

# Aula 4 - Autômatos Temporais Estocástico

①

## (Capítulo 6 - Cassandra)

### 1. Introdução

Como na realidade os sistemas de eventos discretos existem na presença de incertezas, modelos mais refinados são exigidos, incorporando elementos estocásticos.

### 2. Processo Estocástico

Um processo estocástico, ou randômico, é simplesmente um conjunto de variáveis randômicas indexadas por meio de algum parâmetro. (normalmente o "tempo").

Definição: Um processo estocástico ou randômico  $X(\omega, t)$  é uma coleção de variáveis randômicas indexadas por  $t$ . As variáveis randômicas são definidas sobre um espaço de probabilidade  $(\Omega, E, P)$  com  $\omega \in \Omega$ .

$\Omega$  --- conjunto de variáveis randômicas (Espaço Amostral)

$E$  --- subconjunto de  $\Omega$  (Espaço de Eventos de interesse)

$P$  --- Probabilidade ( $A \in E \rightarrow P[A]$ )

$t$  --- varia dentro de um conjunto  $T \subseteq \mathbb{R}$

a) Processo Estocástico de Estado-Contínuo x Estado-Discreto

Estado-Discreto:  $X(t)$  definido sobre um conjunto finito ou contável de estados. Em geral um processo de estado-discreto é denominado por Cadeia (Chain).

Caso contrário: Estado-Contínuo

## b) Processo Estocástico Tempo-Contínuo x Tempo-Discreto

(2)

Tempo-Discreto: O conjunto  $T$ , que especifica os valores permitidos da variável indexadora  $t$ , é finito ou contável.

Caso contrário, tempo contínuo.

## c) Classes Importantes de Processo Estocástico

Para caracterizar uma variável aleatória  $X$ , normalmente é especificada uma função distribuição de probabilidade acumulativa ("cumulative distribution function") - cdf

$$F_X(x) = P[X \leq x]$$

Seja o vetor aleatório:  $X = [X(t_0), X(t_1), \dots, X(t_n)]$

que pode assumir os valores  $x = [x_0, x_1, \dots, x_n]$

$$\Rightarrow F_X(x_0, \dots, x_n; t_0, \dots, t_n) = P[X(t_0) \leq x_0, \dots, X(t_n) \leq x_n]$$

Algumas características são mais relevantes quando se modela os Sistemas de Eventos Discretos.

### c.1) Processos Estacionários

Estacionária é a propriedade de um sistema em manter seu comportamento dinâmico invariante no tempo.

$$F_X(x_0, \dots, x_n; t_0 + \tau, \dots, t_n + \tau) = F_X(x_0, \dots, x_n; t_0, \dots, t_n) \\ \text{para } \forall \tau \in \mathbb{R}$$

## c.2) Processos Independentes

Seja a sequência de variáveis aleatórias:

$$\{X_0, X_1, \dots, X_n\}$$

Sé diz que trata-se de processos independentes se:

$$F_X(x_0, \dots, x_n; t_0, \dots, t_n) = F_{X_0}(x_0; t_0) \dots F_{X_n}(x_n; t_n)$$

Neste caso  $\{X_k\}$  representa uma sequência de variáveis aleatórias independentemente e distribuídas identicamente (sequência iid) se também todas tiverem a mesma função distribuição.

## c.3) Processo de Markov

Suponha que observemos uma cadeia de  $t_0$  até  $t_k$ , onde  $t_0 \leq t_1 \leq \dots \leq t_{k-1} \leq t_k$ .

Observamos o valor  $x_k$  no instante  $t_k$  ("estado presente")

História Passada:  $\{x_0, x_1, \dots, x_{k-1}\}$

Futuro Desconhecido:  $\{x_{k+1}, x_{k+2}, \dots\}$

Numa Cadeia de Markov existe a independência, ou seja, o futuro é completamente independente do passado. Este fato é conhecido como Propriedade Sem Memória, depende apenas do presente.

Fundamente, um processo é Markoviano se

$$\begin{aligned}
 & P[X(t_{k+1}) \leq x_{k+1} \mid X(t_k) = x_k, X(t_{k-1}) = x_{k-1}, \dots, X(t_0) = x_0] \\
 &= P[X(t_{k+1}) \leq x_{k+1} \mid X(t_k) = x_k] \\
 &\quad \text{(Espaço de Estado)} \\
 &\quad \text{(Espaço Contínuo)}
 \end{aligned}$$

ou

$$\begin{aligned}
 & P[X(t_{k+1}) = x_{k+1} \mid X(t_k) = x_k, X(t_{k-1}) = x_{k-1}, \dots, X(t_0) = x_0] \\
 &= P[X(t_{k+1}) = x_{k+1} \mid X(t_k) = x_k]
 \end{aligned}$$

(Espaço de Estado Discreto)

No caso de Cadeias de Markov em tempo-discreto, as transições de estado são limitadas aos instantes de tempo 0, 1, 2, ..., K, ...

Assim a propriedade Sem Memória tem dois aspectos:

(M1) Todas informações dos estados passados são irrelevantes

(M2) Quanto tempo o processo está no estado presente também é irrelevante, ou seja, sua idade é irrelevante.

Em um sistema de Estado Discreto, as transições de estado são causadas por ocorrência de eventos. Deste forma, as variáveis randômicas com propriedade sem memória ~~no caso de~~ correspondem aos tempos entre eventos. Há diversos sistemas reais que essa propriedade é válida, e pode ser justificada em larga escala.

### 3. Estrutura de Relógio Estocástico (Clock)

(5)

Nos Autômatos Temporais foi vista a estrutura do tempo como:  $V = \{v_i : i \in E\}$  onde

$v_i = \{v_{i1}, v_{i2}, \dots\}$  corresponde a frequência de clock para o evento  $i \in E$ .

O objetivo agora é estender este modelo para incorporar as características estocásticas dos Sistemas de Evento Discretos.

Deste forma, teremos que:

$$\{V_{i,k}\} = \{V_{i1}, V_{i2}, V_{i3}, \dots\}$$

↑  
randômico

Definição: Autômato Temporal Estocástico

$$(E, X, T, p, p_0, G)$$

$E$  --- Conjunto de Eventos contáveis

$X$  --- Espaço de Estados contáveis

$T(x)$  --- função de eventos permitidos

$p(x'; x, e')$  --- probabilidade de transição de estado  
↑  
atual

$p_0(x)$  --- probabilidade de estar no estado inicial  $X_0$

$G$  --- Estrutura do Clock Estocástico

## O Processo de Contagem de Poisson

(6)

Considere um Sistema de Evento Discreto com um único evento. Adote-se  $\{N(t)\}$  como sendo o processo que conta o número de ocorrências deste evento no intervalo  $(0, t]$ .

$$N(0) \leq N(t_1) \leq \dots \leq N(t_k),$$

$$0 \leq t_1 \leq \dots \leq t_k.$$

$$N(t_{k-1}, t_k) = N(t_k) - N(t_{k-1}), \quad k=1, 2, \dots$$

conta o número de ocorrências do evento no intervalo  $(t_{k-1}, t_k)$ .

A probabilidade de  $n$  eventos ocorrerem em  $(0, t]$  será dada por:  $P_n(t) = P[N(t) = n], \quad n=0, 1, \dots$

### Hipóteses

- (1) Apenas 1 evento pode ocorrer num instante de tempo
- (2) As variáveis aleatórias  $N(t), N(t_1, t_2), N(t_2, t_3), \dots, N(t_{k-1}, t_k), \dots$  são mutuamente independentes para  $0 \leq t \leq t_1 \leq \dots \leq t_k$  e qualquer  $k=1, 2, \dots$

Os eventos futuros em algum intervalo futuro  $(t_{k-1}, t_k)$  não são afetados pelo que aconteceu no passado, antes de  $t_{k-1}$ . [Processo com Incrementos Independentes]


- (3)  $P[N(t_{k-1}, t_k) = n], \quad n=0, 1, \dots$ , pode depender do comprimento do intervalo  $(t_k - t_{k-1})$ , mas <sup>não</sup> do instante  $t_{k-1}$ , para todo intervalo. [Processo com Incrementos Independentes Estacionários]

Objetivo: Calcularmos  $P_n(t) = P[N(t)=n]$

7

Passo 1: Determinar  $P_0(t) = P[N(t)=0]$

$$P_0(t+s) = P_0(t) \cdot P_0(s)$$



$$\frac{d}{ds} P_0(t+s) = P_0(t) \cdot \underbrace{\frac{dP_0(s)}{ds}}_{P_0'(s)}$$

$$\text{Fazemos } s=0 \Rightarrow \frac{dP_0(t)}{ds} = P_0(t) \cdot \underbrace{P_0'(0)}_{cte}$$

$$\Rightarrow \frac{dP_0(t)}{ds} = cte \cdot P_0(t) \Rightarrow P_0(t) = e^{cte \cdot t}$$

Para satisfazer  $P_0(t) \leq 1$  para todo  $t \geq 0 \Rightarrow \underline{cte < 0}$   
(cte = -1)

$$\Rightarrow \boxed{P_0(t) = e^{-\lambda t}}$$

Passo 2: Determinar  $P[N(\Delta t)=0]$  para um pequeno intervalo  $\Delta t$ .

$$P[N(\Delta t)=0] = e^{-\lambda \Delta t} = 1 - \lambda \Delta t + \lambda^2 \frac{(\Delta t)^2}{2!} - \lambda^3 \frac{(\Delta t)^3}{3!} \dots$$

[Série de Taylor]

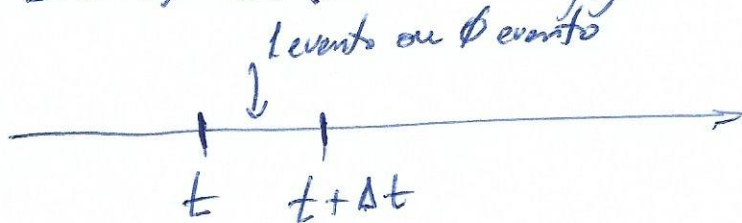
$$\text{Quando } \Delta t \rightarrow 0 \Rightarrow \boxed{P[N(\Delta t)=0] \approx 1 - \lambda \Delta t}$$

Passo 3: Determinar  $P[N(\Delta t)=n]$ ,  $n=1, 2, \dots$  para pequeno  $\Delta t$ .

Como  $\Delta t$  muito pequeno, vamos assumir baseado em (1) que no intervalo  $\Delta t$  acontece apenas um evento (no máximo)

$$\Rightarrow P[N(\Delta t)=1] = 1 - (1 - \lambda \Delta t) \Rightarrow \boxed{P[N(\Delta t)=1] = \lambda \Delta t}$$

Passo 4: Derivar a expressão  $P[N(t+\Delta t)=n]$  em termos de  $P[N(t)=n]$ . ( $\Delta t$  muito pequeno.)



$$P_n(t+\Delta t) = P_n(t) \underbrace{(1-\lambda\Delta t)}_{\substack{\uparrow \\ \text{zero eventos}}} + \underbrace{P_{n-1}(t)}_{\substack{\uparrow \\ \text{evento}}} \cdot \lambda\Delta t$$

Passo 5: Fazer  $\lim_{\Delta t \rightarrow 0}$

$$\frac{P_n(t+\Delta t) - P_n(t)}{\Delta t} = -\lambda P_n(t) + \lambda P_{n-1}(t)$$

$\Downarrow \lim_{\Delta t \rightarrow 0}$

$$\boxed{\frac{dP_n(t)}{dt} = -\lambda P_n(t) + \lambda P_{n-1}(t)}$$

Passo 6: Resolver a equação diferencial

Para  $n=1 \Rightarrow \frac{dP_1(t)}{dt} = -\lambda P_1(t) + \lambda P_0(t)$

$$\frac{dP_1(t)}{dt} = -\lambda P_1(t) + \lambda e^{-\lambda t} \Rightarrow \boxed{P_1(t) = (\lambda t) e^{-\lambda t}}$$

$$\text{para } n=2, 3, \dots \Rightarrow \boxed{P_n(t) = \frac{(\lambda t)^n}{n!} e^{-\lambda t}}, t \geq 0$$

$n=0, 1, 2, 3, \dots$



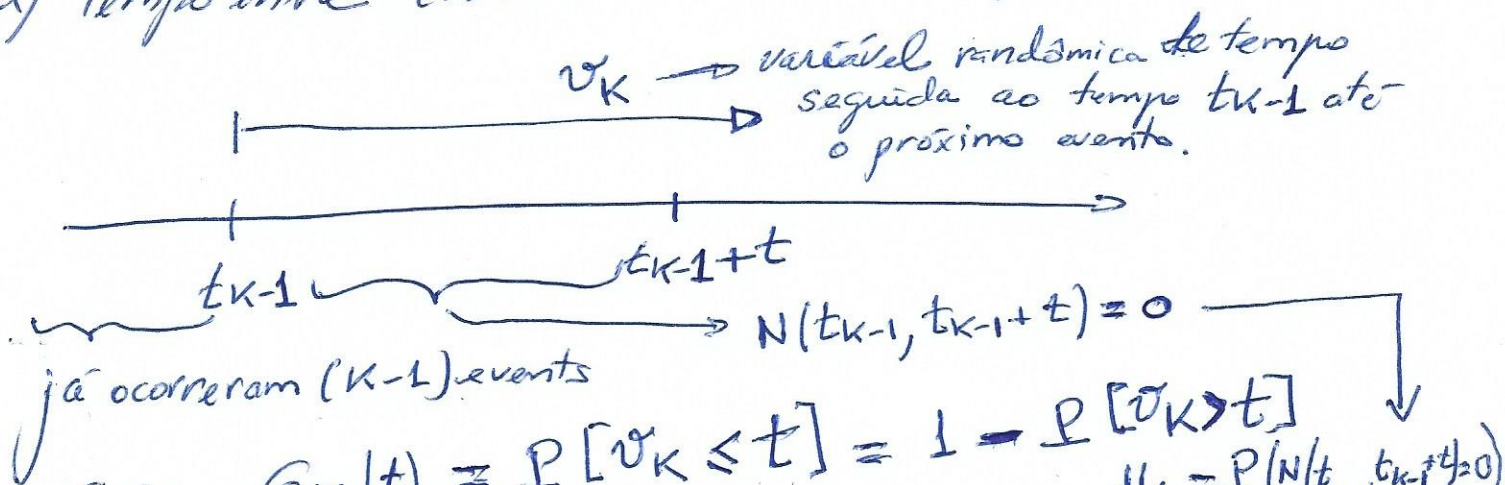
Esta expressão é conhecida como Distribuição de Poisson (com hipóteses (1), (2) e (3))

9

$$\begin{cases} E[N(t)] = \lambda t & \text{Média (*)} \\ \text{Var}[N(t)] = \lambda t & \text{Variancia} \end{cases}$$


Propriedades do Processo de Poisson

a) Tempo entre Eventos distribuído Exponencialmente



Seja  $G_k(t) = P[v_k \leq t] = 1 - P[v_k > t]$   
 $\Downarrow = P(N(t_{k-1}, t_{k-1} + t) = 0)$

$\Rightarrow G_k(t) = 1 - e^{-\lambda t}$  probabilidade de ~~ocorrer~~ ocorrer um evento até  $t$ .  
 ( $P_0(t)$  ←)  
 (função distribuição de probabilidade cumulativa)



(\*)  $\Rightarrow \lambda = \frac{E[N(t)]}{t}$  Intuitivamente podemos interpretar o parâmetro  $\lambda$  como sendo a taxa média


em que os eventos ocorrem por unidade de tempo.

No caso de eventos de falha,  $\lambda$  passa a representar taxa de falha.

# A Propriedade "Sem Memória"

10

Vamos supor que no instante  $T$  ocorreu o último evento observado. Quer-se calcular a probabilidade do próximo evento, a partir  $T$ , sabendo-se que ele não ocorreu até o tempo  $z$  depois de ocorrência em  $T$ .



$$P[V \leq z+t \mid V > z]$$

Da teoria de probabilidade:  $P(A \cap B) = P(A|B) \cdot P(B)$


$$\Rightarrow P(A|B) = \frac{P(A \cap B)}{P(B)}$$

Aplicando-se tem:

$$P[V \leq z+t \mid V > z] = \frac{P[V \leq z+t \text{ e } V > z]}{P[V > z]}$$

$$= \frac{P[z < V \leq z+t]}{P[V > z]}$$

$$= \frac{(1 - e^{-\lambda(z+t)}) - (1 - e^{-\lambda z})}{e^{-\lambda z}}$$



$$= \frac{e^{-\lambda z} - e^{-\lambda z} \cdot e^{-\lambda t}}{e^{-\lambda z}} \Rightarrow P[V \leq z+t \mid V > z] = 1 - e^{-\lambda t}$$

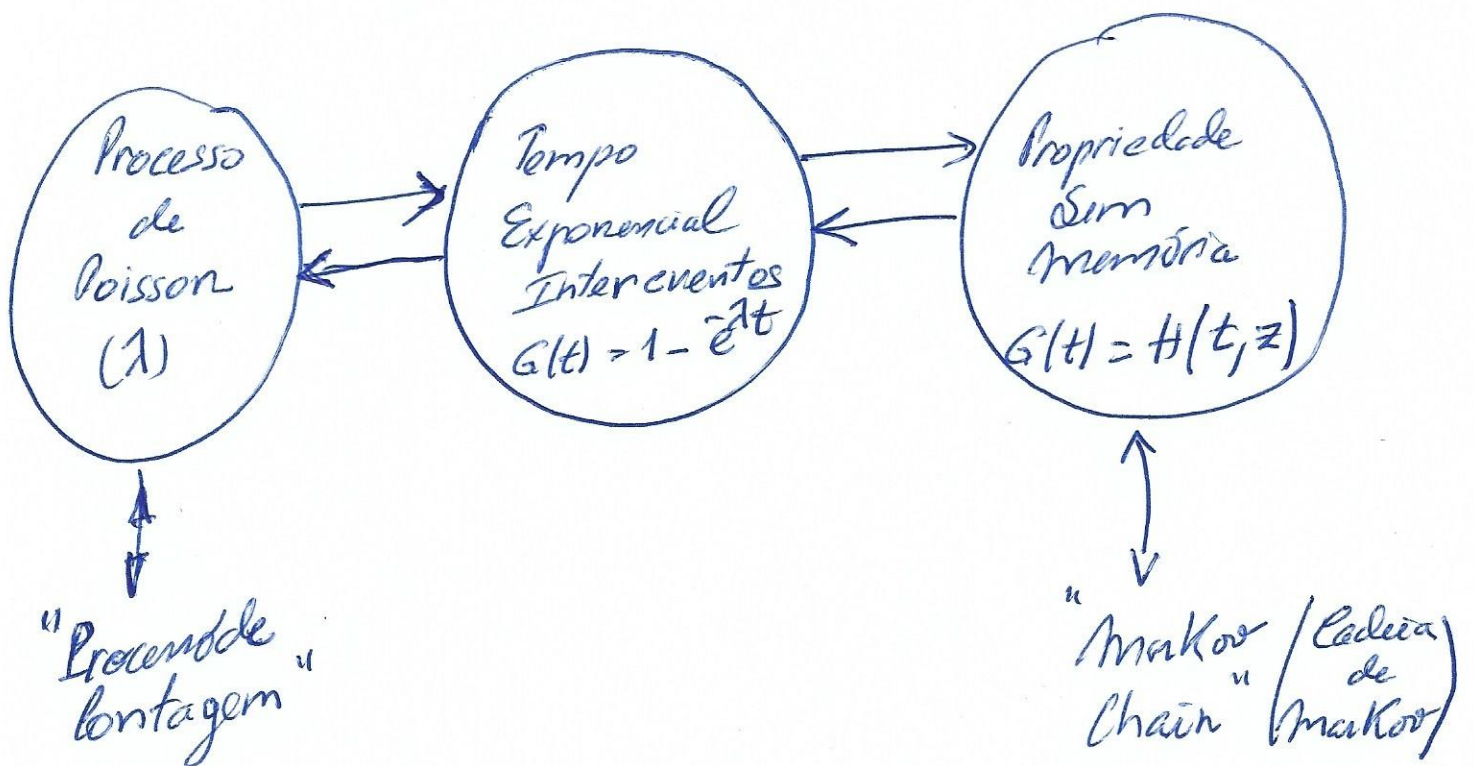
Ou seja, a probabilidade cumulativa da ocorrência do próximo evento até  $\underline{t}$  independe da idade ( $\underline{z}$ ) do ~~evento~~ <sup>próximo</sup> evento. (14)  
 Isso é o que se denomina de propriedade "sem memória" da distribuição exponencial.



Definição: Cada tempo de vida residual (clock), num Processo de Poisson, é caracterizado pela mesma distribuição exponencial do tempo de vida original:

$$H(t, z) = P[Y \leq t | Y > z] = \underline{G(t)} = 1 - e^{-\lambda t}$$

independentemente da idade do evento ( $\underline{z}$ ),



## Superposição de Processos de Poisson

(12)

Nós havíamos considerado no Sistema de Evento Discreto com apenas um único evento.

Vamos considerar agora este sistema de Evento Discreto com  $m$  eventos,  $m > 1$ , segunidade de

Assume-se que cada evento é modelado por um processo de Poisson com parâmetro  $\lambda_i$ ,  $i = 1, \dots, m$ .

Assume-se também que estes  $m$  processos de Poisson são mutuamente independentes.

Pergunta: o processo resultante continua sendo de Poisson?

$$P[Y^* \leq t] = 1 - P[Y^* > t]$$

$$P[Y^* \leq t] = 1 - \left[ \prod_{i=1}^m P[Y_i > t] \right]$$

$$P[Y^* \leq t] = 1 - \prod_{i=1}^m e^{-\lambda_i t}$$

$$P[Y^* \leq t] = 1 - e^{-\Lambda t}$$

onde  $\Lambda = \sum_{i=1}^m \lambda_i$

Ou seja, a superposição de  $m$  processos de Poisson independentes, com parâmetros  $\lambda_i$ ,  $i = 1, \dots, m$ , é também um processo de Poisson com parâmetro

$$\Lambda = \sum_{i=1}^m \lambda_i$$