

# Modelagem para Avaliação de Desempenho e Confiabilidade

Paulo Maciel

Centro de Informática

## - Interpretações do Tempo -

A noção de tempo pode ser representada de diversas maneiras nos sistemas computacionais.

- **Tempo Lógico** é definido a partir de relações de precedência entre eventos permitindo estabelecer ordens causais entre conjunto de eventos.
- **Tempo Físico** é um tempo métrico que permite representar quantitativamente a distância entre eventos e estabelecer ordens totais entre eventos.
- **Tempo Contínuo** segue a natureza uniforme e contínua do tempo físico e é isomorfo ao conjunto dos reais.
- **Tempo Discreto** é uma simplificação do tempo contínuo onde a relação de isomorfismo é com o conjunto dos naturais.
- **Tempo Global** fornece uma única referência temporal para todos os componentes do sistema.
- **Tempo Local** é a noção em que cada componente do sistema tem sua própria referência temporal.

## Classificação da Técnicas de Avaliação de Desempenho



## Análise de Desempenho

- **Modelagem**
  - Determinística
    - Melhor e pior casos
  - Probabilística
    - Valores prováveis
  - Operacional
    - Informações observáveis
- **Simulação**
  - Análise exaustiva
- **Medição**
  - Medidas obtidas do sistema real
  - Protótipos

## Modelos Temporizados

- Com todos estes pontos de vistas, diversos modelos têm sido propostos na literatura para tratar (modelar e analisar) os sistemas sob o ponto de vista temporal.
- Dentre os modelos temporais, podemos ressaltar:
  - **Lógicas Temporais**: *Linear Time Temporal Logic, Causal Temporal Logic*
  - **Álgebras de Processos Temporais**: *Timed CSP*
  - **Autômatos Temporizados**
  - **Cadeias de Markov**
  - **Redes de Fila**
  - **Redes de Petri Temporizadas**: *Timed PN, Time PN, SPN, GSPN, DSPN*

## Modelos Temporizados

- **Modelagem para Análise de Desempenho**
  - Análise Operacional
  - Modelos para Simulação
  - Modelos Analíticos
    - Cadeias de Markov
      - Teoria das Filas
      - Redes de Petri Estocásticas
      - Álgebras de Processo Estocásticas

## Modelos Temporizados

- Algumas destas classes de modelos temporizados possibilitam a análise temporal dos sistemas seja sob o ponto de vista determinístico ou sob o ponto de vista probabilístico. Para modelagem e avaliação de sistemas críticos, são de particular interesse os modelos que possibilitem a representação de tempos físicos e não apenas o tempo lógico.
- Os modelos que possibilitam a especificação do tempo físico, podem representar os tempo de foras distintas, por exemplo:
  - por **Intervalos**
  - de forma **Determinística**
  - de forma **Probabilística**

## Modelagem para Análise de Desempenho


- **Algumas Medidas**
  - Tempo de resposta
  - *Throughput*
  - Utilização
  - Capacidade
  - Confiabilidade
  - Taxa de descarte

## Análise Operacional

- Informações observáveis
- Jeff Buzzen and Peter Denning

## Notação de Kendall

- **A/B/m/K**
  - **A** – distribuição do tempo entre chegadas.
  - **B** – distribuição do tempo de serviço.
  - **m** – número de servidores.
  - **K** = capacidade de armazenamento.



$A, B = \{M, D, G, E\}$   
 • M - Markovian,  
 • D - Determinística,  
 • G - General  
 • E - Erlangian

## Notação de Kendall

- **A/B/m/K**
  - **A** – distribuição do tempo entre chegadas.
  - **B** – distribuição do tempo de serviço.
  - **m** – número de servidores.
  - **K** = capacidade de armazenamento.

Exemplos:  
 M/M/1  
 M/M/1/K  
 M/G/2

• Muitas vezes quando K e m são ∞, estes termos são omitidos ou usa-se //

## Análise Operacional

- **Variáveis operacionais**
  - **T**: Período de observação
  - **K**: Número de recursos do sistema
  - **A<sub>i</sub>**: Número total de solicitações (ex.:chegadas) do recurso i no período T.
  - **A<sub>0</sub>**: Número total de solicitações (ex.:chegadas) ao sistema no período T.
  - **C<sub>i</sub>**: Número total de serviços finalizados pelo recurso i no período T.
  - **C<sub>0</sub>**: Número total de serviços finalizados pelo sistema no período T.
  - **B<sub>i</sub>**: Tempo de ocupação do recurso i no período T.

## Análise Operacional

- Métricas derivadas (*derived measures*)
  - $S_i$ : Tempo médio de serviço por finalização relativa ao recurso  $i$ ;  $S_i = B_i/C_i$
  - $U_i$ : Tempo médio de serviço por finalização relativa ao recurso  $i$ ;  $U_i = B_i/T$
  - $X_i$ : *throughput* (ex.: finalizações por unidade de tempo) do recurso  $i$ ;  $X_i = C_i/T$
  - $\lambda_i$ : taxa de chegada (ex.: chegadas por unidade de tempo) ao recurso  $i$ ;  $\lambda_i = A_i/T$
  - $X_0$ : *throughput* do sistema;  $X_0 = C_0/T$
  - $V_i$ : Número médio de visitas ao recurso  $i$  por solicitação;  $V_i = C_i/C_0$

## Análise Operacional

- Exemplo1
 

Suponha que ao se monitorar um processador por um período de 1 min, verificou-se que o recurso esteve ocupado por 36s. O número total de transações que chegaram ao sistema é 1800. O sistema também finalizou a execução de 1800 transações no mesmo período.

  1. Qual a taxa de chegada ao sistema ( $\lambda_0$ )?
  2. Qual é o *throughput* do sistema ( $X_0$ )?
  3. Qual é a utilização da CPU ( $U_{CPU}$ )?
  4. Qual é o tempo médio por transações finalizadas pelo sistema ( $S_0$ )?

## Análise Operacional

- Exemplo1
 

É importante salientar que o único recurso do sistema é a CPU, portanto as métricas associadas à CPU serão as mesmas associadas ao sistema.

Handwritten notes for Example 1:

$T = 1 \text{ min}$        $B_{CPU} = 36 \text{ s}$

$A_0 = 1800 \text{ transações}$

$C_0 = 1800 \text{ transações}$

$A_0 = A_1$        $S_0 = S_1 = S_{CPU}$

$C_0 = C_1$        $U_0 = U_1 = U_{CPU}$

$X_0 = X_1 = \frac{1800}{60} = 30 \text{ transações/s}$        $X_0 = X_1 = X_{CPU}$

$X_0 = X_1 = \frac{1800}{60} = 30 \text{ transações/s}$

## Análise Operacional

- Exemplo1
 

É importante salientar que o único recurso do sistema é a CPU, portanto as métricas associadas à CPU serão as mesmas associadas ao sistema.

Handwritten calculations for Example 1:

$U_0 = U_{CPU} = \frac{B_{CPU}}{T} = \frac{36 \text{ s}}{60 \text{ s}} = 0,6$

$S_0 = S_1 = \frac{B_{CPU}}{C_{CPU}} = \frac{36}{1800} = 0,02 \text{ s}$

## Análise Operacional

- Utilization Law
 
$$U_i = \frac{B_i}{T} = \frac{B_i}{T} \times \frac{C_i}{C_i} = \frac{B_i}{C_i} \times \frac{C_i}{T} = S_i \times X_i$$

Relacionamento da utilização de um dispositivo com o seu *throughput*.

## Análise Operacional

- Utilization Law
 
$$U_i = S_i \times X_i$$

Exemplo: Considere que 125 pacotes por segundo chegam a um roteador e que o roteador leva em média 2 milissegundos para tratar o pacote. Portanto:

$$U_i = 0,002 \times 125 = 25\%$$

## Análise Operacional

- Exemplo2

A banda passante de um *link* de comunicação é 56000 bps. Pacotes de 1500 bytes são transmitidos ao *link* a uma taxa de 3 pacotes por segundo

- Qual é a utilização do link?

## Análise Operacional

- Exemplo2

bandwidth: 56000 bps      Time to send 1 bit (T<sub>SB</sub>)

T<sub>SB</sub> = 1/bandwidth = 1/56000 = 1.7857e-5

(T<sub>SB</sub>) Time to send 1 byte = 8 x T<sub>SB</sub> = 1.4286e-4

Packet size = 1500 bytes

Time to send 1 packet (T<sub>P</sub>) = 1500 x T<sub>SB</sub> = 0.0026786

Arrival rate (λ) = 3 packets/s

U = T<sub>P</sub> × λ = 0,0026786 × 3 = 0.0080357

## Análise Operacional

- Forced Flow Law

$$X_i = \frac{C_i}{T} = \frac{C_i}{T} \times \frac{C_0}{C_0} = \frac{C_i}{C_0} \times \frac{C_0}{T} = V_i \times X_0$$

Uma maneira interessante de relacionar o throughput do sistema ao throughput dos recursos.

## Análise Operacional

- Forced Flow Law

$$X_i = V_i \times X_0$$

Exemplo: suponha que toda vez que executa uma transação faz-se 2 acessos a uma unidade de disco. Se 5,6 transações são finalizadas por segundo, portanto:

$$X_i = 2 \times 5,6 = 11,2 \text{ tps}$$

## Análise Operacional

- Service Demand Law

– *Service demand* de um recurso é o tempo médio total que uma transação passa em no recurso.

Da *Utilization Law*, tem-se:

$$U_i = X_i \times S_i$$

Da *Forced Flow Law*, tem-se:

$$X_i = V_i \times X_0$$

Portanto:

## Análise Operacional

- Service Demand Law

$$U_i = V_i \times X_0 \times S_i = D_i \times X_0$$

Portanto:

$$D_i = \frac{U_i}{X_0}$$

Observe que a utilização  $U_i$  do dispositivo  $i$  é diretamente proporcional à demanda  $D_i$  (*service demand*), portanto o dispositivo com mais alta demanda  $\max_i\{D_i\}$  tem a mais alta utilização e é o "gargalo" do sistema.

## Análise Operacional

U

Service Demand Law

$$X_i = \frac{C_i}{T}$$

$$\Rightarrow \frac{C_i}{X_i} = T$$

$$B_i = U_i \times T$$

$$U_i = X_i \times S_i$$

$$D_i = V_i \times S_i = \frac{C_i}{C_0} \times S_i = \frac{C_i}{C_0} \times \frac{U_i}{X_i} = \frac{C_i}{C_0} \times \frac{U_i}{\frac{C_i}{T}} = \frac{C_i}{C_0} \times \frac{U_i \times T}{C_i} = \frac{U_i \times T}{C_0} = \frac{B_i}{C_0}$$

And by rule,  $C_0 \times T = X_0$ , then  $\frac{C_0}{C_0} = \frac{U_i}{X_0}$

$$D_i = V_i \times S_i = \frac{B_i}{C_0} = \frac{U_i}{X_0}$$

## Análise Operacional

◀

Exemplo 3

Considere que um *Web Server* foi monitorado por **10 min** e que a CPU esteve ocupada por **90%**. O *log* do *Web Server* registrou **30.000** solicitações processadas. Qual é a CPU *Service Demand* ( $D_{CPU}$ ) relativa as solicitações ao *Web Server*?

$T = 10 \times 60s = 600s$   
 $X_0 = 30.000/600 = 50$  solicitações por segundo.  
 $D_{CPU} = U_{CPU}/X_0 = 0,9/50 = 0,018$  s/solicitação

## Análise Operacional

◀ OL

Exemplo 4

Suponha um departamento composto por cinco recursos (pessoas: R1, R2, R3 e R4). Esse departamento foi monitorado por um período de 6 horas. Verificou-se que R1 esteve ocupado por 4h25min, R2 por 4h5min, R3 por 5h15min e R4 por 3h56min. O número total de transações que chegaram ao departamento foram 96. O sistema também finalizou a execução de 96 transações no mesmo período. O número total de chegadas a cada recurso e as respectiva finalizações são  $A_1 = C_1 = 60$ ,  $A_2 = C_2 = 110$ ,  $A_3 = C_3 = 100$  e  $A_4 = C_4 = 55$ .

- Qual a taxa de chegada ao sistema ( $A_0$ )?
- Qual é o *throughput* do sistema ( $X_0$ )?
- Qual é a utilização de cada recurso ( $U_i$ )?
- Qual é o tempo médio por transações finalizadas por cada recurso do sistema ( $S_i$ )?
- Qual é o número médio de visitas por recurso ( $V_i$ )?
- Qual é o tempo médio de uma transação qualquer (não necessariamente a que visitou o recurso  $i$ ) no recurso  $i$  ( $D_i$ )?



## Análise Operacional

OL

Exemplo 4

$A_0 = 96$      $A_3 = 100$   
 $A_1 = 60$      $A_4 = 55$   
 $A_2 = 110$

$T_h = 6$

$C_0 = 96$      $C_4 = 55$   
 $C_1 = 60$   
 $C_2 = 110$   
 $C_3 = 100$

$T = 6 \times 60 = 360$  minutos

$B_1 = 4 \times 60 + 25$      $B_2 = 4 \times 60 + 5$   
 $B_3 = 5 \times 60 + 15$      $B_4 = 3 \times 60 + 56$

## Análise Operacional

OL

Exemplo 4

$U_1 = \frac{B_1}{T} = 0.736111$      $S_1 = \frac{B_1}{C_1} = 4.41667$   
 $U_2 = \frac{B_2}{T} = 0.680556$      $S_2 = \frac{B_2}{C_2} = 2.22727$   
 $U_3 = \frac{B_3}{T} = 0.875$      $S_3 = \frac{B_3}{C_3} = 3.15$   
 $U_4 = \frac{B_4}{T} = 0.655556$      $S_4 = \frac{B_4}{C_4} = 4.29091$

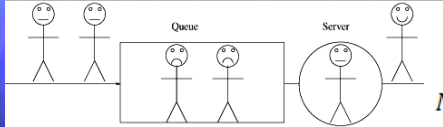
$V_1 = \frac{C_1}{C_0} = 0.625$      $V_2 = \frac{C_2}{C_0} = 1.14583$   
 $V_3 = \frac{C_3}{C_0} = 1.04167$      $V_4 = \frac{C_4}{C_0} = 0.572917$

$\lambda_0 = \frac{A_0}{T} = 0.266667$      $X_0 = \frac{C_0}{T} = 0.266667$

$D_1 = \frac{U_1}{X_0} = 2.7604$      $D_2 = \frac{U_2}{X_0} = 2.55208$      $D_3 = \frac{U_3}{X_0} = 3.28125$      $D_4 = \frac{U_4}{X_0} = 2.45833$

## Análise Operacional

■ Little's Law



$$N_i = \lambda_i \times R_i$$

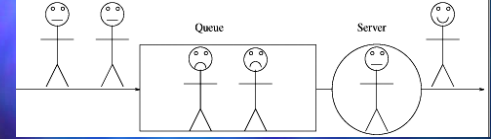
A lei de Little também é uma lei operacional, pois utiliza apenas informações mensuráveis. Adotamos essa lei para relacionar o tamanho da fila  $N_i$  de um dispositivo  $i$  ao tempo de resposta deste dispositivo  $R_i$ , em função do número de chegadas ( $A_i$ ) observadas no período ( $T$ ).  $\lambda_i = \frac{A_i}{T}$

$R$  – Response time  
 $W$  – Waiting time  
 $S$  – Service time

$N$  – Número de clientes no sistema  
 $X$  – Throughput

## Análise Operacional

■ Little's Law



Se o sistema é balanceado, a taxa de chegada é igual ao throughput, portanto:

$$N_i = \lambda_i \times R_i = X_i \times R_i$$

Quando não há fila e se considera apenas um servidor, a Little's law corresponde a Utilization law:  
e  $R=S$

## Análise Operacional

■ Exemplo 5

Um call center precisa redimensionar o número de atendentes em função de uma previsão de crescimento de demanda. Atualmente o call center recebe 20000 chamadas diárias. Espera-se que esse número chegue a 30000 chamadas diárias em 6 meses.

Os estudos mostram que 75% das chamadas diárias ocorrem num intervalo de 3 horas e a duração média das chamadas é de 5 minutos.

A empresa adota como meta um nível de utilização de 70% para os atendentes.

Quantos atendentes a empresa deve ter em 6 meses?

## Análise Operacional

■ Exemplo 5

O peak throughput nos próximos 6 meses será:

$$X = 75\% \times \frac{30000 \text{ chamadas}}{3 \text{ horas}} = 7500 \text{ chamadas por hora} = 125 \text{ chamadas por minuto}$$

Se a duração média das chamadas é de 5 minutos, então para se ter uma utilização de 70%, a frequência entre chamadas é:

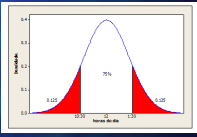
$$U = \lambda \times S$$

$$0,7 = \lambda \times 5$$

$\lambda = 0,14$  chamadas por minuto

$$C = \frac{1}{\lambda} = \frac{1}{0,14} = 7,142857 \text{ minutos}$$

(C- tempo entre chamadas)



## Análise Operacional

■ Exemplo 5

O número de atendentes necessários pode ser estimado através da Little's Law, considerando  $R = C$

$$N = X \times R$$

$$N = 125 \times 7,142857 = 892,8571 \text{ atendentes.}$$

## Análise Operacional

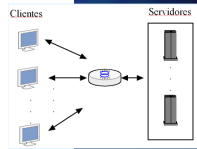
■ General Response Time Law

A Little's law pode ser aplicada a qualquer parte do sistema, basta apenas que o fluxo esteja "balanceado". Portanto, pode-se aplicá-la a parte central do sistema (servidores) e ao sistema periférico (clientes).

$N$  é o número total de transações no sistema,  $R$  é o response time, e  $X$  é o throughput do sistema.

$$N = X \times R$$

Dado que  $N_i$  é o número de transações em cada dispositivo,  $N$  pode ser calculado:

$$N = N_1 + N_2 + \dots + N_M$$


## Análise Operacional

**General Response Time Law**

Dividindo-se ambos os lados por  $X$ , tem-se:

$$R = V_1 \times R_1 + V_2 \times R_2 + \dots + V_M \times R_M$$

$$R = \sum_{i=1}^M V_i \times R_i$$

## Análise Operacional

**Interactive Response Time Law**

Em um sistema interativo, os clientes fazem uma solicitação a um sistema servidor, o sistema servidor processa essa solicitação e devolve um resultado ao cliente. Após um período de espera (*think time*)  $Z$ , o cliente faz uma nova solicitação. Se o *system response time* é  $R$ , o tempo total desse ciclo é  $R + Z$ .

## Análise Operacional

**Interactive Response Time Law**

Se considerarmos um período  $T$ , cada cliente gerará:

$$\frac{T}{R + Z} \text{ solicitações no período } T.$$

Se considerarmos  $N$  clientes, teremos:

$$\frac{N \times T}{R + Z} \text{ solicitações no período } T.$$

Portanto, o *throughput* do sistema é:

$$X = \frac{N \times T}{R + Z}$$

$$X = \frac{N}{R + Z} \quad \text{and} \quad R = \frac{N}{X} - Z$$

## Análise Operacional

**Bottleneck Analysis**

Observe que a utilização  $U_i$  do dispositivo  $i$  é diretamente proporcional à demanda  $D_i$  (*service demand*), portanto o dispositivo com mais alta demanda  $\max_i \{D_i\}$  tem a mais alta utilização e é o "gargalo" do sistema.

$$X_0 \leq \frac{1}{D_{max}}$$

Sistema com  $N$  componentes em paralelo

Todas atividades começam no mesmo momento, mas a tarefa "maior" só finaliza quando todas as atividades finalizarem.

## Análise Operacional

**Bottleneck Analysis**

Considere agora outra situação limite: um sistema composto por  $N$  componentes em série e que o clientes tenham um *think time*  $Z$ .

Portanto,  $R = D$

E como sabemos que

$$X = \frac{N}{R + Z}$$

Temos:

$$X = \frac{N}{D + Z}$$

Portanto:

$$X \leq \frac{N}{D}$$

Consequentemente:

$$X = \min \left\{ \frac{1}{D_{max}}, \frac{N}{D} \right\}$$

## Análise Operacional

**Bottleneck Analysis**

Portanto,  $R = D$

E como sabemos que

$$X = \frac{N}{R + Z}$$

Temos:

$$X = \frac{N}{D + Z}$$

Portanto:

$$X \leq \frac{N}{D}$$

Consequentemente:

$$X = \min \left\{ \frac{1}{D_{max}}, \frac{N}{D} \right\}$$

## Análise Operacional

### Bottleneck Analysis

Problema:

Considere um servidor de email que é composto de um processador e duas unidades de disco (**disco 1** e **disco 2**). Cada transação a esse sistema, faz sete acessos ao **disco 1** e oito acessos **disco 2**, assim como dezesseis acessos ao processador. O *service time* do **disco 1** e **disco 2** é 20 e 30 ms, respectivamente. O *service time* do processador é 10 ms.

- Qual é o dispositivo "gargalo" do sistema?
- Qual é o tempo de *response time* do sistema?
- Qual é a utilização máxima da configuração atual desse sistema?
- Qual é o *throughput* máximo desse sistema?

## Análise Operacional

### Leis Operacionais (*derived measures*)

Utilization Law:  $U_i = X_i \times S_i = \lambda_i \times S_i$

Forced Flow Law:  $X_i = V_i \times X_0$

Service Demand Law:  $D_i = V_i \times S_i = U_i / X_0$

Little's Law:  $N = X \times R$

Interactive Response Time Law:  $R = \frac{N}{X} - Z$



## Modelo de Probabilidade

- Espaço amostral ( $\Omega$ ):** um conjunto de todos os possíveis "estados" observáveis (eventos elementar) de um fenômeno aleatório.
- Conjuto de eventos ( $\mathcal{S}$ ):** um conjunto de todos sub-conjuntos de  $\Omega$ .
- Probabilidade dos eventos ( $P$ ):** a probabilidade de ocorrência de um evento observável.

PM é a tupla:  $PM = (\Omega, \mathcal{S}, P)$ .

## Modelo de Probabilidade

Considere um experimento que consiste no acionamento do condicionador de ar, com dois possíveis resultados mutuamente exclusivos:  $S$  – *Sucesso*  $F$  – *Defeito (Failure)*

Portanto:

$$\Omega = \{S, F\}$$

$$\mathcal{S} = \{\{S\}, \{F\}, \{S, F\}, \phi\}$$

$$P(\{S\}) = p$$

$$P(\{F\}) = 1 - p$$

$$P(\{S, F\}) = 1$$

$$P(\phi) = 0$$

## Espaço Amostral

- A probabilidade de um evento representa a **chance** de que o resultado de um experimento resulte na **ocorrência do evento**.
- Assume-se que os experimentos são aleatório.
- Um experimento aleatório pode ter muito resultados. Cada resultado é um **ponto amostral (evento elementar)** e tem uma probabilidade.
- Um espaço amostral  $\Omega$  : um **conjunto de todos os possíveis "estados" observáveis** (eventos elementares) de um fenômeno aleatório.
  - Finito** (ex.: execução das ações associadas a opções de um **if**; dois resultados)
  - Countável** (ex.: número de vezes que "corpo" de um laço **while** é executado; O espaço amostral por ser finito ou contável infinito.)
  - Contínuo** (ex.: tempo de falha de componente)



## Eventos

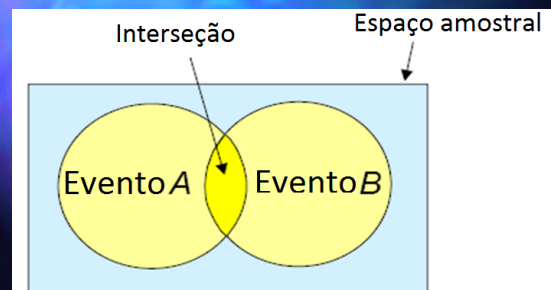
- Um evento  $E$  é uma coleção de zero ou mais pontos amostrais (evento elementar) de  $\Omega$ . Um evento  $E$  é um sub-conjunto de  $\Omega$ .

$$E \subseteq \Omega$$

- $\Omega$  é o evento universal e o conjunto vazio é apresentado por  $\emptyset$

$$\begin{aligned} \Omega \in \mathcal{S} \\ A \in \mathcal{S} \Rightarrow \bar{A} \in \mathcal{S} \\ A, B \in \mathcal{S} \Rightarrow A \cup B, A \cap B \in \mathcal{S} \end{aligned}$$

## Diagrama de Venn União e Inteseção de Eventos



## Probabilidade

- Probabilidade é um valor numérico que representa a chance de que um evento ocorra.
- Os valores de uma Probabilidade estão entre 0 e 1.
- A probabilidade próxima de 0 representa grande improbabilidade de ocorrência do evento.
- A probabilidade próxima de 1 denota que a ocorrência do evento é quase certa.

## Eventos e suas Probabilidades

- Um evento é uma coleção de pontos amostrais. A probabilidade de um evento é a soma das probabilidades do pontos amostrais.
- Se pudermos identificar todos os pontos amostrais (eventos elementares) de um experimento e associar probabilidades a eles, podemos calcular a probabilidade de qualquer evento.

## Terminologia e Definições

### $\Omega$ e $\mathcal{E}$

- $\bar{E}_1 = \Omega - E_1$  - Complemento
- $E_3 = E_1 \cap E_2$ , interseção
- $E_4 = E_1 \cup E_2$ , União

Para n eventos  $\bigcup_{i=1}^n E_i = E_1 \cup E_2 \dots \cup E_n$

$$\bigcap_{i=1}^n E_i = E_1 \cap E_2 \dots \cap E_n$$

## Álgebra

- Eventos mutuamente exclusivos (disjuntos)
  - Dois eventos são mutuamente exclusivos sse

$$A \cap B = \emptyset$$



Um conjunto de  $n$  eventos ( $n > 2$ ) é mutuamente exclusivo sse

$$A_i \cap A_j = \begin{cases} A_i, & i = j \\ \emptyset & \text{otherwise} \end{cases}$$

## Axiomas

- Espaço de Probabilidade:  $OS = (\Omega, S, P)$ 
  - Para qualquer evento  $A$ , a probabilidade de  $A$  é:
    1.  $1 \geq P(A) \geq 0, \forall A \in S$
    2.  $P(\Omega) = 1$
    3. Se  $A$  e  $B$  são disjuntos, então:
 
$$P(A \cup B) = P(A) + P(B)$$

## Consequências

- Espaço de Probabilidade:  $OS = (\Omega, S, P)$ 
  - Sejam  $A$  e  $\bar{A}$  (seu complemento) eventos

$$P(\emptyset) = 0$$

$$P(\bar{A}) = 1 - P(A)$$

- 4. Se  $A$  e  $B$  são dois eventos que **não** são mutuamente exclusivos:

$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$

## Consequências: Eventos não mutuamente exclusivos

$$P\left(\bigcup_{i=1}^n A_i\right) = \sum_{i=1}^n P(A_i) - \sum_{i>j} P(A_i, A_j) + \sum_{i>j>k} P(A_i, A_j, A_k) - \dots + (-1)^{n+1} P(A_1, A_2, \dots, A_n)$$

Princípio da inclusão e exclusão (acima)  
Um método muito melhor é:

- 5. Soma dos Produtos Disjuntos (SDP):

$$P\left(\bigcup_{i=1}^n A_i\right) = P(A_1) + P(\bar{A}_1 \cap A_2) + P(\bar{A}_1 \cap \bar{A}_2 \cap A_3) + \dots + P(\bar{A}_1 \cap \bar{A}_2 \cap \dots \cap \bar{A}_{n-1} \cap A_n)$$

## Exemplo

Fenômeno aleatório:

Dois resultados de um teste de condição em um *if statement*:

**if**  $B$  then  $T$ ;  
**else**  $E$ ;

$\Omega = \{T, E\}$ ; Conjunto de resultados

$S = \{\emptyset, \{E\}, \{T\}, \{T, E\}\}$ ; Conjunto de todos os eventos

$P = \{0, 1/2, 1/2, 1\}$ ; probabilidade atribuídas

## Variáveis Aleatórias Resumo

- **Variáveis Aleatórias** é uma função que confere um número real a cada resultado (do espaço amostral) de um experimento aleatório.
- **Variável Aleatória** é uma função que reflete o resultado de um experimento aleatório.  $X: \omega \rightarrow \mathfrak{R}$ .  
 $\{\omega : \omega \in \Omega, X(\omega) \leq x\} \in \mathfrak{R}$ .

## Variáveis Aleatórias Resumo

- **Variáveis aleatórias contínuas** assumem quaisquer valores no intervalo  $[a, b]$ , onde  $-\infty \leq a \leq b \leq +\infty$
- **Variáveis aleatórias discretas** assumem apenas valores discretos.

## Variáveis Aleatórias Resumo

- Propriedade Markoviana
  - Ausência de Memória
- Variáveis Aleatórias com Propriedade Markoviana
  - Variável Aleatória Geométrica
  - Variável Aleatória Exponencial

## Variáveis Aleatórias Resumo

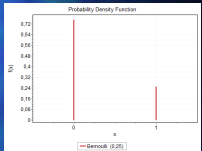
- **Probability mass function (pmf)** – Seja  $\Omega$  um espaço amostral discreto.  $p(x)$ , que denota uma pmf de uma variável aleatória  $X$ , é definida por  $p(x) = P[X=x]$ , onde  $x$  assume valores de  $\Omega$ .

## Variáveis Aleatórias Resumo

- **Função de Distribuição de Probabilidade Acumulativa (CDF)** de uma variável aleatória  $X$ , denotada por  $F(X)$ , é definida por  $F(x) = P[X \leq x] \forall x \in \mathfrak{R}$
- $F(x)$  é uma função monotônica não-decrescente tal que  $0 \leq F(x) \leq 1$ , onde  $F(-\infty) = 0$  e  $F(\infty) = 1$
- $F(x) = \sum_{y \leq x} p(y) \Rightarrow F(\infty) = \sum_{y} p(y) = 1$

## Variáveis Aleatórias Resumo

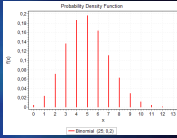
- Discreta
  - Bernoulli
    - Considere um experimento aleatório com dois resultados possíveis ( $X=0, X=1$ ).
    - pmf (probability mass function) de  $X$  é dada por:  $P(X=0) = 1-p$  e  $P(X=1) = p$ ,  $0 \leq p \leq 1$



## Variáveis Aleatórias Resumo

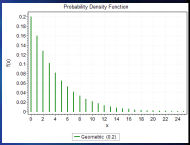
- Discreta
  - Binomial
    - Considere um experimento aleatório independentes com dois resultados possíveis (0 e 1 por exemplo) realizados  $n$  vezes. A variável aleatória é o número de vezes que se tem resultado 1.
    - pmf de  $X$  é dada por:  $P(X=k) = \binom{n}{k} p^k (1-p)^{n-k}$   
 $k=0, 1, \dots, n$ .

*Ver slides de medição*



## Variáveis Aleatórias Resumo

- Discreta
  - Geométrica
    - Considere um experimento aleatório independentes com dois resultados possíveis (0 e 1 por exemplo) realizados  $n$  vezes. A variável aleatória é o número de vezes que se realiza o experimento para se ter o primeiro resultado 1.
    - pmf de  $X$  é dada por:  $P(X=k) = p (1-p)^{n-k}$   
 $k=0, 1, \dots$



## Variáveis Aleatórias Resumo

- Discreta
  - Valor Médio ou Valor Esperado
    - $\bar{X} = E[X] = \sum_{\forall k} k \cdot P(X=k)$
  - Uma função de uma variável aleatória ( $Y=f(X)$ ) é uma variável aleatória com Valor Esperado
    - $E[f(X)] = \sum_{\forall k} f(k) \cdot P(X=k)$

## Variáveis Aleatórias Resumo

- Discreta
  - **n-ésimo momento** (em torno da origem) de uma variável aleatória  $X$  é o valor esperado da **n-ésima potência** de  $X$ 
    - $\bar{X}^n = E[X^n] = \sum_{\forall k} k^n \cdot P(X=k)$
  - **n-ésimo momento central** de uma variável aleatória  $X$  é o valor esperado da n-ésima potência da diferença entre  $X$  e o valor esperado de  $X$  ( $E(X) = \bar{X}$ )
    - $\overline{(X-\bar{X})^n} = \sum_{\forall k} (k-\bar{X})^n \cdot P(X=k)$

## Variáveis Aleatórias Resumo

- Discreta
  - O primeiro momento é o valor esperado.
  - O primeiro momento central é 0
  - O segundo momento central (variância)
    - $\text{var}(X) = \sigma^2 = \overline{(X-\bar{X})^2} = \sum_{\forall k} (k-\bar{X})^2 \cdot P(X=k)$
  - O coeficiente de variação é a normalização do desvio padrão
    - $c_x = \sigma / \bar{X}$

## Variáveis Aleatórias Resumo

- Função Geratriz de Momentos
  - Dada uma variável aleatória  $X$ , a função geratriz de momento  $M_X(t)$  de sua distribuição de probabilidade é o valor esperado de  $e^{tX}$ .
    - $M_X(t) = E[e^{tX}]$
    - $= \sum_i e^{tx_i} p_X(x_i)$        $X$  discreta.
    - $= \int_{-\infty}^{+\infty} e^{tx} f_X(x) dx$        $X$  contínua.

## Variáveis Aleatórias Resumo

- Função Geratriz de Momentos
  - $e^{tX} = 1 + tX + t^2 X^2 / 2! + \dots + t^r X^r / r! + \dots$

$$f(t) = e^{(-a t)}$$

$$= 1 - a t + \frac{a^2 t^2}{2} - \frac{a^3 t^3}{6} + \frac{a^4 t^4}{24} - \frac{a^5 t^5}{120} + \frac{a^6 t^6}{720} - \frac{a^7 t^7}{5040} + \frac{a^8 t^8}{40320} - \frac{a^9 t^9}{362880} + \dots$$

Para  $a=2$ , tem-se:

$$= 1 - 2t + 2t^2 - \frac{4t^3}{3} + \frac{2t^4}{3} - \frac{4t^5}{15} + \frac{4t^6}{45} - \frac{8t^7}{315} + \frac{2t^8}{315} - \frac{4t^9}{2835} + \dots$$

- Tomando a esperança:
- $E[e^{tX}] = 1 + E[X] t + E[X^2] t^2 / 2! + E[X^r] t^r / r! + \dots$

## Variáveis Aleatórias Resumo

- Procedimento para obtenção dos momentos
  - Determine  $M_X(t)$  analiticamente para uma distribuição particular
  - Ache  $E[X^r] = d^r/dt^r M_X(t)|_{t=0}$

## Variáveis Aleatórias Resumo

- Discreta
  - Bernoulli
    - Parâmetro:  $p$ ;
    - Valor Esperado =  $p$ ,
    - Variância =  $p(1-p)$ ,
    - Coeficiente de variação =  $(1-p)/p$
    - Função geratriz de momentos
 
$$M_{X_j}(t) = q + pe^t$$

## Variáveis Aleatórias Resumo

- Discreta
  - Binomial
    - Parâmetros:  $n, p$ ;
    - Valor Esperado =  $np$ ,
    - Variância =  $np(1-p)$ ,
    - Coeficiente de variação =  $(1-p)/np$
    - Função geratriz de momentos
 
$$M_{X_j}(t) = (q + pe^t)^n$$

## Variáveis Aleatórias Resumo

- Discreta
  - Geométrica
    - Parâmetro:  $p$ ;
    - Valor Esperado =  $1/p$ ,
    - Variância =  $(1-p)/p^2$ ,
    - Coeficiente de variação =  $(1-p)$
    - Função geratriz de momentos
 
$$M_{X_j}(t) = pe^t / (1 - qe^t)$$

## Variáveis Aleatórias Resumo

- Contínua
  - Uma variável aleatória que pode assumir qualquer valor no intervalo  $[a, b]$ , onde  $-\infty \leq a, b \leq +\infty$ , é denominada Variável Aleatória Contínua.
  - *Cumulative Distribution Function (CDF)*

$$F_X(x) = P(X \leq x)$$
    - Se  $x < y$  então:  $F_X(x) < F_X(y)$
    - $P(x < X \leq y) = F_X(y) - F_X(x)$

## Variáveis Aleatórias Resumo

- Contínua
  - *Cumulative Distribution Function (CDF)*

$$F_X(x) = P(X \leq x)$$
    - Se  $x < y$  então:  $F_X(x) < F_X(y)$
    - $P(x < X \leq y) = F_X(y) - F_X(x)$
  - *Probability density function (pdf)*
    - $f_X(x) = dF_X(x) / dx$
    - $f_X(x) \geq 0$
    - $\int_{-\infty}^{+\infty} f_X(x) dx = 1$

## Variáveis Aleatórias Resumo

- Contínua
  - *Probability density function (pdf)*
    - $f_X(x) = dF_X(x) / dx$
    - Como  $F_X(x)$  não é decrescente, então  $f_X(x) \geq 0$
    - $\int_{-\infty}^{+\infty} f_X(x) dx = 1$
    - $P(x_1 \leq X \leq x_2) = \int_{x_1}^{x_2} f_X(x) dx$
    - $P(X=x) = \int_x^x f_X(x) dx = 0$

## Variáveis Aleatórias Resumo

- Contínua
  - Valor Médio ou Valor Esperado
    - $\bar{X} = E[X] = \int_{-\infty}^{+\infty} x \cdot f_X(x) dx$
  - Uma função de uma variável aleatória ( $g(X)$ ) é uma variável aleatória com Valor Esperado
    - $E[g(X)] = \int_{-\infty}^{+\infty} g(x) \cdot f_X(x) dx$

## Variáveis Aleatórias Resumo

- Contínua
  - n-ésimo momento
    - $\bar{X}^n = E[X^n] = \int_{-\infty}^{+\infty} x^n \cdot f_X(x) dx$
  - n-ésimo momento central
    - $\overline{(X-\bar{X})^n} = \int_{-\infty}^{+\infty} (x-\bar{X})^n \cdot f_X(x) dx$

## Variáveis Aleatórias Resumo

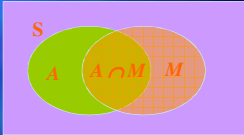
- Contínua
  - O segundo momento central (variância)
    - $\sigma^2 = \overline{(X-\bar{X})^2} = \int_{-\infty}^{+\infty} (x-\bar{X})^2 \cdot f_X(x) dx$
  - O coeficiente de variação e a normalização do desvio padrão
    - $c_x = \sigma / \bar{X}$

## Variáveis Aleatórias Resumo

- Propriedade Markoviana
  - Ausência de Memória
- Variáveis Aleatórias com Propriedade Markoviana
  - Variável Aleatória Geométrica
  - Variável Aleatória Exponencial

## Probabilidade Condicional

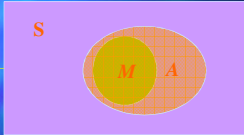
- Seja  $A$  um evento arbitrário em um espaço amostral  $S$ . A probabilidade de que ocorra um evento  $A$  uma vez que  $M$  tenha ocorrido é denotado por  $P(A/M)$  que é definido por:
  - Caso  $M \subset A$  então  $P(A/M)=1$
  - Caso  $A \subset M$  então  $P(A/M) = \frac{P(A)}{P(M)}$



$$P(A/M) = \frac{P(A \cap M)}{P(M)}$$

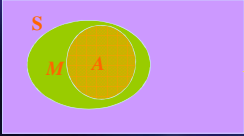
## Probabilidade Condicional

- Caso  $M \subset A$  então  $P(A/M)=1$



$$P(A/M) = \frac{P(A)}{P(M)}$$

- Caso  $A \subset M$  então  $P(A/M) = \frac{P(A)}{P(M)}$



$$P(A/M) = \frac{P(A)}{P(M)}$$

## Distribuição Exponencial

- Arises commonly in reliability & queuing theory.
- A non-negative continuous random variable.
- It exhibits memoryless property (continuous counterpart of geometric distribution).
- Related to (discrete) Poisson distribution

85

## Distribuição Exponencial

- Esse modelo é comumente usado:
  - Tempo de chegada entre pacotes IP (ou entre chamadas de voz)
  - Tempo de serviço de um servidor de arquivo, web, db
  - Tempo de falhas, tempo de reparo, de reboot etc.
- Se a distribuição exponencial não é apropriada, uma outra deve ser adequadamente escolhida.

86

## Distribuição Exponencial


- Por exemplo, distribuição Weibull é comumente usada para representar tempos de falha.
- A distribuição Lognormal é muito usada para representar tempos de reparo.
- *Markov modulated Poisson processes* são muito usados para representar chegada de pacotes IP que não obedece tempo entre chegada exponencialmente distribuído.

87

## Distribuição Exponencial

### Variável Aleatória Exponencial

#### fdp exponencial




$$f_X(t) = \lambda e^{-\lambda t}, 0 \leq t < \infty$$


$$CDF(t) = \begin{cases} 1 - e^{-\lambda t}, & 0 \leq t < \infty \\ 0, & \text{caso contrário} \end{cases}$$

- Valor Esperado  $E(X) = 1/\lambda$
- Variância:  $var(X) = 1/\lambda^2$
- Propriedade: Não possui memória


## Distribuição Exponencial



## Distribuição Exponencial



$$P\{X>t\} = e^{-\lambda t}$$



Probabilidade Condicional

## Distribuição Exponencial

**Um exemplo:**  
 $P\{X > 80\} = e^{-0,01 \times 80} = 0,449329$

- $P\{X > (80+80) \mid X > 80\} = \frac{P\{X > (80+80) \wedge X > 80\}}{P\{X > 80\}}$
- $P\{X > (80+80) \mid X > 80\} = \frac{P\{X > 160\}}{P\{X > 80\}}$

$P\{X > (80+80) \mid X > 80\} = \frac{e^{-0,01 \times (80+80)}}{e^{-0,01 \times 80}} = e^{-0,01 \times 80} = 0,449329$

$P\{X > 160 \mid X > 80\} = P\{X > 80\} = 0,449329$

80	160
80	160

## Distribuição Exponencial

### Variável Aleatória Exponencial

$P\{X > t\} = e^{-\lambda t}$

- $P\{X > t+u \mid X > t\} = \frac{P\{X > t+u \wedge X > t\}}{P\{X > t\}}$
- $P\{X > t+u \mid X > t\} = \frac{P\{X > t+u\}}{P\{X > t\}}$

$P\{X > t+u \mid X > t\} = \frac{e^{-\lambda(t+u)}}{e^{-\lambda t}} = e^{-\lambda u} = P\{X > u\}$

t	t+u
t	t+u

Probabilidade Condicional

## Distribuição Exponencial

- Contínua
- Exponencial
  - Parâmetro:  $\lambda$ ,
  - Valor Esperado:  $1/\lambda$ ,
  - Variância:  $1/\lambda^2$ ,
  - Coeficiente de variação: 1
  - Função geratriz de momentos  
 $M_X(t) = (1-t/\lambda)^{-1}$

## Distribuição Exponencial

Lembre-se destas fórmulas

- Matematicamente (CDF e pdf são):

$$CDF: F(x) = \begin{cases} 1 - e^{-\lambda x}, & \text{if } 0 \leq x < \infty \\ 0, & \text{otherwise} \end{cases}$$

where  $\lambda$  is a parameter and the base of natural logarithm,  $e = 2.7182818284$

$$pdf: f(x) = \begin{cases} \lambda e^{-\lambda x}, & \text{if } x > 0 \\ 0, & \text{otherwise} \end{cases}$$

- Também

$$P(X > t) = \int_t^{\infty} f(x) dx = e^{-\lambda t}$$

$$P(a < X \leq b) = \int_a^b f(x) dx = F(b) - F(a) = e^{-\lambda a} - e^{-\lambda b}$$

94

## Distribuição Exponencial

$$R(t) = e^{-\lambda t}, \quad t \geq 0,$$

$$F(t) = 1 - e^{-\lambda t}, \quad t \geq 0,$$

$$h(t) = \lambda,$$

$$E[T] = MTTF = \frac{1}{\lambda},$$

$$Var[T] = \sigma^2 = \frac{1}{\lambda^2}.$$

95

## Distribuição Exponencial

$$X_i(t) = \begin{cases} 0, & \text{if } S \text{ has failed} \\ 1, & \text{if } S \text{ is operational} \end{cases}$$

States of  $X_i(t)$

The memoryless property can be demonstrated with conditional reliability:

$$R(x | t) = \Pr(T > x + t \mid T > t) = \frac{\Pr(T > x + t)}{\Pr(T > t)}$$

$$= \frac{e^{-\lambda(t+x)}}{e^{-\lambda t}} = e^{-\lambda x} = R(x), \quad x \geq 0.$$

96



## Distribuição Hiperexponencial

$F_X(x) = \sum_{j=1}^k q_j (1 - e^{-\mu_j x}), \quad x \geq 0.$

pdf:  $f_X(x) = \sum_{j=1}^k q_j \mu_j e^{-\mu_j x}, \quad x > 0,$

mean:  $\bar{X} = \sum_{j=1}^k \frac{q_j}{\mu_j} = \frac{1}{\mu}, \quad x > 0,$

variance:  $\text{var}(X) = 2 \sum_{j=1}^k \frac{q_j}{\mu_j^2} - \frac{1}{\mu^2},$

$c_X = \sqrt{2\mu^2 \sum_{j=1}^k \frac{q_j}{\mu_j^2} - 1} \geq 1$

97

## Distribuição Hiperexponencial

Hiperexponencial

- Parâmetros:  $k, \mu_j, q_j;$
- Valor Esperado:  $E(X) = \bar{X} = \sum_{j=1}^k q_j / \mu_j$
- Coefficiente de variação:  $\text{sqrt}(2 \times (1/\bar{X})^2 \times \sum_{j=1}^k q_j / \mu_j^2 - 1) \geq 1$
- Variância:  $2 \sum_{j=1}^k q_j / \mu_j^2 - \bar{X}^2$

$$F_X(x) = \sum_{j=1}^k q_j (1 - e^{-\mu_j x}), \quad t \geq 0$$

$$f_X(x) = \sum_{j=1}^k q_j \mu_j e^{-\mu_j x}, \quad t \geq 0$$

## Distribuição Hiperexponencial

Hiperexponencial

- Uma distribuição desconhecida de  $\bar{X}$  e  $c \geq 1$  pode ser aproximada por uma
  - Parâmetros:  $k=2, \mu_1, \mu_2, q_1, q_2$
  - $\mu_1 = 1/\bar{X} \cdot (1 - \text{sqrt}(q_2/q_1 \cdot (c^2 - 1)/2))^{-1}$
  - $\mu_2 = 1/\bar{X} \cdot (1 + \text{sqrt}(q_1/q_2 \cdot (c^2 - 1)/2))^{-1}$
  - $q_1 + q_2 = 1, q_1, q_2 \geq 0, \mu_1, \mu_2 > 0$

98

## Distribuição Hiperexponencial

$\lambda = 0.01$

$f_X(x) := \lambda x e^{-\lambda x}$

$m = \int_0^\infty t \times f_X(t) dt = 100$

$sd = \sqrt{\left( \int_0^\infty t^2 \times f_X(t) dt - m^2 \right)} = 100$

Exponencial

$\lambda h = 0.004$

$q = 0.4$

$f_X(x) := q \times \lambda h x e^{-\lambda h x}$

$m h = \int_0^\infty t \times f_X(t) dt = 100$

$sd h = \sqrt{\left( \int_0^\infty t^2 \times f_X(t) dt - m h^2 \right)} = 200$

$m h = \frac{q}{\lambda h}$

$sd h = \sqrt{\frac{2q}{\lambda h^2} - \frac{q^2}{\lambda h^2}}$

Hiperexponencial

## Distribuição Erlang

Erlang-k

$F_X(x) = 1 - e^{-k\mu x} \sum_{j=0}^{k-1} (k\mu x)^j / j!, \quad t \geq 0$

$f_X(x) = [(k\mu(k\mu x)^{k-1}) / (k-1)!] e^{-k\mu x}, \quad t \geq 0, k = 1, 2, \dots$

- Parâmetros:  $k, \mu;$
- Valor Esperado:  $k/\mu$
- Variância:  $k/\mu^2$
- Coefficiente de variação:  $1/\text{sqrt}(k) \leq 1$
- Função geratriz de momentos:  $M_X(t) = (1 - t/\lambda)^{-k}$

99

## Distribuição Erlang

$F_X(x) = 1 - e^{-k\mu x} \sum_{j=0}^{k-1} \frac{(k\mu x)^j}{j!}, \quad x \geq 0, k = 1, 2, \dots$

pdf:  $f_X(x) = \frac{k\mu(k\mu x)^{k-1}}{(k-1)!} e^{-k\mu x}, \quad x > 0, k = 1, 2, \dots$

mean:  $\bar{X} = \frac{1}{\mu}$

variance:  $\text{var}(X) = \frac{1}{k\mu^2}$

coefficient of variation:  $c_X = \frac{1}{\sqrt{k}} \leq 1.$

$k = \left\lceil \frac{1}{c_X^2} \right\rceil$

$\mu = \frac{1}{c_X^2 k \bar{X}}$

102


## Distribuição Erlang

### Erlang-K

- Uma distribuição desconhecida de  $\bar{X}$  e  $c \leq 1$  pode ser aproximada por uma

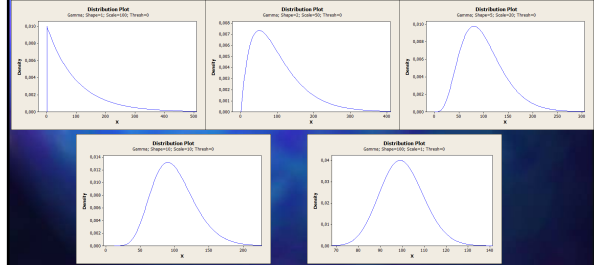
$$k = \lceil 1/c^2 \rceil$$

$$\mu = 1/(c^2 k \bar{X})$$



## Distribuição Erlang

- Erlang-K (*Shape = fase, Scale = valor da fase*)



## Distribuição Hipo-exponencial

$$\text{pdf: } f_X(x) = \sum_{i=1}^k a_i \mu_i e^{-\mu_i x}, \quad x > 0,$$

$$\text{with } a_i = \prod_{j=1, j \neq i}^k \frac{\mu_j}{\mu_j - \mu_i}, \quad 1 \leq i \leq k,$$

$$\text{mean: } \bar{X} = \sum_{i=1}^k \frac{1}{\mu_i},$$

$$\text{coefficient of variation: } c_X = \left( 1 + 2 \frac{\sum_{i=1}^k \left( \mu_i \sum_{j=i+1}^k \mu_j \right)}{\sum_{i=1}^k \mu_i^2} \right)^{-\frac{1}{2}}.$$

105

## Distribuição Hipo-exponencial

A distribuição **hipo-exponencial** é uma generalização da distribuição de **Erlang** quando se admite fases com taxas diferentes.

Para uma variável aleatória com distribuição hipo-exponencial com duas fases  $\mu_1 \neq \mu_2$ , tem-se:

- $F_X(x) = 1 - [\mu_2 / (\mu_2 - \mu_1)] e^{-\mu_1 t} + [\mu_1 / (\mu_2 - \mu_1)] e^{-\mu_2 t}$ ,  $t \geq 0$
- $f_X(x) = [(\mu_1 \mu_2) / (\mu_1 - \mu_2)] (e^{-\mu_2 t} - e^{-\mu_1 t})$ ,  $t \geq 0$

## Distribuição Hipo-exponencial

### Hipo-exponencial

- Parâmetros:**  $\mu_{1r}, \mu_{2r}$
- Valor Esperado:**  $1/\mu_1 + 1/\mu_2$
- Variância:**  $1/\mu_1^2 + 1/\mu_2^2$
- Coefficiente de variação:**  $[\text{sqrt}(\mu_1^2 + \mu_2^2) / (\mu_1 + \mu_2)] < 1$

## Distribuição Hipo-exponencial

### Contínua

- Uma distribuição desconhecida de  $\bar{X}$  como valor esperado e  $0.5 \leq c^2 < 1$  pode ser aproximada por uma Hipo-exponencial

$$\mu_1 = (2/\bar{X}) \{1 + \text{sqrt}[1 + 2(c^2 - 1)]\}^{-1}$$

$$\mu_2 = (2/\bar{X}) \{1 - \text{sqrt}[1 + 2(c^2 - 1)]\}^{-1}$$

## Distribuição Hipo-exponencial

### Contínua


Para uma variável aleatória com distribuição hipo-exponencial com  $k$  fases e taxas  $\mu_1, \mu_2, \dots, \mu_k$  tem-se:

$$f_X(x) = \sum_{j=1}^k a_j \mu_j e^{-\mu_j x}, \quad t \geq 0$$


$$a_j = \prod_{i=1, i \neq j}^k \left[ \frac{\mu_i}{\mu_j - \mu_i} \right], \quad 1 \leq i \leq k$$

$$\text{Valor Médio} = \sum_{j=1}^k 1/\mu_j$$


## Variáveis Aleatórias Resumo



## Variáveis Aleatórias Resumo



## Distribuição Cox




The model consists of  $k$  phases in series with exponentially distributed times and rates  $\mu_1, \mu_2, \dots, \mu_k$ . After phase  $j$ , another phase  $j+1$  follows with probability  $a_j$  and with probability  $b_j = 1 - a_j$  the total time span is completed.

## Distribuição Cox

Case 1:  $c_X \leq 1$

$$\mu_j = \mu \quad j = 1, \dots, k,$$

$$a_j = 1 \quad j = 2, \dots, k-1$$



$$\bar{X} = \frac{b_1 + k(1 - b_1)}{\mu}$$

$$\text{var}(X) = \frac{k + b_1(k-1)(b_1(1-k) + k-2)}{\mu^2}$$

$$c_X^2 = \frac{k + b_1(k-1)(b_1(1-k) + k-2)}{[b_1 + k(1 - b_1)]^2}$$

$$k = \left\lceil \frac{1}{c_X^2} \right\rceil$$

$$b_1 = \frac{2kc_X^2 + (k-2) - \sqrt{k^2 + 4 - 4kc_X^2}}{2(c_X^2 + 1)(k-1)}$$

$$\mu = \frac{k - b_1 \cdot (k-1)}{\bar{X}}$$

## Distribuição Cox

Case 2:  $c_X > 1$

$$\bar{X} = \frac{1}{\mu_1} + \frac{a}{\mu_2}$$


$$\text{var}(X) = \frac{\mu_2^2 + a\mu_1^2(2-a)}{\mu_1^2 \cdot \mu_2^2}$$

$$c_X^2 = \frac{\mu_2^2 + a\mu_1^2(2-a)}{(\mu_2 + a\mu_1)^2}$$

$$\mu_1 = \frac{2}{\bar{X}}$$

$$a = \frac{1}{2c_X^2}$$

$$\mu_2 = \frac{1}{\bar{X}c_X^2}$$



## Variáveis Aleatórias Resumo

- Uma função de uma variável aleatória ( $Y=f(X)$ ) é uma variável aleatória com Valor Esperado
  - $E[f(X)] = \sum_{x,k} f(k) \cdot P(X=k)$
- Uma função de uma variável aleatória ( $Y=g(X)$ ) é uma variável aleatória com Valor Esperado
  - $E[g(X)] = \int_{-\infty}^{+\infty} g(x) \cdot f_X(x) dx$

Função densidade de Probabilidade de X

## Variáveis Aleatórias Resumo

- Se  $f(X) = X$ 
  - Valor Esperado
    - $E[f(X)] = E(X) = \mu$
  - Variância
    - $Var[f(X)] = E\{[f(X) - E(f(X))]^2\}$
    - $= E[(X - E(X))^2] = E(X^2) - [E(X)]^2$  (Variância de X)
    - $= Var(X) = \sigma^2$

## Variáveis Aleatórias Resumo

- Se  $f(X) = aX + b$ 
  - Valor Esperado
    - $E[f(X)] = aE(X) + b$
  - Variância
    - $Var[f(X)] = a^2 Var(X)$
    - Prova:  $Var(aX + b) = a^2 Var(X)$ .

Por definição  $Var(aX + b) = E[(aX + b) - E(aX + b)]^2$

$$= E[aX + b - (aE(X) + b)]^2$$

$$= E[a(X - E(X))]^2$$

$$= E[a^2(X - E(X))^2] = a^2 E(X - E(X))^2 = a^2 Var(X)$$

## Variáveis Aleatórias Resumo

- Se  $f(X) = b$ 
  - Valor Esperado
    - $E(b) = b$
  - Variância
    - $Var(b) = 0$

## Variáveis Aleatórias Resumo

- Exemplo

Suponha que X seja uma variável aleatória tal que  $E(X) = 3$  e  $Var(X) = 5$ . Além disto, seja  $Y(X) = 2X - 7$ .

Portanto:

$$E(Y(X)) = [2 \times E(X)] - 7 = -1$$

$$Var(Y(X)) = 2^2 \times Var(X) = 20$$

## Variáveis Aleatórias Resumo

Quando  $Y=f(X)$  é muito complicada, os cálculos de  $E(f(X))$  e  $Var(f(X))$  podem ser difíceis. Pode-se obter aproximações de  $E(f(X))$  e  $Var(f(X))$  expandindo-se  $Y=f(X)$  (série de Taylor) até três termos (para a média).

$$Y = f(E(X)) + [(X - E(X)) \times f'(E(X))] + [(1/2) \times (X - E(X))^2 \times f''(E(X))] + R$$

Resto da expansão

### Variáveis Aleatórias Resumo

- $Y = f(E(X)) + (X - E(X)) f'(E(X)) + [(1/2) \times (X - E(X))^2 \times f''(E(X))] + R$ . Portanto:  $R \approx 0$
- $E(f(X)) = E[f(E(X))] + E[(X - E(X)) f'(E(X))] + E[(1/2) \times (X - E(X))^2 \times f''(E(X))] + E(R) = E[f(E(X))] + E[(1/2) \times E[f''(E(X))] \times E[(X - E(X))^2]] + E(R) = f(E(X)) + (1/2) \times f''(E(X)) \times \text{Var}(X) + E(R) \cong f(E(X)) + (1/2) \times f''(E(X)) \times \text{Var}(X) \Rightarrow E(f(X)) \cong f(E(X)) + [(1/2) \times f''(E(X)) \times \text{Var}(X)]$

### Variáveis Aleatórias Resumo

**Aproximação** (série de Taylor) do **Valor Esperado** e **Variância** para **variáveis aleatórias** que são **função de variáveis aleatórias**.

- Seja  $X$  uma variável aleatória com  $E[X]$  e  $\text{Var}(X)$ . Suponha que  $Y=f(X)$ . Portanto:
- $E[Y] \cong f(E[X]) + (f''(E[X]) \times \text{Var}(X))/2$
- $\text{Var}(Y) \cong (f'(E[X]))^2 \times \text{Var}(X)$

### Variáveis Aleatórias Resumo

**Aproximação** (série de Taylor) do **Valor Esperado** e **Variância** para **variáveis aleatórias** que são **função de variáveis aleatórias**.

- Suponha uma variável aleatória  $t$ , onde  $E[t]=20s$  e  $\text{Var}(t)=5s$ . Considere uma função  $v(t)=dt^{-1} = 10^3 t^{-1}$
- $v'(t) = -10^3 t^{-2}$  e  $v''(t)=2 \times 10^3 t^{-3}$
- $E[v(t)] = v(E[t]) + (v''(E[t]) \times \text{Var}(t))/2$
- $E[v(t)] = v(20) + (v''(20) \times 5)/2 = 50,625 \text{ m/s}$
- $\text{Var}(v(t))=[v'(E[t])]^2 \times \text{Var}(t)$
- $\text{Var}(v(t))=[v'(20)]^2 \times 5 = 12,5 \text{ m/s}$

### Variáveis Aleatórias Multidimensionais Resumo

- **Múltiplas Variáveis Aleatórias**
  - Seja  $\Omega$  o espaço amostral associado a um experimento  $E$ .  $e \in E$  é um resultado do experimento  $E$ .
  - Seja  $X_1, X_2, \dots, X_k$  variáveis aleatórias que associam um número real  $X_1(e), X_2(e), \dots, X_k(e)$  a cada resultado  $e$ .
  - $[X_1, X_2, \dots, X_k]$  é chamado de **vetor aleatório k-dimensional**.

### Variáveis Aleatórias Multidimensionais Resumo

- **Múltiplas Variáveis Aleatórias**


The diagram illustrates the relationship between a sample space  $\Omega$  and a specific event  $E$ . Within  $E$ , a point  $e$  is shown. Three lines radiate from  $e$  to three separate ellipses representing the ranges of random variables  $X_1, X_2,$  and  $X_k$ . Each ellipse contains a point representing the value of that variable at  $e$ , labeled as  $x_1 = X_1(e), x_2 = X_2(e),$  and  $x_k = X_k(e)$  respectively. The ranges are denoted as  $\mathfrak{R}_{X_1}, \mathfrak{R}_{X_2},$  and  $\mathfrak{R}_{X_k}$ .

### Variáveis Aleatórias Multidimensionais Resumo

- **Variáveis Aleatórias Bidimensionais** (vetores aleatórios bidimensionais)
  - Se os valores possíveis de  $[X_1, X_2]$  formam um conjunto finito ou infinito enumerável,  $[X_1, X_2]$  é um **vetor aleatório discreto bidimensional**.
  - Se os valores possíveis de  $[X_1, X_2]$  formam um conjunto não enumerável do plano euclidiano,  $[X_1, X_2]$  é um **vetor aleatório contínuo bidimensional**.

## Variáveis Aleatórias Multidimensionais Resumo

- Variáveis Aleatórias Bidimensionais (vetores aleatórios bidimensionais)



## Variáveis Aleatórias Multidimensionais Resumo

- Probabilidade Bivariada

– Caso Discreto: a cada resultado  $[x_1, x_2]$  de  $[X_1, X_2]$  associamos um número  $p(x_1, x_2) = P(X_1 = x_1, X_2 = x_2)$ , onde  $p(x_1, x_2) \geq 0, \forall x_1, x_2$

$$\sum_{x_1} \sum_{x_2} p(x_1, x_2) = 1$$

- Distribuição de probabilidade de  $[X_1, X_2]$


$$([x_1, x_2], p(x_1, x_2)), \forall x_1, x_2$$

## Variáveis Aleatórias Multidimensionais Resumo

- Probabilidade Bivariada

– Caso Contínuo: Se  $[X_1, X_2]$  é um vetor aleatório contínuo,  $f(x_1, x_2) \geq 0, \forall (x_1, x_2) \in \mathbb{R}_{x_1 \times x_2}$  é a função de densidade conjunta.

$$\iint_{\mathbb{R}_{x_1 \times x_2}} f(x_1, x_2) dx_1 dx_2 = 1$$



## Variáveis Aleatórias Multidimensionais Resumo

- Probabilidade Marginal

– Caso Discreto : a distribuição marginal de  $X_1$  é

$$p_1(x_1) = \sum_{x_2} p(x_1, x_2), \forall x_1$$

A distribuição marginal de  $X_2$  é

$$p_2(x_2) = \sum_{x_1} p(x_1, x_2), \forall x_2$$

## Variáveis Aleatórias Multidimensionais Resumo




- Probabilidade Marginal: Caso Discreto

$\begin{matrix} x_1 \\ x_2 \end{matrix}$	1	2	3	4	5	$p_2(x_2)$
1	1/30	1/30	2/30	3/30	1/30	8/30
2	1/30	1/30	3/30	4/30		9/30
3	1/30	2/30	3/30			6/30
4	1/30	3/30				4/30
5	3/30					3/30
$p_1(x_1)$	7/30	7/30	8/30	7/30	1/30	$\sum p(x) = 1$

## Variáveis Aleatórias Multidimensionais Resumo

- Probabilidade Marginal: Caso Discreto



## Variáveis Aleatórias Multidimensionais Resumo

- Probabilidade Marginal
  - Caso Contínuo : a distribuição marginal de  $X_1$  é

$$f_1(x_1) = \int_{-\infty}^{+\infty} f(x_1, x_2) dx_2$$

A distribuição marginal de  $X_2$  é

$$f_2(x_2) = \int_{-\infty}^{+\infty} f(x_1, x_2) dx_1$$

## Variáveis Aleatórias Multidimensionais Resumo

- Linearidade do Valor Esperado
  - Sejam X e Y duas variáveis aleatórias e seja

$$Z = X + Y.$$

$$\text{Portanto } E[Z] = E[X + Y] = E[X] + E[Y]$$

## Variáveis Aleatórias Multidimensionais Resumo

- Linearidade do Valor Esperado

Considerando X, Y e Z variáveis aleatórias discretas, temos que :

$$E[Z] = E[X + Y] =$$

$$\sum_x \sum_y (x + y) p(x, y) = \text{(Ver exemplo da página seguinte)}$$

$$\sum_x x p_x(x) + \sum_y y p_y(y) =$$

$$E[X] + E[Y]$$

## Variáveis Aleatórias Multidimensionais Resumo

Ver  
Tabela  
Original

- Linearidade do Valor Esperado

x2,x1	0	1	2	3	4	p2(x2)	x2 p(x2)
0	0,0333	0,0333	0,0667	0,1000	0,0333	0,2667	0
1	0,0333	0,0333	0,1000	0,1333		0,3000	0,3
2	0,0333	0,0667	0,1000			0,2000	0,4
3	0,0333	0,1000				0,1333	0,4
4	0,1000					0,1000	0,4
p1(x1)	0,2333	0,2333	0,2667	0,2333	0,0333	2,0000	1,5000
1,6000	0	0,233333	0,533333	0,7	0,133333	x1 p(x1)	E[X2]
E[X1]						E[X1+X2]=	3,1000

## Variáveis Aleatórias Multidimensionais Resumo

- Linearidade do Valor Esperado

Considerando X, Y e Z variáveis aleatórias contínuas, temos que :

$$E[Z] = E[X + Y] =$$

$$\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} (x + y) f(x, y) dx dy =$$

$$\int_{-\infty}^{+\infty} x \int_{-\infty}^{+\infty} f(x, y) dy dx + \int_{-\infty}^{+\infty} y \int_{-\infty}^{+\infty} f(x, y) dx dy =$$

$$\int_{-\infty}^{+\infty} x f_x(x) dx + \int_{-\infty}^{+\infty} y f_y(y) dy =$$

$$E[X] + E[Y]$$

## Variáveis Aleatórias Multidimensionais Resumo

- Linearidade do Valor Esperado

De forma mais geral, considere Z, Y e X variáveis aleatórias contínuas, onde

$$Z(X, Y) = aX + bY, \text{ e } a \text{ e } b \text{ são constantes.}$$

$$E(aX + bY) = aE(X) + bE(Y)$$

## Variáveis Aleatórias Multidimensionais Resumo

### Linearidade do Valor Esperado

Prova:

$$\begin{aligned}
 E(aX + bY) &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (ax + by)f(x, y) dx dy \\
 &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} [axf(x, y) + byf(x, y)] dx dy \\
 &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} axf(x, y) dx dy + \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} byf(x, y) dx dy \\
 &= a \int_{-\infty}^{\infty} x \left[ \int_{-\infty}^{\infty} f(x, y) dy \right] dx + b \int_{-\infty}^{\infty} y \left[ \int_{-\infty}^{\infty} f(x, y) dx \right] dy \\
 &= a \int_{-\infty}^{\infty} x f_X(x) dx + b \int_{-\infty}^{\infty} y f_Y(y) dy \\
 &= aE(X) + bE(Y).
 \end{aligned}$$

## Variáveis Aleatórias Multidimensionais Resumo

### Linearidade do Valor Esperado

Este resultado pode ser generalizado de forma que:  
para  $a_1, \dots, a_n$  constantes e qualquer variável aleatória multivariada  $(X_1, \dots, X_n)$

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

Se  $E(X_i)$  não divergem.

## Variáveis Aleatórias Multidimensionais Resumo



### Linearidade do Valor Esperado

Sejam X e Y duas variáveis aleatórias independentes e seja

$$Z = XY.$$

$$\text{Portanto } E[Z] = E[XY] = E[X]E[Y]$$

Prova:  $E[XY] = \sum_i \sum_j x_i y_j p(x_i, y_j) =$   
 $\sum_i \sum_j x_i y_j p_X(x_i) p_Y(y_j) =$  (dado que são independentes)  
 $\sum_i x_i y_j p_X(x_i) \sum_j y_j p_Y(y_j) =$   
 $E[X]E[Y]$

## Variáveis Aleatórias Multidimensionais Resumo

### Soma de Variâncias

Sejam X e Y duas variáveis aleatórias e seja

$$Z = X + Y$$

$$\text{Portanto } \text{Var}[Z] = \text{Var}[X + Y]$$

$$= \text{Var}[X] + \text{Var}[Y] + 2 \times \text{Cov}(X, Y)$$

## Variáveis Aleatórias Multidimensionais Resumo

### Soma de Variâncias

$$\begin{aligned}
 \text{Var}[X + Y] &= E[(X + Y) - E[X + Y]]^2 \\
 &= E[(X + Y) - E[X] - E[Y]]^2 \\
 &= E[(X - E[X]) + (Y - E[Y])]^2 \\
 &= E[(X - E[X])^2 + (Y - E[Y])^2 + 2(X - E[X])(Y - E[Y])] \\
 &= E[(X - E[X])^2] + E[(Y - E[Y])^2] + E[2(X - E[X])(Y - E[Y])] \\
 &= E[(X - E[X])^2] + E[(Y - E[Y])^2] + 2E[(X - E[X])(Y - E[Y])] \\
 &= \text{Var}[X] + \text{Var}[Y] + 2\text{Cov}(X, Y)
 \end{aligned}$$

## Variáveis Aleatórias Multidimensionais Resumo

### Soma de Variâncias

$$\begin{aligned}
 \text{Cov}(X, Y) &= E[(X - E[X])(Y - E[Y])] \\
 &= E(XY - YE[X] - XE[Y] + E[X]E[Y])
 \end{aligned}$$

Devido à propriedade de linearidade do valor esperado, temos:

$$\begin{aligned}
 &= E[XY] - E[YE[X]] - E[XE[Y]] + E[X]E[Y] \\
 &= E[XY] - E[Y]E[X] - E[X]E[Y] + E[X]E[Y] \\
 &= E[XY] - E[X]E[Y] \quad (\text{Se X e Y forem independentes}) \\
 &= 0 \quad (\text{devido à linearidade})
 \end{aligned}$$

Ver também o slide 101



## Variáveis Aleatórias Multidimensionais Resumo

### Soma de Variâncias

$$\text{Var} (X + Y) = \text{Var} [X] + \text{Var} [Y] + 2\text{Cov} (X, Y)$$

Dado que se X e Y forem independentes, tem-se  $\text{Cov}(X,Y)=0$ .  
Portanto:

$$\text{Var} (X + Y) = \text{Var} [X] + \text{Var} [Y]$$

## Variáveis Aleatórias Multidimensionais Resumo

### Soma de Variâncias

$$\text{Var} (X + Y) = \text{Var} [X] + \text{Var} [Y]$$

O teorema acima pode generalizado para n variáveis aleatória  
Mutuamente independentes  $X_1, \dots, X_n$  com constantes  $a_1, \dots, a_n$

$$\text{Var} \left[ \sum_{i=1}^n a_i X_i \right] = \sum_{i=1}^n a_i^2 \text{Var} [X_i]$$

Ver também  
o slide 77

## Variáveis Aleatórias Multidimensionais Resumo

### Soma de Variâncias

$$\text{Var} (X - Y) = \text{Var} [X] + \text{Var} [Y]$$

$$\text{Dado que } \text{Var} \left[ \sum_{i=1}^n a_i X_i \right] = \sum_{i=1}^n a_i^2 \text{Var} [X_i]$$

$$\text{Pois } a_x = 1 \text{ e } a_y = -1$$

$$\text{Var} [X - Y] = a_x^2 \text{Var} [X] + a_y^2 \text{Var} [Y]$$

$$= (1)^2 \text{Var} [X] + (-1)^2 \text{Var} [Y]$$

$$= \text{Var} [X] + \text{Var} [Y]$$

## Processos Estocásticos

Processo Estocástico é definido por um conjunto de variáveis aleatórias,  
 $\{X(t) : t \in T\}$ , onde  $X(t)$  é uma variável aleatória para cada  $t \in T$ .  
 $t$  é denominado parâmetro e cada valor de  $X(t)$  são estados.

Processo Estocástico Markoviano é um processo estocástico onde as variáveis aleatórias não dependem da história passada.

### Tipos de Processos Estocásticos

- Processos de espaço de estados e tempo discretos (*Discret Time Markov Chain - DTMC*)
- Processos de espaço de estados contínuo e tempo discreto
- Processos de espaço de estados discreto e tempo contínuo (*Continuous Time Markov Chain - CTMC*)
- Processos de espaço de estados e tempo contínuos

## Processos Estocásticos

### Classificação de Estados:

- Estado Alcançável (*reachable*): um estado  $s_j$  é um alcançável de um estado  $s_i$  se  $p_{ij} > 0$ .
- Um sub-conjunto de estado  $S$  é definido com fechado (*closed*) se  $\forall s_i \in S, p_{ij} = 0, \forall s_j \notin S$ .
- Um estado é absorvente se ele é o único membro de conjunto fechado de estados  $S$ .
- Um conjunto fechado de estado  $S$  é dito irredutível se  $p_{ij} > 0 \forall s_i, s_j \in S$  (todo estado  $s_j$  é alcançável de qualquer estado  $s_i$ ).

## Processos Estocásticos

Processo Estocástico Markoviano é um processo estocástico onde as variáveis aleatórias não dependem da história passada.

### Observam-se dois aspectos associados a ausência de memória:

- 1 Todo estado passado é irrelevante.
- 2 O tempo que o processo passa em um estado é irrelevante.

Processo Estocástico Semi-Markoviano é uma extensão de um processo Markoviano onde a restrição 2 é relaxada.

## Continuous Time Markov Chain

### Equação de Chapman-Kolmogorov

Considere uma CTMC (não-homogênea)  $\{X(t); t \geq 0\}$  com espaço de estado  $\{0, 1, 2, \dots\}$ . Vamos usar  $i, j$  e  $k$  para denotar estados típicos e  $s, u$  e  $t$  para denotar parâmetro de tempo.

Para  $0 \leq s \leq t$ , considere  $p_{ij}(s, t) = P\{X(t)=j \mid X(s)=i\}$ . Pode ser representada na forma matricial por  $H(s, t) = [p_{ij}(s, t)]$

A equação de Chapman-Kolmogorov

$$p_{ij}(s, t) = \sum_k p_{ik}(s, u) p_{kj}(u, t); 0 \leq s \leq u \leq t$$

Na forma matricial, temos:

$$H(s, t) = H(s, u) H(u, t); 0 \leq s \leq u \leq t$$

## Continuous Time Markov Chain

### Equação de Chapman-Kolmogorov

$$H(s, t) = H(s, u) H(u, t); 0 \leq s \leq u \leq t$$

Substituindo  $u$  por  $t$  e  $t$  por  $t+h$ , então:

$$H(s, t+h) = H(s, t) H(t, t+h)$$

Subtraindo-se ambos os lados por  $H(s, t)$ , temos:

$$H(s, t+h) - H(s, t) = H(s, t) [H(t, t+h) - I]$$

Dividindo-se por  $h$  e aplicando-se o limite  $h \rightarrow 0$ , tem-se:

$$\lim_{h \rightarrow 0} \frac{H(s, t+h) - H(s, t)}{h} = H(s, t) \left[ \lim_{h \rightarrow 0} \frac{H(t, t+h) - I}{h} \right]$$

Levando à equação diferencial parcial  $\frac{\partial H(s, t)}{\partial t} = H(s, t)Q(t)$

## Continuous Time Markov Chain

### Equação de Chapman-Kolmogorov

$$\frac{\partial H(s, t)}{\partial t} = H(s, t)Q(t) \quad (\text{forward Kolmogorov eq.})$$

$$\text{Onde } Q(t) = \lim_{h \rightarrow 0} \frac{H(t, t+h) - I}{h}$$

Os elementos de  $Q(t)$  são dados por

$$q_{ii}(t) = \lim_{h \rightarrow 0} \frac{p_{ii}(t, t+h) - 1}{h}$$

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

## Continuous Time Markov Chain

### Equação de Chapman-Kolmogorov

$$1 - p_{ii}(t, t+h) = -hq_{ii}(t) + o(h)$$

$$p_{ij}(t, t+h) = hq_{ij}(t) + o(h)$$

Onde  $o(h)$  é uma função de converge para zero mais rápido que  $h$ .

Dado que  $\sum_j p_{ij}(s, t) = 1, \forall i$ , portanto:

$$\sum_j q_{ij}(s, t) = 0, \forall i$$

Ou seja, a soma de elementos de uma linha de  $Q$  é zero.

## Continuous Time Markov Chain

### Equação de Chapman-Kolmogorov

$$\frac{\partial H(s, t)}{\partial t} = H(s, t)Q(t) \quad (\text{forward Kolmogorov eq.})$$

Para cadeias homogêneas, tem-se:

$$Q(t) = Q \quad \text{e} \quad H(s, t) = \Pi(t)$$

## Continuous Time Markov Chain

### Steady State Analysis

$$\frac{d\Pi(t)}{dt} = \Pi(t)Q \quad (\text{homogêneas})$$

Em estado estacionário ( $t \rightarrow \infty$ ), pode ser que

$\lim_{t \rightarrow \infty} \Pi(t) = \Pi(t)$  exista.

Caso exista, então  $\sum_{s_i \in S} \pi_{s_i} = 1$

$$\frac{d\Pi(t)}{dt} = 0, \text{ então } \Pi Q = 0$$

## Continuos Time Markov Chain

- Soluções para *Steady-States*

$$\Pi Q = 0$$

$$\sum_{s_i \in S} \pi_{s_i} = 1$$

Onde  $\pi_{s_i}$  fornece a *steady-state probability* de um sistema estar no estado  $s_i$

- Soluções Transientes

$$\frac{d\Pi(t)}{dt} = \Pi(t)Q$$

Onde  $\pi(t)_{s_i}$  é probabilidade de se estar na estado  $s_i$  no instante  $t$

## Continuos Time Markov Chain

- Uma CTMC é dita irredutível se  $p_{ij} > 0 \quad \forall s_i, s_j \in S$  (todo estado  $s_j$  é alcançável de qualquer estado  $s_i$ ).
- Uma CTMC finita, irredutível e homogênea é dita ergódica (*ergodic*) se o vetor de probabilidade estacionária (*steady-state probability vector*)  $\Pi$  existe.

## Continuos Time Markov Chain

- Soluções para *Steady-States*

$$\Pi Q = 0 \quad \sum_{s_i \in S} \pi_{s_i} = 1$$

- Métodos diretos**

- Eliminação de Gauss
- Decomposição LU
- Método de Grassmann


- Métodos Iterativos**

- Power Method
- Método de Jacobi
- Método de Gauss-Seidel


## Continuos Time Markov Chain

Exemplo

- $\lambda = 0,2$ ,
- $\mu = 0,4$




$$Q = \begin{pmatrix} -\lambda & \lambda & 0 & 0 \\ \mu & -(\lambda + \mu) & \lambda & 0 \\ 0 & \mu & -(\lambda + \mu) & \lambda \\ 0 & 0 & \mu & -\mu \end{pmatrix}$$



$$\pi(0) = 0.5333, \quad \pi(1) = 0.2667, \quad \pi(2) = 0.1333, \quad \pi(3) = 0.0667$$

## Continuos Time Markov Chain

- $\lambda = 0,2$ ,
- $\mu = 0,4$



- Utilização:  $\rho = 1 - \pi(0) = 0.4667$



- Throughput  $tp = \pi(1) \times \mu + \pi(2) \times \mu + \pi(3) \times \mu$   
 $tp = 0.2667 \times 0.4 + 0.1333 \times 0.4 + 0.0667 \times 0.4$   
 $tp = 0.18668$

## Continuos Time Markov Chain

Sharpe  
(chamado via Desktop)

Exemplo

- Tamanho do buffer=11
- $\lambda$
- $\mu$
- FCFS



State probability of State  $i=\{0,1,\dots,11\}$   
 State\_Prob(i):

## Continuous Time Markov Chain

- Métricas - Métricas de interesse pode ser calculadas através da soma ponderada das probabilidades de estado.
  - Reward rate em estado estacionário

$$E[Z] = \sum_i r_i \pi_i$$

- Reward rate instantânea

$$E[Z(t)] = \sum_i r_i \pi_i(t)$$

\*Ver métricas nas páginas 91,92,93 e 94 de QN and MC [Bolch et al.]

## Continuous Time Markov Chain

- Métricas – a probabilidade acumulada de que se esteja num estado é dada por:

$$L(t) = \int_0^t \pi(u) du$$

Portanto,  $L_i(t)$  tempo médio (esperado) que se permanece no estado  $i$  durante o intervalo  $[0,t)$ .

\*Ver métricas nas páginas 91,92,93 e 94 de QN and MC [Bolch et al.]

## Continuous Time Markov Chain

Exemplo

$\lambda = 20 \text{ tps}$ ,  $COV = 1$   
 $\mu = 40 \text{ tps}$ ,  $COV_{TS} = 1$   
 $E[ST] = \frac{1}{\mu} = \frac{1}{40} = 0.025$

State probability of 0: 5.16129024e-001  
 State probability of 1: 2.58064518e-001  
 State probability of 2: 1.29032262e-001  
 State probability of 3: 6.45161314e-002  
 State probability of 4: 3.22580656e-002

Utilization= 0.483871

The CTMV (M/M/M/1/K=4)



## Continuous Time Markov Chain

Exemplo

$\lambda = 20 \text{ tps}$ ,  $COV = 1$   
 $E[TBA] = 0.05s$   
 $\mu = 40 \text{ tps}$ ,  $COV_{ST} = 0.5$   
 $E[ST] = 0.025s$

Considering:

$$\gamma = \left( \frac{E[ST]}{\sigma_{ST}} \right)^2$$

$$\mu_E = \left( \frac{\gamma}{E[ST]} \right)$$


$$\gamma = \left( \frac{0.025}{0.0125} \right)^2 = 4$$

$$\mu_E = \frac{4}{0.025} = 160$$

Therefore, the ST is represented by a Erlang( $\gamma=4, \mu_E=160$ ).

## Continuous Time Markov Chain


The CTMC (M/E/1/K=4)



$\pi_0 = 5.06605425 \times 10^{-1}$     $\pi_5 = 2.42068626 \times 10^{-2}$     $\pi_{10} = 1.04731260 \times 10^{-3}$     $\pi_{15} = 3.95578062 \times 10^{-5}$   
 $\pi_1 = 9.01648794 \times 10^{-2}$     $\pi_6 = 3.04223846 \times 10^{-2}$     $\pi_{11} = 1.31936488 \times 10^{-2}$     $\pi_{16} = 5.95104472 \times 10^{-3}$   
 $\pi_2 = 8.01465589 \times 10^{-2}$     $\pi_7 = 3.49578293 \times 10^{-2}$     $\pi_{12} = 1.59621117 \times 10^{-2}$   
 $\pi_3 = 7.12413851 \times 10^{-2}$     $\pi_8 = 3.81098122 \times 10^{-2}$     $\pi_{13} = 9.97433581 \times 10^{-3}$   
 $\pi_4 = 6.33256751 \times 10^{-2}$     $\pi_9 = 7.97946839 \times 10^{-3}$     $\pi_{14} = 2.30657440 \times 10^{-3}$

## Continuous Time Markov Chain

The CTMC (M/E/1/K=4)



$\lambda = 20 \text{ tps}$ ,  $COV = 1$   
 $E[TBA] = 0.05s$   
 $\mu = 40 \text{ tps}$ ,  $COV_{ST} = 0.5$   
 $E[ST] = 0.025s$

$$\gamma = \left( \frac{0.025}{0.0125} \right)^2 = 4$$

$$\mu_E = \frac{4}{0.025} = 160$$

$\pi_0 = 5.06605 \times 10^{-1}$   
 $\pi_{S1} = 3.04878 \times 10^{-1}$   
 $\pi_{S2} = 1.27697 \times 10^{-1}$   
 $\pi_{S3} = 4.76094 \times 10^{-2}$   
 $\pi_{S4} = 2.21877 \times 10^{-2}$

Utilization = 0.493395

# Continuous Time Markov Chain

Sharpe (chame via Desktop)

Exemplo

Sistema Computacional com degradação

Suponha um sistema representado por uma CPU que opera em três estágios: **CPU\_OK**, **Degradable** e **Faulty\_CPU**.

As taxas entre os estados são:

- CPU\_OK** para **Degradable** é (**OK\_D\_rate**) 100, **Degradable** para **CPU\_OK** (**D\_OK\_rate**) é 20, **Degradable** para **Faulty\_CPU** (**D\_F\_rate**) é 5, **Faulty\_CPU** para **Degradable** (**F\_D\_rate**) é 10, **CPU\_OK** para **Faulty\_CPU** (**OK\_F\_rate**) é 1 e do estado **Faulty\_CPU** para **CPU\_OK** (**F\_OK\_rate**) é 1.

# Continuous Time Markov Chain

Sistema Computacional com degradação

Suponha um sistema representado por uma CPU que opera em três estágios: **CPU\_OK**, **Degradable** e **Faulty\_CPU**. As taxas entre os estados são:

- CPU\_OK** para **Degradable** é (**OK\_D\_rate**) 100, **Degradable** para **CPU\_OK** (**D\_OK\_rate**) é 20, **Degradable** para **Faulty\_CPU** (**D\_F\_rate**) é 5, **Faulty\_CPU** para **Degradable** (**F\_D\_rate**) é 10, **CPU\_OK** para **Faulty\_CPU** (**OK\_F\_rate**) é 1 e do estado **Faulty\_CPU** para **CPU\_OK** (**F\_OK\_rate**) é 1.

# Continuous Time Markov Chain

Sistema Computacional com degradação

Matrix	CPU_OK	Degradable	Faulty_CPU
CPU_OK	OK_D_rate	OK_F_rate	
Degradable	D_OK_rate	D_F_rate	
Faulty_CPU	F_OK_rate	F_D_rate	

# Continuous Time Markov Chain

Exemplo

Suponha um sistema representado por um autômato estocástico, onde:

- $S = \{0, 1, 2\}$
- $E = \{a, d\}$
- $f(0,a)=1, f(1,a)=2, f(2,a)=2, f(2,d)=0$
- $\Gamma(0) = \{a\}, \Gamma(1) = \{a\}, \Gamma(2) = \{a, d\}$
- Os eventos **a** ocorrem com taxa igual =  $\lambda$ ,
- Os eventos **d** ocorrem com taxa igual =  $\mu$

# Continuous Time Markov Chain

Identifier	Description	Input State	Output State	Transition Reward	Rate	Cost
1	Transition1	State1	State2	Loss	1,000000	0,00
2	Transition2	State2	State1	Loss	20,000000	20,00
3	Transition3	State2	State3	Loss	1,000000	0,00
4	Transition4	State3	State2	Loss	5,000000	20,00
5	Transition5	State3	State4	Loss	1,000000	0,00
6	Transition6	State4	State3	Loss	1,000000	40,00

# Continuous Time Markov Chain

Steady State Results:

Result	Value
Availability	0,857143
Cost Per Unit Time	765,714286
MTTR	0,999997

Results at time 1000,000000:

Result	Value
Availability	0,857143
Cost Per Unit Time	765,714286
Failure Rate	NA
Mean Availability	0,857163
Mean Cost	765,744608
Mean Unavailability	0,142837
Reliability	0,000000
Total Cost	765744,607972
Total Downtime	142,835854
Total Uptime	857,164146
Unreliability	1,000000

### Continuos Time Markov Chain

State Transition Rate Diagram

$\sum_{s \in S} \pi_s = 1$   
 $\Pi Q = 0$   
 $(\pi_0, \pi_1, \pi_2) Q = \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix}$

$$Q = \begin{pmatrix} -\lambda & \lambda & 0 & 0 \\ 0 & -\lambda & \lambda & 1 \\ \mu & 0 & -\mu & 2 \\ 0 & 1 & 2 & 2 \end{pmatrix}$$

$\pi_0 = \pi_1 = \mu / (2\mu + \lambda)$   
 $\pi_2 = \lambda / (2\mu + \lambda)$

$-\lambda \pi_0 + \mu \pi_2 = 0$   
 $\lambda \pi_0 - \lambda \pi_1 = 0$   
 $-\lambda \pi_1 - \mu \pi_2 = 0$   
 $\pi_0 + \pi_1 + \pi_2 = 1$

### Continuos Time Markov Chain

State Transition Rate Diagram

$\sum_{s \in S} \pi_s = 1$   
 $\Pi Q = 0$   
 $(\pi_0, \pi_1, \pi_2, \pi_3) Q = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \end{pmatrix}$

$$Q = \begin{pmatrix} -\lambda & \lambda & 0 & 0 & 0 \\ 0 & -(\gamma + \mu) & \gamma & 1 & 1 \\ \delta & 0 & -\delta & 0 & 0 \\ \sigma & 0 & 0 & -\sigma & 3 \\ 0 & 1 & 2 & 3 & 3 \end{pmatrix}$$

$T = 1 / (\pi_0 \times \lambda)$  - Tempo médio entre finalizações

### Continuos Time Markov Chain

Birth-death chain

Considere o automata

$f(i, a_i) = i + 1$   
 $f(i + 1, b_i) = i$   
 enquanto  $i > 0$

CTMC

### Continuos Time Markov Chain

Birth-death chain

$$-(\lambda_j + \mu_j)\pi_j + \lambda_{j-1}\pi_{j-1} + \mu_{j+1}\pi_{j+1} = 0,$$

$$-\lambda_0\pi_0 + \mu_1\pi_1 = 0$$

$$\sum_j \pi_j = 1$$

### Continuos Time Markov Chain

Birth-death chain

$$\pi_1 = \frac{\lambda_0}{\mu_1} \pi_0 \Rightarrow \mu_2 \pi_2 = -\lambda_0 \pi_0 + (\lambda_1 + \mu_1) \pi_1 \Rightarrow \pi_2 = \frac{\lambda_0 \lambda_1}{\mu_1 \mu_2} \pi_0$$

$$\pi_j = \left( \frac{\lambda_0 \cdots \lambda_{j-1}}{\mu_1 \cdots \mu_j} \right) \pi_0 \Rightarrow \pi_0 = \frac{1}{1 + \sum_{j=1}^{\infty} \left( \frac{\lambda_0 \cdots \lambda_{j-1}}{\mu_1 \cdots \mu_j} \right)}$$

### Continuos Time Markov Chain

M/M/1 queueing system

Se  $\lambda_i = \lambda$  e  $\mu_i = \mu$  para todo  $i$ , tem-se:

Utilização

$$\pi_0 = \frac{1}{1 + \sum_{n=1}^{\infty} \left( \frac{\lambda}{\mu} \right)^n} = \frac{\lambda/\mu}{1 - \lambda/\mu}$$

Desde que  $\lambda < \mu$

$$\pi_0 = 1 - \frac{\lambda}{\mu}$$

$$\pi_n = \left( \frac{\lambda}{\mu} \right)^n (1 - \rho)$$

$\rho = \lambda/\mu$   $0 \leq \rho < 1$   
 $\pi_0 = 1 - \rho$

QBM

## Contínuos Time Markov Chain

### M/M/1 queueing system

Se  $\lambda_i = \lambda$  e  $\mu_i = \mu$  para todo  $i$ , tem-se:

**Utilização** **Desde que  $\lambda < \mu$**

$\rho = \lambda/\mu$   $0 \leq \rho < 1$

$\pi_0 = 1 - \rho$

$\pi_n = \left(\frac{\lambda}{\mu}\right)^n (1 - \rho)$

$\pi_n = (1 - \rho)\rho^n, \quad n = 0, 1, \dots$

QBM

## Contínuos Time Markov Chain

### M/M/1 queueing system

**Throughput** **Tamanho médio da fila**

Desde que  $\lambda < \mu$   $E[X] = \frac{\rho}{1 - \rho}$   $0 \leq \rho < 1$

O throughput é  $\lambda$   $E[X] \rightarrow \infty$   $\rho \rightarrow 1$

Se  $\lambda > \mu$  **Mean response time** **Mean waiting time**

throughput é  $\mu$   $E[S] = \frac{1/\mu}{1 - \rho}$   $0 \leq \rho < 1$   $E[W] = \frac{\rho}{\mu(1 - \rho)}$

$E[S] \rightarrow \infty$   $\rho \rightarrow 1$   $E[W] \rightarrow \infty$

QBM

## Contínuos Time Markov Chain

### M/M/m queueing system

$\pi_n = \begin{cases} \frac{(m\rho)^n}{n!} & n = 1, 2, \dots, m-1 \\ \frac{m^m}{\pi_0 m!} \rho^n & n = m, m+1, \dots \end{cases}$

$\pi_0 = \left[ 1 + \sum_{n=1}^{m-1} \frac{(m\rho)^n}{n!} + \frac{(m\rho)^m}{m!} \frac{1}{1 - \rho} \right]^{-1}$

**Utilização** **Throughput**

$\rho = \lambda/m\mu$  Desde que  $\lambda < \mu m$

O throughput é  $\lambda$  O throughput é  $\lambda$

Se  $\lambda \geq \mu m$  throughput é  $\mu$

QBM

## Contínuos Time Markov Chain

### M/M/m queueing system

**Tamanho médio da fila**

$E[X] = m\rho + \frac{(m\rho)^m}{m!} \frac{\rho}{(1 - \rho)^2} \pi_0$   $\lambda < \mu m$  **Fórmula C de Erlang**

$E[X] \rightarrow \infty$   $\lambda \geq \mu m$  Probabilidade de um cliente chegar e não encontrar o servidor disponível!

**Mean response time**

$E[S] = \frac{1}{\mu} + \frac{1}{\mu} \frac{(m\rho)^m}{m!} \frac{\pi_0}{m(1 - \rho)^2}$   $\lambda < \mu m$   $P_Q = P[X \geq m] = \sum_{n=m}^{\infty} \pi_n$

$E[S] \rightarrow \infty$   $\lambda \geq \mu m$   $P_Q = \frac{(m\rho)^m}{m!} \frac{\pi_0}{1 - \rho}$

QBM

## Contínuos Time Markov Chain

### M/M/1/K queueing system

$\pi_0 = \frac{1 - \rho}{1 - \rho^{K+1}}$

$\pi_n = \begin{cases} \frac{1 - \rho}{1 - \rho^{K+1}} \rho^n & \text{if } 0 \leq n \leq K \\ 0 & \text{if } n > K \end{cases}$

**Utilização** **Probabilidade de Descarte**

Se  $\lambda > \mu$  a utilização  $\rightarrow 1$   $P_D = \pi_K = (1 - \rho) \frac{\rho^K}{1 - \rho^{K+1}}$

Se  $\lambda < \mu$  a utilização  $= \rho = \frac{\lambda}{\mu}$

QBM

## Contínuos Time Markov Chain

### M/M/1/K queueing system

**Tamanho médio da fila**

$E[X] = \frac{\rho}{1 - \rho^{K+1}} \left[ \frac{1 - \rho^K}{1 - \rho} - K\rho^K \right]$

**Mean response time**

$E[S] = \frac{E[X]}{\lambda(1 - \pi_K)}$

$\lambda(1 - \pi_K)$  - taxa de chegada dos clientes admitidos

QTM

## Continuous Time Markov Chain

**M/M/m /m queueing system**

Lost customers

$$\pi_0 = \left[ 1 + \sum_{n=1}^m \frac{\lambda^n}{(\mu)(2\mu) \cdots (n\mu)} \right]^{-1} = \left[ 1 + \sum_{n=1}^m \left( \frac{\lambda}{\mu} \right)^n \frac{1}{n!} \right]^{-1}$$

$$\pi_n = \left[ \sum_{j=0}^m \frac{\rho^j}{j!} \right]^{-1}$$

$$\lambda_n = \begin{cases} \lambda & \text{if } 0 \leq n < m \\ 0 & \text{if } n \geq m \end{cases}$$

$$\mu_n = n\mu \quad \text{for all } n = 1, 2, \dots, m$$

$$\pi_n = \begin{cases} \frac{1}{\sum_{j=0}^m \frac{\rho^j}{j!}} \frac{\rho^n}{n!} & \text{if } 0 \leq n \leq m \\ 0 & \text{if } n > m \end{cases}$$

QBM

## Continuous Time Markov Chain

**M/M/m /m queueing system**

**Blocking Probability**

Lost customers

$$P_B = \pi_m = \frac{\rho^m / m!}{\sum_{j=0}^m \frac{\rho^j}{j!}} \quad \text{Erlang B formula}$$

$$\lambda_n = \begin{cases} \lambda & \text{if } 0 \leq n < m \\ 0 & \text{if } n \geq m \end{cases}$$

$$\mu_n = n\mu \quad \text{for all } n = 1, 2, \dots, m$$

## Discrete Time Markov Chain

- O comportamento de uma rede estocástica é representado por DTMC

Matriz de Propabilidades de Próximo Estados

$$P = \begin{vmatrix} p_{00} & p_{01} & 0 \\ p_{10} & p_{11} & 1 \end{vmatrix}$$

Matemática

## Discrete Time Markov Chain

**Evolução de uma DTMC**

Época 0, Época 1, Época 2, Época 3

## Discrete Time Markov Chain

- Estado transiente: um estado é transiente se a probabilidade de não se retornar ao estado é diferente de zero.
- Estado recorrente (*recurrent*): o estado  $i$  é chamado de recorrente se a probabilidade de se sair de  $i$  e retornar a  $i$  é 1.
- MRT (*mean recurrence time*):  $\mu_i = \sum_{n=1}^{\infty} n \times f_{ii}(n)$   
 $f_{ii}$  é a probabilidade de se retornar a  $i$  após  $n$  passos.

## Discrete Time Markov Chain

- Estado recorrente:
  - um estado é classificado como recorrente não-nulo se  $\mu_i < \infty$ ,
  - caso contrário é classificado como recorrente nulo (*recurrent null*).
- Um período ( $d$ ) de um estado recorrente  $i$  é definido por:
 
$$d(i) = MDC = \{ n \mid p_{i,i}(n) > 0 \}$$
Periodic DTMC
- Se  $d(i) = 1$ , o estado  $i$  é aperiódico, se  $d(i) > 1$  é periódico.
- Um estado  $i$  é ergódico se é aperiódico e recorrente não-nulo.
- Uma DTMC é ergódica de todos os seus estados são ergódicos.



## Discrete Time Markov Chain

Considere uma máquina que pode estar em um dos dois estados, UP ou DOWN, onde 1 denota UP e 0 denota DOWN. O estado da máquina é verificada a cada hora, e nós horas de índice  $k = 0, 1, \dots$

Consideremos que se a máquina estiver UP, tem uma probabilidade  $\alpha$  de falhar durante a próxima hora. Se a máquina estiver no estado DOWN, tem probabilidade  $\beta$  de ser reparada durante a próxima hora.

$$P = \begin{pmatrix} 1 - \alpha & \alpha \\ \beta & 1 - \beta \end{pmatrix}$$

Chamar o modelo C:\Users\Paulo\Dropbox\Models\Models\_SHARPE\dtmc1.rgl

## Discrete Time Markov Chain

### Soluções para Steady-States

$$P = \begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{pmatrix} \quad \begin{matrix} A_1 = (a_{11} & a_{12} & a_{13}) \\ A_2 = (a_{21} & a_{22} & a_{23}) \\ A_3 = (a_{31} & a_{32} & a_{33}) \end{matrix}$$

$a_{ij}$  - probabilidade  $\sum_{s_i \in S} a_{ij} = 1$

$\Pi \cdot P = \Pi$ ,  $\sum_{s_i \in S} \pi_i = 1$ , onde  $\pi_i$  fornece o número relativo de visitas ao estado  $s_i$

Chamar o modelo C:\Users\Paulo\Dropbox\Models\Models\_SHARPE\dtmc1.rgl

## Discrete Time Markov Chain

### Soluções para Transiente

$\Pi(1) = \Pi(0) P$ ,  
 $\Pi(2) = \Pi(1) P = \Pi(0) P^2$   
 $\Pi(k) = \Pi(0) P^k$ ,  $k=1,2,\dots$

## Discrete Time Markov Chain

### Mapping Applications to Discrete Time Markov Chains

More specifically, the Control Flow Graph (CFG) of the application is mapped into an ergodic DTMC. In this approach, energy consumption as well as execution time are numerically evaluated.

**Modeling.** Each basic block<sup>1</sup>  $B_i$  in the CFG is mapped into a state  $X_i$  in the DTMC. Similarly, control flow edges are mapped as transitions between states and are labeled by the state transition probabilities, as:

$$P(B_i, B_j) = Pr(B_i \text{ jumps to } B_j),$$

which defines the probability of executing  $B_j$  after  $B_i$ .

```

1. int main() {
2.   int x,y;
3.
4.   if (x < 10) // <0.5>
5.   {
6.     for(y=0; y<10; y++) { // <9>
7.       x++;
8.     }
9.   } else { // <0.5>
10.    x = 0;
11.  }
12. }
13. }

```

## Discrete Time Markov Chain

### Mapping Applications to Discrete Time Markov Chains

*Excel e abrir também o SHARPE;*

$$P = \begin{pmatrix} p_{11} & p_{12} & \dots & p_{1n} \\ p_{21} & p_{22} & \dots & p_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ p_{n1} & p_{n2} & \dots & p_{nn} \end{pmatrix}$$

$0 \leq p_{ij} \leq 1$ ,  $\sum_{j=1}^n p_{ij} = 1$  for each  $i$ .

$$\Pi = (\pi_1, \pi_2, \pi_3, \dots, \pi_n)$$

$$V_j = \frac{\pi_j}{\pi_i}$$

$$E = \sum_{b=\text{all basic blocks}} v_b \times \left( \sum_{c=\text{all instruction classes}} I_{b,c} \times (e_c + O_b \times e_o) \right)$$

$$T = \sum_{b=\text{all basic blocks}} v_b \times \left( \sum_{c=\text{all instruction classes}} I_{b,c} \times (t_c + O_b \times t_o) \right)$$

## Continuous Time Markov Chain

### Soluções Transientes

$\frac{d\Pi(t)}{dt} = \Pi(t)Q$ ,  $\Pi(0) = (\pi_0(0), \dots, \pi_{n-1}(0))$

Onde  $\pi_{s_i}(t)$  é probabilidade de se estar na estado  $s_i$  no instante  $t$

### Métodos de Solução:

- Solução via Sistemas de Eq. Diferencial Ordinária
- Solução através de transformada de Laplace
- Runge-Kutta
- Uniformização (Transformar CTMC em DTMC)

## Continuous Time Markov Chain

### Soluções Transientes (Laplace Transform)

Find transient solution through LT.

$$\frac{d\pi_1(t)}{dt} + \lambda \pi_1(t) - \mu \pi_2(t) = 0$$

$$\frac{d\pi_2(t)}{dt} + \mu \pi_2(t) - \lambda \pi_1(t) = 0$$

by LT:  $\lambda \text{LT}[\pi_1(t)] = \pi_1(0)$

## Continuous Time Markov Chain

Then, considering (I):

$$\lambda \text{LT}[\pi_1(t)] - \pi_1(0) + \text{LT}[\lambda \pi_1(t)] = \text{LT}[\mu \pi_2(t)]$$

$$\lambda \text{LT}[\pi_1(t)] - 1 + \text{LT}[\lambda \pi_1(t)] = \text{LT}[\mu \pi_2(t)]$$

Stop here for a while:

Let's consider (II):

$$\frac{d\pi_2(t)}{dt} + \mu \pi_2(t) - \lambda \pi_1(t) = 0$$

We know that  $\pi_1(t) + \pi_2(t) = 1$ ,  
then:  $\pi_1(t) = 1 - \pi_2(t)$ , so:

$$\frac{d\pi_2(t)}{dt} + \mu \pi_2(t) - \lambda (1 - \pi_2(t)) = 0$$

## Continuous Time Markov Chain

Applying LT:

$$\frac{d\pi_2(t)}{dt} = \lambda \text{LT}[\pi_2(t)] - \pi_2(0)$$

As  $\pi_2(0) = 0$ , then:

$$\frac{d\pi_2(t)}{dt} = \lambda \text{LT}[\pi_2(t)]$$

Hence:

$$\lambda \text{LT}[\pi_2(t)] + \text{LT}[\mu \pi_2(t)] - \text{LT}[\lambda \pi_1(t)] = 0$$

$$\lambda \text{LT}[\pi_2(t)] + \text{LT}[\mu \pi_2(t)] - \text{LT}[\lambda (1 - \pi_2(t))] = 0$$

## Continuous Time Markov Chain

$$\lambda \text{LT}[\pi_2(t)] + \mu \text{LT}[\pi_2(t)] - \frac{\lambda}{\lambda} = 0$$

$$\lambda \text{LT}[\pi_2(t)] = 0$$

$$\lambda \text{LT}[\pi_2(t)] + (\mu + \lambda) \text{LT}[\pi_2(t)] - \frac{\lambda}{\lambda} = 0$$

$$\text{LT}[\pi_2(t)] (\lambda + \mu + \lambda) = \frac{\lambda}{\lambda}$$

$$\text{LT}[\pi_2(t)] = \frac{\lambda}{\lambda(1 + \mu + \lambda)}$$

$$\pi_1(t) + \pi_2(t) = 1$$

$$\text{LT}[\pi_1(t) + \pi_2(t)] = \text{LT}[1]$$

$$\text{LT}[\pi_1(t)] + \text{LT}[\pi_2(t)] = \frac{1}{\lambda}$$

$$\text{LT}[\pi_1(t)] = \frac{1}{\lambda} - \frac{\lambda}{\lambda(1 + \mu + \lambda)}$$

## Continuous Time Markov Chain

$$\lambda \text{LT}[\pi_2(t)] = \frac{\lambda}{\lambda(1 + \mu + \lambda)}$$

then applying  $L^{-1}[\text{LT}[\pi_2(t)]] =$

So:

$$\pi_2(t) = L^{-1}\left[\frac{\lambda}{\lambda(1 + \mu + \lambda)}\right]$$

We may say that, there are A and B,

that:

$$L^{-1}\left[\frac{\lambda}{\lambda(1 + \mu + \lambda)}\right] = L^{-1}\left[\frac{A}{1} + \frac{B}{1 + \mu + \lambda}\right]$$

So:

$$\frac{\lambda}{\lambda(1 + \mu + \lambda)} = \frac{A}{1} + \frac{B}{1 + \mu + \lambda}$$

$$\lambda = A(1 + \mu + \lambda) + B \cdot 1$$

## Continuous Time Markov Chain

$$\lambda = A(1 + \mu + \lambda) + B \cdot 1$$

for  $\lambda = 0$

$$A = \frac{\lambda}{\mu + \lambda}$$

then

$$\lambda = \frac{\lambda}{\mu + \lambda} (1 + \mu + \lambda) + B \cdot 1$$

$$\lambda = \frac{\lambda \cdot 1}{\mu + \lambda} + \lambda \left(\frac{\mu}{\mu + \lambda} + \frac{\lambda}{\mu + \lambda}\right) + B \cdot 1$$

$$\lambda = \frac{\lambda \cdot 1}{\mu + \lambda} + \lambda \left(\frac{\mu + \lambda}{\mu + \lambda}\right) + B \cdot 1$$

$$B = \frac{\lambda}{\mu + \lambda}$$

## Continuous Time Markov Chain

$$L^{-1}\left[\frac{\lambda}{\lambda(\lambda+\mu+\lambda)}\right] = L^{-1}\left[\frac{\lambda}{\lambda(\mu+\lambda)} + \frac{\lambda}{(\lambda+\mu+\lambda)(\mu+\lambda)}\right]$$

$$L^{-1}\left[\frac{\lambda}{\lambda(\lambda+\mu+\lambda)}\right] = L^{-1}\left[\frac{\lambda}{\mu+\lambda} \times \frac{1}{\lambda}\right] + L^{-1}\left[\frac{\lambda}{\mu+\lambda} \times \frac{1}{\lambda+\mu+\lambda}\right]$$

$$L^{-1}\left[\frac{\lambda}{\lambda(\lambda+\mu+\lambda)}\right] = \frac{\lambda}{\mu+\lambda} + \frac{\lambda}{\mu+\lambda} e^{-(\mu+\lambda)t}$$

## Continuous Time Markov Chain

$$\pi_2(t) = L^{-1}\left[\frac{\lambda}{\lambda(\lambda+\mu+\lambda)}\right] = \frac{\lambda}{\mu+\lambda} (1 + e^{-(\mu+\lambda)t})$$

$$\pi_1(t) + \pi_2(t) = 1, \therefore \pi_1(t) = 1 - \pi_2(t)$$

$$\pi_1(t) = 1 - \frac{\lambda}{\mu+\lambda} (1 + e^{-(\mu+\lambda)t})$$

$$\pi_1(t) = \frac{\mu+\lambda - \lambda}{\mu+\lambda} (1 + e^{-(\mu+\lambda)t})$$

## Continuous Time Markov Chain

$$\pi_1(t) = \frac{\mu}{\mu+\lambda} (1 - e^{-(\mu+\lambda)t})$$

$$\pi_2(t) = \frac{\lambda}{\mu+\lambda} (1 - e^{-(\mu+\lambda)t})$$

## Continuous Time Markov Chain

### Soluções Transientes

$$\frac{d\Pi(t)}{dt} = \Pi(t)Q, \quad \Pi(0) = (\pi_0(0), \dots, \pi_{n-1}(0))$$

Uma solução formal para o sistema acima é:

$$\Pi(t) = \Pi(0)e^{Qt}$$

Pela série de Taylor/Maclaurin, temos:

$$e^{Qt} = I + Qt/1! + (Qt)^2/2! + (Qt)^3/3! + \dots$$

$$= \sum_{k=0}^{\infty} (Qt)^k/k!$$

## Continuous Time Markov Chain

### Soluções Transientes

$$\Pi(t) = \Pi(0)e^{Qt} = \Pi(0) \sum_{k=0}^{\infty} (Qt)^k/k!$$

- Problemas de arredondamento ocorrem devido aos valores positivos e negativos que Q contém.
- A matriz  $(Qt)^k$  se torna não-esparso o que requer capacidade muito maior.

Para evitar estes problemas aplica-se o método chamado de uniformização (ou aleatorização - *Randomization*) também chamado de método de Jensen

## Continuous Time Markov Chain

### Uniformização



$$\Lambda(i) = q_{ij} + q_{ik}$$

$$\lambda \geq \max_{i \in S} \{\Lambda(i)\}$$

Sabe-se também que:

$$p_{ij} = q_{ij}/\Lambda(i) \quad \text{e} \quad p_{ik} = q_{ik}/\Lambda(i)$$

Considere que tomemos uma taxa uniforme  $\lambda \geq \Lambda(i)$  onde:

$$\lambda = q_{ij} + q_{ik} + \nu \quad (\lambda - \Lambda(i) = \nu)$$

e  $\nu \geq 0$  é a taxa de arbitrária de um evento fictício que não muda o estado  $i$ .

Tempo de permanência no estado  $i$ :

$$1/(-q_{ii}) = 1/\Lambda(i)$$

### Continuos Time Markov Chain

**Uniformização**

Em todos os estados na CMTC que tiverem tempo de permanência igual a  $1/(-q_{ii})$ , não teremos transição (auto-laço) na DTMC. Para os estados que tiverem tempo de permanência maior, ou seja uma época não é longa o suficiente, estes estados **devem ser revisitados** (auto-laço).

Tempo de permanência no estado  $i$ :  
 $\Delta t = 1/(-q_{ii}) = 1/\Lambda(i)$

Sabe-se também que:

$p_{ij} = q_{ij}/\Lambda(i)$  e  $p_{ik} = q_{ik}/\Lambda(i)$

### Continuos Time Markov Chain

**Uniformização**

$\Lambda(i) = q_{ij} + q_{ik}$

Sabe-se também que:

$p_{ij} = q_{ij}/\Lambda(i)$  e  $p_{ik} = q_{ik}/\Lambda(i)$

$\lambda = q_{ij} + q_{ik} + \nu$

$\lambda \geq \max_{\forall si \in S} \{|q_{ij}|\}$

### Continuos Time Markov Chain

**Uniformização**

$\lambda = q_{ij} + q_{ik} + \nu$

$\lambda \geq \max_{\forall si \in S} \{-q_{ij}\}$

$P = I + Q/\lambda$

$Q = \lambda(P - I)$

### Continuos Time Markov Chain

**Uniformização**

$\lambda = q_{ij} + q_{ik} + \nu$

$\lambda \geq \max_{\forall si \in S} \{-q_{ij}\}$

Outra interpretação:  
 Considerando  $1/\lambda = \Delta t$  como uma época (time-step),  $P = I + Q \Delta t$  que é igual aos dois primeiros termos da expansão de Taylor, portanto a cadeia uniformizada é uma aproximação de primeira ordem da CTMC.

$P = I + Q/\lambda$

$Q = \lambda(P - I)$

### Continuos Time Markov Chain

**Uniformização**

$Q = \begin{bmatrix} -4 & 2 & 2 \\ 1 & -2 & 1 \\ 6 & 0 & -6 \end{bmatrix}$

$P = \frac{1}{6} \begin{bmatrix} 2 & 2 & 2 \\ 1 & 4 & 1 \\ 6 & 0 & 0 \end{bmatrix}$

$P = I + Q/\lambda$

$Q = \lambda(P - I)$

$\lambda \geq \max_{\forall si \in S} \{|q_{ij}|\}$

### Continuos Time Markov Chain

**Soluções Transientes**

$\Pi(t) = \Pi(0)e^{Qt} = \Pi(0)e^{\lambda t} e^{-\lambda t}$

$= \Pi(0)e^{\lambda t} e^{-\lambda t} = \Pi(0)e^{\lambda t} e^{-\lambda t} =$

$\Pi(0) e^{-\lambda t} e^{\lambda t} = \Pi(0) e^{-\lambda t} \sum_{n=0}^{\infty} (\lambda P t)^n / n! =$

$\Pi(0) e^{-\lambda t} \sum_{n=0}^{\infty} (\lambda t)^n P^n / n!, n \in \mathbb{N}$

Na matriz P os valores estão entre 0 e 1. Não há valores negativos, o que evita os erros de arredondamento que ocorrem na expansão com a matriz Q.

## Continuos Time Markov Chain

### Soluções Transientes

$$\Pi(t) = \Pi(0)e^{Qt} = \Pi(0) e^{-\lambda t} \sum_{n=0}^{\infty} (\lambda t)^n P^n / n! , \quad n \in \mathbb{N}$$

$$\psi(\lambda t, n) = [e^{-\lambda t} (\lambda t)^n] / n! , \quad n \in \mathbb{N}$$

$$\Pi(t) = \Pi(0) \sum_{n=0}^{\infty} \psi(\lambda t, n) P^n , \quad n \in \mathbb{N}$$

## Continuos Time Markov Chain

### Soluções Transientes

$$\Pi(t) = \sum_{n=0}^{\infty} \psi(\lambda t, n) \Pi(0) P^n , \quad n \in \mathbb{N}$$

Uma solução iterativa:

$$\hat{\Pi}(t) = \sum_{n=0}^{\infty} \psi(\lambda t, n) \hat{\Pi}(n) , \quad n \in \mathbb{N}$$

$$\hat{\Pi}(0) = \Pi(0), \quad \hat{\Pi}(n) = \hat{\Pi}(n-1)P , \quad n \in \mathbb{N}$$

Podemos truncar a série de maneira que a se atinja uma exatidão  $1-\varepsilon$  ( $\varepsilon = \text{erro}$ ).

## Continuos Time Markov Chain

### Soluções Transientes

$$\hat{\Pi}(t) = \sum_{n=0}^{ke} \psi(\lambda t, n) \hat{\Pi}(n) , \quad n \in \mathbb{N}$$

$$\| \Pi(t) - \hat{\Pi}(t) \|_{\infty} = \| [\Pi(0) e^{-\lambda t} \sum_{n=0}^{\infty} (\lambda t)^n P^n / n! - \sum_{n=0}^{ke} \psi(\lambda t, n) \hat{\Pi}(n)] \|_{\infty}$$

$$\| \Pi(0) e^{-\lambda t} \sum_{n=0}^{\infty} (\lambda t)^n P^n / n! \|_{\infty} \leq$$

A desigualdade ocorre, pois  $[P^n]_{ij}$  são menores ou iguais a um.

$$\sum_{n=ke+1}^{\infty} e^{-\lambda t} (\lambda t)^n / n! \leq \varepsilon$$

## Continuos Time Markov Chain

### Soluções Transientes

Dado que  $\psi(\lambda t, n) = [e^{-\lambda t} (\lambda t)^n] / n!$  é uma distribuição discreta (Poisson), portanto:

$$\sum_{n=0}^{\infty} \psi(\lambda t, n) = 1 = \sum_{n=0}^{ke} \psi(\lambda t, n) + \sum_{n=ke+1}^{\infty} \psi(\lambda t, n) , \quad n \in \mathbb{N}$$

Do slide anterior, tem-se:

$$\sum_{n=ke+1}^{\infty} e^{-\lambda t} (\lambda t)^n / n! \leq \varepsilon \quad \text{Desta forma:}$$

$$\sum_{n=ke+1}^{\infty} e^{-\lambda t} (\lambda t)^n / n! = [1 - e^{-\lambda t} \sum_{n=0}^{ke} (\lambda t)^n / n!] \leq \varepsilon$$

## Continuos Time Markov Chain

### Soluções Transiente

$$\sum_{n=ke+1}^{\infty} e^{-\lambda t} (\lambda t)^n / n! = [1 - e^{-\lambda t} \sum_{n=0}^{ke} (\lambda t)^n / n!] \leq \varepsilon$$

$$\sum_{n=0}^{ke} e^{-\lambda t} (\lambda t)^n / n! \geq 1 - \varepsilon \quad \Rightarrow$$

$$\sum_{n=0}^{ke} (\lambda t)^n / n! \geq (1 - \varepsilon) e^{\lambda t}$$

## Continuos Time Markov Chain

### Solução Transiente (exemplo)

$$Q = \begin{bmatrix} -4 & 2 & 2 \\ 1 & -2 & 1 \\ 6 & 0 & -6 \end{bmatrix} \quad P = \frac{1}{6} \begin{bmatrix} 2 & 2 & 2 \\ 1 & 4 & 1 \\ 6 & 0 & 0 \end{bmatrix}$$

$$P = I + Q/\lambda$$

$$Q = \lambda(P - I)$$

$$\lambda \geq \max_{i \in S} \{|q_{ij}|\}$$

Considere  $\varepsilon = 10^{-4}$



### Continuos Time Markov Chain

Solução Transiente (exemplo)

$$Q = \begin{pmatrix} -4 & 2 & 2 \\ 1 & -2 & 1 \\ 6 & 0 & -6 \end{pmatrix} \quad P = \frac{1}{6} \begin{pmatrix} 2 & 2 & 2 \\ 1 & 4 & 1 \\ 6 & 0 & 0 \end{pmatrix}$$

Para  $t=0.1$ , tem-se:  $(1-\epsilon) e^{\lambda t} = (1-10^{-4}) e^{0.6} = 1,8219$

$$\sum_{n=0}^{ke} (\lambda t)^n / n! \geq (1-\epsilon) e^{\lambda t}$$

Dado  $\lambda = 6$  e considerando  $\epsilon = 10^{-4}$

### Continuos Time Markov Chain

Solução Transiente (exemplo)

t	0,1	0,2	0,5	1	5	10	20	50	100
ke	5	7	11	17	52	91	163	367	693

Dado  $\lambda = 6$  e considerando  $\epsilon = 10^{-4}$

Para  $t=0.1$ , tem-se:  $(1-\epsilon) e^{\lambda t} = (1-10^{-4}) e^{0.6} = 1,8219$

$$\sum_{n=0}^{ke} (\lambda t)^n / n! \geq (1-\epsilon) e^{\lambda t}$$

$\sum_{n=0}^4 (0,6)^n / n! = 1,8214$

$\sum_{n=0}^5 (0,6)^n / n! = 1,8221$

### Continuos Time Markov Chain

Solução Transiente (exemplo)

t	0,1	0,2	0,5	1	5	10	20	50	100
ke	5	7	11	17	52	91	163	367	693

Para  $t=0.1 \Rightarrow ke = 5$

$$\psi(\lambda t, n) = [e^{-\lambda t} (\lambda t)^n] / n! \quad , n \in \{0, 1, 2, 3, 4, 5\}$$

$$\tilde{\Pi}(t) = \sum_{n=0}^{ke} \psi(\lambda t, n) \hat{\Pi}(n) \quad , n \in \{0, 1, 2, 3, 4, 5\}$$

### Continuos Time Markov Chain

Solução Transiente (exemplo)

t	0,1	0,2	0,5	1	5	10	20	50	100
ke	5	7	11	17	52	91	163	367	693

Para  $t=0.1 \Rightarrow ke = 5$  Portanto:

$$\hat{\Pi}(0) = \hat{\Pi}(0) = (1, 0, 0)$$

obtem-se:

$$\hat{\Pi}(1), \hat{\Pi}(2), \hat{\Pi}(3), \hat{\Pi}(4), \hat{\Pi}(5)$$

através de

$$\hat{\Pi}(n) = \hat{\Pi}(n-1)P \quad , n \in \{1, 2, 3, 4, 5\}$$

### Continuos Time Markov Chain

Solução Transiente (exemplo)

t	0,1	0,2	0,5	1	5	10	20	50	100
ke	5	7	11	17	52	91	163	367	693

Para  $t=0.1 \Rightarrow ke = 5$

$$\psi(0.6, n) = [e^{-0.6} (0.6)^n] / n! \quad , n \in \{0, 1, 2, 3, 4, 5\}$$

$$\tilde{\Pi}(0.1) = \sum_{n=0}^5 \psi(0.6, n) \hat{\Pi}(n) \quad , n \in \{0, 1, 2, 3, 4, 5\}$$

### Continuos Time Markov Chain

Solução Transiente (exemplo)

t	0,1	0,2	0,5	1	5	10	20	50	100
ke	5	7	11	17	52	91	163	367	693

Para  $t=0.1 \Rightarrow ke = 5$

$$\psi(0.6, n) = [e^{-0.6} (0.6)^n] / n! \quad , n \in \{0, 1, 2, 3, 4, 5\}$$

$$\psi(0.6, 0) = [e^{-0.6} (0.6)^0 / 0!]$$

$$\psi(0.6, 1) = [e^{-0.6} (0.6)^1 / 1!]$$

$$\psi(0.6, 2) = [e^{-0.6} (0.6)^2 / 2!]$$

$$\psi(0.6, 3) = [e^{-0.6} (0.6)^3 / 3!]$$

$$\psi(0.6, 4) = [e^{-0.6} (0.6)^4 / 4!]$$

$$\psi(0.6, 5) = [e^{-0.6} (0.6)^5 / 5!]$$

## Continuos Time Markov Chain

- Solução Transiente (exemplo)

t	0.1	0.2	0.5	1	5	10	20	50	100
ke	5	7	11	17	52	91	163	367	693

Para  $t=0.1 \Rightarrow ke=5$

$$\psi(0.6, n) = [e^{-\lambda t} (\lambda t)^n / n!], n \in \{1, 2, 3, 4, 5\}$$

$$\tilde{\Pi}(0.1) = \sum_{n=0}^5 \psi(0.6, n) \hat{\Pi}(n), n \in \{1, 2, 3, 4, 5\}$$

## Continuos Time Markov Chain

- Solução Transiente (exemplo)

t	0.1	0.2	0.5	1	5	10	20	50	100
ke	5	7	11	17	52	91	163	367	693


Para  $t=0.1 \Rightarrow ke=5$

$$\tilde{\Pi}(0.1) = \sum_{n=0}^5 \psi(0.6, n) \hat{\Pi}(n), n \in \{1, 2, 3, 4, 5\}$$

$$\tilde{\Pi}(0.1) = (0.71, 0.1502, 0.1268)$$

## Continuos Time Markov Chain

- Solução Transiente (exemplo)



## Semi-Markovian Chain (SMC)

- Considere uma DTMC, contudo também considere um tempo de permanência (no domínio contínuo:  $t \in \mathbb{R}$ ), em cada estado  $i \in S$  da DTMC, com distribuição  $F_i(t)$  e densidade  $f_i(t)$ .
- Este modelo é denominado SMC.

## Semi-Markovian Chain (SMC)

- SMC é caracterizada por:
  - matriz de probabilidade de 1 passo ( $P$ ),
  - vetor de probabilidade inicial ( $\Pi(0)$ ) e
  - o vetor de distribuições de permanência nos estados ( $F(t) = (F_1(t), \dots, F_i(t), \dots, F_{|S|}(t))$ ).

## Semi-Markovian Chain (SMC)

- Interpretação
  - Em cada instante em que ocorrem mudanças de estados, a SMC tem comportamento igual ao da correspondente DTMC (comportamento descrito por  $P$ ) e é independente do passado.
  - Quando se alcança um estado  $i$ , um tempo distribuído conforme  $F_i(t)$  deve se passar para que ocorra nova transição entre estados.

## Semi-Markovian Chain (SMC)

### Solução Estacionária

– Encontre a solução estacionária para DTMC embutida (caracterizada por  $P$ ):

$$\Omega P = \Omega$$

$$\sum_{j \in S} \omega_j = 1$$

– Calcule o tempo médio de permanência ( $h_i$ ) em cada estado  $i$ :

$$h_i = \int_0^{\infty} t f_i(t) dt$$

## Semi-Markovian Chain (SMC)

### Solução Estacionária

– A probabilidade de estado estacionário da SMC é obtida por:

$$\pi_i = (\omega_i \times h_i) / (\sum_{j \in S} \omega_j \times h_j), \quad \forall i$$


– Em muitas aplicações,  $h_i$  é fornecido diretamente.

■ Solução transiente é mais sofisticada.

## Semi-Markovian Chain (SMC)

### Solução Estacionária

– Exemplo:



$$\Omega P = \Omega$$

$$\sum_{j \in S} \omega_j = 1$$

$$h_0=10, h_1=5$$

## Semi-Markovian Chain (SMC)

### Solução Estacionária

– Exemplo:



Matriz de Probabilidades de Próximo Estados

$$P = \begin{array}{cc|c} & 0 & 1 & \\ \hline 0 & 0,4 & 0,6 & 0 \\ 1 & 0,3 & 0,7 & 1 \end{array}$$

$$\Omega P = \Omega$$

$$\sum_{j \in S} \omega_j = 1$$


$$h_0=10, h_1=5$$

$$\left\{ \begin{array}{l} \omega_0=0,5385 \\ \omega_1=0,4615 \end{array} \right.$$

## Semi-Markovian Chain (SMC)

### Solução Estacionária

– Exemplo:



Matriz de Probabilidades de Próximo Estados

$$P = \begin{array}{cc|c} & 0 & 1 & \\ \hline 0 & 0,4 & 0,6 & 0 \\ 1 & 0,3 & 0,7 & 1 \end{array}$$

$$\omega_0=0,5385$$

$$\omega_1=0,4615$$

$$\pi_i = \frac{(\omega_i \times h_i)}{(\sum_{j \in S} \omega_j \times h_j)}, \quad \forall i \in S$$

$$\pi_0 = \frac{(0,5385 \times 10)}{(0,5385 \times 10) + (0,4615 \times 5)}$$

$$\pi_1 = \frac{(0,4615 \times 5)}{(0,5385 \times 10) + (0,4615 \times 5)}$$

## Semi-Markovian Chain (SMC)

### Solução Estacionária

– Exemplo:



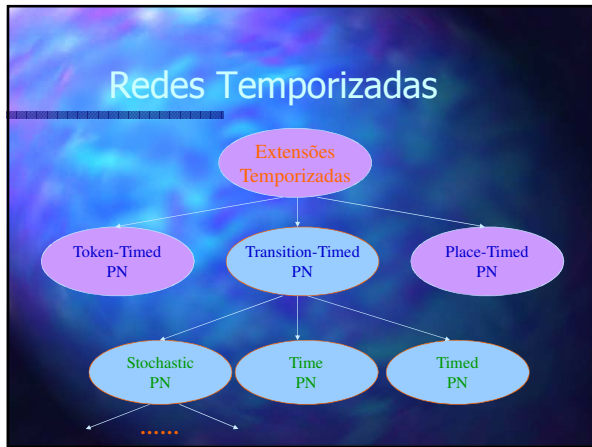
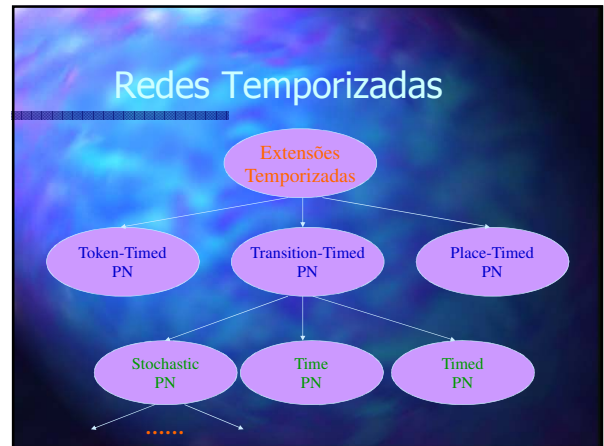

Matriz de Probabilidades de Próximo Estados

$$P = \begin{array}{cc|c} & 0 & 1 & \\ \hline 0 & 0,4 & 0,6 & 0 \\ 1 & 0,3 & 0,7 & 1 \end{array}$$

$$\pi_0 = \frac{(0,5385 \times 10)}{(0,5385 \times 10) + (0,4615 \times 5)} = 0,7$$

$$\pi_1 = \frac{(0,4615 \times 5)}{(0,5385 \times 10) + (0,4615 \times 5)} = 0,3$$

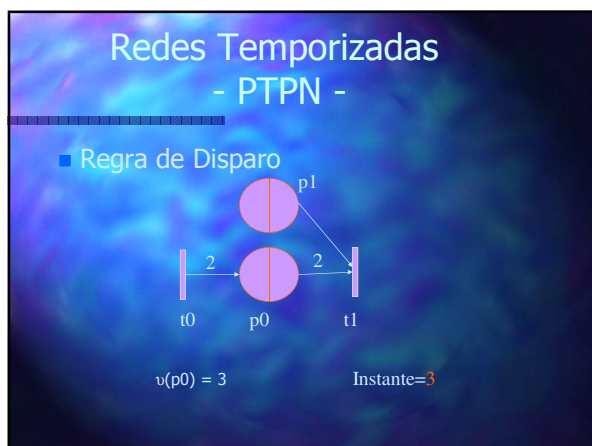
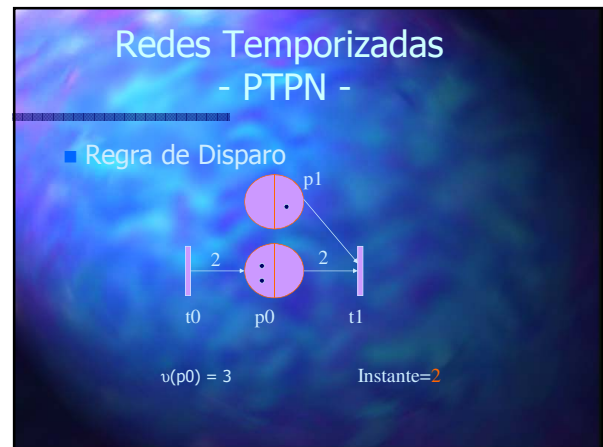
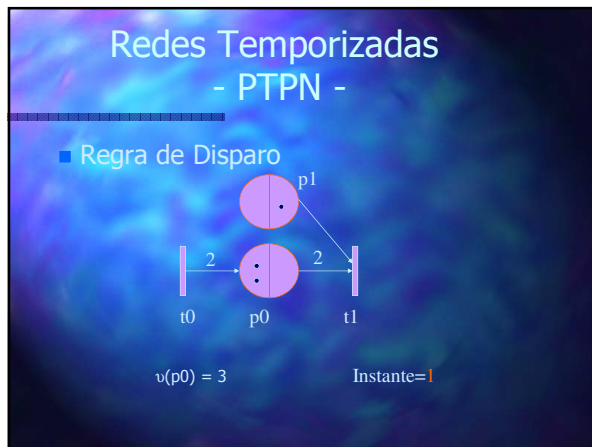
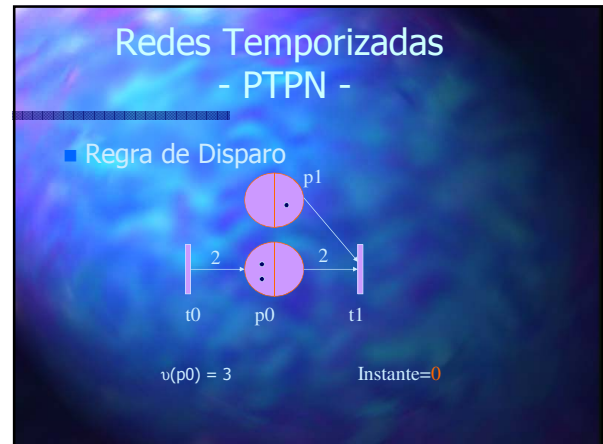
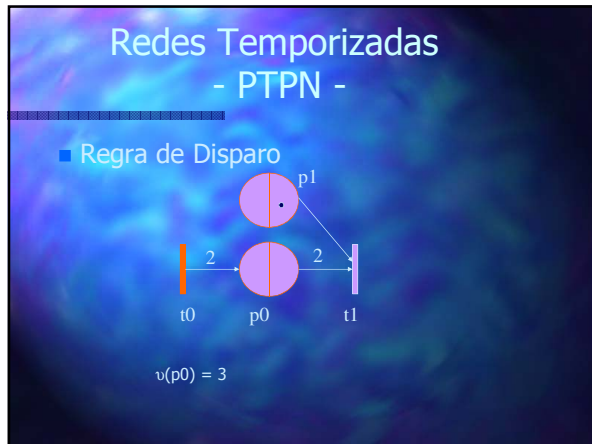




- ## Redes Temporizadas
- Ramchandani, 1973 - Transition Timed Net
  - Merlin, 1976 - Transition Time Net
  - Sifakis, 1977 - Place Timed Net

- ## Redes Temporizadas Estocásticas
- ⊗ Natkin - 1980
  - ⊗ Molloy - 1981
  - ⊗ Marsan et al. - 1984
- É uma rede temporizada onde o *delay* associado à transição é uma variável aleatória de distribuição exponencial

- ## Redes Temporizadas
- **Redes de Petri com Lugares Temporizados (PTPN)** (Sifakis77)
  - Definição:  $PTPN = (P, T, F, K, W, M_0, \Gamma, \nu)$ , onde
    - $P$  é o conjunto de lugares,
    - $T$  o conjunto de transições,
    - $F \subseteq (P \times T) \cup (T \times P)$  uma relação que representa os arcos
    - $W$  - Valoração (peso dos arcos) -  $W: F \rightarrow \mathbb{N}$
    - $M_0$  - Marcação inicial -  $M_0: P \rightarrow \mathbb{N}$
    - $\Gamma = \{\gamma_1, \gamma_2, \dots, \gamma_n, \dots\}$  números reais denominada base de tempo.
    - $\nu: P \rightarrow \Gamma$  um mapeamento que  $\nu(p) = \gamma_j$



- ### Redes de Petri Temporizadas - Tempo Associado às Transições -
- Conceitos Básicos:
- **Duração (disparo em três fases)**
    - Marcas são consumidas dos lugares de entrada
    - Há uma duração
    - Marcas são geradas nos lugares de saída
  - **Disparo atômico**
    - As marca permanecem nos lugares de entrada pelo período igual ao *delay* associada à transição. Após o *delay* as marcas são consumidas e geradas nos lugares de saída imediatamente.

## Redes de Petri Temporizadas

### - Tempo Associado às Transições -

#### ■ Conceitos Básicos:

##### - Duração (disparo em três fases)

- Pode ser representada por uma rede com disparo atômico
- Modelo mais compacto
- O estado é uma informação mais complexa do que o modelo não-temporizado

##### - Disparo atômico

- Pode representar o modelo com duração
- O conjunto de marcações alcançáveis é um sub-conjunto das marcações do modelo não-temporizado.

## Redes de Petri Temporizadas

### - Tempo Associado às Transições -

#### ■ Conceitos Básicos:

##### - Regras de Seleção:

- Pré-seleção: (duração e *delay*)
  - Prioridade
  - Probabilidade
- Race (corrida): (*delay*)
  - Transições habilitadas com menor *delay* são disparadas

## Redes de Petri Temporizadas

### - Tempo Associado às Transições -

#### ■ Conceitos Básicos:

- Quando uma das transições conflitantes é desabilitada pelo disparo da outra, o que acontece com o *timer* da que ficou desabilitada quando a mesma tornar-se habilitada outra vez?

## Redes de Petri Temporizadas

### - Tempo Associado às Transições -


- Como fica a memorização do tempo de habilitação anterior?

#### ■ Continue

- O *timer* associado à transição mantém o valor atual e quando a transição se tornar novamente habilitada o valor do *timer* iniciará daquele valor.

#### ■ Restart

- Quando a transição for novamente habilitada o *timer* será re-iniciado.



## Redes de Petri Temporizadas

### - Tempo Associado às Transições -

#### ■ Conceitos Básicos:

- O que acontece com o *timer* das transições habilitadas após o disparo de uma transição?
  - Todas as transições. Não somente as transições conflitantes.

• Algumas políticas de memória podem ser construídas

## Redes de Petri Temporizadas

### - Tempo Associado às Transições -

#### ■ Conceitos Básicos:

##### - Resampling

- Após cada disparo os *timers* de **TODAS as transições são re-iniciado** (*restart*)
  - Não há memória
- Após descartar todos os *timers*, os valores iniciais são associados a todas as transições que se tornarem habilitadas na nova marcação.

## Redes de Petri Temporizadas

- Tempo Associado às Transições -

- **Conceitos Básicos:**
  - *Enabling Memory*
    - Após cada disparo os *timers* das transições que ficaram **desabilitadas** são re-iniciados (*restart*)
    - As **transições que permanecerem habilitadas** com o disparo matêm seus valores presentes(*continue*)

## Redes de Petri Temporizadas

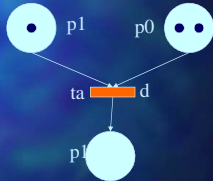
- Tempo Associado às Transições -

- **Conceitos Básicos:**
  - *Age Memory*
    - Após cada disparo os *timers* de **todas** as transições são mantidos em seus valores presentes (*continue*)

## Redes de Petri Temporizadas

- Tempo Associado às Transições -

- **Conceitos Básicos:**
  - *Grau de Habilitação (Enabling Degree)*
    - É o número de vezes que uma determinada transição pode ser disparada, numa determinada marcação, antes de se torna desabilitada.
    - Quando o grau de habilitação é **maior que um**, atenção especial à semântica de temporização deve ser considerada.



## Redes de Petri Temporizadas

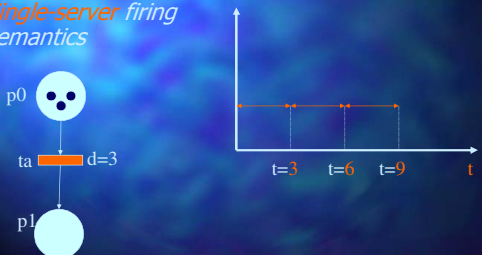
- Tempo Associado às Transições -

- **Conceitos Básicos:**
  - Semântica de Temporização
    - *Single-server firing semantics*
    - *Infinite-server firing semantics*
    - *Multiple-server firing semantics*
      - K é o máximo grau de paralelismo. Quando  $K \rightarrow \infty$ , *Multiple-server firing semantics* é igual a *infinite-server firing semantics*.

## Redes de Petri Temporizadas

- Tempo Associado às Transições -


- **Conceitos Básicos:**
  - *Single-server firing semantics*



## Redes de Petri Temporizadas

- Tempo Associado às Transições -



- **Conceitos Básicos:**
  - *Infinite-server firing semantics*



# Redes de Petri Temporizadas - Tempo Associado às Transições -

## Conceitos Básicos:

- Multiple-server firing semantics  $k=2$



# Classificação da Técnicas de Avaliação de Desempenho



# Redes com Arco Inibidor


## Definição:

$$PN=(P,T,I,O,H,\Pi,M_0)$$

$P,T,I,O$  definidos como usualmente.

$H : P \times T \rightarrow \mathbb{R}$  é a função de mapeamento de que representam os arcos inibidores

$M_0$ - Marcação inicial -  $M_0: P \rightarrow \mathbb{R}$



# Redes com Prioridade

## Definição:

$$PN=(P,T,I,O,H,\Pi,M_0)$$

$P,T,I,O$  definidos como usualmente.


$H : P \times T \rightarrow \mathbb{R}$  é a função de mapeamento de que representam os arcos inibidores

$\Pi : T \rightarrow \mathbb{R}$  é uma função que mapeia às transições níveis de prioridade.

$M_0$ - Marcação inicial -  $M_0: P \rightarrow \mathbb{R}$


# Redes com Prioridade

$$PN=(P,T,I,O,H,\Pi,M_0)$$



# Redes com Prioridade

$$PN=(P,T,I,O,H,\Pi,M_0)$$



## Redes Estocásticas

$$SPN = (P, T, I, O, H, \Pi, G, M_0, Atts)$$

$P = \{p_1, p_2, \dots, p_n\}$  is the set of places,  
 $T = \{t_1, t_2, \dots, t_m\}$  is the set of transitions,  
 $I \in (\mathbb{N}^n \rightarrow \mathbb{N})^{n \times m}$  is a matrix of marking-dependent multiplicities of input arcs  
 $O \in (\mathbb{N}^n \rightarrow \mathbb{N})^{n \times m}$  is a matrix of marking dependent multiplicities of output arcs.  
 $H \in (\mathbb{N}^n \rightarrow \mathbb{N})^{n \times m}$  is a matrix of marking-dependent inhibitor arcs.


## Redes Estocásticas

$$SPN = (P, T, I, O, H, \Pi, G, M_0, Atts)$$

$\Pi \in \mathbb{N}^m$  is the priority vector  
 $G \in (\mathbb{N}^n \rightarrow \{\text{true}, \text{false}\})^m$  is the guard vector  
 $M_0 \in \mathbb{N}^n$  is the initial marking vector  
 $Atts = (\text{Dist}, W, \text{Markdep}, \text{Policy}, \text{Concurrency})^m$   
 $\text{Dist} \in \mathbb{N}^m \rightarrow \mathcal{F}$  is a firing probability distribution  
 $W: T \rightarrow \mathbb{R}$  is a function that assigns  
 weight to immediate transitions  
 and delay to time timed transitions  
 $\text{Markdep} \in \{\text{constant}, \text{enabdep}\}$   
 $\text{Policy} \in \{\text{prd}, \text{prs}\}$  is the preemption policy  
 $\text{Concurrency} \in \{\text{ss}, \text{is}\}$

## Redes Estocásticas


Definição:  
 $SPN = (P, T, I, O, W, M_0)$



$P$  é o conjunto de lugares,  
 $T$  o conjunto de transições,  
 $I: P \times T \rightarrow \mathbb{R}$  é a função de mapeamento de que representam as pré-condições,  
 $O: P \times T \rightarrow \mathbb{R}$  é a função de mapeamento de que representam as pós-condições  
 $W: T \rightarrow \mathbb{R}^+$  (ou  $W: T \times M \rightarrow \mathbb{R}^+$ ) é uma função que associa taxas de distribuição exponencial às transições  
 $M_0$  - Marcação inicial -  $M_0: P \rightarrow \mathbb{R}$

## Redes Estocásticas


Definição:  
 $SPN = (P, T, I, O, H, W, M_0)$



$P$  é o conjunto de lugares,  
 $T$  o conjunto de transições,  
 $I: P \times T \rightarrow \mathbb{R}$  é a função de mapeamento de que representam as pré-condições,  
 $O: P \times T \rightarrow \mathbb{R}$  é a função de mapeamento de que representam as pós-condições  
 $H: P \times T \rightarrow \mathbb{R}$  é a função de mapeamento de que representam os arcos inibidores  
 $W: T \rightarrow \mathbb{R}^+$  (ou  $W: T \times M \rightarrow \mathbb{R}^+$ ) é uma função que associa taxas de distribuição exponencial às transições  
 $M_0$  - Marcação inicial -  $M_0: P \rightarrow \mathbb{R}$

## Redes Estocásticas

Rede Estocástica



Grafo de Marcações / CTMC



## Redes Estocásticas

Semântica de Disparo de Transição

Uma transição  $t_j$  é **disparável se estiver habilitada**

– Regras de habilitação

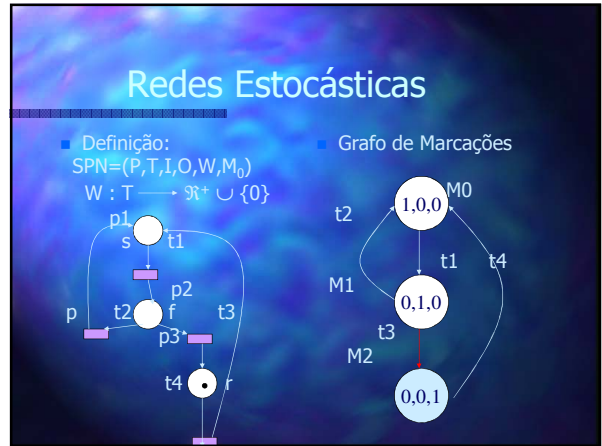




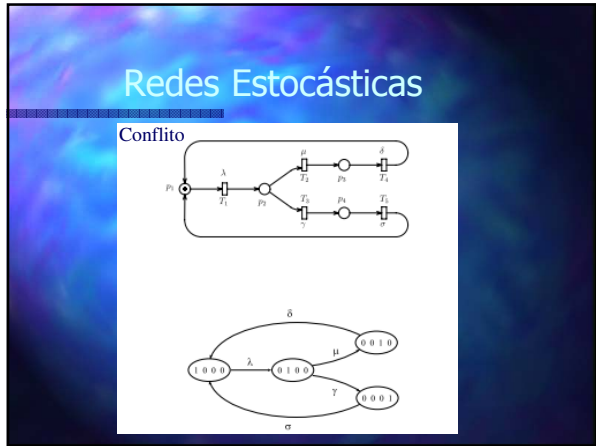
$$M[t_j > , \quad M(p_i) \geq I(p_i, t_j) \\ \forall p_i \in P$$

Transições com **delays menores** disparam primeiro (*Race*)

*Enabling memory, resampling, age memory*

Regras de disparo

$$\text{Se } M[t_j > M' \\ M'(p_i) = M_0(p_i) - I(p_i, t_j) + O(p_i, t_j), \quad \forall p_i \in P$$



## Redes Estocásticas

- Definição:
  - SPN=(P,T,I,O,W,M<sub>0</sub>)
  - W : T → ℝ<sup>+</sup> ∪ {0}
- Grafo de Marcações

## Redes Estocásticas

- Definição:
  - SPN=(P,T,I,O,W,M<sub>0</sub>)
  - W : T → ℝ<sup>+</sup> ∪ {0}
- Grafo de Marcações

## Redes Estocásticas

### Semântica de Temporização

SSS

ISS

## Redes Estocásticas

- Em geral, a CTMC associada a uma SPN é obtida da seguinte maneira:
  - O espaço de estados  $S = \{s_i\}$  corresponde ao *reachability set*  $RS(N, M_0) = \{M_i\}$  da rede marcada  $N$ .
  - As *transition rates* de cada estado  $s_i$  (corresponde a marcação  $M_i$ ) para cada estado  $s_j$  ( $M_j$ ) são obtidas pela *soma de todas as firing rates* associadas às *transições* que estão habilitadas em  $M_i$  e cujo disparo levam a  $M_j$ .

## Redes Estocásticas

- Assumindo-se que todas as transições operam em *Single Server Semantics* (SS) e taxas (*rates*) independentes da marcação, tem-se:
 
$$q_{ij} = \begin{cases} \sum_{t_k \in e_j(M_i)} \omega_k & (i \neq j) \\ -q_i & (i = j) \end{cases}$$
- onde  $Q = [q_{ij}]$  gerador infinitesimal (matriz de taxas)
- $q_i = \sum_{t_k \in e_i(M_i)} \omega_k$
- $\omega_k$  é a taxa de disparo de  $t_k$ .
- $e_i(M_i) = \{t_k \mid t_k \in e(M_i) \wedge M_i[t_k > M_j]\}$  é o conjunto de transições que estão habilitadas em  $M_i$  e cujo disparo levam a  $M_j$ .
- $e(M_i)$  conjunto de transições habilitadas em  $M_i$ .

## Redes Estocásticas Generalizada (GSPN)

- Definição:
  - GSPN=(P,T,I,O,H;II,W,M<sub>0</sub>)

P,T,I,O definidos como usualmente.  
 H : P×T → ℝ é a função de mapeamento de que representam os arcos inibidores

II : T → ℝ se t for temporizada (ou seja) | ℝ<sup>+</sup> se t for imediata

W : T → ℝ<sup>+</sup> (ou W : T×M → ℝ<sup>+</sup>) é uma função que associa *taxas de distribuição exponencial* às *transições temporizadas* e *2 pesos* usados na computação das *probabilidades de disparo das transições imediatas*

M<sub>0</sub>- Marcação inicial - M<sub>0</sub>; P → ℝ



## Redes Estocásticas Generalizada (GSPN)

**Semântica de Disparo de Transição**

- Regras de habilitação
 
$$M[t_j > , \quad M(p_i) \geq I(p_i, t_j) \text{ e } M(p_i) < H(p_i, t_j) \\ \forall p_i \in P$$
- Uma transição  $t_j$  é **disparável se estiver habilitada**
- Transições com **delays menores** disparam primeiro (*Race*)
- Transições **imediatas** disparam **instantaneamente** com **prioridades sobre as temporizadas**
- Diferentes **níveis de prioridade** podem ser associados às **transições imediatas**.
- **Transições imediatas com mesmo nível de prioridade** associada **disparam** de acordo com o **peso associado** a cada uma.
- *Enabling memory, resampling, age memory*
- Regras de disparo
 
$$\text{Se } M[t_j > M' \\ M'(p_i) = M_0(p_i) - I(p_i, t_j) + O(p_i, t_j), \quad \forall p_i \in P$$

## Redes Estocásticas Generalizada (GSPN)

*Reachability Set*

**RS = VS  $\cup$  TS**

**VS  $\cap$  TS =  $\emptyset$**

**VS – Vanishing set:**  
 Marcações em que as transições disparáveis são imediatas.

**TS – Tangible set:**  
 Marcações onde as transições habilitadas são temporizadas.

## Redes Estocásticas Generalizada (GSPN)

■ Grafo de Marcações

## Redes Estocásticas Generalizada (GSPN)

$P\{t_k | m_j\} = \omega_k / q_j$

$q_j = \sum_{t_k \in e(M_j)} \omega_k$

$\omega_k$  é a taxa de disparo de  $t_k$ .

$e(M_j)$  conjunto de transições habilitadas em  $M_j$ .

Quando a marcação é *vanishing*,  $\omega_k$  é um peso (transição imediata).

Quando a marcação é *tangible*,  $\omega_k$  é a taxa.

## Redes Estocásticas Generalizada (GSPN)

Quando diversas transições imediatas estão habilitadas em uma mesma marcação (*vanishing*), decidir qual transição dispara só faz sentido quando na presença de conflito.

Assumindo a ausência de confusão, o cálculo do ECS consiste em particionar as transições imediatas em conjuntos os quais as transição de cada conjunto possam estar em conflito.

Contudo, transições de diferentes ECS são concorrente.

## Redes Estocásticas Generalizada (GSPN)

Quando diversas transições imediatas estão habilitadas em uma mesma marcação (*vanishing*), decidir qual transição dispara só faz sentido quando na presença de conflito.

Quando transições de um único ECS são as únicas imediatas

$P\{t_k | m_i\} = \omega_k / w_k(m_i)$

$w_k(m_i) = \sum_{t_j \in [ECS(t_k) \wedge e(M_i)]} \omega_j$

Os pesos podem ser diferentes em diferentes marcações, mas a relação entre estes pesos é constante (sem confusão)

## Redes Estocásticas Generalizada (GSPN)

*Reachability Set*

**RS = VS ∪ TS**

**VS ∩ TS = ∅**

**VS – Vanishing set:**  
 Marcações em que as transições disparáveis são imediatas.

**TS – Tangible set:**  
 Marcações onde as transições habilitadas são temporizadas.

## Redes Estocásticas Generalizada (GSPN)

*Grafo de Marcações*

## Redes Estocásticas

- Para garantir a existência de probabilidade estacionária, a rede deve ser:
  - limitada (bounded)
  - reversível e livre de bloqueio (deadlock-free)

$\Pi Q = 0, \sum_{M_i \in RS(N)} \pi_i = 1$

Probabilidade estacionária de uma marcação  $M_i$   
 $(\pi_1, \dots, \pi_i, \dots, \pi_n) \quad Q = (0, \dots, 0, \dots, 0)$

$\sum_1^n \pi_i = 1$

## Redes Estocásticas

- Soluções Transientes

$\frac{d\Pi(t)}{dt} = \Pi(t)Q, \quad \Pi(0) = (\pi_0(0), \dots, \pi_{n-1}(0))$

Uma solução formal para o sistema acima é:

$\Pi(t) = \Pi(0)e^{Qt}$

## Redes Estocásticas

- Dada  $M_j \in TS(N)$ , a probabilidade de se disparar  $t_k$  ( $t_k$  está habilitada em  $M_j$ ) em  $M_j$  é:
 
$$p(t_k, M_j) = \frac{\lambda_k}{\lambda_j}, \quad \lambda_j = \sum_{t \in T_j} \lambda_t$$

$T_j = \{t \mid M_j[t >\}$

$\lambda_t$  é a taxa associada a transição  $t$  através da  $W$

## Redes Estocásticas

- Dadas  $M_i \in VS(N)$ , a probabilidade de se disparar  $t_k$  em  $M_i$  é:
 
$$p(t_k, M_i) = \frac{\omega_k}{\omega_i(M_i)},$$

$$\omega_k(M_i) = \sum_{t \in \{ECS(t_k) \cap M_i[t >\}} \omega_t$$

**ECS( $t_k$ ) – Extended Conflict Set**  
 $\omega_k(M_i)$  o peso associado à transição  $t_k$  na marcação  $M_i$ .

Caso haja mais de uma transição imediata, de diferentes ECS, habilitadas em uma marcação  $M_i$ , não importa a ordem de disparo, desde que a rede seja livre de confusão.

## Redes Estocásticas

- Tempo de permanência numa marcação (*sojourn time*)

$$tm_j = 1/\lambda_j$$

$$\lambda_j = \sum_{t \in T_j} \lambda_t$$

$$T_j = \{t \mid M_j(t) > 0\}$$

$\lambda_t$  é a taxa associada a transição  $t$  através da  $W$

## Redes Estocásticas

- Probabilidade que um lugar  $p_j$  tenha  $k$  marcas
- Número esperado de marcas no lugar  $p_j$

$$p(p_j, k) = \sum_{i \in S_1} p_i$$

$$S_1 = \{i \in \{1, 2, \dots, S\} \mid M(p_j, i) = k\}$$

$$Em(p_j) = \sum_{x=1}^K x \cdot p(p_j, x)$$

$K$  é o número máximo de marcas que o lugar  $p_j$  pode conter

## Redes Estocásticas

- Throughput rate* de uma transição temporizada

$$TR(t_j) = \sum_{i \in S_2} p_i \cdot \lambda_j$$

$$S_2 = \{i \in \{1, 2, \dots, S\} \mid M(t_j) > 0\}$$

- $p_i$  é a probabilidade estacionária de uma marcação  $M_i$  que habilita  $t_j$
- $\lambda_j$  é a taxa associada à transição  $t_j$

## Redes Estocásticas

- Tempo médio entre disparos de uma transição

$$T = 1/TR(t_j) = 1/(\sum_{i \in S_2} p_i \cdot \lambda_j)$$

$$S_2 = \{i \in \{1, 2, \dots, S\} \mid M(t_j) > 0\}$$

- $p_i$  é a probabilidade estacionária de uma marcação  $M_i$  que habilita  $t_j$
- $\lambda_j$  é a taxa associada à transição  $t_j$

## Redes Estocásticas

- Throughput rate* de uma transição imediata

– Pode ser calculada de uma transição exponencial e a estrutura do modelo GSPN.

$$TR(t_j) = TR(t) \times (\omega_j / (\omega_j + \omega_k))$$

$t_j$  e  $t_k$  são as únicas transições de um ECS.

## Redes Estocásticas

- Little's law*

$$E[X] = \lambda E[s] \text{ (ergódico)}$$

$E[X]$  - tamanho médio da fila.  
 $E[s]$  - Tempo médio de serviço do sistema.  
 $\lambda$  - taxa de chegada

## Redes Estocásticas

**Tempo médio de espera em um lugar**

- $W_{avg}(p_i) = \frac{Em(p_i)}{\sum_{t_j=0(p_i)} TR(t_j)} = \frac{Em(p_i)}{\sum_{t_j=0(p_i)} TR(t_j)}$
- $Em(p_i)$  é o número médio de marcas no lugar  $p_i$ .
- $TR(t_j)$  throughput da transição  $t_j$ .

## Redes Estocásticas

### MM1K

**Representação explícita do descarte**

$\lambda = 8, \mu = 10, n = 1, k = 20;$   
 $q = \text{QueueingProcess}(\lambda, \mu, n, k);$   
 $QueueProperties(q);$

Basic Properties	
QueueNotation	M,M/1/20
ArriveRate	8
ServiceRate	10
UtilizationFactor	0.798138
Throughput	7.98138
ServiceChannels	1
SystemCapacity	20
InitialState	0
MeanSystemTime	0.80451
MeanSystemTime	0.80451
MeanQueueTime	0.0637
MeanQueueTime	0.0637

Utilization = P{#P5=0} Throughput = E{#P4}\*TBA  
 MOS = E{#P5}  
 MSS = E{#P2}\*E{#P4}  
 MST = E{#P2}\*E{#P4}\*(1+AR)\*(1-P{#P2=BS} AND #P4=NS)  
 MOT = E{#P2}\*(AR)\*(1-P{#P2=BS} AND #P4=NS)  
 DiscardProb = P{#P2=BS} AND #P4=NS  
 DiscardRate = P{#P2=BS} AND #P4=NS)\*AR

Utilization = 0.798138153086 Throughput = 0.09976729136  
 MOS = 3.00039732393  
 MSS = 3.804506074016  
 MST = 0.474456476769  
 MOT = 0.374921396861  
 DiscardProb = 0.002327339843  
 DiscardRate = 0.01851846914

## Redes Estocásticas

### MM2K

**Representação implícita do descarte**

$\lambda = 8, \mu = 10, n = 2, k = 20;$   
 $q = \text{QueueingProcess}(\lambda, \mu, n, k);$   
 $QueueProperties(q);$

Basic Properties	
QueueNotation	M,M/2/20
ArriveRate	8
ServiceRate	10
UtilizationFactor	0.4
Throughput	8
ServiceChannels	2
SystemCapacity	20
InitialState	0
MeanSystemTime	0.252381
MeanSystemTime	0.252381
MeanQueueTime	0.119048
MeanQueueTime	0.119048

Utilization = (NS-E{#P5})/NS  
 Throughput = E{#P4}\*SR  
 MOS = E{#P2}  
 MSS = E{#P2}\*E{#P4}  
 MST = E{#P2}\*E{#P4}\*TBA  
 MOT = E{#P2}\*TBA  
 DiscardProb = P{#P1=1} AND #P2=BS AND #P4=NS  
 DiscardRate = P{#P1=1} AND #P2=BS AND #P4=NS)\*AR

Utilization = 0.39999998432 Throughput = 7.99999998432  
 MOS = 0.152380897055  
 MSS = 0.95238089404  
 MST = 0.119047611755  
 MOT = 0.019047612132  
 DiscardProb = 3.77E-9  
 DiscardRate = 3.0158E-8

## Redes Estocásticas

### MM2K

**Equivalente ao anterior. Servidores representados individualmente**

$\lambda = 8, \mu = 10, n = 2, k = 20;$   
 $q = \text{QueueingProcess}(\lambda, \mu, n, k);$   
 $QueueProperties(q);$

Basic Properties	
QueueNotation	M,M/2/20
ArriveRate	8
ServiceRate	10
UtilizationFactor	0.4
Throughput	8
ServiceChannels	2
SystemCapacity	20
InitialState	0
MeanSystemTime	0.252381
MeanSystemTime	0.252381
MeanQueueTime	0.119048
MeanQueueTime	0.119048

UtilizationS1 = (NS1-E{#P5})/NS1  
 UtilizationS2 = (NS2-E{#P5})/NS2  
 Throughput = E{#P4}\*SR1  
 Throughput = E{#P4}\*SR2  
 Throughput = E{#P6}\*SR2 + E{#P4}\*SR1  
 MOS = E{#P2}  
 MSS = E{#P2}\*E{#P4}\*E{#P6}  
 MOT = E{#P2}\*E{#P4}\*E{#P6}\*TBA  
 DiscardProb = P{#P2=BS AND #P4=NS1 AND #P4=NS2}  
 DiscardRate = P{#P2=BS AND #P4=NS1 AND #P4=NS2}\*AR

UtilizationS1 = 0.5999999823 UtilizationS2 = 0.5999999823  
 Throughput = 7.9999999823 Throughput = 7.9999999823  
 MOS = 0.152380823774 MOS = 0.152380823774  
 Throughput = 3.999999962302 Throughput = 3.999999962302  
 MST = 0.119047603722 MST = 0.119047603722  
 DiscardProb = 9.424E-9 DiscardRate = 7.5395E-8

## Redes Estocásticas

### MMnIn2K

**Servidores com características diferentes.**

UtilizationS1 = 0.376547230927  
 UtilizationS2 = 0.376547230927  
 ThroughputS1 = 3.765472309273  
 ThroughputS2 = 4.234527682749  
 Throughput = 7.999999992022

MOS = 0.103515658175  
 MSS = 0.818825103722  
 MST = 0.102353137965  
 MOT = 0.012938457272  
 DiscardProb = 9.97E-10  
 DiscardRate = 7.978E-9

## Redes Estocásticas

### Throughput de transições K-server semantics

$$\text{Throughput}(T_0) = \sum_{i=1}^n P\{\text{EnablingDegree}(T_0) = i\} \times i\lambda$$

Where  $n$  is the highest enabling degree of  $T_0$ .

# Redes Estocásticas

## Throughput de transições *K-server semantics*

Throughput( $T_0$ ) =  $\pi(s_0) \times 2\lambda + \pi(s_1) \times \lambda$   
 Throughput( $T_0$ ) =  $P(m(P_0) = 2) \times 2\lambda + P(m(P_0) = 1) \times \lambda$   
 Throughput( $T_0$ ) =  $P(\text{EnablingDegree}(T_0) = 2) \times 2\lambda + P(\text{EnablingDegree}(T_0) = 1) \times \lambda$   
 $TP(T_0) = P(\#P0 = 2) \times 0.2 + P(\#P0 = 1) \times 0.1 = 0.009954751$

Directly from the CTMC:

$\pi(s_2) = 0.9049773755656109$   
 $\pi(s_1) = 0.09049773755656108$   
 $\pi(s_0) = 0.004524886877828055$   
 Throughput( $T_0$ ) =  $\pi(s_0) \times 2\lambda + \pi(s_1) \times \lambda = 0.009954751$

# Redes Estocásticas

## Exemplo – Banco

Todas as transições têm SSS, exceto a transição Service, que tem ISS.

Arriving\_Time = 2  
 Service\_Time = 4  
 Work\_Slot\_Time = 120  
 Resting\_Time = 15

Number\_of\_Client\_in\_the\_Queue = 74.8073013  
 System\_Time = 18.3025546  
 Probability\_of\_at\_least\_one\_Server\_not\_being\_serving = 0.0  
 Waiting\_Time = 18.3823380  
 Probability\_Client\_Does\_Not\_Enter\_the\_Bank = 0.0

# Redes Estocásticas

## Análise Qualitativa

### Structural Analysis Output

ESTRUCTURAL ANALYSIS ...

RGS: Does\_Not\_Enter Start\_Serving  
 Warning: inner confusion between Start\_Serving and Does\_Not\_Enter  
 Warning: direct external (inhibitor) confusion between Start\_Serving and Does\_Not\_Enter

The net contains 3 P-invariants:  
 Queue + Queue\_Capacity = QS  
 Servers\_Available + Servers\_Out\_of\_Service + Client\_Being\_Served + NS  
 Client + Client\_Active\_In\_Bank + Client\_Cannot\_Enter\_the\_Bank + NC

All places are covered by p-invariants.

### EXTENDED CONFLICT SET

Priority Immediate Transitions

- 1 Enter
- 1 Does\_Not\_Enter Start\_Serving

Removing temporary files

Structural Analysis finished.

### Estimate Statespace Output

Estimating statespace ...  
 Result of estimation (based on state equation with backtracking):  
 Statespace = 1268  
 Time passed with computation: 7.11 s  
 Removing temporary files

Estimate Statespace finished.

### Traps Output

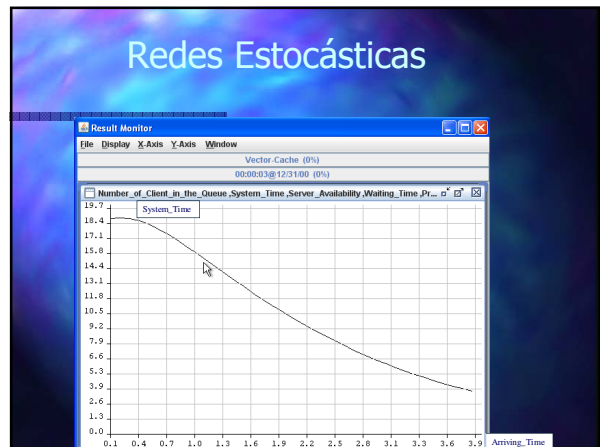
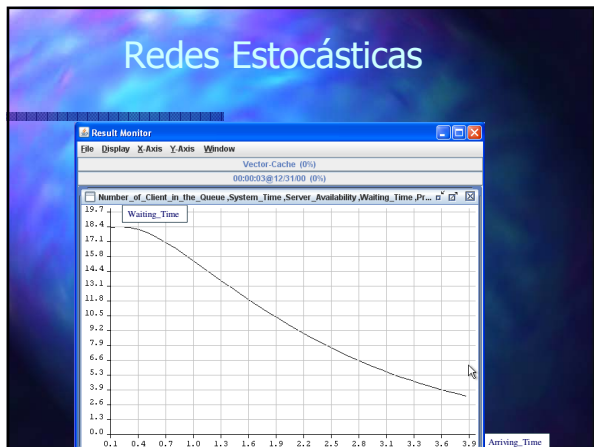
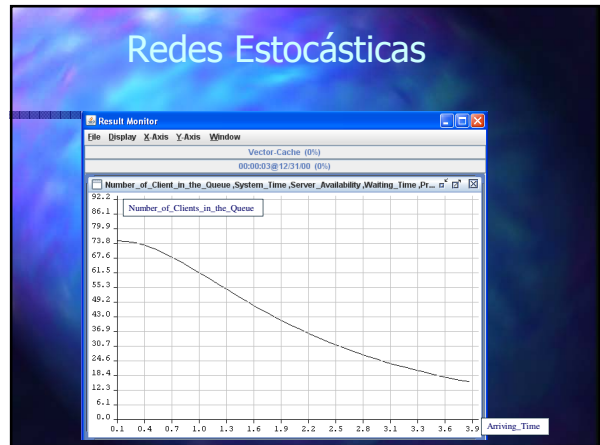
Removing temporary files  
 Calculation of Traps:  
 Time passed with computation: 0.14 s  
 No. of traps = 3  
 MARKING: 2 (Servers\_Available Servers\_Out\_of\_Service Client\_Being\_Served)  
 MARKING: 1 (Client\_Client\_Active\_In\_Bank Client\_Cannot\_Enter\_the\_Bank)  
 MARKING: 75 (Queue Queue\_Capacity)

Traps finished.

### Siphons Output

Removing temporary files  
 Calculation of Siphons:  
 Time passed with computation: 0.17 s  
 No. of siphons = 3  
 MARKING: 2 (Servers\_Available Servers\_Out\_of\_Service Client\_Being\_Served)  
 MARKING: 1 (Client\_Client\_Active\_In\_Bank Client\_Cannot\_Enter\_the\_Bank)  
 MARKING: 75 (Queue Queue\_Capacity)

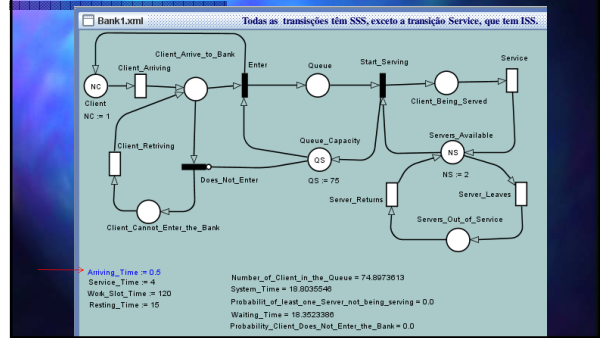
Siphons finished.




# Redes Estocásticas




# Redes Estocásticas




# Redes Estocásticas



# Redes Estocásticas



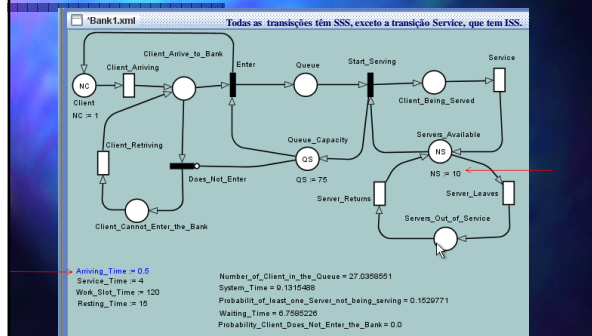
# Redes Estocásticas




# Redes Estocásticas



## Redes Estocásticas

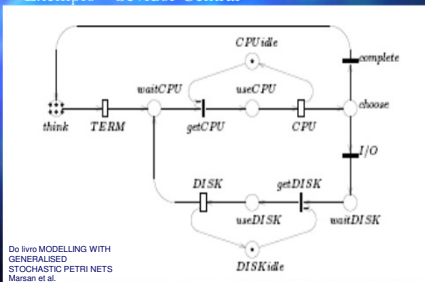


## Redes Estocásticas



## Redes Estocásticas

### Exemplo – Servidor Central



## Redes Estocásticas

### Aproximando Outras Distribuições

- Variáveis Suplementares
- Aproximação por Fases
- *Moment Matching*

Para encontrar uma distribuição por fase adequada para uma distribuição genérica, duas atividades são fundamentais:

- Determinar o tipo de aproximação necessária.
- Encontrar os parâmetros numéricos da aproximação.

## Redes Estocásticas

### Aproximação por Fases

Pontos a serem considerados na escolha de uma aproximação por fases.

- **Qualidade da aproximação:** quanto mais próximo for a distribuição por fase da distribuição real, melhor.
- Medidas de aproximação:
  - *Moment matching*
  - Encontrar um pdf (ou cdf) que seguem a pdf real numa determinada região de interesse.

## Redes Estocásticas

### Aproximação por Fases

Pontos a serem considerados na escolha de uma aproximação por fases.

- **Número de Estados da Aproximação:** é importante fazer com que o número de estados seja o menor possível.
- **Facilidade da obtenção do modelo markoviano resultante:** pode ser possível obter uma aproximação que gere excelentes resultados. No entanto, pode não ser fácil a integração no modelo markoviano resultante.

## Redes Estocásticas

- **Aproximação por Fases**

Pontos a serem considerados na escolha de uma aproximação por fases.

- Facilidade de obtenção dos parâmetros da aproximação: quanto mais parâmetros sejam necessários para especificar a aproximação, mais difícil se torna para encontrá-los.

## Redes Estocásticas

*t, μ<sub>E</sub>, n (fases)*

- **Aproximação por Fases**
- **Distribuição de Erlang**
  - $\tau = \tau_1 + \tau_2$  ( $\lambda_1 = 1/\mu_1, \lambda_2 = 1/\mu_2$ )
  - $f_{\tau}(t) = (f_{\tau_1} * f_{\tau_2})(t) = \lambda_1 \lambda_2 (e^{-\lambda_1 t} - e^{-\lambda_2 t}) / (\lambda_1 - \lambda_2)$
- Generalizando para n fases iguais a  $\lambda$ .
  - $f_{\tau}(t) = (\lambda^n t^{n-1} e^{-\lambda t}) / (n-1)!, t \geq 0$

Parâmetros:  $n, \lambda$ ; Valor Esperado:  $\mu_E = n/\lambda$   
 Variância:  $1/n\lambda^2$  ( $\lambda$  - de cada fase)

## Redes Estocásticas

**Distribuição Especificada (empírica)**

- **Moment Matching**

- Se  $\mu_D/\sigma_D = 1$  então uma transição exponencial é suficiente.  $\lambda_1 = 1/\mu_D$

## Redes Estocásticas

**Distribuição Especificada (empírica)**

- **Moment Matching**

- Se  $\mu_D/\sigma_D = n \neq 1, n \in \mathbb{Z}$   
 $\gamma = (\mu_D/\sigma_D)^2 = n^2, \lambda = \gamma/\mu_D = n^2/\mu_D$

## Redes Estocásticas

**Distribuição Especificada (empírica)**

- **Moment Matching**

Erlang distribution  
 $CV < 1$        $\gamma = \left(\frac{1}{CV}\right)^2$   
 $\frac{1}{CV} = \frac{E[t]}{\sigma} = \frac{\mu_D}{\sigma_D} = n$        $\lambda = \frac{\gamma}{E[t]}$   
 $n \in \mathbb{Z}, n > 1$        $delay = \frac{1}{\lambda}$

## Redes Estocásticas

**Distribuição Especificada (empírica)**

- **Moment Matching**

- Se  $\mu_D/\sigma_D > 1$  e  $\mu_D/\sigma_D \notin \mathbb{Z}$   
 $(\mu_D/\sigma_D)^2 - 1 \leq \gamma < (\mu_D/\sigma_D)^2$   
 $\lambda_1 = 1/\mu_1, \mu_1 = \mu_D + \text{sqrt}(\gamma(\gamma+1) \sigma_D^2 - \gamma \mu_D^2) / (\gamma+1)$   
 $\lambda_2 = 1/\mu_2, \mu_2 = \gamma \mu_D \pm \text{sqrt}(\gamma(\gamma+1) \sigma_D^2 - \gamma \mu_D^2) / (\gamma+1)$



## Redes Estocásticas

Distribuição Especificada (empírica)

■ *Moment Matching*

$-$  Se  $\mu_D/\sigma_D > 1$  e  $\mu_D/\sigma_D \notin \mathbb{Z}$   
 $-$   $(\mu_D/\sigma_D)^2 - 1 \leq \gamma < (\mu_D/\sigma_D)^2$   
 $\lambda_1 = 1/\mu_1$   $\mu_1 = \mu_D + \text{sqrt}(\gamma(\gamma+1) \sigma_D^2 - \gamma \mu_D^2)/(\gamma+1)$   
 $\lambda_2 = 1/\mu_2$   $\mu_2 = \gamma \mu_D \pm \text{sqrt}(\gamma(\gamma+1) \sigma_D^2 - \gamma \mu_D^2)/(\gamma+1)$   
 $\text{delay}_1 = 1/\lambda_1, \text{delay}_2 = 1/\lambda_2$

## Redes Estocásticas

Distribuição Determinística

■ *Moment Matching*

Aproxima-se, fazendo-se  $\sigma_D$  pequeno  
 $\Rightarrow \gamma$  torna-se grande.

$-$  Se  $\mu_D/\sigma_D = x \neq 1, x \in \mathbb{Z}$  ( $c = \sigma_D/\mu_D < 1$ )  
 $\gamma = x^2, \lambda = x^2/\mu_D$

## Redes Estocásticas

■ Aproximação por Fases

■ Distribuição de Hiperexponencial

$f_{\tau}(t) = \omega_1 f_{\tau_1}(t) + \omega_2 f_{\tau_2}(t), t \geq 0$   
 $\sum_{j=1}^n \omega_j = 1$

Parâmetros:  
 Valor Esperado:  $\mu_H = \sum_j \omega_j / \lambda_j$   
 Variância:  $2 \sum_j \omega_j / \lambda_j^2 - \mu_H^2$

## Redes Estocásticas

Distribuição Especificada (empírica)

■ *Moment Matching*

$\mu_H = \omega_1 / \lambda_{H1}$  (para esta Hiperexponencial)  
 $\sigma_H = [\text{sqrt}(2 \omega_1 - \omega_1^2)] / \lambda_{H1}$   
 $-$  Se  $\mu_D/\sigma_D < 1$  ( $c = \sigma_D/\mu_D > 1$ )

$\omega_1 = 2\mu_D^2 / (\mu_D^2 + \sigma_D^2), \omega_2 = 1 - \omega_1$   
 $\lambda_h = 2\mu_D / (\mu_D^2 + \sigma_D^2)$

## Redes Estocásticas

Distribuição Especificada (empírica)

■ *Moment Matching*

$\mu_H = \omega_1 / \lambda_{H1}$  (para esta Hiperexponencial)  
 $\sigma_H = [\text{sqrt}(2 \omega_1 - \omega_1^2)] / \lambda_{H1}$   
 $-$  Se  $\mu_D/\sigma_D < 1$  ( $c = \sigma_D/\mu_D > 1$ )  
 $\omega_1 = 2\mu_D^2 / (\mu_D^2 + \sigma_D^2), \omega_2 = 1 - \omega_1$   
 $\lambda_h = 2\mu_D / (\mu_D^2 + \sigma_D^2)$   
 $\text{delay} = 1/\lambda_h$

## Redes Estocásticas

Distribuição de Cox

Cox generalizou a idéia de composição de fase exponenciais para gera probabilidades e taxas complexas.

Nestes slides  $\mu_k$  são taxas (diferentemente dos anteriores)

## Redes Estocásticas

**Distribuição de Cox**

Nestes slides  $\mu$  é taxa (diferentemente dos anteriores)

Simplificamos em dois casos particulares:

- Caso  $CV \leq 1$

$$\mu_j = \mu \quad j = 1, \dots, k,$$

$$a_j = 1 \quad j = 2, \dots, k-1.$$

$$\bar{X} = \frac{b_1 + k(1 - b_1)}{\mu}$$

$$\text{var}(X) = \frac{k + b_1(k - 1)(b_1(1 - k) + k - 2)}{\mu^2}$$

$$c_X^2 = \frac{k + b_1(k - 1)(b_1(1 - k) + k - 2)}{[b_1 + k(1 - b_1)]^2}$$

$$k = \left\lceil \frac{1}{c_X^2} \right\rceil \quad \text{> Número de fases}$$

$$b_1 = \frac{2kc_X^2 + (k - 2) - \sqrt{k^2 + 4 - 4kc_X^2}}{2(c_X^2 + 1)(k - 1)}$$

$$\mu = \frac{k - b_1 \cdot (k - 1)}{\bar{X}} \quad \text{> Taxa das fases}$$

## Redes Estocásticas

**Distribuição de Cox**

Nestes slides  $\mu_1$  e  $\mu_2$  são taxas (diferentemente dos anteriores)

Simplificamos em dois casos particulares:

- Caso  $CV > 1$

$$\bar{X} = \frac{1}{\mu_1} + \frac{a}{\mu_2}$$

$$\text{var}(X) = \frac{\mu_2^2 + a\mu_1^2(2 - a)}{\mu_1^2 \cdot \mu_2^2}$$

$$c_X^2 = \frac{\mu_2^2 + a\mu_1^2(2 - a)}{(\mu_2 + a\mu_1)^2}$$

$$\mu_1 = \frac{2}{\bar{X}}$$

$$\mu_2 = \frac{1}{\bar{X}c_X^2}$$

$$a = \frac{1}{2c_X^2}$$

## Redes Estocásticas

Exemplo – Servidor Central

Do livro MODELLING WITH GENERALISED STOCHASTIC PETRI NETS Marsan et al.

## Redes Estocásticas

Exemplo – Servidor Central com Interrupção

Do livro MODELLING WITH GENERALISED STOCHASTIC PETRI NETS Marsan et al.

## Modelando Políticas de Memória


Erlang com 3 Fases

## Modelando Políticas de Memória

Conflito entre Erlang com 3 fases e exponencial


## Modelando Políticas de Memória

- Erlang com 3 fases com interrupção




## Modelando Políticas de Memória

- Conflito com política Age Memory



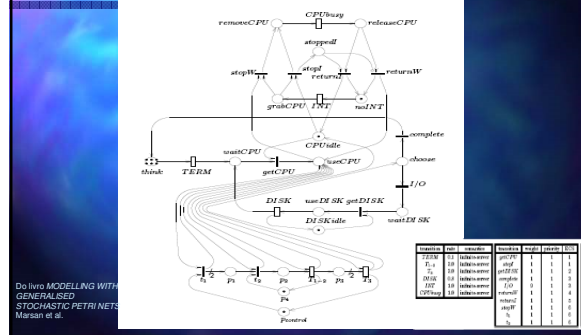
## Modelando Políticas de Memória

- Conflito com política Enabling Memory



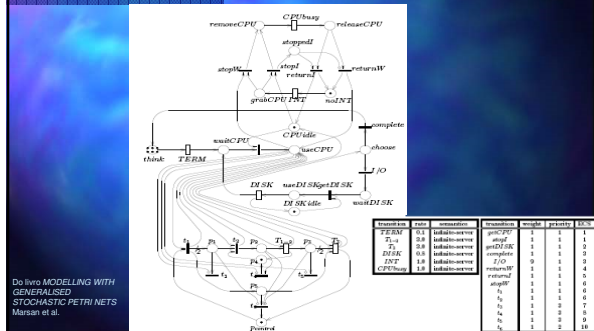
## Modelando Políticas de Memória

- Conflito com política Enabling Memory

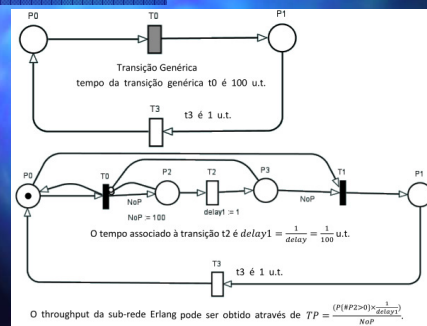


## Modelando Políticas de Memória

- Conflito com política Enabling Memory



## Throughput de uma Transição Erlang



## DSPN – Deterministic and Stochastic PN

- Definição
- DSPN = (P, T, I, O, H, II, M<sub>0</sub>, D, W) - Marsan, Chiola 1987
  - P é o conjunto de lugares,
  - $T = T_{im} \cup T_{exp} \cup T_{det}$ ,
  - I, O, H denotam funções (vetores de funções) de entrada, saídas e de inibição que mapeiam transições em multi-conjuntos de lugares:
  - $i_k(t_j): P \times T \rightarrow \mathbb{N}, \forall p_k \in P, \forall t_j \in T$
  - $o_k(t_j): P \times T \rightarrow \mathbb{N}, \forall p_k \in P, \forall t_j \in T$
  - $h_k(t_j): P \times T \rightarrow \mathbb{N}, \forall p_k \in P, \forall t_j \in T$
  - II:  $T_{im} \rightarrow \mathbb{N}$ ,
  - M<sub>0</sub> é marcação inicial,


## DSPN – Deterministic and Stochastic PN

- DSPN = (P, T, I, O, H, II, M<sub>0</sub>, D, W)
  - D:  $T_{exp} \cup T_{det} \rightarrow \mathbb{R}^+ \cup \{0\}$  atribui um tempo médio às transições estocásticas e um tempo constante às transições determinísticas,
  - W:  $T_{exp} \rightarrow \mathbb{R}^+ \cup \{0\}$  atribui um peso às transições imeditadas.
- Quando  $T_{det} = \emptyset$  a DSPN é uma GSPN.
- Embora seja possível a análise de modelos com mais de uma transição determinística simultaneamente habilitadas, as ferramentas, normalmente, somente implementam métodos que considerem apenas uma transição determinística habilitada por marcação.

## DSPN – Deterministic and Stochastic PN

### Exemplo:

- $T_{im} = \{t_1\}$
- $T_{exp} = \{t_3, t_4\}$
- $T_{det} = \{t_2\}$



## EDSPN – Extended Deterministic and Stochastic PN


- Definição
- EDSPN = (P, T, I, O, H, II, M<sub>0</sub>, D, W) -
  - P é o conjunto de lugares,
  - $T = T_{im} \cup T_{exp} \cup T_{det}$ ,
  - I, O, H denotam funções (vetores de funções) de entrada, saídas e de inibição que mapeiam transições em multi-conjuntos de lugares:
  - $i_k(t_j): P \times T \times \mathbb{N}^{|P|} \rightarrow \mathbb{N}, \forall p_k \in P, \forall t_j \in T$
  - $o_k(t_j): P \times T \times \mathbb{N}^{|P|} \rightarrow \mathbb{N}, \forall p_k \in P, \forall t_j \in T$
  - $h_k(t_j): P \times T \times \mathbb{N}^{|P|} \rightarrow \mathbb{N}, \forall p_k \in P, \forall t_j \in T$
  - II:  $T_{im} \rightarrow \mathbb{N}$ ,
  - M<sub>0</sub> é marcação inicial,

## EDSPN – Extended Deterministic and Stochastic PN

- EDSPN = (P, T, I, O, H, II, M<sub>0</sub>, D, W)
  - D:  $(T_{exp} \cup T_{det}) \times \mathbb{N}^{|P|} \rightarrow \mathbb{R}^+ \cup \{0\}$  atribui um tempo médio às transições estocásticas e um tempo constante às transições determinísticas,
  - W:  $T_{im} \times \mathbb{N}^{|P|} \rightarrow \mathbb{R}^+ \cup \{0\}$  atribui um peso às transições imeditadas.

## EDSPN – Extended Deterministic and Stochastic PN


### Exemplo:



Modelo em DSPN para limpar p<sub>1</sub>.  
Modelo em EDSPN para limpar p<sub>1</sub>. (arcos dependentes de marcação).

## EDSPN – *Extended Deterministic and Stochastic PN*

- Tempos dependentes da carga



## Redes Estocásticas

- Considerações
  - ⊗ Redes de Petri estocásticas são uma representação compacta de alto nível das CTMC
  - ⊗ Equivalência com CTMC
  - ⊗ Análise quantitativa
  - ⊗ Análise qualitativa
  - ⊗ Modelagem de sistemas concorrentes, não-determinísticos e assíncronos. Modelagem de sincronismo, escolha, mútua exclusão etc

## Redes Estocásticas

- Algumas Referências:
  - ⊗ Modelling with Generalized Stochastic Petri Nets, A. Marsan et al, John Wiley & Sons, 1995.
  - ⊗ Performance Modelling with Deterministic and Stochastic Petri Nets, C. Lindermann, John Wiley & Sons, 1998.
- <http://www.daimi.au.dk/PetriNets>