

Modelagem para Avaliação de Desempenho e Confiabilidade

Paulo Maciel

Centro de Informática

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

- 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 isomórfico 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.

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*

Classificação da Técnicas de Avaliação de Desempenho

```

graph TD
    A[Avaliação de Desempenho] --> B[Measurements]
    A --> C[Modelagem]
    B --> D[Medição]
    B --> E[Prototipação]
    C --> F[Análise Probabilística]
    C --> G[Análise Determinística]
    F --> H[Simulação]
    F --> I[Análise Operacional]
  
```

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 tempos de foras distintas, por exemplo:
 - por **Intervalos**
 - de forma **Determinística**
 - de forma **Probabilística**

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*

Modelagem para Análise de Desempenho

Algumas Medidas

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

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

- Informações observáveis
- Jeff Buzen and Peter Denning

Análise Operacional

- **Variáveis operacionais**
 - **T**: Período de observação
 - **K**: Número de recursos do sistema
 - **A_i**: Número total de solicitações (ex.: chegadas) do recurso i no período T.
 - **A₀**: Número total de solicitações (ex.: chegadas) ao sistema no período T.
 - **C_i**: Número total de serviços finalizados pelo recurso i no período T.
 - **C₀**: Número total de serviços finalizados pelo sistema no período T.
 - **B_i**: Tempo de ocupação do recurso i no período T.

Análise Operacional

Métricas derivadas (*derived measures*)

- Si:** Tempo médio de serviço por finalização relativa ao recurso i ; $S_i = Bi/Ci$
- Ui:** Tempo médio de serviço por finalização relativa ao recurso i ; $U_i = Bi/T$
- Xi:** throughput (ex.: finalizações por unidade de tempo) do recurso i ; $X_i = Ci/T$
- λi:** taxa de chegada (ex.: chegadas por unidade de tempo) ao recurso i ; $\lambda_i = Ai/T$
- X0:** throughput do sistema; $X_0 = C_0/T$
- Vi:** Número médio de visitas ao recurso i por solicitação; $V_i = Ci/C_0$

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.

$$J_0 = V_{CPU} \xrightarrow{B_{CPU}} \frac{36\text{ s}}{60\text{ s}} = 0,6$$

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

Análise Operacional

Exemplo1

Suponha que ao se monitorar uma 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.

- Qual a taxa de chegada ao sistema (λ_0)?
- Qual é o throughput do sistema (X_0)?
- Qual é a utilização da CPU(U_{CPU})?
- Qual é o tempo médio por transações finalizadas pelo sistema (S_0)?

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

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.

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

$$A_0 = 1800 \text{ transactions}$$

$$C_0 = 1800 \text{ transactions}$$

$$\lambda_0 = \frac{A_0}{T} = \frac{1800}{60} = 30\text{ t/s}$$

$$X_0 = \lambda_0 = \frac{1800}{60} = 30\text{ t/s}$$

$$X_0 = X_i = \frac{1800}{60} = 30\text{ t/s}$$

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

$$U_0 = U_i = \frac{B_{CPU}}{C_{CPU}} = \frac{36}{1800} = 0,02\text{ s}$$

$$\lambda_i = \lambda_0 = 30\text{ t/s}$$

$$X_0 = X_i = 30\text{ t/s}$$

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 milisegundos 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

- 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

- Exemplo2

bandwidth: 56000 bps Time to send 16,17 (TSB)
 $\text{TSB} = 1/\text{bandwidth} \Rightarrow 1/56000 = 0,000017857$

(TSB) Time to send 1 byte = $8 \times \text{TSB} = 0,00014286$

Packet size = 1500 bytes
 $Time \text{ to } send \text{ 1 packet (TSP)} = 1500 \times 0,00014286 = 0,214286$

Arrival rate (λ) = 3 packets/s
 $\lambda = TSP \times \lambda = 0,214286 \times 3 = 0,642857$

Análise Operacional

- Service Demand Law

– Service demand de um recursos 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

- 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

- 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

Service Demand Law

$$D_i = U_i \times S_i = \frac{C_i \times S_i}{C_0} = \frac{C_i \times U_i}{C_0} \times \frac{X_i}{X_0}$$

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

And since $C_0 \propto X_0$, then $B_i = U_i / X_0$


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


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/solichtação




Análise Operacional

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 respectivas 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 (λ_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 tempo médio de uma transação qualquer (não necessariamente a que visitou o recurso i) no recurso i (D_i)?



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 (λ_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

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:

$$U = \lambda \times S$$

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

$$\lambda = 0,14 \text{ chamadas por minuto}$$

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

(C - tempo entre chamadas)

Análise Operacional

Little's Law

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

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

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

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

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:

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

$$R = \sum_i^M V_i \times R_i$$

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.

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

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

Bottleneck Analysis

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

Sistema com N componentes em série:

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:

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

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

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:

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

Análise Operacional

- Bottleneck Analysis**
- Problemas:** Um servidor de arquivos foi monitorado por 10^4 s. Observaram-se 40000 requisições ao servidor. Cada requisição ao servidor requer, em média, quatro acessos a uma unidade de disco. O tempo médio de serviço provido pela unidade de disco é 10 ms. Durante esse período de observação, o processador teve uma utilização em torno de 60%.
 - Estime o *time demand* do processador.
 - Estime a utilização do disco.
 - Quem é o "gargalo" desse sistema se considerarmos que o período de observação e carga adotados são significativos?

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 dezenas de 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?

Modelo de Probabilidade

- Espaço amostral (Ω):** um conjunto de todos os possíveis "estados" observáveis (eventos elementar) de um fenômeno aleatório.
- Conjunto de eventos (S):** um conjunto de todos os possíveis eventos de interesse.
- Probabilidade dos eventos (P):** a probabilidade de ocorrência de um evento observável.

PM é a tupla: $PM = (\Omega, S, P)$.

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**

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

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 aleatórios.
- Um experimento aleatório pode ter muito resultados. Cada resultado é um **ponto amostral** (evento elementar) e tem uma probabilidade.
- Um espaço amostral Ω : 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)

Modelagem de Fenômenos Aleatórios

```

graph LR
    Medicao[Medição] --> Analise[Análise Estatística]
    subgraph Representacao [Representação dos parâmetros de entrada]
        Analise
    end
    Analise --> Modelo[Modelo Probabilístico]
    subgraph Resultados [Resultados]
        Modelo
    end
    Validação{Validação} --> Analise
    Validação --> Modelo
  
```







Eventos

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

$$E \subseteq \Omega$$

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

$\Omega \in S$ $A \in S \Rightarrow \bar{A} \in S$ $A, B \in S \Rightarrow A \cup B, A \cap B \in S$
--



Consequências

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

$$P(\emptyset) = 0$$

$$P(\bar{A}) = 1 - P(A)$$
- Se A e B são dois eventos que não são mutuamente exclusivos:

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

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. $X: \omega \rightarrow \mathbb{R}$. $\{\omega : \omega \in \Omega, X(\omega) \leq x\} x \in \mathbb{R}$.

Consequências: Eventos não mutuamente exclusivos

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

- Soma dos Produtos Disjuntos (SDP):

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

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

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.

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

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 Ω 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 Ω .

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: $P(X=k) = \binom{n}{k} p^k (1-p)^{n-k}$

Ver slides de medição

Variáveis Aleatórias Resumo

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

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: $P(X=k) = p (1-p)^{k-1}$

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

- 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 ($E(X) = \bar{X}$)

$$(\bar{X})^n = \sum_{\forall k} (k - \bar{X})^n \cdot P(X=k)$$

Variáveis Aleatórias Resumo

■ Discreta

- O **primeiro momento** é o **valor esperado**.
- O **primeiro momento central** é **0**
- O **segundo momento central (variância)**
 - $\text{var}(X) = \sigma^2 = (\bar{X})^2 = \sum_{\forall k} (k - \bar{X})^2 \cdot P(X=k)$
- 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} .

$$M_X(t) = E[e^{tX}]$$

$$= \sum_i e^{tx_i} p_X(x_i) \quad X \text{ discreta.}$$

$$= \int_{-\infty}^{+\infty} e^{tx} f_X(x) dx \quad X \text{ contínua.}$$

Variáveis Aleatórias Resumo

■ Função Geratriz de Momentos

$$e^{tX} = 1 + tX + t^2 X^2 / 2! + \dots + t^r X^r / r! + \dots$$

$$\begin{aligned} f(t) &= e^{(-a)t} \\ &= 1 - a + \frac{a^2 t^2}{2} - \frac{a^3 t^3}{6} + \frac{a^4 t^4}{24} - \frac{a^5 t^5}{120} + \frac{a^6 t^6}{720} - \frac{a^7 t^7}{5040} + \frac{a^8 t^8}{40320} - \frac{a^9 t^9}{362880} + \dots \end{aligned}$$

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

Variáveis Aleatórias Resumo

■ Discreta

Bernoulli

■ **Parâmetro: p :**

■ **Valor Esperado = p ,**

■ **Variância = $p(1-p)$,**

■ **Coeficiente de variação = $(1-p)/p$**

■ **Função geratriz de momentos**

$$M_{X_j}(t) = q + p e^t$$

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

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

Discreta

Geométrica

- Parâmetro: p ;
- Valor Esperado = $1/p$,
- Variância = $(1-p)/p^2$,
- Coeficiente de variação = $(1-p)$
- Função geratriz de momentos

$$M_{X_j}(t) = p^t / (1-qe^t)$$

Variáveis Aleatórias Resumo

Contínua

Probability density function (pdf)

$$f_X(x) = df_X(x) / dx$$

■ Como $F_X(x)$ não é decrescente, então $f_X(x) \geq 0$

$$\int_{-\infty}^{+\infty} f_X(x) dx = 1$$

$$P(x_1 \leq X \leq x_2) = \int_{x_1}^{x_2} f_X(x) dx$$

$$P(X=x) = \int_x^\infty f_X(x) dx = 0$$

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

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
 - $(\bar{X}-\bar{X})^n = \int_{-\infty}^{+\infty} (x-\bar{X})^n \cdot f_X(x) dx$

Variáveis Aleatórias Resumo


- Contínua
 - O segundo momento central (variância)
 - $\sigma^2 = (\bar{X}-\bar{X})^2 = \int_{-\infty}^{+\infty} (x-\bar{X})^2 \cdot f_X(x) dx$
 - 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:
- $P(A|M) = \frac{P(A \cap M)}{P(M)}$
- Caso $M \subset A$ então $P(A|M)=1$
- Caso $A \subset M$ então $P(A|M) = \frac{P(A)}{P(M)}$



Probabilidade Condicional

- Caso $M \subset A$ então $P(A|M)=1$
- Caso $A \subset M$ então $P(A|M) = \frac{P(A)}{P(M)}$



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

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

84


Distribuição Exponencial

- Often used to model

- Interarrival times between two IP packets (or voice calls)
- Service times at a file (web, compute, database) server
- Time to failure, time to repair, time to reboot etc.

- The use of exponential distribution is an assumption that needs to be validated with experimental data; if the data does not support the assumption, then other distributions may be used

Distribuição Exponencial




Distribuição Exponencial

- For instance, Weibull distribution is often used to model times to failure;
- Lognormal distribution is often used to model repair time distributions
- Markov modulated Poisson process is often used to model arrival of IP packets (which has non-exponentially distributed inter-arrival times)

86

Distribuição Exponencial




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

t $t+u$

Probabilidade Condisional

Distribuição Exponencial

Variável Aleatória 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: $\text{var}(X) = 1/\lambda^2$
- Propriedade:
 Não possui memória

Distribuição Exponencial

Um exemplo:

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

- $P\{X>(80+80) | X > 80\} = \frac{P\{X>(80+80) \wedge X > 80\}}{P\{X>80\}}$ Probabilidade
- $P\{X>(80+80) | X > 80\} = \frac{P\{X>160\}}{P\{X>80\}}$ Condisional
- $P\{X>(80+80) | X > 80\} = \frac{e^{-0,01*(80+80)}}{e^{-0,01*80}} = e^{-0,01*80} = 0,449329$

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

Distribuição Exponencial

Variável Aleatória Exponencial

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

Distribuição Exponencial

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

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

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

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

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

94

Distribuição Exponencial

- Contínua
- Exponencial
 - Parâmetro: λ ,
 - 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

The memoryless property can be demonstrated with conditional reliability:

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

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

95

Lembre-se destas fórmulas

Distribuição Exponencial

- Mathematically (CDF and pdf are given as):

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

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

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

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

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

93

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

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

96

Distribuição Hiperexponencial

Hiperexponencial

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

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

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

Distribuição Erlang

Erlang-k



1 2 ... k fase

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

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

Parâmetros: k, μ ; Valor Esperado: k/μ ; Variância: k/μ^2 ; Coeficiente de variação: $1/\sqrt{k}$; Função geratriz de momentos


$M_X(t) = (1-t/\lambda)^k$



Distribuição Hiperexponencial


Hiperexponencial

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



Distribuição Erlang

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



Distribuição Hipo-exponencial

- Hipo-exponencial

Parâmetros: μ_1, μ_2

Valor Esperado: $1/\mu_1 + 1/\mu_2$

Variância: $1/\mu_1^2 + 1/\mu_2^2$

- Coeficiente de variação: $[\sqrt{\mu_1^2 + \mu_2^2}] / (\mu_1 + \mu_2) < 1$

Distribuição Hipo-exponencial

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

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

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

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

104

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

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

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

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:

$$\begin{aligned} \bullet F_X(t) &= 1 - [\mu_2 / (\mu_2 - \mu_1) e^{-\mu_2 t}] + [\mu_1 / (\mu_2 - \mu_1) e^{-\mu_1 t}], \quad t \geq 0 \\ \bullet f_X(t) &= [(\mu_1 \mu_2) / (\mu_1 - \mu_2)] (e^{-\mu_2 t} - e^{-\mu_1 t}), \quad t \geq 0 \end{aligned}$$

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:

$$f_X(x) = \sum_{i=1}^k a_i \mu_i e^{-\mu_i x}, \quad t \geq 0$$

$$a_i = \prod_{j=1, j \neq i}^k [\mu_j / (\mu_j - \mu_i)], \quad 1 \leq i \leq k$$

$$\text{Valor Médio} = \sum_{i=1}^k 1/\mu_i$$



Variáveis Aleatórias Resumo

- Uma função de uma variável aleatória ($Y=f(X)$) é uma variável aleatória com Valor Esperado
- $E[f(X)] = \sum_{k=1}^{\infty} f(k) \cdot P(X=k)$
- Uma função de uma variável aleatória ($Y=g(X)$) é uma variável aleatória com Valor Esperado

Função densidade de Probabilidade de X

$$E[g(X)] = \int_{-\infty}^{+\infty} g(x) \cdot f_X(x) dx$$

Variáveis Aleatórias Resumo

Se $f(X) = X$

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

Variáveis Aleatórias Resumo

- Exemplo

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

Portanto:

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

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

Variáveis Aleatórias Resumo

1. Se $f(X) = aX + b$

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

Por definição

$$\begin{aligned} \text{Var}(aX + b) &= E[(aX + b) - E(aX + b)]^2 \\ &= E[aX + b - (aE(X) + b)]^2 \\ &= E(aX - aE(X))^2 \\ &= E(a^2(X - E(X))^2) = a^2E(X - E(X))^2 = a^2\text{Var}(X). \end{aligned}$$

Variáveis Aleatórias Resumo

Quando $Y=f(X)$ é muito complicada, os cálculos de $E(f(X))$ e $\text{Var}(f(X))$ podem ser difíceis. Pode-se obter aproximações de $E(f(X))$ e $\text{Var}(f(X))$ 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

2. Se $f(X) = b$

- Valor Esperado
 - $E(b) = b$
- Variância
 - $\text{Var}(b) = 0$

Variáveis Aleatórias Resumo

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


Variáveis Aleatórias Resumo

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

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

Variáveis Aleatórias Multidimensionais Resumo

Múltiplas Variáveis Aleatórias



Variáveis Aleatórias Resumo

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

- Suponha uma variável aleatória t , onde $E[t]=20\text{s}$ e $\text{Var}(t)=5\text{s}^2$. 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

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

Múltiplas Variáveis Aleatórias

- Seja Ω 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

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

[Retornar](#)

Probabilidade Marginal: Caso Discreto


x_1	1	2	3	4	5	$p_2(x_2)$
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 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



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 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 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

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

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

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

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

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

Variáveis Aleatórias Multidimensionais Resumo

Linearidade do Valor Esperado

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

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

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

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[X1]
E[X1]						E[X1+X2]	3,1000

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

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



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)
 $\sum_i x_i p_X(x_i) \sum_j y_j p_Y(y_j) =$
 $E[X]E[Y]$

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 da linearidade do valor esperado, temos:

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

Ver também o slide 101

Variáveis Aleatórias Multidimensionais Resumo

Soma de Variâncias

Sejam X e Y duas variáveis aleatórias e seja

$$Z = X + Y$$

$$\begin{aligned} \text{Portanto } \text{Var}[Z] &= \text{Var}[X + Y] \\ &= \text{Var}[X] + \text{Var}[Y] + 2 \times \text{Cov}(X, Y) \end{aligned}$$

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

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 $\forall s_i \in S, p_{ij} = 0, \forall s_j \in S$.
- 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 $p_{ij} > 0 \quad \forall s_i, s_j \in S$ (todo estado s_j é alcançável de qualquer estado s_i).

Variáveis Aleatórias Multidimensionais Resumo

Soma de Variâncias

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

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

Pois $a_x = 1$ e $a_y = -1$

$$\begin{aligned} \text{Var}[X - Y] &= a_x^2 \text{Var}[X] + a_y^2 \text{Var}[Y] \\ &= (1)^2 \text{Var}[X] + (-1)^2 \text{Var}[Y] \\ &= \text{Var}[X] + \text{Var}[Y] \end{aligned}$$

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.

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 (*Continuos Time Markov Chain - CTMC*)
 - Processos de espaço de estados e tempo contínuos

Continuos 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 $p_{ij}(s,t) = P\{X(t)=j | X(s)=i\}$. Pode ser representada na forma matricial por $H(s,t) = [p_{ij}(s,t)]$

A equação de Chapman-Kolmogorov

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

Na forma matricial, temos:

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

Continuos 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:

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

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

Continuos 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:

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

Continuos 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

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

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

Continuos 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

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

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

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

Continuos Time Markov Chain

■ Equação de Chapman-Kolmogorov

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

$$p_i(t,t+h) = hq_{ii}(t) + o(h)$$

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

Dado que $\sum_j p_j(s,t) = 1, \forall i$, portanto:

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

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

Continuos Time Markov Chain

■ Soluções para Steady-States

$$\Pi Q = 0$$

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

Onde π_s fornece a steady-state probability de um sistema estar no estado s .

■ Soluções Transientes

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

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

Continuos Time Markov Chain

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

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

- 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

Sharpe
(share via Desktop)

Exemplo

- Tamanho do buffer=11
- λ
- μ
- FCFS

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

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

- 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.]

Continuos 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 [Boch et al.]

Continuos Time Markov Chain

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

$\pi_0 = 5.06605425 \times 10^{-1}$ $\pi_5 = 2.42068626 \times 10^{-2}$ $\pi_{10} = 1.04731260 \times 10^{-2}$ $\pi_{15} = 3.95578062 \times 10^{-3}$
 $\pi_1 = 9.01648794 \times 10^{-2}$ $\pi_6 = 3.04223846 \times 10^{-2}$ $\pi_{11} = 1.31936488 \times 10^{-2}$ $\pi_{16} = 5.95104472 \times 10^{-3}$
 $\pi_2 = 8.01465589 \times 10^{-2}$ $\pi_7 = 3.49578293 \times 10^{-2}$ $\pi_{12} = 1.59621117 \times 10^{-2}$
 $\pi_3 = 7.12413851 \times 10^{-2}$ $\pi_8 = 3.81098122 \times 10^{-2}$ $\pi_{13} = 9.97433581 \times 10^{-4}$
 $\pi_4 = 6.33256751 \times 10^{-2}$ $\pi_9 = 7.97946839 \times 10^{-3}$ $\pi_{14} = 2.30657440 \times 10^{-3}$

Continuos Time Markov Chain

Exemplo

$\lambda = 20 \text{ tps}, \text{ COV} = 1$
 $\mu = 40 \text{ tps}, \text{ COV}_{TS} = 1$

$$E[ST] = \frac{1}{\mu} = \frac{1}{40} = 0.025$$

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)

Continuos Time Markov Chain

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

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

$$\gamma = \left(\frac{E[ST]}{\sigma_{ST}}\right)^2 = 4$$

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

$\pi_0 = 5.06605 \times 10^{-1}$ $\pi_{S1} = 3.04878 \times 10^{-1}$ $\pi_{S2} = 1.27697 \times 10^{-1}$
 $\pi_{S3} = 4.76084 \times 10^{-2}$ $\pi_{S4} = 2.21877 \times 10^{-2}$

Utilization = 0.493395

Continuos Time Markov Chain

Exemplo

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

$$E[ST] = 0.025s$$

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($\gamma=4, \mu_E=160$).

Continuos Time Markov Chain



Exemplo

Sistema Computacional com degradação

C:\\$harpé-Gui\SHARPE GUI Examples\Markov\Degradable

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.



Continuos Time Markov Chain

State Transition Rate Diagram

$$Q = \begin{bmatrix} -\lambda & \lambda & 0 \\ 0 & -\lambda & \lambda \\ \mu & 0 & -\mu \end{bmatrix}$$

$$\sum_{s \in S} \pi_s = 1$$

$$\prod Q = 0$$







$$(\pi_0, \pi_1, \pi_2) Q = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$$

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

$$\lambda \pi_0 - \lambda \pi_1 = 0$$

$$-\lambda \pi_1 - \mu \pi_2 = 0$$

$$\pi_0 + \pi_1 + \pi_2 = 1$$



OBM

Continuos Time Markov Chain

- M/M/1 queueing system**

<p>Throughput</p> <p>Desde que $\lambda < \mu$</p> $E[X] = \frac{\rho}{1 - \rho} \quad 0 \leq \rho < 1$ <p>O throughput é λ</p> $E[X] \rightarrow \infty \quad \rho \rightarrow 1$ <p>Se $\lambda > \mu$ throughput é μ</p> $E[S] = \frac{1/\mu}{1 - \rho} \quad 0 \leq \rho < 1 \quad E[W] = \frac{\rho}{\mu(1 - \rho)}$ $E[S] \rightarrow \infty \quad \rho \rightarrow 1 \quad E[W] \rightarrow \infty$	<p>Tamanho médio da fila</p>
--	------------------------------

OBM

Continuos Time Markov Chain

- M/M/1/K queueing system**

<p>Utilização</p> <p>Se $\lambda > \mu$ a utilização $\rightarrow 1$</p> <p>Se $\lambda < \mu$ a utilização $= \rho = \frac{\lambda}{\mu}$</p>	$\pi_0 = \frac{1 - \rho}{1 - \rho^{K+1}}$ $\pi_n = \begin{cases} \frac{1 - \rho}{1 - \rho^{K+1}} \rho^n & \text{if } 0 \leq n \leq K \\ 0 & \text{if } n > K \end{cases}$ <p>Probabilidade de Descarte</p> $P_D = \pi_K = (1 - \rho) \frac{\rho^K}{1 - \rho^{K+1}}$
--	---

OBM

Continuos Time Markov Chain

- M/M/n queueing system**

<p>Utilização</p> $\rho = \lambda / m\mu$	$\pi_n = \begin{cases} \pi_0 \frac{(m\rho)^n}{n!} & n = 1, 2, \dots, m-1 \\ \pi_0 \frac{m^m \rho^n}{m!} & n = m, m+1, \dots \end{cases}$ <p>Throughput</p> <p>Desde que $\lambda < \mu m$</p> <p>O throughput é λ</p> <p>Se $\lambda \geq \mu m$ throughput é μ</p>
---	--

OBM

Continuos Time Markov Chain

- M/M/1/K queueing system**

<p>Tamanho médio da fila</p> $E[X] = \frac{\rho}{1 - \rho^{K+1}} \left[\frac{1 - \rho^K}{1 - \rho} - K\rho^K \right]$ <p>Mean response time</p> $E[S] = \frac{E[X]}{\lambda(1 - \pi_K)}$ <p>$\lambda(1 - \pi_K)$- taxa de chegada dos clientes admitidos</p>
--

OBM

Continuos Time Markov Chain

- M/M/n queueing system**

<p>Tamanho médio da fila</p> $E[X] = m\rho + \frac{(m\rho)^m}{m!} \frac{\rho}{(1 - \rho)^2} \pi_0 \quad \lambda < \mu m$ <p>Probabilidade de um cliente chegar e não encontrar o servidor disponível</p> $E[X] \rightarrow \infty \quad \lambda \geq \mu m$	<p>Fórmula C de Erlang</p> $P_Q = P[X \geq m] = \sum_{n=m}^{\infty} \pi_n$ $P_Q = \frac{(m\rho)^m}{m!} \frac{\pi_0}{1 - \rho}$
<p>Mean response time</p> $E[S] = \frac{1}{\mu} + \frac{1}{\mu} \frac{(m\rho)^m}{m!} \frac{\pi_0}{m(1 - \rho)^2} \quad \lambda < \mu m$ <p>$E[S] \rightarrow \infty \quad \lambda \geq \mu m$</p>	






OBM

Discrete Time Markov Chain

- O comportamento de uma rede estocástica é representado por **DTMC**

Matriz de Propriedades de Próximo Estados

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



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 block¹ 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<4) // <0.5>
5.     {
6.         for(y=0; y<10; y++) { // <9>
7.             x++;
8.         }
9.     } else { // <0.5>
10.        x = 0;
11.    }
12. }

```

Continuos Time Markov Chain

$\lambda \Pi_1(t) + \Pi_2(t)$	$\lambda \Pi_1(t)$
$\lambda \Pi_2(t) + \Pi_3(t)$	$\lambda \Pi_2(t)$
$\lambda \Pi_3(t) + \Pi_4(t)$	$\lambda \Pi_3(t)$
$\lambda \Pi_4(t) + \Pi_5(t)$	$\lambda \Pi_4(t)$
$\lambda \Pi_5(t) + \Pi_1(t)$	$\lambda \Pi_5(t)$

Soluções Transientes (Laplace Tranform)

Final transient solution through LT.

$$\frac{d\Pi_1(t)}{dt} + \lambda \Pi_1(t) - \mu \Pi_2(t) = 0 \quad (1)$$

$$\frac{d\Pi_2(t)}{dt} + \mu \Pi_2(t) - \lambda \Pi_1(t) = 0 \quad (2)$$

$$\frac{d\Pi_3(t)}{dt} = \lambda \text{LT}[\Pi_1(t)] - \Pi_3(0)$$

by LT:

Discrete Time Markov Chain

Mapping Applications to Discrete Time Markov Chains

```

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

```

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

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

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

$$v_j = \frac{\pi_j}{\pi_i}, \quad E = \sum_{b=c} v_b \times \left(\sum_{c=a} I_{b,c} \times (e_c + O_b \times e_a) \right)$$

$$T = \sum_{b=c} v_b \times \left(\sum_{c=a} I_{b,c} \times (t_c + O_b \times t_a) \right)$$

Mathematica Example

Excel e abrir também o SHARPE.

Universidade de São Paulo / Modelos de Modelos / SHARPE / www.spm.unicamp.br

Continuos Time Markov Chain

Then, considering (1):

$$\lambda \text{LT}[\Pi_1(t)] - \Pi_1(0) + \text{LT}[\lambda \Pi_1(t)] = \text{LT}[\lambda],$$

$$\lambda \text{LT}[\Pi_1(t)] - 1 + \text{LT}[\lambda] \times \text{LT}[\Pi_1(t)] = \text{LT}[\lambda]$$

Stop here for a while.

Let's consider (2):

$$\frac{d\Pi_2(t)}{dt} + \mu \Pi_2(t) - \lambda \Pi_1(t) = 0$$

We know that $\Pi_1(t) + \Pi_2(t) = 1$, then: $\Pi_1(t) = 1 - \Pi_2(t)$,

$$\frac{d\Pi_2(t)}{dt} + \mu \Pi_2(t) - \lambda (1 - \Pi_2(t)) = 0$$

Continuos Time Markov Chain

- Soluções Transientes**

$$\frac{d\Pi_1(t)}{dt} = \Pi_1(t)Q, \quad \Pi_1(0) = (\pi_1(0), \dots, \pi_{n-1}(0))$$

$$\frac{d\Pi_2(t)}{dt} = \lambda \text{LT}[\Pi_1(t)] - \Pi_2(0)$$

Onde $\pi_s(t)$ 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)

Continuos Time Markov Chain

Applying LT:

$$\frac{d\Pi_2(t)}{dt} = \lambda \text{LT}[\Pi_1(t)] - \Pi_2(0)$$

As $\Pi_2(0) = 0$, then:

$$\frac{d\Pi_2(t)}{dt} = \lambda \text{LT}[\Pi_1(t)].$$

Hence:

$$\lambda \text{LT}[\Pi_1(t)] + \text{LT}[\mu \Pi_2(t)] - \text{LT}[\lambda \Pi_2(t)] = 0$$

$$\lambda \text{LT}[\Pi_1(t)] + \text{LT}[\mu \Pi_2(t)] - \text{LT}[\lambda \Pi_2(t)] = 0$$

Continuos Time Markov Chain

$$\begin{aligned} & \lambda L\Gamma[\pi_2(t)] + \mu L\Gamma[\pi_2(t)] = \frac{\lambda}{\lambda - \mu} \\ & \lambda L\Gamma[\pi_2(t)] = 0 \\ & \lambda L\Gamma[\pi_2(t)] + (\mu + \lambda) \times L\Gamma[\pi_2(t)] = \frac{\lambda}{\lambda - \mu} \\ & L\Gamma[\pi_2(t)](1 + \mu + \lambda) = \frac{\lambda}{\lambda - \mu} \\ & L\Gamma[\pi_2(t)] = \frac{\lambda}{\lambda(1 + \mu + \lambda)} \\ & \pi_1(t) + \pi_2(t) = 1 \\ & L\Gamma[\pi_1(t)] + L\Gamma[\pi_2(t)] = L\Gamma[1] \\ & L\Gamma[\pi_1(t)] + L\Gamma[\pi_2(t)] = 1 \\ & L\Gamma[\pi_1(t)] = \frac{1}{\lambda} - \frac{\lambda}{\lambda(1 + \mu + \lambda)} \end{aligned}$$

Continuos Time Markov Chain

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

Continuos Time Markov Chain

$$\begin{aligned} & \lambda L\Gamma[\pi_2(t)] = \frac{\lambda}{\lambda(1 + \mu + \lambda)} \\ & \text{then applying } L^{-1}[L\Gamma[\pi_2(t)]] = \\ & \text{so: } \pi_2(t) = L^{-1}\left[\frac{\lambda}{\lambda(1 + \mu + \lambda)}\right] \\ & \text{that: we now say that, there are A and B,} \\ & L^{-1}\left[\frac{\lambda}{\lambda(1 + \mu + \lambda)}\right] = L^{-1}\left[\frac{A}{\lambda} + \frac{B}{\lambda + \mu + \lambda}\right] \\ & \text{so } \frac{\lambda}{\lambda(1 + \mu + \lambda)} = \frac{A}{\lambda} + \frac{B}{\lambda + \mu + \lambda} \\ & \lambda = A(1 + \mu + \lambda) + B\lambda \end{aligned}$$

Continuos Time Markov Chain

$$\begin{aligned} \pi_2(t) &= L^{-1}\left[\frac{\lambda}{\lambda(1 + \mu + \lambda)}\right] = \frac{\lambda}{\mu + \lambda}(1 + e^{-(\mu + \lambda)t}) \\ \pi_1(t) + \pi_2(t) &= 1 \quad \therefore \quad \pi_1(t) = 1 - \pi_2(t) \\ \pi_1(t) &= 1 - \frac{\lambda}{\mu + \lambda}(1 + e^{-(\mu + \lambda)t}) \\ \pi_1(t) &= \frac{\mu + \lambda - \lambda(1 + e^{-(\mu + \lambda)t})}{\mu + \lambda} \end{aligned}$$

Continuos Time Markov Chain

$$\begin{aligned} & \lambda = \lambda(A + B) + A(\mu + \lambda) \\ & \text{for } \lambda = 0 \\ & \boxed{A = \frac{\lambda}{\mu + \lambda}} \\ & \text{then} \\ & \lambda = \frac{\lambda}{\mu + \lambda} (1 + \mu + \lambda) + B\lambda \\ & \lambda = \frac{\lambda}{\mu + \lambda} + \left(\frac{\lambda}{\mu + \lambda} + \frac{\lambda}{\mu + \lambda}\right) + B\lambda \\ & \lambda = \frac{\lambda}{\mu + \lambda} + \lambda\left(\frac{1}{\mu + \lambda} + 1\right) + B\lambda \quad \boxed{B = \frac{\lambda}{\mu + \lambda}} \end{aligned}$$

Continuos Time Markov Chain

$$\begin{aligned} \pi_1(t) &= \frac{\mu}{\mu + \lambda} (1 - e^{-(\mu + \lambda)t}) \\ \pi_2(t) &= \frac{\lambda}{\mu + \lambda} (1 - e^{-(\mu + \lambda)t}) \end{aligned}$$

Continuos Time Markov Chain

- Soluções Transientes

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

Uma solução formal para o sistema acima é:
 $\Pi(t) = \Pi(0)e^{Qt}$

Pela série de Taylor/MacLaurin, temos:
 $e^{Qt} = I + Qt/1! + (Qt)^2/2! + (Qt)^3/3! + \dots$

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

Continuos Time Markov Chain

- Uniformização

CTMC

Estado de menor tempo de permanência

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

Sabe-se também que:

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

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

Continuos 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-esparsa 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

Continuos Time Markov Chain

- Uniformização

CTMC

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

DTMC

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

Sabe-se também que:

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

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

Continuos Time Markov Chain

- Uniformização

CTMC

Estado de menor tempo de permanência

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

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

Sabe-se também que:

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

Continuos Time Markov Chain

- Uniformização

CTMC

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

DTMC

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

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

Continuos Time Markov Chain

- Uniformização

CTMC  \rightarrow DTMC 

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

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

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

- Soluções Transientes

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

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

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

Continuos Time Markov Chain

- Uniformização
- $Q = \begin{pmatrix} -4 & 2 & 2 \\ 1 & -2 & 1 \\ 6 & 0 & -6 \end{pmatrix}$
- $P = \frac{1}{6} \begin{pmatrix} 2 & 2 & 2 \\ 1 & 4 & 1 \\ 6 & 0 & 0 \end{pmatrix}$
- $P = I + Q/\lambda$
- $Q = \lambda(P - I)$
- $\lambda \geq \max_{\forall s \in S} \{|q_{ij}|\}$



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:

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

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

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

Continuos Time Markov Chain

- Soluções Transientes

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

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

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

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

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

$$\| \Pi(t) - \tilde{\Pi}(t) \|_{\infty} = \| [\Pi(0) e^{-\lambda t} \sum_{n=0}^{\infty} (\lambda Pt)^n / n!] - [\Pi(0) e^{-\lambda t} \sum_{n=0}^{k_e} (\lambda Pt)^n / n!]] \|_{\infty} \leq$$

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

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

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:

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

Desta forma:

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

Continuos Time Markov Chain

- Solução Transiente (exemplo)**

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

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

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

Continuos Time Markov Chain

- Soluções Transiente**

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

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

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

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)**

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

$P = I + Q/\lambda$

$Q = \lambda(P - I)$

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

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

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

Para $t = 0.1 \Rightarrow ke = 5$

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

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

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:

$$\hat{\Pi}(0) = \Pi(0) = (1,0,0) \text{ obtém-se:}$$

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

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

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 $t = 0,1 \Rightarrow ke = 5$

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

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

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 $t = 0,1 \Rightarrow ke = 5$

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

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

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 $t = 0,1 \Rightarrow ke = 5$

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

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

Continuos Time Markov Chain

- Solução Transiente (exemplo)

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

Para $t = 0,1 \Rightarrow ke = 5$

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


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

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

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

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

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

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


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)

Solução Estacionária

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

$$\begin{aligned} & \Omega P = \Omega \\ & \sum_{j \in S} \omega_j = 1 \end{aligned}$$

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)

- 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)

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 transitória é mais sofisticada.

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

- Exemplo:






Redes Temporizadas

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

Redes Temporizadas - PTPN -

Regra de Disparo



$$v(p_0) = 3$$


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 - PTPN -

Regra de Disparo



$$v(p_0) = 3$$


Instante=0

Redes Temporizadas

- Redes de Petri com Lugares Temporizados (PTPN)
(Sifakis77)
- Definição: $PTPN = (P, T, F, K, W, M_0, \Gamma, v)$, 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) – $W: F \rightarrow N$
 M_0 – Marcação inicial – $M_0: P \rightarrow N$
 $\Gamma = \{\gamma_1, \gamma_2, \dots, \gamma_r\}$ números reais denominada base de tempo.
 $v: P \rightarrow \Gamma$ um mapeamento que $v(p) = \gamma_j$

Redes Temporizadas - PTPN -

Regra de Disparo




$$v(p_0) = 3$$

Instante=1

Redes Temporizadas - PTPN -

- Regra de Disparo



$v(p_0) = 3$

Instante=2

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 Temporizadas - PTPN -

- Regra de Disparo



$v(p_0) = 3$

Instante=3

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:

- Duração (disparo em três fases)

- Marcas são consumidas nos 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:

- 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 é 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.

```

graph TD
    p0((p0)) -- "da, ta" --> p1((p1))
    p0 -- "db" --> p2((p2))
  
```

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 permaneceram habilitadas com o disparo matêm seus valores presentes (*continue*)

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:

- 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:

- 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:

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

```

graph TD
    ta[t] --> p1((p1))
    ta --> p0((p0))
    p1 -- "d" --> p1
  
```

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:
 - Multiple-server firing semantics k=2*

A Petri net diagram showing place p0 with three tokens, transition ta with duration d=3, and place p1. A graph below shows tokens being fired at times t=3, t=6, and t=9.

Redes de Petri Temporizadas

- Tempo Associado às Transições -

- Conceitos Básicos:
 - Single-server firing semantics*

A Petri net diagram showing place p0 with three tokens, transition ta with duration d=3, and place p1. A graph below shows tokens being fired at times t=3, t=6, and t=9.



Redes de Petri Temporizadas

- Tempo Associado às Transições -

- Conceitos Básicos:
 - Infinite-server firing semantics*







A Petri net diagram showing place p0 with three tokens, transition ta with duration d=3, and place p1. A graph below shows tokens being fired at times t=3, t=6, and t=9.






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 –
 $M_0 : P \rightarrow \mathbb{R}$

A Petri net diagram with places p1, p2, and p3. Arcs from p1 to p2 and p1 to p3 are labeled n. Arc from p2 to p3 is labeled m. Arc from p3 back to p1 is labeled k. There is also a self-loop arc on p3 labeled t.







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 Generalizada (GSPN)

Semântica de Disparo de Transição

- Regras de habilitação**
 $M[t_j] > , \quad M(pi) \geq I(pi, t_j) \text{ e } M(pi) < H(pi, t_j)$
 $\forall pi \in P$
- 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.
- Transiões 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
 $M'[pi] = M_0(pi) - I(pi, t_i) + O(pi, t_i), \quad \forall pi \in P$

Redes Estocásticas

- Assumindo-se que todas as transições operam em *Single Server Semantics (SS)* e taxas (*rates*) independentes da marcação, tem-se:

$$d_{ij} = \begin{cases} \sum_{t_k \in e(M_j)} \omega_k & i \neq j \\ -q_i & i=j \end{cases}$$

onde $Q = [d_{ij}]$ gerador infinitesimal (matriz de taxas)
 $q_i = \sum_{t_k \in e(M_i)} \omega_k$
 ω_k é a taxa de disparo de t_k .

$e(M_i) = \{t_k \mid t_k \in e(M_i) \wedge M_i[t_k] > M_i\}$ é o conjunto de transições que estão habilitadas em M_i e cujo disparo levam a M_j , $e(M_j)$ conjunto de transições habilitadas em M_j .

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)

- Definição:
 $GSPN = (P, T, I, O, H, \Pi, W, M_0)$
- P, T, I, O definidos como usualmente.
 $H : P \times T \rightarrow \mathbb{R}$ é a função de mapeamento de que representam os arcos inhibidores
- $\Pi : T \rightarrow \begin{cases} 0 & \text{se } t \text{ for temporizada} \\ \mathbb{R}^+ & \text{se } t \text{ for imediata} \end{cases}$
- $W : T \rightarrow \mathbb{R}$ (ou $W : T \times M \rightarrow \mathbb{R}^+$) é 1 uma função que associa taxas de distribuição exponencial às transições temporizadas e 2 pesos usados na computação das probabilidades de disparo das transiões imediatas
- M_0 : Marcação inicial - $M_0 : P \rightarrow \mathbb{R}$

Redes Estocásticas Generalizada (GSPN)

Grafo de Marcações





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

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

$$tm_i = 1/\lambda_j$$

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

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

λ_t é a taxa associada a transição t através da W

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:

$$p(t_k, M_j) = \lambda_k / \lambda_j, \quad \lambda_j = \sum_{t \in T_j} \lambda_t$$

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

λ_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

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

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

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

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

Redes Estocásticas

- Dadas $M_i \in VS(N)$, a probabilidade de se disparar t_k em M_i é:

$$p(t_k, M_i) = \omega_k / \omega_k(M_i),$$

$$\omega_k(M_i) = \sum_{l \in ECS(t_k) \wedge M_l[t_k]} \alpha_l$$

$ECS(t_k)$ – 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 , não importa a ordem de disparo, desde que a rede seja livre de confusão.

Redes Estocásticas

- Throughput rate de uma transição temporizada

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

$$S_2 = \{i \in \{1, 2, \dots, S\} \mid M_i[t_j]\}$$

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

Redes Estocásticas

- Tempo médio entre disparos de uma transição

$$T = 1/TR(t_j) = 1/(\sum_{i \in S2} p_i \cdot \lambda_j)$$

$$S_2 = \{ i \in \{1, 2, \dots, S\} \mid M_i[t_j] \}$$
 - p_i é a probabilidade estacionária de uma marcação M_i que habilita t_j
 - λ_j é a taxa associada à transição t_j

Redes Estocásticas

- Tempo médio de espera em um lugar

$$\text{Wait}(p_i) = \frac{\text{Em}(p_i)}{\sum_{j \in O(p_i)} TR(t_j)} = \frac{\text{Em}(p_i)}{\sum_{j \in O(p_i)} \text{Throughput}(t_j)}$$
 - $\text{Em}(p_i)$ é o número médio de marcas no lugar p_i .
 - $\text{TR}(t_j)$ throughput da transição t_j .

Redes Estocásticas

- Throughput rate de uma transição imediata
 - Pode ser calculada de uma transição exponencial e a estrutura do modelo GSPN.

$TR(t_j) = TR(t_i) \times (\omega_j / (\omega_j + \omega_p))$

t_j e t_k são as únicas transições de um ECS.

Redes Estocásticas

Representação explícita do descarte

MM1K

$\lambda = 8$, $\mu = 10$, $n = 1$, $k = 20$
\diamond OneToOpProcess(λ, μ, n, k)
QueueProperties(Q)

Basic Properties
QueueStation: M4&1/20
ArriveRate: 8
ServiceRate: 10
UtilizationFactor: 0.798138
Throughput: 7.98138
ServiceChannels: 1
SystemCapacity: 20
InitalState: 0

Performance Measures
MeanSystemSize: 3.80451
MeanSystemTime: 0.476673
MeanQueueSize: 3.00637
MeanQueueTime: 0.376673

Redes Estocásticas

- Littles's law

$$E[X] = \lambda E[s]$$
 (ergódico)

$E[X]$ - tamanho médio da fila.

$E[s]$ - Tempo médio de serviço do sistema.

λ - taxa de chegada

Redes Estocásticas







Representação implícita do descarte

MM2K


$\lambda = 8$, $\mu = 10$, $n = 2$, $k = 20$
\diamond OneToOpProcess(λ, μ, n, k)
QueueProperties(Q)

Basic Properties
QueueStation: M4&2/20
ArriveRate: 8
ServiceRate: 10
UtilizationFactor: 0.4
Throughput: 8
ServiceChannels: 2
SystemCapacity: 20
InitalState: 0


Performance Measures
MeanSystemSize: 0.952381
MeanSystemTime: 0.119048
MeanQueueSize: 0.152281
MeanQueueTime: 0.0190476




Redes Estocásticas



Redes Estocásticas




Redes Estocásticas




Redes Estocásticas




Redes Estocásticas



Redes Estocásticas




Redes Estocásticas




Redes Estocásticas

- Exemplo – Sevidor Central



Redes Estocásticas



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



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

Distribuição Especificada (empírica)

- *Moment Matching*



Se $\mu_D/\sigma_D = 1$ então uma transição exponencial é suficiente. $\lambda_1 = 1/\mu_D$

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

Distribuição Especificada (empírica)

- *Moment Matching*



Se $\mu_D/\sigma_D = x \neq 1$, $x \in Z$

$$\gamma = (\mu_D/\sigma_D)^2 = x^2, \lambda = \gamma/\mu_D = x^2/\mu_D$$

Redes Estocásticas

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 λ .
 - $f\tau(t) = (\lambda^n t^{(n-1)} e^{-\lambda t}) / (n-1)!$, $t \geq 0$

Parâmetros: n, λ ; Valor Esperado: $\mu_E = n/\lambda$
Variância: $1/n\lambda^2$ (λ - de cada fase)

Redes Estocásticas

Aproximação por Fases

Distribuição de Hiperexponencial


$$f\tau(t) = r_1 f\tau_1(t) + r_2 f\tau_2(t), t \geq 0$$

$$\sum_{j=1}^n r_j = 1$$

Parâmetros:

$$\text{Valor Esperado: } \mu_H = \sum_j q_j / \lambda_j$$

$$\text{Variância: } 2 \sum_j q_j / \lambda_j^2 - \mu_H^2$$



Redes Estocásticas

Distribuição Especificada (empírica)

- **Moment Matching**

$\mu_H = r_1/\lambda_H$ (para esta Hipereexponencial)
 $\sigma_H = [\sqrt{2(r_1 - r_1^2)}]/\lambda_H$

Se $\mu_D/\sigma_D < 1$ ($c = \sigma_D/\mu_D > 1$)

$$r_1 = 2\mu_D^2/(\mu_D^2 + \sigma_D^2), \quad r_2 = 1 - r_1$$

$$\lambda_h = 2\mu_D/(\mu_D^2 + \sigma_D^2),$$

Redes Estocásticas

Distribuição Determinística

- **Moment Matching**

Aproxima-se, fazendo-se σ_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

Distribuição Especificada (empírica)

- **Moment Matching**

Se $\mu_D/\sigma_D > 1$ e $\mu_D/\sigma_D \notin \mathbb{Z}$

$-(\mu_D/\sigma_D)^2 - 1 \leq \gamma < (\mu_D/\sigma_D)^2$

$\lambda_1 = 1/\mu_1 \quad \mu_1 = \mu_D \pm \sqrt{\gamma(\gamma+1) \sigma_D^2 - \gamma\mu_D^2}/(\gamma+1)$
 $\lambda_2 = 1/\mu_2 \quad \mu_2 = \gamma\mu_D \pm \sqrt{\gamma(\gamma+1) \sigma_D^2 - \gamma\mu_D^2}/(\gamma+1)$

Redes Estocásticas

Distribuição de Cox

Cox generalizou a idéia de composição de fase exponenciais para gerar probabilidades e taxas complexas.

Nestes slides μ_k são taxas (diferentemente dos anteriores)

Redes Estocásticas

Distribuição Especificada (empírica)

- **Moment Matching**

$\mu_H = r_1/\lambda_H$ (para esta Hipereexponencial)
 $\sigma_H = [\sqrt{2(r_1 - r_1^2)}]/\lambda_H$

Se $\mu_D/\sigma_D < 1$ ($c = \sigma_D/\mu_D > 1$)

$$r_1 = 2\mu_D^2/(\mu_D^2 + \sigma_D^2), \quad r_2 = 1 - r_1$$

$$\lambda_h = 2\mu_D/(\mu_D^2 + \sigma_D^2),$$

Redes Estocásticas

Distribuição de Cox

Nestes slides μ é taxa (diferentemente dos anteriores)

Simplificamos em dois casos particulares:

- Caso $CV_X \leq 1$

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

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




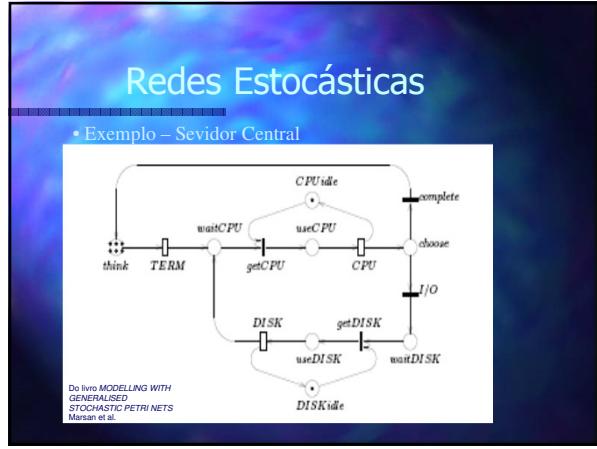


$$\text{var}(X) = \frac{k + b_1(k-1)(b_1(1-k) + k-2)}{\mu^2},$$





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

$k = \lceil \frac{1}{\sigma_X^2} \rceil \quad \triangleright$ Número de fases

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

$$\mu = \frac{k - b_1 \cdot (k-1)}{\bar{X}}. \quad \triangleright$$
 Taxa das fases






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

- Exemplo:



Modelo em EDSPN para limpar p_1 (arcos dependentes de marcação).


Modelo em DSPN para limpar p_1 .

EDSPN – Extended Deterministic and Stochastic PN

- Definição
- EDSPN = $(P, T, I, O, H, \Pi, M_0, D, W)$ -
 - 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:
 - $i_k(t_j): P \times T \times N^{|P|} \rightarrow N, \forall p_k \in P, \forall t_j \in T$
 - $o_k(t_j): P \times T \times N^{|P|} \rightarrow N, \forall p_k \in P, \forall t_j \in T$
 - $h_k(t_j): P \times T \times N^{|P|} \rightarrow N, \forall p_k \in P, \forall t_j \in T$
 - $\Pi: T_{im} \rightarrow N$,
 - M_0 é marcação inicial,

EDSPN – Extended Deterministic and Stochastic PN

- Tempos dependentes da carga



EDSPN – Extended Deterministic and Stochastic PN

- EDSPN = $(P, T, I, O, H, \Pi, M_0, D, W)$
 - $D: (T_{exp} \cup T_{det}) \times N^{|P|} \rightarrow \mathbb{R}^+ \cup \{0\}$ atribui um tempo médio às transições estocásticas e um tempo constante às transições determinísticas,
 - $W: T_{im} \times N^{|P|} \rightarrow \mathbb{R}^+ \cup \{0\}$ atribui um peso às transições imeditadas.

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. Lindemann, John Wiley &
Sons, 1998.
- <http://www.daimi.au.dk/PetriNets>