ .

**Exercício 39.** Um supermercado dispõe de duas caixas de *checkout*. Uma caixa tem um operador e a outra é automática. A caixa com operador tem um tempo médio de serviço de 30 segundos, enquanto que a caixa automática tem um tempo médio de serviço de 50 segundos. Supondo que os clientes chegam às caixas com uma intensidade de 1 cliente por minuto, compare os comprimentos das filas de espera das duas caixas.

**Exercício 40.** Considere uma fila de espera  $M/M/2$ . Determine o tempo médio de espera  $W$  quando  $\lambda = 2$  e  $\mu = 1.2$ . Compare com o tempo médio de espera numa fila  $M/M/1$  com  $\lambda = 1$  e  $\mu = 1.2$ . Explique a diferença dos tempos de espera.

**Exercício 41.** Suponha que clientes chegam a uma repartição das finanças seguindo um processo de Poisson com intensidade de 5 clientes por hora. A repartição tem um único funcionário que demora, em média, 10 minutos a atender cada cliente. Quando o número de clientes na repartição excede um certo número  $N$  o funcionário encerra a repartição. Determine o menor  $N$  tal que, a longo prazo, a probabilidade de o funcionário encerrar a repartição não exceda 0.01.

# Chapter 6

## Martingalas

O termo Marginala tem as suas origens nos jogos de apostas e descreve o conceito de jogo honesto. As martingalas encontram aplicações em diversas áreas, nomeadamente em matemática financeira, na modelação de activos financeiros.

**Definição 6.0.1.** Uma sucessão de variáveis aleatórias  $(X_n)_{n \geq 1}$  é uma **martingala** se

1.  $X_n$  é integrável, ou seja,  $E(|X_n|) < \infty \forall n \geq 1$ .
2. Para todo  $n \geq 1$ ,

$$E(X_{n+1}|X_1 = x_1, \dots, X_n = x_k) = x_n.$$

Da definição de esperança condicional obtemos as seguintes propriedades.

**Proposição 6.0.1.**

1. *Uma martingala tem valor esperado constante, i.e.,*

$$E(X_n) = E(X_1), \quad \forall n \geq 1.$$

2. *Se  $k \leq n$ , então*

$$E(X_n|X_1 = x_1, \dots, X_k = x_k) = x_k.$$

*Demonstração.* Faremos apenas a demonstração da primeira propriedade no caso particular em que a martingala  $X_n$  é contínua e qualquer vector de probabilidade do processo admite uma densidade de probabilidade conjunta. Não faremos a prova da segunda propriedade. Esta usa a propriedade da

torre da esperança condicional que não foi abordada neste curso. Segue da lei de probabilidade total que

$$E(X_{n+1}) = \int_{\mathbb{R}^n} E(X_{n+1}|X_1 = x_1, \dots, X_n = x_n) f_{X_1, \dots, X_n}(\mathbf{x}) d\mathbf{x}$$

onde  $\mathbf{x} = (x_1, \dots, x_n)$  e  $d\mathbf{x} = dx_1 \cdots dx_n$ . Pela definição de martingala obtemos,

$$E(X_{n+1}) = \int_{\mathbb{R}^n} x_n f_{X_1, \dots, X_n}(\mathbf{x}) d\mathbf{x} = \int_{\mathbb{R}} x_n f_{X_n}(x_n) dx_n = E(X_n).$$

Portanto,  $E(X_n) = E(X_1)$  para todo  $n \geq 1$ . □

**Exemplo 6.0.2** (Passeio aleatório). Sejam  $\xi_1, \xi_2, \dots$  variáveis aleatórias independentes,  $E(\xi_n) < \infty$  e  $E(\xi_n) = 0$  para todo  $n \geq 1$ . A soma

$$X_n = \xi_1 + \xi_2 + \cdots + \xi_n,$$

é uma martingala. De facto, a primeira condição da definição de martingala é fácil verificar usando a desigualdade triangular e a aditividade da esperança condicional. Relativamente à segunda condição temos que,

$$\begin{aligned} E(X_{n+1}|X_1 = x_1, \dots, X_n = x_n) &= E(\xi_{n+1} + X_n|X_1 = x_1, \dots, X_n = x_n) \\ &= E(\xi_{n+1}) + E(X_n|X_1 = x_1, \dots, X_n = x_n) \\ &= x_n \end{aligned}$$

**Exemplo 6.0.3.** Sejam  $\xi_1, \xi_2, \dots$  variáveis aleatórias independentes,  $E(\xi_n) < \infty$  e  $E(\xi_n) = 1$  para todo  $n \geq 1$ . O produto

$$X_n = \prod_{k=1}^n \xi_k,$$

é uma martingala.

No jogo da moeda, dois jogadores atiram uma moeda perfeita ao ar e observam o resultado. Se sair coroa, o primeiro jogador dá 1 euro ao segundo jogador. Se sair cara, o segundo jogador dá 1 euro ao primeiro jogador. Os jogadores continuam a jogar fazendo sucessivos lançamentos da moeda. Ao fim do  $n$ -ésimo lançamento, ganho total do primeiro jogador é,

$$X_n = \xi_1 + \cdots + \xi_n,$$

onde  $\xi_n$  são variáveis aleatórias iid que tomam valores  $\pm 1$  com igual probabilidade ( $\xi_i = 1$  se sair cara, e  $\xi_i = -1$  se sair coroa no  $i$ -ésimo lançamento). Concluimos do Exemplo 6.0.2 que  $X_n$  é uma martingala. O jogo da moeda perfeita é um exemplo de um **jogo justo**, ou seja, que perante a informação acumulada até ao  $n$ -ésimo lançamento, espera-se que no lançamento seguinte o ganho total não se altere.

Nem todos os jogos são justos, no sentido em que podem existir jogos mais favoráveis que outros. Um exemplo de um jogo favorável seria o do lançamento de dois dados em que o apostador ganharia se a soma dos dados fosse maior ou igual a 6.

**Definição 6.0.2.** Uma sucessão de variáveis aleatórias  $(X_n)_{n \geq 1}$  é uma **submartingala** se

1.  $X_n$  é integrável, ou seja,  $E(|X_n|) < \infty \forall n \geq 1$ .
2. Para todo  $n \geq 1$ ,

$$E(X_{n+1} | X_1 = x_1, \dots, X_n = x_n) \geq x_n.$$

Portanto, uma submartingala representa um jogo favorável. Invertendo a desigualdade na definição anterior, temos a definição de **supermartingala** que representa um jogo desfavorável.

## 6.1 Estratégias

Considere um jogo de apostas em que em cada jogada é possível apostar uma certa quantidade que pode ou não perder com certa probabilidade. Ou seja, considere uma sucessão de variáveis aleatórias  $(\xi_n)_{n \geq 1}$  tais que  $E(|\xi_n|) < \infty$  representam o valor que pode ganhar ou perder em cada jogada. Se as suas apostas em cada jogada são igual à unidade então o ganho total no final de  $n$  jogadas é

$$X_n = \xi_1 + \dots + \xi_n.$$

Suponhamos que decide em cada jogada alterar a sua aposta com base nas jogadas anteriores. Ou seja, na jogada  $n$  faz uma aposta  $\alpha_n$  que é uma função dos ganhos anteriores  $(X_1, \dots, X_{n-1})$ . É conveniente definir  $\alpha_1 = 1$ , uma vez que não é possível fazer uma aposta "informada" logo na primeira jogada. A sucessão das apostas  $(\alpha_n)_{n \geq 1}$  é chamada uma **estratégia** relativa a  $(X_n)_{n \geq 1}$ . Então o ganho total até à  $n$ -ésima jogada usando uma estratégia é dado por,

$$Z_n = \alpha_1 \xi_1 + \dots + \alpha_n \xi_n.$$

Numa situação real, as apostas  $\alpha_n$  terão de ser funções limitadas, uma vez que nenhum jogador pode dispor de fundos ilimitados. Portanto, consideraremos apenas **estratégias limitadas**, i.e., a função  $\alpha_n(x_1, \dots, x_{n-1})$  é limitada para todo  $n \geq 1$ .

Note-se que dada uma sucessão  $(X_n)_{n \geq 1}$  de variáveis aleatórias, podemos sempre decompor  $X_n$  como uma soma de incrementos,  $X_n = \xi_1 + \dots + \xi_n$  onde  $\xi_k = X_k - X_{k-1}$  para  $k \geq 2$  e  $\xi_1 = X_1$ . Portanto, a discussão anterior aplica-se a qualquer sucessão de variáveis aleatórias integráveis.

A seguinte proposição demonstra que é impossível através de uma estratégia limitada alterar um jogo a nosso favor.

**Proposição 6.1.1.** *Se  $X_n$  é uma martingala e  $(\alpha_n)_{n \geq 1}$  é uma estratégia limitada relativa a  $X_n$ , então  $(Z_n)_{n \geq 1}$  é uma martingala.*

*Demonstração.* Seja  $C_n = \max_{1 \leq k \leq n} |\alpha_n|$ . Note-se que  $C_n < \infty$  por hipótese. Então,

$$E(|Z_n|) = E(|\alpha_1 \xi_1 + \dots + \alpha_n \xi_n|) \leq C_n \sum_{i=1}^n E(|\xi_i|) < \infty.$$

Verifiquemos agora a segunda condição na definição de martingala. Em primeiro lugar, note-se que

$$\begin{aligned} E(Z_{n+1} | Z_1 = z_1, \dots, Z_n = z_n) &= E(Z_n + \alpha_{n+1} \xi_{n+1} | Z_1 = z_1, \dots, Z_n = z_n) \\ &= z_n + E(\alpha_{n+1} \xi_{n+1} | Z_1 = z_1, \dots, Z_n = z_n). \end{aligned}$$

Uma vez que  $\alpha_{n+1}$  é função de  $(Z_1, \dots, Z_n)$  podemos retirar para fora da esperança condicional. Por outro lado,

$$E(\xi_{n+1} | Z_1 = z_1, \dots, Z_n = z_n) = E(X_{n+1} - X_n | Z_1 = z_1, \dots, Z_n = z_n) = 0$$

e portanto

$$E(\alpha_{n+1} \xi_{n+1} | Z_1 = z_1, \dots, Z_n = z_n) = 0.$$

Logo,  $E(Z_{n+1} | Z_1 = z_1, \dots, Z_n = z_n) = z_n$ . □

**Exemplo 6.1.2** (A estratégia da martingala). Considere novamente o jogo do lançamento de uma moeda perfeita. O ganho acumulado é dado por

$$X_n = \xi_1 + \dots + \xi_n,$$

onde  $\xi_1, \xi_2, \dots$  são variáveis aleatórias iid tais que  $\xi_n = \pm 1$  com igual probabilidade.

A **martingala** é um tipo de estratégia usada nos jogos de apostas que teve origem em França no século XVIII. A estratégia consiste em cada jogada duplicar a aposta anterior caso o resultado tenha sido desfavorável. Ou seja,

$$\alpha_n = \begin{cases} 2^{n-1} & \text{se } \xi_1 = \xi_2 = \dots = \xi_{n-1} = -1 \\ 0 & \text{caso contrário} \end{cases}, \quad n \geq 2$$

com  $\alpha_1 = 1$ . Portanto, ao fim de  $n$  jogadas temos um ganho acumulado

$$Z_n = \alpha_1 \xi_1 + \dots + \alpha_n \xi_n,$$

Segue da proposição anterior que  $Z_n$  é uma martingala. Das propriedades da martingala temos que

$$E(Z_n) = E(Z_1) = 0, \quad \forall n \geq 1.$$

Considere agora o menor  $n$  tal que o resultado da  $n$ -ésima jogada foi favorável, ou seja, a variável aleatória

$$\tau = \min \{n \in \mathbb{N} : \xi_n = 1\}.$$

Note-se que o acontecimento  $\{\tau = n\} \in \mathcal{F}_n$ . Dizemos que  $\tau$  é um **tempo de paragem**. Usando o tempo de paragem podemos escrever o ganho acumulado,

$$Z_n = \begin{cases} -1 - 2 - \dots - 2^{n-1} & \text{se } n < \tau \\ 1 & \text{se } n \geq \tau \end{cases}.$$

Um vez que  $\mathbb{P}(\tau < \infty) = 1$  temos que  $Z_\tau = 1$ . Logo

$$E(Z_\tau) = 1.$$

Por outro lado,

$$E(Z_{\tau-1}) = \sum_{n=2}^{\infty} (-1 - \dots - 2^{n-2}) P(\tau = n) = \sum_{n=2}^{\infty} \frac{1 - 2^{n-1}}{2^n} = -\infty.$$

Ou seja, um jogador pode ir acumulando pequenos ganhos ao longo do tempo dando a ilusão de que a sua estratégia é ganhadora. No entanto, a possibilidade remota de ter um prejuízo catastrófico contrabalança esses ganhos e pode levar o jogador à falência rapidamente. Portanto, a estratégia da martingala é apenas bem sucedida se o jogador dispõe de recursos e tempo ilimitados.

## 6.2 Tempos de paragem

Motivados pelo exemplo anterior, fazemos a seguinte definição.

**Definição 6.2.1.** Um **tempo de paragem** relativo a uma sucessão  $(X_n)_{n \geq 1}$  de variáveis aleatórias é uma variável aleatória  $\tau : \Omega \rightarrow \mathbb{N} \cup \{\infty\}$  definida,

$$\tau = \min\{n \geq 1 : X_n \in B\}$$

onde  $B \subset \mathbb{R}$  é um Boreliano de  $\mathbb{R}$  (por exemplo um intervalo).

É também usual chamar-se  $\tau$  um **tempo de primeira entrada** de  $X_n$  em  $B$ . Dado um tempo de paragem  $\tau$  podemos definir

$$X_\tau = \sum_{n=1}^{\infty} X_n \cdot \chi_{\{\tau=n\}}.$$

que designamos por  $X_n$  **no momento exacto do tempo de paragem**. Definimos também uma nova sucessão,

$$X_n^\tau = \begin{cases} X_n & \text{se } n \leq \tau \\ X_\tau & \text{se } n > \tau \end{cases},$$

que representa a **sucessão  $(X_n)_{n \geq 1}$  parada no instante  $\tau$** . Por exemplo, se  $\tau = 3$  então

$$X_1^\tau = X_1, \quad X_2^\tau = X_2, \quad X_3^\tau = X_3, \quad X_4^\tau = X_3, \quad \text{etc.}$$

Vimos na secção anterior que não é possível através de uma estratégia limitada alterar um jogo justo a nosso favor. A seguinte proposição mostra um resultado semelhante no contexto dos tempos de paragem.

**Proposição 6.2.1.** *Seja  $X_n$  uma martingala e  $\tau$  um tempo de paragem relativo a  $X_n$ . Então  $X_n^\tau$  é uma martingala.*

*Demonstração.* Seja

$$\alpha_n = \begin{cases} 1 & \text{se } n \leq \tau \\ 0 & \text{se } n > \tau \end{cases}.$$

Note-se que  $\alpha_n = 0$  se  $X_k \in B$  para algum  $k < n$ , e  $\alpha_n = 1$  caso contrário. Portanto,  $\alpha_n$  é uma função do vector  $(X_1, \dots, X_{n-1})$ . Claramente,  $\alpha_n$  é limitada, portanto é uma estratégia limitada relativa a  $X_n$ . Assim,

$$Z_n = \alpha_1 \xi_1 + \dots + \alpha_n \xi_n$$

onde  $\xi_1 = X_1$  e  $\xi_k = X_k - X_{k-1}$  para  $k \geq 2$  é uma martingala pela Proposição 6.1.1. No entanto, é fácil verificar que  $Z_n = X_n^\tau$ . Logo  $X_n^\tau$  é uma martingala.  $\square$

### 6.3 Teorema de paragem opcional

Vimos na secção anterior que se  $X_n$  é uma martingala e  $\tau$  um tempo de paragem então  $X_n^\tau$  é também uma martingala. Adicionalmente,

$$E(X_n^\tau) = E(X_n) = E(X_1),$$

uma vez que martingalas têm valor esperado constante. No entanto, se considerarmos  $X_n$  no momento exacto do tempo de paragem, i.e.,  $X_\tau$ , então nem sempre  $E(X_\tau) = E(X_1)$ . Como exemplo veja-se o caso da estratégia de martingala (ver Exemplo 6.1.2). O teorema de paragem opcional estabelece condições suficientes para que a propriedade da martingala se estenda a tempos de paragem, i.e.,

$$E(X_\tau) = E(X_1).$$

Antes de enunciar o teorema, necessitamos de uma definição técnica.

**Definição 6.3.1.** Uma sucessão de variáveis aleatórias  $(Y_n)_{n \geq 1}$  diz-se **uniformemente integrável** sse existir uma função integrável  $g : \Omega \rightarrow [0, \infty]$  tal que  $|Y_n| \leq g$  para todo  $n = 1, 2, \dots$

Estamos em condições de enunciar o teorema.

**Teorema 6.3.1** (da paragem opcional de Doob). *Seja  $(X_n)_{n \geq 1}$  uma martingala e  $\tau$  um tempo de paragem. Se  $P(\tau < \infty) = 1$  e  $(X_n^\tau)_{n \geq 1}$  é uniformemente integrável então*

$$E(X_\tau) = E(X_1).$$

Ou seja, não é possível alterar um jogo a nosso favor usando uma estratégia de paragem que satisfaça as condições do teorema. Antes de comentarmos acerca das condições do teorema vejamos a sua demonstração.

*Demonstração.* Uma vez que  $P(\tau < \infty) = 1$  segue que

$$\lim_{n \rightarrow \infty} X_n^\tau = X_\tau, \quad P\text{-q.c.}$$

Logo, segue do Teorema da convergência dominada que

$$E(X_\tau) = \lim_{n \rightarrow \infty} E(X_n^\tau) = \lim_{n \rightarrow \infty} E(X_1) = E(X_1).$$

□

Das duas condições do teorema da paragem opcional a mais difícil de verificar é  $X_n^\tau$  uniformemente integrável. Contudo existem alguns casos em que podemos verificar essa condição com facilidade.

**Proposição 6.3.2.** *A martingala  $(X_n^\tau)_{n \geq 1}$  é uniformemente integrável se alguma das seguintes condições se verificar:*

1.  $X_n$  toma um número finito de valores, i.e., o conjunto dos estados é finito.
2. A sucessão  $(X_n^\tau)_{n \geq 1}$  é limitada, ou seja, existe um  $M \geq 0$  tal que  $|X_n^\tau| \leq M$  para todo  $n \geq 1$ .
3. O tempo de paragem é limitado, i.e.,  $P(\tau \leq k) = 1$  para algum  $k \geq 1$ .

*Demonstração.*

1. Trivial, uma vez que  $|X_n|$  é majorado pelo maior dos seus estados.
2. Segue directamente da Definição 6.3.1.
3. Se  $\tau \leq k$   $P$ -q.c. então

$$|X_n^\tau| \leq \max \{|X_1|, \dots, |X_k|\} .$$

Logo,  $X_n^\tau$  é uniformemente integrável.

□

**Exemplo 6.3.3** (O jogo da ruína). Retomemos o jogo do lançamento de uma moeda perfeita. Sejam  $\xi_1, \xi_2, \dots$  variáveis aleatórias iid tais que  $\xi_n = \pm 1$  com igual probabilidade. Então o passeio aleatório,

$$X_n = \xi_1 + \dots + \xi_n ,$$

é uma martingala. Considere-se o tempo de paragem,

$$\tau = \min \{n \in \mathbb{N}: X_n \in \{-a, b\}\} ,$$

onde  $0 < a, b$ . Ou seja, o jogo termina quando o jogador obtiver um prejuízo de  $a$  euros ou um lucro de  $b$  euros. Desejamos calcular a probabilidade  $p_a = P(X_\tau = -a)$ , isto é, a probabilidade de o jogador acabar o jogo com um prejuízo de  $a$  euros em vez de um lucro de  $b$  euros.

Suponhamos que as condições de aplicabilidade do teorema da paragem opcional se verificam,

- $P(\tau < \infty) = 1$
- $X_n^\tau$  é uniformemente integrável

Então, do teorema da paragem opcional segue que  $E(X_\tau) = E(X_1) = 0$ . Por outro lado,

$$0 = E(X_\tau) = -ap_a + b(1 - p_a).$$

Logo,

$$p_a = \frac{b}{b + a}.$$

Portanto, se o jogador tiver  $a$  euros e estiver disposto jogar enquanto não os perder, então a probabilidade de ruína é,

$$\lim_{b \rightarrow \infty} p_a = \lim_{b \rightarrow \infty} \frac{b}{b + a} = 1.$$

Verifiquemos agora as condições do teorema.

- Uma vez que  $X_n^\tau \in [-a, b]$  logo  $X_n^\tau$  é uma sucessão limitada, portanto uniformemente integrável.
- Demonstremos  $P(\tau < \infty) = 1$ . O jogo da ruína pode ser visto como uma cadeia de Markov no espaço de estados  $S = \{-a, \dots, b\}$  onde os estados  $-a$  e  $b$  são absorventes, os restantes transientes e probabilidades de transição  $P_{i,i+1} = P_{i,i-1} = 1/2$  com  $i \in S \setminus \{-a, b\}$ . Neste contexto,  $\tau$  é o tempo de primeira entrada no conjunto fechado  $\{-a, b\}$ . Assim,  $\mathbb{P}(\tau < \infty)$  é a probabilidade de absorção de partindo do estado 0 a cadeia ser absorvida em  $\{-a, b\}$ . Podemos calcular esta probabilidade resolvendo o sistema da Proposição 3.9.3. Deixa-se como exercício.

**Proposição 6.3.4** (Equação de Wald). *Seja  $X_n$  uma sucessão de variáveis aleatórias iid com  $E(|X_n|) \leq M$  para algum  $M \geq 0$  e  $\tau$  um tempo de paragem relativo a  $X_n$  tal que  $P(\tau < \infty) = 1$  e  $E(\tau) < \infty$ . Então*

$$E\left(\sum_{i=1}^{\tau} X_i\right) = \mu E(\tau),$$

onde  $\mu = E(X_n)$  para todo  $n = 1, 2, \dots$

*Demonstração.* Seja  $Z_n = \sum_{i=1}^n X_i - n\mu$ . É fácil ver que  $Z_n$  é uma martingala (Exercício 43). Para aplicarmos o teorema da paragem opcional temos de verificar que  $Z_n^\tau$  é uniformemente integrável. Este facto não é trivial (a menos que  $X_n$  esteja nas condições da Proposição 6.3.2) e portanto omitimos a prova. Aplicando o teorema temos que

$$0 = E(Z_\tau) = E\left(\sum_{i=1}^{\tau} X_i - \tau\mu\right) = E\left(\sum_{i=1}^{\tau} X_i\right) - \mu E(\tau).$$

□

**Exemplo 6.3.5.** Seja  $X_1, X_2, \dots$  variáveis aleatórias iid tais que  $X_n \in \{0, 1\}$  e  $\alpha = P(X_n = 1)$ . Forme-se a soma,

$$S_n = X_1 + \dots + X_n,$$

e considere-se o tempo de paragem,

$$\tau_k = \min \{n \in \mathbb{N} : S_n = k\}.$$

Uma vez que  $P(\tau_k < \infty) = 1$  temos pela equação de Wald que

$$k = E(S_{\tau_k}) = \alpha E(\tau_k).$$

Logo,  $E(\tau_k) = \frac{k}{\alpha}$ .

**Exemplo 6.3.6.** Retomando o jogo da ruína (Exemplo 6.3.3), desejamos calcular  $E(\tau)$ . A equação de Wald não ajuda uma vez que  $E(X_\tau) = 0$  e  $\mu = 0$ . No entanto se considerarmos uma nova sucessão  $Z_n = X_n^2 - n$  é possível calcular  $E(\tau)$ . Note-se que  $Z_n$  é uma martingala (Exercício 44), logo  $Z_n^\tau$  é também uma martingala. Assim, pelo teorema da paragem opcional

$$0 = E(Z_1) = E(Z_\tau) = E(X_\tau^2 - \tau).$$

Portanto,

$$E(X_\tau^2) = E(\tau).$$

Mas como,  $E(X_\tau^2) = a^2 \frac{b}{b+a} + b^2(1 - \frac{b}{b+a}) = ab$ , logo,

$$E(\tau) = ab.$$

O teorema da paragem opcional tem uma versão no caso das supermartingalas (submartingalas).

**Teorema 6.3.7.** *Seja  $(X_n)_{n \geq 1}$  uma supermartingala (submartingala) e  $\tau$  um tempo de paragem. Se  $P(\tau < \infty) = 1$  e  $(X_n^\tau)_{n \geq 1}$  é uniformemente integrável então  $E(X_\tau) \leq E(X_1)$  ( $E(X_\tau) \geq E(X_1)$ ).*

## 6.4 Convergência de martingalas

O resultado que se segue estabelece a convergência de uma martingala com probabilidade 1 desde que a sucessão  $E(|X_n|)$  seja limitada. A sua demonstração pode ser consultada num dos livros da bibliografia recomendada.

**Teorema 6.4.1.** *Seja  $X_n$  uma martingala. Se existe um  $M > 0$  tal que  $E(|X_n|) \leq M$  para todo  $n \geq 1$ , então existe uma variável aleatória  $X_\infty$  integrável tal que*

$$X_\infty = \lim_{n \rightarrow \infty} X_n, \quad P - q.c.$$

Como corolário tem-se o seguinte resultado.

**Corolário 6.4.2.** *Se  $X_n$  é uma martingala não-negativa, i.e.,  $X_n \geq 0$ , então existe uma variável aleatória  $X_\infty$  tal que*

$$X_\infty = \lim_{n \rightarrow \infty} X_n, \quad P - q.c.$$

*Demonstração.* Uma vez que  $X_n$  é não-negativa tem-se

$$E(|X_n|) = E(X_n) = E(X_1), \quad \forall n \geq 1.$$

O resultado segue do teorema anterior. □

**Exemplo 6.4.3.** Considere novamente o passeio aleatório,

$$X_n = \xi_1 + \dots + \xi_n,$$

onde  $\xi_n$  é uma sucessão de variáveis aleatórias iid tais que  $\xi_n = \pm 1$  com igual probabilidade. Suponha que o jogador dispõe de crédito limitado,  $a$  euros, e só decide abandonar o jogo quando o seu prejuízo atingir esse limite,

$$\tau = \min \{n \geq 1 : X_n = -a\}.$$

Vejamos que  $\mathbb{P}(\tau < \infty) = 1$  usando o teorema da convergência das martingalas. Em primeiro lugar, a martingala  $X_n^\tau + a$  é não-negativa. Logo, segue do corolário anterior que

$$X_\tau = \lim_{n \rightarrow \infty} X_n^\tau = -a, \quad P - q.c.$$

Uma vez que

$$|X_{n+1} - X_n| = |\xi_{n+1}| = 1, \quad \forall n \geq 1$$

então  $\tau$  é finito  $P$ -q.c., caso contrário a sucessão  $X_n^\tau$  não seria convergente  $P$ -q.c. para  $-a$ .

Conclui-se assim que com probabilidade 1, o jogador será obrigado a abandonar o jogo ao fim de um número finito de jogadas.

**Exemplo 6.4.4.** Sejam  $X_1, X_2, \dots$  variáveis aleatórias iid tais que  $X_n \in \{0, 2\}$  com igual probabilidade. Uma vez que  $E(X_n) = 1$  então

$$Z_n = \prod_{i=1}^n X_i$$

é uma martingala. Como  $Z_n \geq 0$  então aplicando o corolário anterior tem-se

$$Z_\infty = \lim_{n \rightarrow \infty} Z_n, \quad P - \text{q.c.}$$

De facto,  $Z_\infty = 0$ ,  $P$ -q.c.

## 6.5 Exercícios

**Exercício 42.** Mostre que a sucessão definida no Exemplo 6.0.3 é uma martingala.

**Exercício 43.** Seja  $(X_n)_{n \geq 1}$  uma sucessão de variáveis aleatórias iid e  $E(|X_n|) < \infty$  para todo  $n \geq 1$ . Mostre que

$$Z_n = \sum_{k=1}^n X_k - n\mu$$

é uma martingala, onde  $\mu = E(X_1)$ .

**Exercício 44.** Considere o passeio aleatório  $X_n = \xi_1 + \dots + \xi_n$  onde a sucessão  $(\xi_n)_{n \geq 1}$  é iid e  $\mathbb{P}(\xi_n = \pm 1) = \frac{1}{2}$ . Mostre que

$$Z_n = X_n^2 - n$$

é uma martingala.

**Exercício 45.** Seja  $X_n = \xi_1 + \dots + \xi_n$  o passeio aleatório com  $(\xi_n)_{n \geq 1}$  iid,  $\xi_n = \pm 1$  com igual probabilidade. Mostre que

$$Z_n = (-1)^n \cos(\pi X_n)$$

é uma martingala.

**Exercício 46.** Seja  $X_0 = 0$  e

$$X_n = X_{n-1} + \xi_n - 1, \quad n = 1, 2, \dots$$

onde  $(\xi_n)_{n \geq 1}$  é uma sucessão de variáveis aleatórias iid que têm uma distribuição de Poisson com valor esperado  $\mu > 0$ . Determine os valores de  $\mu$  para os quais a sucessão  $(X_n)_{n \geq 1}$  é uma martingala, submartingala ou supermartingala.

**Exercício 47.** Mostre que  $\mathbb{P}(\tau < \infty) = 1$  no jogo da ruína.

**Exercício 48.** Sejam  $(\xi_n)_{n \geq 1}$  variáveis aleatórias iid tais que  $\xi_n = \pm 1$  com probabilidade  $P(\xi_n = 1) = p$  e  $P(\xi_n = -1) = q$  onde  $p \neq q$ . Considere o passeio aleatório,

$$X_n = \xi_1 + \dots + \xi_n,$$

e o tempo de paragem

$$\tau = \min \{n \geq 1 : X_n \in \{-a, b\}\},$$

onde  $a, b > 0$ . Mostre que:

1. A sucessão  $Z_n = (q/p)^{X_n}$  é uma martingala.
- 2.

$$P(X_\tau = b) = \frac{1 - (q/p)^{-a}}{(q/p)^b - (q/p)^{-a}}$$

**Exercício 49.** Seja  $X_n = \xi_1 + \dots + \xi_n$  o passeio aleatório onde  $(\xi_n)_{n \geq 1}$  são iid tais que  $\xi_n = \pm 1$  com igual probabilidade. Supondo que  $k \in \mathbb{N}$ :

1. Mostre que  $Z_n = (-1)^n \cos(\pi(X_n + k))$  é uma martingala.
2. Calcule  $E((-1)^\tau)$  onde  $\tau$  é o tempo de paragem

$$\tau = \min \{n \geq 1 : |X_n| = k\}.$$

**Exercício 50.** Sejam  $X_1, X_2, \dots$  variáveis aleatórias iid tais que  $X_n \in \{-1, 1\}$  para todo  $n = 1, 2, \dots$ . Considere o tempo de paragem

$$\tau = \min \{n \geq 1 : X_1 + \dots + X_n = 1\}.$$

Determine  $E(\tau)$ .

**Exercício 51** (difícil). Seja  $(X_n)_{n \geq 1}$  uma sucessão de variáveis aleatórias e  $\tau$  um tempo de paragem relativo a  $X_n$  tal que para algum  $k \in \mathbb{N}$  e algum  $\epsilon > 0$ ,

$$\mathbb{P}(\tau \leq n + k | X_1 = x_1, \dots, X_n = x_n) > \epsilon, \quad \forall n \geq 1.$$

Mostre que  $\mathbb{P}(\tau < \infty) = 1$ .

# Chapter 7

## Movimento Browniano

O movimento Browniano (ou processo de Wiener) é um processo estocástico usado para descrever o movimento descrito por uma partícula imersa num líquido quando esta colide com as moléculas do líquido. O movimento Browniano é amplamente utilizado em matemática financeira.

**Definição 7.0.1.** Um processo estocástico a tempo contínuo  $\{B(t) : t \in [0, \infty[ \}$  é um **movimento Browniano** se:

1.  $B(0) = 0$ ,
2. tem incrementos independentes, i.e., para quaisquer  $0 \leq t_0 < t_1 < \dots < t_n$  as variáveis aleatórias

$$B(t_1) - B(t_0), \dots, B(t_n) - B(t_{n-1})$$

são independentes.

3. tem incrementos estacionários e normalmente distribuídos, i.e., para quaisquer  $t, h > 0$  o incremento  $B(t+h) - B(t)$  tem distribuição normal com média 0 e variância  $h$ .
4. as trajectórias  $t \mapsto B(t)$  são contínuas  $\mathbb{P}$ -q.c.

Dado  $x \in \mathbb{R}$ , designamos por  $B_x(t) = x + B(t)$  o movimento Browniano com início em  $x$ . Note-se que a lei de probabilidade de  $B_x(t)$  é a mesma de  $B(t)$ .

**Proposição 7.0.1.**

1.  $E(B(t)) = 0$
2.  $V(B(t)) = t$

3.  $Cov(B(t), B(s)) = \min\{t, s\}$

*Demonstração.* Exercício. □

Definimos,

$$W(t) = x + \mu t + \sigma B(t).$$

Segue da proposição anterior que

$$E(W(t)) = x + \mu t \quad e \quad V(W(t)) = \sigma^2 t.$$

Os parâmetros  $\mu$  e  $\sigma$  são denominados por *drift* e difusão, respectivamente. Ao processo estocástico  $W(t)$  chamamos o **processo de Wiener** com parâmetros  $(x, \mu, \sigma)$ .

A proposição seguinte mostra como é possível determinar a lei de probabilidade do movimento Browniano.

**Proposição 7.0.2.** *Seja  $f_{t_1, \dots, t_n}$  a densidade de probabilidade conjunta de  $(B(t_1), \dots, B(t_n))$ . Então*

$$f_{t_1, \dots, t_n}(x_1, \dots, x_n) = f_{t_1}(x_1) f_{t_2-t_1}(x_2 - x_1) \cdots f_{t_n-t_{n-1}}(x_n - x_{n-1}),$$

onde

$$f_t(x) = \frac{1}{\sqrt{2\pi t}} e^{-\frac{x^2}{2t}}$$

é a densidade de probabilidade de  $B(t)$ .

*Demonstração.* Escrevemos

$$(B(t_1), B(t_2), \dots, B(t_n)) = (U_1, U_1 + U_2, \dots, U_1 + U_2 + \cdots + U_n)$$

onde  $U_i$  são incrementos, i.e.,  $U_i = B(t_i) - B(t_{i-1})$  com  $i = 1, \dots, n$  e  $t_0 = 0$ . Segue da definição do movimento Browniano que  $U_i$  tem distribuição normal de média 0 e variância  $t_i - t_{i-1}$ . Como os incrementos são independentes, a densidade de probabilidade de  $(U_1, \dots, U_n)$  é

$$f_{U_1, \dots, U_n}(u_1, \dots, u_n) = f_{t_1}(u_1) f_{t_2-t_1}(u_2) \cdots f_{t_n-t_{n-1}}(u_n),$$

onde  $f_t(x)$  é a densidade da normal (média 0 e variância  $t$ ). Seja  $F(x_1, \dots, x_n)$  a função de distribuição do vector  $(B(t_1), B(t_2), \dots, B(t_n))$ . Então

$$\begin{aligned} F(x_1, \dots, x_n) &= \mathbb{P}(B(t_1) \leq x_1, B(t_2) \leq x_2, \dots, B(t_n) \leq x_n) \\ &= \mathbb{P}(U_1 \leq x_1, U_1 + U_2 \leq x_2, \dots, U_1 + \cdots + U_n \leq x_n) \\ &= \int_R f_{t_1}(u_1) f_{t_2-t_1}(u_2) \cdots f_{t_n-t_{n-1}}(u_n) du_1 du_2 \cdots du_n \end{aligned}$$

onde a região de integração é

$$R = \{(u_1, \dots, u_n) \in \mathbb{R}^n : u_1 \leq x_1, u_1 + u_2 \leq x_2, \dots, u_1 + \dots + u_n \leq x_n\}$$

Fazendo a mudança de variável  $v_1 = u_1$ ,  $v_2 = u_1 + u_2$ , etc,  $v_n = u_1 + \dots + u_n$  obtemos

$$F(x_1, \dots, x_n) = \int_{-\infty}^{x_1} \dots \int_{-\infty}^{x_n} f_{t_1}(v_1) f_{t_2-t_1}(v_2 - v_1) \dots f_{t_n-t_{n-1}}(v_n - v_{n-1}) d\mathbf{v}$$

onde  $d\mathbf{v} = dv_1 \dots dv_n$ . □

## 7.1 Propriedades

O movimento Browniano tem a propriedade de invariância de escala.

**Proposição 7.1.1.** *Seja  $a \neq 0$ . O processo estocástico*

$$X(t) = \frac{1}{a} B(a^2 t)$$

*é um movimento Browniano.*

*Demonstração.* A continuidade das realizações é óbvia e também  $X(0) = 0$ . A independência dos incrementos também segue directamente da definição. Resta calcular a distribuição do incremento. Seja  $t > s$ . Então

$$X(t) - X(s) = \frac{1}{a} (B(a^2 t) - B(a^2 s)).$$

Sabemos que  $B(a^2 t) - B(a^2 s)$  tem distribuição normal com média 0 e variância  $a^2(t - s)$ . Portanto,  $X(t) - X(s)$  tem distribuição normal com média 0 e variância  $t - s$ . □

O movimento Browniano também tem a propriedade de inversão do tempo.

**Proposição 7.1.2.** *O processo estocástico*

$$X(t) = \begin{cases} 0, & t = 0 \\ tB(1/t), & t > 0 \end{cases}$$

*é um movimento Browniano.*

*Demonstração.* É claro que  $X(0) = 0$  e os incrementos são independentes. A continuidade das realizações é óbvia para  $t > 0$ . O caso  $t = 0$  requer algum cuidado (procurar na bibliografia). Vamos calcular a distribuição do incremento. Dado  $t > s > 0$  temos

$$\begin{aligned} X(s) - X(t) &= sB(1/s) - tB(1/t) \\ &= sB(1/s) - tB(1/t) - sB(1/t) + sB(1/t) \\ &= s(B(1/s) - B(1/t)) + (s - t)B(1/t) \end{aligned}$$

Uma vez que os incrementos  $B(1/t)$  e  $B(1/s) - B(1/t)$  são independentes e normalmente distribuídos, concluímos que  $X(t) - X(s)$  também tem distribuição normal com média 0 e variância,

$$\begin{aligned} V(X(t) - X(s)) &= s^2V(B(1/s) - B(1/t)) + (s - t)^2V(B(1/t)) \\ &= s^2 \left( \frac{1}{s} - \frac{1}{t} \right) + (s - t)^2 \frac{1}{t} \\ &= t - s \end{aligned}$$

□

Como corolário da proposição anterior obtemos a lei dos grandes números para o movimento Browniano.

**Proposição 7.1.3.** *Se  $B(t)$  é um movimento Browniano, então*

$$\lim_{t \rightarrow +\infty} \frac{B(t)}{t} = 0, \quad \mathbb{P} - q.c.$$

*Demonstração.* Considere o movimento Browniano  $X(t)$  da proposição anterior. Então

$$\lim_{t \rightarrow +\infty} \frac{X(t)}{t} = \lim_{t \rightarrow +\infty} \frac{tB(1/t)}{t} = \lim_{t \rightarrow +\infty} B(1/t) = B(0) = 0.$$

□

Este resultado diz que a ordem do crescimento do movimento Browniano  $B(t)$  é inferior ao crescimento linear. De facto, existe um resultado mais preciso que indica exactamente a ordem do crescimento. Esse resultado é conhecido pela **lei do logaritmo iterado** e diz que

$$\limsup_{t \rightarrow +\infty} \frac{B(t)}{\sqrt{2t \log \log t}} = 1$$

A proposição seguinte demonstra como as trajectórias do movimento Browniano podem ser muito irregulares (apesar de contínuas).

**Proposição 7.1.4.** *Quase certamente, o movimento Browniano não é monótono em qualquer intervalo  $[a, b]$ .*

*Demonstração.* Considere um intervalo  $[a, b]$  e uma partição desse intervalo,

$$a = a_0 < a_1 < \dots < a_{n-1} < a_n = b$$

Se o movimento Browniano é monótono em  $[a, b]$ , então todos os incrementos  $B(a_i) - B(a_{i-1})$  têm o mesmo sinal (positivo ou negativo). Como os incrementos são independentes, o evento que consiste em todos os incrementos terem o mesmo sinal tem probabilidade  $2 \times \frac{1}{2^n}$ , uma vez que há duas escolhas possíveis para o sinal e  $n$  incrementos no total. Tomando  $n \rightarrow \infty$ , obtemos que a probabilidade do movimento Browniano ser monótono em  $[a, b]$  é igual a zero. O mesmo é verdade para qualquer intervalo com extremos racionais. Assim, a probabilidade do movimento Browniano ser monótono em qualquer intervalo com extremidades racionais é zero (uma vez que a união numerável de eventos com probabilidade zero também tem probabilidade zero). Como qualquer intervalo contém um intervalo com extremidades racionais, temos demonstrada a proposição.  $\square$

De facto, apesar do movimento Browniano ter trajectórias contínuas, estas têm um comportamento bastante irregular, ao ponto de não serem sequer diferenciáveis.

**Teorema 7.1.5.** *Quase certamente, o movimento Browniano não é diferenciável em nenhum ponto. De facto,*

$$\liminf_{h \rightarrow 0} \frac{B(t+h) - B(t)}{h} = -\infty \quad \text{ou} \quad \limsup_{h \rightarrow 0} \frac{B(t+h) - B(t)}{h} = +\infty$$

## 7.2 Exercícios

**Exercício 52.** Mostre que

$$\text{Cov}(W(t), W(s)) = \sigma^2 \min\{t, s\},$$

onde  $W(t)$  é o processo de Wiener com parâmetros  $(x, \mu, \sigma)$ .

**Exercício 53.** Seja  $B(t)$  um movimento Browniano. Mostre que

$$E(e^{B(t)}) = e^{t/2}$$

para todo  $t \geq 0$ .

**Exercício 54.** Seja  $\{X(t) : t \geq 0\}$  um processo estocástico a tempo contínuo que tem as seguintes propriedades:

1.  $X(0) = 0$
2. trajectórias contínuas  $\mathbb{P}$ -q.c.
3. para quaisquer  $0 < t_1 < \dots < t_n$  o vector aleatório  $(X(t_1), \dots, X(t_n))$  tem função de densidade de probabilidade conjunta,

$$f_{t_1}(x_1)f_{t_2-t_1}(x_2 - x_1) \cdots f_{t_n-t_{n-1}}(x_n - x_{n-1})$$

onde

$$f_t(x) = \frac{1}{\sqrt{2\pi t}} e^{-\frac{x^2}{2t}},$$

é a função de densidade da distribuição normal.

Mostre que  $X(t)$  é um movimento Browniano.

**Exercício 55.** Seja  $B(t)$  um movimento Browniano. Mostre que dados  $0 \leq s < t$  e  $A$  Boreliano de  $\mathbb{R}$  então,

$$\mathbb{P}(B(t) \in A | B(s) = x) = \int_A f_{t-s}(y - x) dy,$$

onde  $f_t(x) = \frac{1}{\sqrt{2\pi t}} e^{-\frac{x^2}{2t}}$ .

**Exercício 56.** Seja  $B(t)$  um movimento Browniano e considere instantes  $0 < t_1 < t_2 < t_3$ . Determine a distribuição de probabilidade das variáveis:

1.  $B(t_1) + B(t_2)$
2.  $B(t_1) + B(t_2) + B(t_3)$