

## 2

### Processos de Markov

Para preparar o leitor, discutiremos aqui a construção de cadeias e processos de Markov em espaços de estados discretos, primeiro a tempo discreto e depois a tempo contínuo. Assim, poderemos finalmente fazer uma definição geral de processo de Markov como uma família de probabilidades.

#### 2.1

##### Cadeias de Markov a tempo discreto

Quando falamos de um processo estocástico no sentido mais geral, temos uma família de variáveis aleatórias (v.a.'s)  $\{X_j\}_{j \in J}$  (onde  $J$  é um conjunto de índices), definidas num espaço de probabilidade  $(\Omega, \mathcal{F}, P)$ . Se o processo evolui no tempo, dizemos que o processo é discreto no caso em que  $J \subseteq \mathbb{N}$  ou contínuo se  $J \subseteq [0, +\infty)$ , embora, podem ser considerados conjuntos mais gerais. Agora, seja  $S$  um conjunto finito ou enumerável, que chamamos espaço de estados do processo e que definimos como os possíveis valores que podem tomar as v.a.'s  $\{X_j\}_{j \in J}$ . Também, definimos uma matriz estocástica  $(p(x, y))_{(x, y) \in S^2}$  como uma matriz de números não negativos, tais que,

$$\sum_{y \in S} p(x, y) = 1, \quad \forall x \in S.$$

Claramente, se  $S$  é um conjunto finito então a matriz é finita. Suponhamos que  $\{X_n\}_{n \geq 0}$  são v.a.'s definidas no espaço de probabilidade  $(\Omega, \mathcal{F}, P)$ . Então,  $\{X_n\}_{n \geq 0}$  é uma cadeia de Markov com probabilidade de transição  $p_n(x, y)$  se, para cada  $n \geq 0$  e qualquer escolha de  $x_0, x_1, \dots, x_{n-1}, x, y \in S$  temos

$$P(\omega \in \Omega : X_{n+1}(\omega) = y | X_n(\omega) = x, \dots, X_0(\omega) = x_0) = p_n(x, y). \quad (2.1)$$

A condição (2.1) diz que, dado o atual estado  $x$ , a evolução futura é totalmente independente da evolução passada, isto é, não depende da escolha de  $x_0, x_1, \dots, x_{n-1}$ , esta condição é chamada de propriedade de Markov. Além disso, se o lado direito de (2.1) não depende do tempo  $n$ , então o processo diz-se homogêneo no tempo.

Assim, dada uma cadeia de Markov  $\{X_n\}_{n \geq 0}$  homogênea no tempo e tomando o conjunto  $[X_0 = x_0] := \{\omega \in \Omega : X_0(\omega) = x_0\}$ <sup>1</sup>, chamamos distribuição inicial do processo, a medida denotada por  $\mu$ , definida por

$$\mu(x_0) := P(X_0 = x_0), \quad \forall x_0 \in S.$$

<sup>1</sup>Daqui em diante, às vezes, vamos usar esta definição sem indicação para o leitor.

Pela equação (2.1), e dada uma cadeia de Markov  $\{X_n\}_{n \geq 0}$  com matriz de transição  $(p(x, y))_{(x, y) \in S^2}$  e distribuição inicial  $\mu$  temos que

$$\begin{aligned} & P(X_0 = x_0, \dots, X_n = x_n) \\ &= P(X_0 = x_0, \dots, X_{n-1} = x_{n-1}) P(X_n = x_n | X_0 = x_0, \dots, X_{n-1} = x_{n-1}), \end{aligned}$$

pela propriedade de Markov temos que a equação acima é igual a

$$\begin{aligned} & P(X_0 = x_0, \dots, X_{n-1} = x_{n-1}) \underbrace{P(X_n = x_n | X_{n-1} = x_{n-1})}_{p(x_{n-1}, x_n)} \\ & \vdots \\ &= P(X_0 = x_0) p(x_0, x_1) p(x_1, x_2) \cdots p(x_{n-1}, x_n) \\ &= \mu(x_0) p(x_0, x_1) p(x_1, x_2) \cdots p(x_{n-1}, x_n). \end{aligned} \tag{2.2}$$

Uma pergunta natural, mas não trivial de responder é: “Será que dada uma matriz estocástica  $p$  e uma probabilidade  $\mu \in S$ , existe uma cadeia de Markov com matriz de transição  $p$  e distribuição  $\mu$ ?”

Sem perda de generalidade, seja  $\mu$  a medida de Dirac no ponto  $x_0$ . Suponhamos que queremos construir um número finito  $m$  de v.a.’s  $(X_0, X_1, \dots, X_m)$  com a propriedade de Markov para  $0 \leq n \leq m - 1$  e com distribuição inicial  $\mu = \delta_{x_0}$ . Seja  $\Omega = S^{m+1}$  o espaço vetorial de dimensão  $m + 1$  com valores em  $S$ , e seja  $\mathcal{F}$  o conjunto de todos os subconjuntos de  $\Omega$ , isto é  $\mathcal{F} = \mathfrak{P}(\Omega)$ . Para cada  $\omega = (s_0, \dots, s_m) \in \Omega$  definimos

$$P^{x_0}(\omega) := \delta_{x_0}(s_0) p(s_0, s_1) p(s_1, s_2) \cdots p(s_{m-1}, s_m). \tag{2.3}$$

Assim, podemos definir as v.a.’s por  $X_j(\omega) := s_j$  com  $0 \leq j \leq m$ . Então conseguimos definir  $P^{x_0}$  sobre o espaço  $S^{m+1}$  tal que as v.a.’s  $X_j$  (projeções) têm a propriedade markoviana (que resulta da construção) com matriz de transição  $p$  e estado inicial  $x_0$ .

Agora, pretendemos estender a construção ao processo infinito  $\{X_n\}_{n \geq 0}$  no espaço  $\Omega = S^\infty$ , cujos elementos são sequências infinitas  $\omega = (s_0, s_1, s_2, \dots)$  com  $s_j \in S$ , tomando  $X_n(\omega) = s_n$ , isto é, considerando

$$\begin{aligned} X_n : \Omega &\longrightarrow S \\ \omega = (s_0, s_1, \dots) &\longmapsto s_n. \end{aligned}$$

A  $\sigma$ -álgebra produto  $\mathcal{F}$  em  $\Omega$  é gerada pelos cilindros (eventos com um número finito de coordenadas). Com um espaço de estado  $S$  enumerável é suficiente

considerar conjuntos da forma

$$\{\omega = (s_0, s_1, s_2, \dots) : X_0(\omega) = s_0, X_1(\omega) = s_1, \dots, X_m(\omega) = s_m\}.$$

Seja  $\mathcal{C}_0$  a classe de tais conjuntos obtidos por deixar os vetores  $(s_0, \dots, s_m)$  variarem sobre  $S^{m+1}$ . Definimos a função  $P^x$  em  $\mathcal{C}_0$  por

$$P^x(X_0 = s_0, X_1 = s_1, \dots, X_m = s_m) = \delta_x(s_0)p(s_0, s_1) \cdots p(s_{m-1}, s_m).$$

Este é um primeiro passo para dar solução à nossa construção, o segundo passo é fornecido pelo Teorema de extensão de Kolmogorov, que garante que para cada  $x$ , a medida de probabilidade  $P^x$ , existe no espaço produto infinito, de tal forma que a probabilidade de cada cilindro é igual à probabilidade dada por (2.3). Se queremos começar com um estado inicial  $X_0$  aleatório com distribuição  $\mu$ , tomamos em  $\Omega$  a medida  $P^\mu$  definida em  $A \in \mathcal{F}$  por

$$P^\mu(A) = \sum_{x \in S} \mu(x)P^x(A).$$

Portanto a resposta à pergunta é afirmativa, e dizemos que uma cadeia de Markov está bem determinada pela sua matriz de transição e pela sua distribuição inicial.

## 2.2

### Cadeias de Markov a tempo contínuo

Vamos construir uma cadeia de Markov  $\{X_t\}_{t \geq 0}$  com  $0 \leq t < \infty$ , mas num espaço de estados enumerável  $S$ . Como  $S$  é enumerável nossa cadeia tem que se mover em saltos, assim a evolução da cadeia é descrita da seguinte forma. No estado  $x$  esperamos um tempo aleatório, e saltamos aleatoriamente a um novo estado  $y$ . Depois esperamos um outro tempo aleatório e saltamos aleatoriamente a um estado  $z$ , e assim por diante. Então, temos que determinar duas coisas:

1. A distribuição de probabilidade dos tempos aleatórios de espera em cada estado  $x \in S$ .
2. O mecanismo para escolher o próximo estado quando ocorre um salto.

Notemos que a propriedade de Markov nos diz que a distribuição do tempo até ao salto seguinte, só pode depender da localização atual  $x$  e não pode depender do tempo passado.

**Teorema 2.2.1.** *A única distribuição contínua com a propriedade de não ter memória é a distribuição exponencial.*

*Demonstração.* Afirmamos que a v.a.  $X$  com distribuição exponencial de parâmetro  $\lambda > 0$  tem perda de memória. De fato, note que,  $\forall s, t > 0$

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

A igualdade anterior significa que a probabilidade de  $X$  ser maior a  $t + s$  sabendo que  $X$  é maior que  $t$ , só depende amplitude do intervalo, ou seja, essa probabilidade coincide com a probabilidade de  $X$  ser maior que  $s$ . Agora vejamos que é única. Seja  $X$  v.a. contínua com perda de memória e seja  $F(t) = P(X > t)$ . Então,  $F(t + s) = F(t)F(s)$ ,  $\forall t, s > 0$  e isto implica que  $F(2) = F^2(1)$  e  $F\left(\frac{1}{2}\right) = F^{\frac{1}{2}}(1)$ . Em geral, se  $a \in \mathbb{Q}$  temos que  $F(a) = F^a(1)$ . Assim a única função contínua que satisfaz a relação acima para  $a \geq 0$  com  $a \in \mathbb{Q}$ , é  $F(a) = F^a(1) = e^{a \ln F(1)}$ . Agora basta tomar  $\lambda = -\ln(F(1))$ .  $\square$

Voltando, a perda de memória força que o tempo de espera em  $x$  seja distribuído exponencialmente. Seja  $(c(x))^{-1}$  a sua média. Então,  $c(x)$  é a taxa de salto do estado  $x$ . Sempre que a cadeia está em  $x$  consideramos que o tempo de espera  $T_x$  tem distribuição exponencial, ou seja,  $\forall t > 0$   $P(T_x > t) = e^{-c(x)t}$ . Quando a cadeia “salta”, a propriedade de Markov diz que a escolha do seguinte estado depende só do atual estado  $x$ . Assim os saltos são descritos pela matriz estocástica  $p(x, y)$ , onde  $p(x, y)$  é a probabilidade de estar em  $x$  e saltar para  $y$ . Como  $p$  não depende do tempo a probabilidade de saltar de  $x$  a  $y$  não depende do tempo em que o salto ocorre.

Então, isto sugere que para construir uma cadeia de Markov  $\{X_t\}_{t \geq 0}$  a tempo contínuo com saltos exponencialmente distribuídos com parâmetros  $c(x)$  e com  $p(x, y)$  como matriz de transição, tomamos uma cadeia de Markov em tempo discreto  $\{Y_n\}_{n \geq 0}$  com matriz de transição  $p(x, y)$  e ajustamos os tempos de espera para produzir os tempos corretos, isto é, exponencialmente distribuídos com média  $(c(x))^{-1}$ .

Seja  $x \in S$  o estado inicial e seja  $(\Omega_1, \mathcal{H}_1, P_1^x)$  o espaço de probabilidade no qual está definida a cadeia discreta  $\{Y_n\}_{n \geq 0}$ , com matriz de transição  $p(x, y)$  e estado inicial  $x$ . Além disso, independentemente de  $\{Y_n\}_{n \geq 0}$ , seja  $\{\tau_j\}_{j \geq 0}$  uma sequência de v.a.’s independentes e identicamente distribuídas (i.i.d), com distribuição exponencial de média 1, no espaço  $(\Omega_2, \mathcal{H}_2, P_2)$ . Tomamos

$(\Omega, \mathcal{H}, \mathbf{P}^x) = (\Omega_1 \otimes \Omega_2, \mathcal{H}_1 \otimes \mathcal{H}_2, P_1^x \otimes P_2)$ . Note que os estados que a cadeia toma em tempo contínuo  $\{X_t\}_{t \geq 0}$ , são  $x = Y_0, Y_1, \dots$ , isto é a cadeia toma os mesmos valores de  $\{Y_n\}_{n \geq 0}$ . Definimos os tempos de espera por  $\sigma_n = (c(Y_n))^{-1} \tau_n$ . Claramente,  $\{\sigma_n\}_{n \geq 0}$  não é independente da cadeia  $\{Y_n\}_{n \geq 0}$ , mas condicionada à variável discreta  $Y_n$ , temos que a variável  $\sigma_n$  é independente de  $\{\sigma_k, Y_k\}_{0 \leq k < n}$ , e além disso, tem distribuição exponencial com média  $(c(Y_n))^{-1}$ . Agora, defina  $T_0 = 0, T_n = \sigma_0 + \sigma_1 + \dots + \sigma_n$ , para  $n \geq 1$ . Então

$$X_t = \sum_{n=0}^{\infty} Y_n \mathbf{1}_{\{[T_n, T_{n+1})\}}(t).$$

Note que  $X_t$  está definida para todo tempo  $0 \leq t < \infty$ , se  $T_n \nearrow \infty$  quando  $n \nearrow \infty$ . De fato, isto acontece quase certamente no caso em que exista uma constante  $C_0 < \infty$ , tal que  $c(x) \leq C_0, \forall x \in S$ , pois, teríamos que  $(c(Y_n))^{-1}$  não se anula quando  $n \nearrow \infty$ . Portanto, daqui para a frente vamos assumir este fato. A nossa construção pode ser repetida para cada estado inicial  $x \in S$ . Defina a probabilidade de transição por  $p_t(x, y) = \mathbf{P}^x(X_t = y)$ . Assim, temos a seguinte propriedade para todos os tempos  $0 \leq t_0 < t_1 < t_2 < \dots < t_n$  e estados iniciais  $x_0, x_1, x_2, \dots, x_n$ :

$$\mathbf{P}^x(X_{t_0} = x_0, \dots, X_{t_n} = x_n) = p_{t_0}(x, x_0) p_{t_1 - t_0}(x_0, x_1) \dots p_{t_n - t_{n-1}}(x_{n-1}, x_n). \tag{2.4}$$

A igualdade anterior, implica que  $\{X_t\}_{t \geq 0}$  tem a propriedade markoviana,

$$\mathbf{P}^x(X_{t_n} = x_n | X_{t_{n-1}} = x_{n-1}, \dots, X_{t_0} = x_0) = p_{t_n - t_{n-1}}(x_{n-1}, x_n).$$

Seja  $D_S$  o espaço de funções  $\xi : [0, +\infty) \rightarrow S$  tal que  $t \mapsto \xi(t)$ , com a propriedade que  $\xi(t) = \lim_{s \downarrow t} \xi(s)$  (contínua à direita) e  $\xi(t^-) = \lim_{s \uparrow t} \xi(s)$  existe (o limite à esquerda existe). Então  $D_S$  é o espaço de funções definidas em  $[0, +\infty)$  contínuas à direita e com limite à esquerda. Daqui em diante, conjuntos de funções com esta propriedade vamos chamar càdlàg (do francês “continue à droite, limite à gauche”).

Seja  $\mathcal{F}$  a  $\sigma$ -álgebra em  $D_S$  gerada pela projeção  $\pi_t : D_S \rightarrow S$  tal que para todo  $t \geq 0, \pi_t(\xi) = \xi(t)$ . Assim, podemos pensar em  $X_\cdot = \{X_t\}_{0 \leq t < \infty}$  como uma v.a. tal que

$$\begin{aligned} X_\cdot : (\Omega, \mathcal{H}, \mathbf{P}^x) &\longrightarrow (D_S, \mathcal{F}, P^x) \\ \omega &\longmapsto X_\cdot(\omega), \end{aligned}$$

com  $P^x(A) = \mathbf{P}^x(X_\cdot \in A)$ , para todo  $A \in \mathcal{F}$ . Isto define uma família de probabilidades  $\{P^x\}_{x \in S}$  em  $D_S$ . Então, para uma v.a.  $Z$  e para  $x \in S$ , podemos definir a esperança  $E^x[Z] = \int_{D_S} Z dP^x$ . A probabilidade de transição pode se

expressar por  $p_t(x, y) = \mathbf{P}^x (X_t = y) = P^x (\xi(t) = y)$ .

Queremos expressar a propriedade de Markov numa forma mais poderosa. Para tal, seja  $\{\theta_t\}_{t \geq 0}$  a aplicação de translações no espaço  $D_S$ , definida por  $\theta_t \xi(s) = \xi(s + t)$ . O efeito da aplicação de translação  $\theta_t$  é reiniciar o processo no tempo  $t$ . Para um evento  $A \in \mathcal{F}$  temos que a imagem inversa

$$\theta_t^{-1}(A) = \{\xi \in D_S : \theta_t(\xi) \in A\}$$

é o evento onde “A acontece do tempo  $t$  em diante”.

Seja  $\mathcal{F}_t = \sigma(\xi(s) : 0 \leq s \leq t)$  a  $\sigma$ -álgebra natural em  $D_S$ . Então, para todos os eventos  $A \in \mathcal{F}$  e  $x \in S$  temos que

$$P^x (\theta_t^{-1}(A) | \mathcal{F}_t) (\xi) = P^{\xi(t)}(A), \quad (2.5)$$

para  $P^x$ -quase todo  $\xi$ . O lado esquerdo da equação (2.5) é a probabilidade condicional de um evento que ocorre do tempo  $t$  em diante, condicionada ao passado até ao tempo  $t$ . Para deduzir (2.5) de (2.4), basta verificar que

$$E^x [\mathbf{1}_B \cdot \mathbf{1}_A \circ \theta_t] = E^x [\mathbf{1}_B \cdot P^{\xi(t)}(A)],$$

primeiro para cilindros  $A \in \mathcal{F}$  e  $B \in \mathcal{F}_t$ , e depois estender a todos os eventos pelo teorema  $\pi - \lambda$  (ver Apêndice 1 de [9]). Acima  $E^x$  é a esperança com respeito a  $P^x$ .

## 2.3

### Processo de Markov geral

Seja  $S$  um espaço métrico e considere em  $S$  a  $\sigma$ -álgebra de Borel que denotamos por  $\mathcal{B}_S$ . Considere para cada  $t \in [0, \infty)$  considere as projeções  $\pi_t(\omega) = \omega(t)$ . Seja  $\mathcal{F}$  a menor  $\sigma$ -álgebra em  $D_S$  na qual todas as projeções  $\pi_t$  são mensuráveis. Para  $t \in [0, \infty)$ , seja  $\mathcal{F}_t$  a menor  $\sigma$ -álgebra em  $D_S$  na qual todas as projeções  $\pi_s$  são mensuráveis, para  $s \leq t$ .

**Definição 2.3.1.** *Um processo de Markov é uma coleção  $\{P^x\}_{x \in S}$  de probabilidades em  $D_S$  tal que*

1.  $P^x (\omega \in D_S : \omega(0) = x) = 1$ .
2.  $\forall A \in \mathcal{F}$  a função  $x \mapsto P^x(A)$  é mensurável em  $\mathcal{S}$ .
3.  $P^x(\theta_t^{-1}(A) | \mathcal{F}_t)(\omega) = P^{\omega(t)}(A)$  para  $P^x$ -quase certamente  $\omega$ , para todo  $x \in \mathcal{S}$  e para todo  $A \in \mathcal{F}$ .

Na definição anterior, 1. diz que  $x$  é o valor inicial para a cadeia partindo da medida  $P^x$ , e o ponto 3. é a propriedade de Markov.

Para começar o processo com uma distribuição  $\mu$  diferente de  $\delta_x$ , definimos  $P^\mu$  em  $D_S$  por

$$P^\mu(A) = \int_S P^x(A)\mu(dx), \forall A \in \mathcal{F}.$$

A probabilidade de transição  $p_t(x, dy)$  é definida para todo  $t \geq 0$ ,  $x \in S$  e  $B \in \mathcal{B}_S$  por

$$p_t(x, B) = P^x(\pi_t \in B). \quad (2.6)$$

As equações de Chapman-Kolmogorov

$$p_{t+s}(x, B) = \int_S p_s(y, B)p_t(x, dy), \quad (2.7)$$

são consequência da propriedade de Markov.

Agora, para funções  $\mathcal{F}$ - mensuráveis e limitadas em  $S$  e  $t \geq 0$  definimos a função  $S_t f$  em  $S$  por

$$S_t f(x) = E^x[f(\pi_t)] = \int_S f(y)p_t(x, dy). \quad (2.8)$$

A mensurabilidade de  $S_t f$  é consequência do ponto 2. da Definição 2.3.1. Denotamos a norma do supremo para funções mensuráveis e limitadas por

$$\|f\|_\infty := \sup_{x \in S} |f(x)|, \quad (2.9)$$

e assim, é fácil ver que:

$$\|S_t f\|_\infty \leq \|f\|_\infty, \quad (2.10)$$

portanto  $S_t$  leva funções mensuráveis e limitadas em  $S$ , em funções mensuráveis e limitadas em  $S$ . Pela linearidade da integral também temos a linearidade de  $S_t$ . Portanto  $S_t$  é um operador linear definido no espaço das funções mensuráveis e limitadas. Logo, pela propriedade de Markov temos que

$$\begin{aligned} S_{s+t}f(x) &= E^x[f(\pi_{s+t})] \\ &= E^x[E^x[f(\pi_{s+t})|\mathcal{F}_s]] \\ &= E^x[E^{\pi_s}[f(\pi_t)]] \\ &= E^x[S_t f(\pi_s)] \\ &= S_s S_t f(x). \end{aligned}$$

Daqui a pouco, vamos ver que  $\{S_t\}_{t \geq 0}$  forma um semigrupo. Além disso, pela propriedade (2.10) dizemos que  $\{S_t\}_{t \geq 0}$  é um semigrupo de contração. Afirmamos, sem demonstração, que  $\{P^x\}_{x \in S}$  são unicamente determinadas pelo semigrupo  $\{S_t\}_{t \geq 0}$  (ver [11], página 9).

**Definição 2.3.2.** *Seja  $C_b(S) = \{f : S \rightarrow \mathbb{R}, \text{ contínua e limitada em } S\}$ .*

Vamos considerar em  $C_b(S)$  a norma definida em (2.9).

**Definição 2.3.3.** Um processo de Markov  $\{P^x\}_{x \in \mathcal{S}}$  é um processo de Feller se,  $C_b(\mathcal{S})$  é fechado sobre a ação do semigrupo, isto é, se  $f \in C_b(\mathcal{S})$  então  $S_t f \in C_b(\mathcal{S})$ ,  $\forall t \geq 0$ .

## 2.4

### Semigrupos e geradores

Esta seção não pretende abarcar toda a teoria de semigrupos, só aquela teoria que precisamos nesta dissertação.

**Definição 2.4.1.** Uma família  $\{S_t\}_{t \geq 0}$  de operadores limitados em  $C_b(\mathcal{S})$  diz-se um semigrupo se:

1.  $S_0 = I$ .
2.  $S_{t+s} = S_t S_s$ ,  $\forall s, t \geq 0$ .

**Definição 2.4.2.** Uma família  $\{S_t\}_{t \geq 0}$  é um semigrupo fortemente contínuo se  $\lim_{t \downarrow 0} \|S_t f - f\|_\infty = 0$ ,  $\forall f \in C_b(\mathcal{S})$ . Se cada  $S_t$  é uma contração, isto é, satisfaz (2.10), então  $\{S_t\}_{t \geq 0}$  diz-se um semigrupo de contração.

**Lema 2.4.3.** Suponha que  $\{S_t\}_{t \geq 0}$  é um semigrupo de contração fortemente contínuo em  $C_b(\mathcal{S})$ . Então, para cada  $f \in C_b(\mathcal{S})$  a função  $t \rightarrow S_t f$  é uma função uniformemente contínua.

*Demonstração.* Para  $t, h \geq 0$  temos

$$\|S_{t+h} f - S_t f\|_\infty = \|S_t(S_h - I)f\|_\infty \leq \|S_h f - f\|_\infty,$$

e para  $0 \leq h \leq t$  temos,

$$\|S_{t-h} f - S_t f\|_\infty = \|S_{t-h}(S_h - I)f\|_\infty \leq \|S_h f - f\|_\infty.$$

Nos dois casos anteriores usamos o fato que  $S_t$  é uma contração. Assim, pela Definição 2.4.2 temos que o lado direito das expressões anteriores se anulam quando  $h \rightarrow 0$ . Logo a função é uniformemente contínua.  $\square$

**Definição 2.4.4.** O gerador infinitesimal ou, simplesmente, gerador de um semigrupo  $\{S_t\}_{t \geq 0}$ , é o operador  $L$  definido por

$$L f = \lim_{t \rightarrow 0} \frac{S_t f - f}{t}, \quad (2.11)$$

com domínio  $D(L)$  que é o conjunto das funções  $f \in C_b(\mathcal{S})$  para as quais o limite existe. A convergência é no sentido da norma de  $C_b(\mathcal{S})$ , isto é, na norma do supremo.

**Lema 2.4.5.** *Suponha que  $\{S_t\}_{t \geq 0}$  é um semigrupo de contração fortemente contínuo em  $C_b(\mathcal{S})$  com gerador  $L$ . Então valem as seguintes afirmações:*

1. Se  $f \in C_b(\mathcal{S})$  e  $t \geq 0$ . Então,  $\int_0^t S_s f ds \in D(L)$  e

$$S_t f - f = L \int_0^t S_s f ds.$$

2. Se  $f \in D(L)$  e  $t \geq 0$ . Então,  $S(s)f \in D(L)$  e

$$\frac{d}{dt} S_t f = L S_t f = S_t L f.$$

3. Se  $f \in D(L)$  e  $t \geq 0$ . Então,

$$S_t f - f = \int_0^t L S_s f ds = \int_0^t S_s L f ds.$$

**Corolário 2.4.6.** *Suponha que  $\{S_t\}_{t \geq 0}$  é um semigrupo de contração fortemente contínuo em  $C_b(\mathcal{S})$  com gerador  $L$ . Então,  $D(L)$  é denso em  $C_b(\mathcal{S})$ .*

Para a demonstração do Lema (2.4.5) e do Corolário (2.4.6), veja [4], página 9 e 10.

## 2.5

### Medida de Probabilidade Invariante

Seja  $\{P^x\}_{x \in \mathcal{S}}$  um processo de Markov a tempo contínuo que é um processo de Feller. Assuma que  $S_t$  é um semigrupo de contração no espaço de Banach  $C_b(\mathcal{S})$ . Seja  $M_1(\mathcal{S})$  o espaço das medidas de probabilidade em  $\mathcal{S}$ , que também é um espaço métrico quando munido da seguinte convergência. A convergência em  $M_1(\mathcal{S})$  é dada pela convergência fraca definida por

$$\mu_n \xrightarrow[n \uparrow \infty]{w} \mu \Leftrightarrow \int f(x) \mu_n(dx) \xrightarrow[n \uparrow \infty]{} \int f(x) \mu(dx), \forall f \in C_b(\mathcal{S}).$$

Para  $\mu \in M_1(\mathcal{S})$  e  $t \geq 0$ , definimos  $\mu S_t \in M_1(\mathcal{S})$  por

$$\int f(x) \mu S_t(dx) = \int S_t f(x) \mu(x), \forall f \in C_b(\mathcal{S}).$$

Assim, se  $B \in \mathcal{B}_{\mathcal{S}}$  temos

$$\mu S_t(B) = \int P^x(X_t \in B) \mu(dx).$$

A medida de probabilidade  $\mu S_t$  é interpretada como a distribuição no tempo  $t$  de um processo com gerador  $L$  e semigrupo  $S_t$ , quando a distribuição inicial desse processo é  $\mu$ .

Agora, dizemos que  $\mu$  é invariante para o processo  $\{X_t\}_{t \geq 0}$  se

$$\mu S_t = \mu, \forall t \geq 0.$$

Seja  $\mathcal{I}$  o conjunto das medidas invariantes para  $\{X_t\}_{t \geq 0}$ . Agora, invariância de  $\mu$  implica que se o estado inicial  $X_0$  tem distribuição  $\mu$ , então  $X_t$  também tem distribuição  $\mu$  para todo  $t \geq 0$ . Além disso, o processo  $\{X_t\}_{t \geq 0}$  é estacionário o que significa que a distribuição do processo transladado no tempo é a mesma que a distribuição do processo original.

**Definição 2.5.1.** Para cada operador linear  $L$ , um subespaço linear  $Y$  de  $D(L)$  é um cerne de  $L$  se o gráfico de  $L$  é o fecho do gráfico de  $L|_Y$ .

**Teorema 2.5.2.** Seja  $L$  o gerador de um semigrupo de contração fortemente contínuo  $S_t$  em  $C_b(\mathcal{S})$  definido por um processo de Markov. Seja  $\mu$  uma medida de probabilidade em  $\mathcal{S}$ . Seja  $Y$  um cerne para  $L$ . Então  $\mu$  é invariante para  $X_t$  se e somente se

$$\int Lf(x)\mu(dx) = 0, \forall f \in Y.$$

*Demonstração.*  $\Rightarrow$ ) Suponhamos que  $\mu$  é invariante e  $f \in D(L)$ . Como  $\frac{S_t f - f}{t} \xrightarrow[n \uparrow \infty]{} Lf$ , uniformemente, então

$$\begin{aligned} \int Lf d\mu &= \lim_{t \rightarrow 0} \int \frac{S_t f - f}{t} d\mu = \lim_{t \rightarrow 0} \frac{1}{t} \left( \int S_t f d\mu - \int f d\mu \right) \\ &= \lim_{t \rightarrow 0} \frac{1}{t} \left( \int f d\mu - \int f d\mu \right) = 0. \end{aligned}$$

$\Leftarrow$ ) Agora, assumamos que  $\int Lf d\mu = 0, \forall f \in Y$ . Pela definição de cerne temos que,  $\forall f \in D(L), \exists \{g_n\}_{n \geq 0} \in Y$  tal que  $Lg_n \xrightarrow[n \uparrow \infty]{} Lf$ , uniformemente, quando  $n \rightarrow \infty$ . Logo  $\int Lf d\mu = 0, \forall f \in D(L)$ .

Fixada  $f \in D(L)$ , pelo Lema 2.4.3, temos que  $S_t f \in D(L), \forall t \geq 0$ . Assim, usando o Teorema de Fubini temos

$$\int S_t f d\mu - \int f d\mu = \int_0^t \left( \int L[S_s f] d\mu \right) ds = 0,$$

isto implica que

$$\int f d(\mu S_t) = \int f d\mu, \forall f \in D(L).$$

Além disso, pelo Corolário 2.4.6, temos que  $D(L)$  é denso em  $C_b(\mathcal{S})$ . Assim, temos que  $\mu S_t = \mu$ .  $\square$