

Modelagem para Avaliação de Desempenho e Confiabilidade

Paulo Maciel

Centro de Informática

- Interpretações do Tempo -

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

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

Classificação da Técnicas de Avaliação de Desempenho



Modelos Temporizados

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

Modelos Temporizados

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


Modelagem para Análise de Desempenho

- **Algumas Medidas**
 - Tempo de Manufatura
 - *Throughput*
 - Utilização
 - Capacidade
 - Confiabilidade


Análise de Desempenho

- **Analíticos**
 - Determinísticos
 - Melhor e pior casos
 - Probabilísticos
 - Valores prováveis
- **Simulação**
 - Análise exaustiva
- **Implementação real**
 - Medidas obtidas do sistema real
 - *Benchmarks*
 - Protótipos


Redes de Petri



Redes Temporizadas



Redes Temporizadas



Redes Temporizadas

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

Redes Temporizadas Estocásticas

- ☒ Natkin - 1980
- ☒ Molloy - 1981
- ☒ Marsan et al. - 1984

É uma rede temporizada onde o *delay* associado à transição é uma variável aleatória de distribuição exponencial

Redes Temporizadas

Redes de Petri com Lugares Temporizados (PTPN) (Sifakis77)

Definição: $PTPN = (P, T, F, K, W, M_0, \Gamma, \nu)$, onde

P é o conjunto de lugares,

T o conjunto de transições,

$F \subseteq (P \times T) \cup (T \times P)$ uma relação que representa os arcos

W - Valoração (peso dos arcos) - $W: F \rightarrow \mathbb{N}$


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

$\Gamma = \{\gamma_1, \gamma_2, \dots, \gamma_r, \dots\}$ números reais denominada base de tempo.

$\nu: P \rightarrow \Gamma$ um mapeamento que $\nu(p) = \gamma_j$

Redes Temporizadas - PTPN -


Regra de Disparo



$\nu(p_0) = 3$

Redes Temporizadas - PTPN -

Regra de Disparo




$\nu(p_0) = 3$

Instante=0

Redes Temporizadas - PTPN -

Regra de Disparo




$\nu(p_0) = 3$

Instante=1

Redes Temporizadas - PTPN -

Regra de Disparo




$\nu(p_0) = 3$

Instante=2

Redes Temporizadas - PTPN -

Regra de Disparo



$\nu(p_0) = 3$

Instante=3

Redes de Petri Temporizadas - Tempo Associado às Transições -

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

Redes de Petri Temporizadas - Tempo Associado às Transições -

- **Conceitos Básicos:**
 - **Duração (disparo em três fases)**
 - Pode ser representada por uma rede com disparo atômico
 - Modelo mais compacto
 - O estado é uma informação mais complexa do que o modelo não-temporizado
 - **Disparo atômico**
 - Pode representar o modelo com duração
 - O conjunto de marcações alcançáveis é um sub-conjunto das marcações do modelo não-temporizado.

Redes de Petri Temporizadas - Tempo Associado às Transições -

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

Redes de Petri Temporizadas - Tempo Associado às Transições -

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

Redes de Petri Temporizadas - Tempo Associado às Transições -


- Como fica a memorização do tempo de habilitação anterior?

- **Continue**

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

- **Restart**

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



Redes de Petri Temporizadas - Tempo Associado às Transições -

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

• **Algumas políticas de memória podem ser construídas**

Redes de Petri Temporizadas

- Tempo Associado às Transições -

■ Conceitos Básicos:

- *Resampling*

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

Redes de Petri Temporizadas

- Tempo Associado às Transições -

■ Conceitos Básicos:

- *Enabling Memory*

- Após cada disparo os *timers* das **transições que ficaram desabilitadas** são re-iniciados (*restart*)
As **transições que permaneceram habilitadas** com o disparo matêm seus valores presentes (*continue*)

Redes de Petri Temporizadas

- Tempo Associado às Transições -

■ Conceitos Básicos:

- *Age Memory*

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


Redes de Petri Temporizadas

- Tempo Associado às Transições -

■ Conceitos Básicos:

- *Grau de Habilitação (Enabling Degree)*

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



Redes de Petri Temporizadas

- Tempo Associado às Transições -

■ Conceitos Básicos:

- Semântica de Temporização

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

Redes de Petri Temporizadas

- Tempo Associado às Transições -

■ Conceitos Básicos:


- *Single-server firing semantics*



Redes de Petri Temporizadas - Tempo Associado às Transições -

Conceitos Básicos:


- *Infinite-server firing semantics*



Redes de Petri Temporizadas - Tempo Associado às Transições -

Conceitos Básicos:

- *Multiple-server firing semantics k=2*



Classificação da Técnicas de Avaliação de Desempenho



Modelagem para Análise de Desempenho

Algumas Medidas

- Tempo de Manufatura
- *Throughput*
- Utilização
- Capacidade
- Confiabilidade

Modelagem para Análise de Desempenho

Modelagem para Análise de Desempenho

- Modelos para Simulação
- Modelos Analíticos
 - Cadeias de Markov
 - Teoria das Filas
 - Redes de Petri Estocásticas
 - Álgebras de Processo Estocásticas

Variáveis Aleatórias Resumo

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

Variáveis Aleatórias Resumo

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

Variáveis Aleatórias Resumo

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

Variáveis Aleatórias Resumo

- **Probability mass function (pmf)** – Seja 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

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

Variáveis Aleatórias Resumo

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

Variáveis Aleatórias Resumo

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

Variáveis Aleatórias Resumo

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

Variáveis Aleatórias Resumo

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

Variáveis Aleatórias Resumo

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

Variáveis Aleatórias Resumo

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

Variáveis Aleatórias Resumo

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

Variáveis Aleatórias Resumo

- Função Geratriz de Momentos
 - $e^{tX} = 1 + tX + \frac{t^2 X^2}{2!} + \dots + \frac{t^r X^r}{r!} + \dots$
- $$f(t) = e^{(-a \cdot t)}$$

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

Para $a=2$, tem-se:

$$= 1 - 2 \cdot t + 2 \cdot t^2 - \frac{4 \cdot t^3}{3} + \frac{2 \cdot t^4}{3} - \frac{4 \cdot t^5}{15} + \frac{4 \cdot t^6}{45} - \frac{8 \cdot t^7}{315} + \frac{2 \cdot t^8}{315} - \frac{4 \cdot t^9}{2835} + \dots$$
- Tomando a esperança:
 - $E[e^{tX}] = 1 + E[X] t + E[X^2] \frac{t^2}{2!} + E[X^r] \frac{t^r}{r!} + \dots$

Variáveis Aleatórias Resumo

- Procedimento para obtenção dos momentos
 - Determine $M_X(t)$ analiticamente para uma distribuição particular
 - Ache $E[X] = d^1/dt^1 M_X(t)|_{t=0}$

Variáveis Aleatórias Resumo

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

Variáveis Aleatórias Resumo

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

Variáveis Aleatórias Resumo

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

Variáveis Aleatórias Resumo

- Contínua
 - Uma variável aleatória que pode assumir qualquer valor no intervalo $[a, b]$, onde $-\infty \leq a, b \leq +\infty$, é denominada Variável Aleatória Contínua.
 - Cumulative Distribution Function (CDF)
$$F_X(x) = P(X \leq x)$$
 - Se $x < y$ então: $F_X(x) < F_X(y)$
 - $P(x < X \leq y) = F_X(y) - F_X(x)$

Variáveis Aleatórias Resumo

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

Variáveis Aleatórias Resumo

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

Variáveis Aleatórias Resumo

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

Variáveis Aleatórias Resumo

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

Variáveis Aleatórias Resumo


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

Variáveis Aleatórias Resumo

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

Probabilidade Condicional


- Seja A um evento arbitrário em um espaço amostral S . A probabilidade de que ocorra um evento A uma vez que M tenha ocorrido é denotado por $P(A/M)$ que é definido por:



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

Probabilidade Condicional

- Caso $M \subset A$ então $P(A/M)=1$




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




Distribuição Exponencial

Variável Aleatória Exponencial

- fdp exponencial
- $f_x(t) = \lambda e^{-\lambda t}, 0 \leq t < \infty$
- $CDF(t) = \begin{cases} 1 - e^{-\lambda t}, & 0 \leq t < \infty \\ 0, & \text{caso contrário} \end{cases}$
- Valor Esperado $E(X) = 1/\lambda$
- Variância: $var(X) = 1/\lambda^2$
- Propriedade: Não possui memória




Distribuição Exponencial



$P\{X>t\} = e^{-\lambda t}$
 $= 0,449329$
 $\lambda = 0,01 \Rightarrow$
 $E[X] = 1/\lambda = 100$
 $t = 80$

Distribuição Exponencial



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

Probabilidade Condicional

Distribuição Exponencial

Um exemplo:

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

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

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

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

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

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

Variáveis Aleatórias Resumo

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

Variáveis Aleatórias Resumo



Hiperexponencial

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


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

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

Variáveis Aleatórias Resumo




Exponencial
 $\lambda=0,01$



$E(t) = \int_0^{10000} e^{-(0.01t-0.01t)} dt = 100$

$\sigma = \sqrt{\int_0^{10000} [(t-100)^2 (0.01e^{-0.01t} + 0.01e^{-0.01t})] dt} = 100$

Hiperexponencial



$E(t) = \int_0^{10000} [(t-200)^2 (0.01e^{-0.01t} + 0.01e^{-0.01t})] dt = 200$

$\sigma = \sqrt{\int_0^{10000} [(t-200)^2 (0.01e^{-0.01t} + 0.01e^{-0.01t})] dt} = 200$

Variáveis Aleatórias Resumo

Hiperexponencial

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


Variáveis Aleatórias Resumo



- Erlang-k
- $F_X(x) = 1 - e^{-k\mu t} \sum_{j=0}^{k-1} (k\mu t)^j / j!, \quad t \geq 0$
- $f_X(x) = [(k\mu(k\mu t)^{k-1}) / (k-1)!] e^{-k\mu t}, \quad t \geq 0, k=1,2,\dots$
- Parâmetros: k, μ ;
- Valor Esperado: k/μ
- Variância: k/μ^2
- Coeficiente de variação: $1/\sqrt{k} \leq 1$
- Função geratriz de momentos
 $M_X(t) = (1-t/\lambda)^{-k}$


Variáveis Aleatórias Resumo

- Erlang-K
- Uma distribuição desconhecida de \bar{X} e $c \leq 1$ pode ser aproximada por uma
 - $k = [1/c^2]$
 - $\mu = 1/(c^2 k \bar{X})$



Variáveis Aleatórias Resumo

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



Variáveis Aleatórias Resumo

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

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

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

Variáveis Aleatórias Resumo

- Hipo-exponencial

- Parâmetros: μ_1, μ_2
- Valor Esperado: $1/\mu_1 + 1/\mu_2$
- Variância: $1/\mu_1^2 + 1/\mu_2^2$
- Coefficiente de variação: $[\text{sqrt}(\mu_1^2 + \mu_2^2) / (\mu_1 + \mu_2)] < 1$

Variáveis Aleatórias Resumo

- Contínua
- Uma distribuição desconhecida de \bar{X} como valor esperado e $0.5 < c^2 < 1$ pode ser aproximada por uma Hipo-exponencial
 - $\mu_1 = (2/\bar{X}) \{1 + \text{sqrt}[1 + 2(c^2 - 1)]\}^{-1}$
 - $\mu_2 = (2/\bar{X}) \{1 - \text{sqrt}[1 + 2(c^2 - 1)]\}^{-1}$

Variáveis Aleatórias Resumo

- Contínua


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

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


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

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

Variáveis Aleatórias Resumo



Variáveis Aleatórias Resumo



Variáveis Aleatórias Resumo

– Uma função de uma variável aleatória ($Y=f(X)$) é uma variável aleatória com Valor Esperado

$$E[f(X)] = \sum_{i=1}^n f(x_i) \cdot P(X=x_i)$$

– Uma função de uma variável aleatória ($Y=g(X)$) é uma variável aleatória com Valor Esperado

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

Função densidade de Probabilidade de X

Variáveis Aleatórias Resumo

■ Se $f(X) = X$

– Valor Esperado

$$E[f(X)] = E(X) = \mu$$

– Variância

$$Var[f(X)] = E\{[f(X) - E(f(X))]^2\}$$

$$= E\{(X - E(X))^2\} = E(X^2) - [E(X)]^2 \text{ (Variância de X)}$$

$$= Var(X) = \sigma^2$$

Variáveis Aleatórias Resumo



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

– Valor Esperado

$$E[f(X)] = aE(X) + b$$

– Variância

$$Var[f(X)] = a^2 Var(X)$$

Prova: $Var(aX + b) = a^2 Var(X)$.

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

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

$$= E\{a(X - E(X))^2\}$$

$$= E\{a^2(X - E(X))^2\} = a^2 E\{(X - E(X))^2\} = a^2 Var(X)$$

Variáveis Aleatórias Resumo

2. Se $f(X) = b$

– Valor Esperado

$$E(b) = b$$

– Variância

$$Var(b) = 0$$

Variáveis Aleatórias Resumo

– Exemplo

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

Portanto:

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

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

Variáveis Aleatórias Resumo

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

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

Resto da expansão

Variáveis Aleatórias Resumo

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

Variáveis Aleatórias Resumo

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

Seja X uma variável aleatória com $E[X]$ e $Var(X)$. Suponha que $Y=f(X)$. Portanto:

- $E[Y] \cong f(E[X]) + (f''(E[X]) \times Var(X))/2$
- $Var(Y) \cong (f'(E[X]))^2 \times Var(X)$

Variáveis Aleatórias Resumo

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

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


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

Múltiplas Variáveis Aleatórias




Variáveis Aleatórias Multidimensionais Resumo

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

Variáveis Aleatórias Multidimensionais Resumo

- Variáveis Aleatórias Bidimensionais (vetores aleatórios bidimensionais)




Variáveis Aleatórias Multidimensionais Resumo

- Probabilidade Bivariada
 - Caso Discreto: a cada resultado $[x_1, x_2]$ de $[X_1, X_2]$ associamos um número $p(x_1, x_2) = P(X_1 = x_1, X_2 = x_2)$, onde $p(x_1, x_2) \geq 0, \forall x_1, x_2$
$$\sum_{x_1} \sum_{x_2} p(x_1, x_2) = 1$$
 - Distribuição de probabilidade de $[X_1, X_2]$
$$([x_1, x_2], p(x_1, x_2)), \forall x_1, x_2$$

Variáveis Aleatórias Multidimensionais Resumo

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

$$\iint_{\mathbb{R}_{X_1 \times X_2}} f(x_1, x_2) dx_1 dx_2 = 1$$



Variáveis Aleatórias Multidimensionais Resumo

- Probabilidade Marginal
 - Caso Discreto : a distribuição marginal de X_1 é
$$p_1(x_1) = \sum_{x_2} p(x_1, x_2), \forall x_1$$

A distribuição marginal de X_2 é

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

Variáveis Aleatórias Multidimensionais Resumo




- Probabilidade Marginal: Caso Discreto

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

Variáveis Aleatórias Multidimensionais Resumo

Probabilidade Marginal: Caso Discreto



Variáveis Aleatórias Multidimensionais Resumo

Probabilidade Marginal

– Caso Contínuo : a distribuição marginal de X_1 é

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

A distribuição marginal de X_2 é

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

Variáveis Aleatórias Multidimensionais Resumo

Linearidade do Valor Esperado

– Sejam X e Y duas variáveis aleatórias e seja

$$Z = X + Y.$$

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

Variáveis Aleatórias Multidimensionais Resumo

Linearidade do Valor Esperado

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

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

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

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

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

Variáveis Aleatórias Multidimensionais Resumo

Linearidade do Valor Esperado

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

Variáveis Aleatórias Multidimensionais Resumo

Linearidade do Valor Esperado

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

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

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

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

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

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

Variáveis Aleatórias Multidimensionais Resumo

Linearidade do Valor Esperado

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

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

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

Variáveis Aleatórias Multidimensionais Resumo

Linearidade do Valor Esperado

Prova:

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

Variáveis Aleatórias Multidimensionais Resumo

Linearidade do Valor Esperado

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

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

Se $E(X_i)$ não divergem.

Variáveis Aleatórias Multidimensionais Resumo



Linearidade do Valor Esperado

Sejam X e Y duas variáveis aleatórias independentes e seja

$$Z = XY.$$

Portanto $E[Z] = E[XY] = E[X]E[Y]$

$$\text{Prova: } E[XY] = \sum_i \sum_j x_i y_j p(x_i, y_j) =$$

$$\sum_i \sum_j x_i y_j p_x(x_i) p_y(y_j) = \text{(dado que são independentes)}$$

$$\sum_i x_i y_j p_x(x_i) \sum_j y_j p_y(y_j) =$$

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

Variáveis Aleatórias Multidimensionais Resumo

Soma de Variâncias

Sejam X e Y duas variáveis aleatórias e seja

$$Z = X + Y$$

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

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

Variáveis Aleatórias Multidimensionais Resumo

Soma de Variâncias

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

Variáveis Aleatórias Multidimensionais Resumo

Soma de Variâncias

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

Devido à propriedade de linearidade do valor esperado, temos:

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

Ver também o slide 101

Variáveis Aleatórias Multidimensionais Resumo

Soma de Variâncias

$$Var(X + Y) = Var[X] + Var[Y] + 2Cov(X, Y)$$

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

$$Var(X + Y) = Var[X] + Var[Y]$$

Variáveis Aleatórias Multidimensionais Resumo

Soma de Variâncias

$$Var(X + Y) = Var[X] + Var[Y]$$

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

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

Ver também o slide 77

Variáveis Aleatórias Multidimensionais Resumo

Soma de Variâncias

$$Var(X - Y) = Var[X] + Var[Y]$$

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

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

$$Var[X - Y] = a_x^2 Var[X] + a_y^2 Var[Y]$$


$$= (1)^2 Var[X] + (-1)^2 Var[Y]$$

$$= Var[X] + Var[Y]$$

Notação de Kendall

A/B/m/K

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



$$A, B = \{M, D, G, E\}$$

- *M - Markovian,
- *D - Determinística,
- *G - General
- *E - Erlangian

Notação de Kendall

A/B/m/K

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

disciplina

- FCFS
- LCFS
- RR
- IS
- Preempção
- ...

Exemplos:

- M/M/1
- M/M/1/K
- M/G/2

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

Análise Operacional

Variáveis operacionais

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

Análise Operacional

Métricas derivadas (*derived measures*)

- **S_i**: Tempo médio de serviço por finalização relativa ao recurso i; $S_i = B_i/C_i$
- **X_i**: *throughput* (ex.: finalizações por unidade de tempo) do recurso i; $X_i = C_i/T$
- **λ_i**: taxa de chegada (ex.: chegadas por unidade de tempo) ao recurso i; $\lambda_i = A_i/T$
- **X₀**: *throughput* do sistema; $X_0 = C/T$
- **V_i**: Número médio de visitas ao recurso i por solicitação; $V_i = C_i/C$

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	$R = \frac{M}{X_0} - Z$

Análise Operacional

Exemplo1

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

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

Análise Operacional

Exemplo1

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

Handwritten notes for Example 1:

$T = 1 \text{ min}$
 $A_0 = 1800 \text{ transactions}$
 $C_0 = 1800 \text{ transactions}$
 $A_0 = \lambda_0$
 $C_0 = X_0$
 $X_0 = \lambda_0 = \frac{1800}{60} = 30 \text{ tps}$
 $X_0 = X_0 = \frac{1800}{60} = 30 \text{ tps}$
 $S_0 = S_0 = \frac{C_{CPU}}{U_{CPU}}$
 $U_0 = U_0 = \frac{C_{CPU}}{T}$
 $X_0 = \lambda_0 = \frac{C_{CPU}}{T}$
 $X_0 = X_0 = \frac{C_{CPU}}{T}$

Análise Operacional

Exemplo1

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

Handwritten calculations for Example 1:

$U_0 = U_{CPU} = \frac{C_{CPU}}{T} = \frac{36 \text{ s}}{60 \text{ s}} = 0,6$
 $S_0 = S_1 = \frac{C_{CPU}}{C_{CPU}} = \frac{36}{1800} = 0,02 \text{ s}$

Análise Operacional

Exemplo2

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

- Qual é a utilização do link?

Análise Operacional

Exemplo2

$$\begin{aligned} \text{bandwidth} &= 56000 \text{ bps} & \text{Time to send 1 bit (TSB)} \\ \text{TSB} &= 1/\text{bandwidth} = 1.785714 \times 10^{-6} \\ \text{Time to send 1 byte} &= 8 \times \text{TSB} = 1.428571 \times 10^{-5} \\ \text{Packet size} &= 1500 \text{ bytes} \\ \text{Time to send 1 packet (TSP)} &= 1500 \times \text{TSB} = 0.026786 \\ \text{Arrival rate } (\lambda) &= 3 \text{ pacotes/s} \\ U &= \text{TSP} \times \lambda = 0,026786 \times 3 = 0,080357 \end{aligned}$$

Análise Operacional

Exemplo3

Para ilustrar o conceito de *Service Demand* considere o caso em que 6 transações fazem 3 acessos (cada uma) a uma unidade de disco. Os tempos de cada acesso são apresentados em ms.

I/O No.	Transaction No.					
	1	2	3	4	5	6
1	10	15	13	10	12	14
2	12	12	12	11	13	12
3	11	14	11	11	11	13
Sum	33	41	36	32	36	39

Qual é a *Service Demand* do sistema? $D_{I/O} = 3,2 \text{ ms}$

Análise Operacional

Exemplo4

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*?

$$T = 10 \times 60s = 600s$$

$$X_0 = 30.000/600 = 50 \text{ solicitações por segundo.}$$

$$D_{CPU} = U_{CPU}/X_0 = 0,9/50 = 0,018 \text{ s/solicitação}$$

Processos Estocásticos

- Processo Estocástico** é definido por um conjunto de variáveis aleatórias, $\{X(t) : t \in T\}$, onde $X(t)$ é uma variável aleatória para cada $t \in T$. t é denominado parâmetro e cada valor de $X(t)$ são estados.
- Processo Estocástico Markoviano** é um processo estocástico onde as variáveis aleatórias não dependem da história passada.
- Tipos de Processos Estocásticos**
 - Processos de espaço de estados e tempo discretos (*Discret Time Markov Chain - DTMC*)
 - Processos de espaço de estados contínuo e tempo discreto
 - Processos de espaço de estados discreto e tempo contínuo (*Continuous Time Markov Chain - CTMC*)
 - Processos de espaço de estados e tempo contínuos

Processos Estocásticos

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

Processos Estocásticos

- **Processo Estocástico Markoviano** é um processo estocástico onde as variáveis aleatórias não dependem da história passada.
- **Observam-se dois aspectos associados a ausência de memória:**
 1. Todo estado passado é irrelevante.
 2. O tempo que o processo passa em um estado é irrelevante.
- **Processo Estocástico Semi-Markoviano** é uma extensão de um processo Markoviano onde a restrição 2 é relaxada.

Continuous Time Markov Chain

- **Equação de Chapman-Kolmogorov**
 Considere uma **CTMC** (não-homogênea) $\{X(t): t \geq 0\}$ com espaço de estado $\{0, 1, 2, \dots\}$. Vamos usar i, j e k para denotar estados típicos e s, u e t para denotar parâmetro de tempo.
 Para $0 \leq s \leq t$, considere $p_{ij}(s, t) = P\{X(t)=j \mid X(s)=i\}$. Pode ser representada na forma matricial por $H(s, t) = [p_{ij}(s, t)]$
 A equação de Chapman-Kolmogorov

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

 Na forma matricial, temos:

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

Continuous Time Markov Chain

- **Equação de Chapman-Kolmogorov**

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

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

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

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

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

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

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

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

Continuous Time Markov Chain

- **Equação de Chapman-Kolmogorov**

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

 Onde $Q(t) = \lim_{h \rightarrow 0} \frac{H(t, t+h) - I}{h}$
 Os elementos de $Q(t)$ são dados por

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

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

Continuous Time Markov Chain

- **Equação de Chapman-Kolmogorov**

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

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

 Onde $o(h)$ é uma função de converge para zero mais rápido que h .
 Dado que $\sum_j p_{ij}(s, t) = 1, \forall i$, portanto:

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

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

Continuous Time Markov Chain

- **Equação de Chapman-Kolmogorov**

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

 Para cadeias **homogêneas**, tem-se:

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

Continuous Time Markov Chain

Steady State Analysis

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

Em estado estacionário ($t \rightarrow \infty$), pode ser que $\lim_{t \rightarrow \infty} \Pi(t) = \Pi$ exista.

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

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

Continuous Time Markov Chain

Soluções para Steady-States

$$\Pi Q = 0$$

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

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

Soluções Transientes

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

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

Continuous Time Markov Chain

- Uma CTMC é dita irredutível se $p_{ij} > 0 \quad \forall s_i, s_j \in S$ (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.

Continuous 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

Continuous Time Markov Chain

- Número de jobs $K = 3$
- $\mu_1 = 1/5$,
- $\mu_2 = 1/2, 5$
- FCFS




$$\begin{aligned} \pi(3,0)\mu_1 &= \pi(2,1)\mu_2, \\ \pi(2,1)(\mu_1 + \mu_2) &= \pi(3,0)\mu_1 + \pi(1,2)\mu_2, \\ \pi(1,2)(\mu_1 + \mu_2) &= \pi(2,1)\mu_1 + \pi(0,3)\mu_2, \\ \pi(0,3)\mu_2 &= \pi(1,2)\mu_1. \end{aligned}$$

$$Q = \begin{pmatrix} -\mu_1 & \mu_1 & 0 & 0 \\ \mu_2 & -(\mu_1 + \mu_2) & \mu_1 & 0 \\ 0 & \mu_2 & -(\mu_1 + \mu_2) & \mu_1 \\ 0 & 0 & \mu_2 & -\mu_2 \end{pmatrix}$$

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

Continuous Time Markov Chain

- Número de jobs $K = 3$
- $\mu_1 = 1/5$,
- $\mu_2 = 1/2, 5$
- FCFS



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

Utilização: $\rho_1 = 1 - \pi_1(0) = 0.9333, \quad \rho_2 = 1 - \pi_2(0) = 0.4667.$



Throughput $\lambda = \lambda_1 = \lambda_2 = \rho_1\mu_1 = \rho_2\mu_2 = 0.1867.$

Continuous Time Markov Chain

Sharpe (chame via Desktop)

C:\Sharpe-Gui\SHARPE GUI Examples\Markov\Performance model\A queue with transmission delay\p239_240.rpl

- Número de jobs $K = 11$
- $\lambda = 1$,
- $\mu = 1$.
- FCFS

State probability of State $i = \{0, 1, \dots, 11\}$
 State_Prob(i): 8.333333333e-002

Continuous Time Markov Chain

Sharpe (chame via Desktop)

C:\Sharpe-Gui\SHARPE GUI Examples\Markov\Degradable


Sistema Computacional com degradação

- Suponha um sistema representado por uma CPU que opera em três estágios: **CPU_OK**, **Degradable** e **Faulty_CPU**.
- As taxas entre os estados são:
 - CPU_OK** para **Degradable** é (**OK_D_rate**) 100, **Degradable** para **CPU_OK** (**D_OK_rate**) é 20, **Degradable** para **Faulty_CPU** (**D_F_rate**) é 5, **Faulty_CPU** para **Degradable** (**F_D_rate**) é 10, **CPU_OK** para **Faulty_CPU** (**OK_F_rate**) é 1 e do estado **Faulty_CPU** para **CPU_OK** (**F_OK_rate**) é 1.

Continuous Time Markov Chain


Sistema Computacional com degradação

- Suponha um sistema representado por uma CPU que opera em três estágios: **CPU_OK**, **Degradable** e **Faulty_CPU**. As taxas entre os estados são:
 - CPU_OK** para **Degradable** é (**OK_D_rate**) 100, **Degradable** para **CPU_OK** (**D_OK_rate**) é 20, **Degradable** para **Faulty_CPU** (**D_F_rate**) é 5, **Faulty_CPU** para **Degradable** (**F_D_rate**) é 10, **CPU_OK** para **Faulty_CPU** (**OK_F_rate**) é 1 e do estado **Faulty_CPU** para **CPU_OK** (**F_OK_rate**) é 1.



Continuous Time Markov Chain

Sistema Computacional com degradação



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

Input parameters values: OK_D_rate=100, D_OK_rate=20, D_F_rate=5, F_D_rate=10, OK_F_rate=1, F_OK_rate=1
 State probability of CPU_OK: State_Prob_0: 1.20957426e-001
 State probability of Degradable: State_Prob_1: 5.95741944e-001
 State probability of Faulty_CPU: State_Prob_2: 2.82259595e-001

Expedited steady-state reward rate for Degradable
 Exp_SS_Reward_Rate: 2.40322595e+001

State configuration:
 Name of the state: CPU_OK
 Reward rate: 100


Up states: CPU_OK, Degradable

Continuous Time Markov Chain

- Suponha um sistema representado por um autômato estocástico, onde:
 - $S = \{0, 1, 2\}$
 - $E = \{a, d\}$
 - $f(0, a) = 1, f(1, a) = 2, f(2, a) = 2, f(2, d) = 0$
 - $r(0) = \{a\}, r(1) = \{a\}, r(2) = \{a, d\}$
 - Os eventos **a** ocorrem com taxa igual $= \lambda$,
 - Os eventos **d** ocorrem com taxa igual $= \mu$



Continuous Time Markov Chain



Identifier	Description	Input State	Output State	Transition Reward	Rate	Cost
1	Transition1	State1	State2	Loss	1,000,000	0,00
2	Transition2	State2	State1	Loss	20,000,000	10,00
3	Transition3	State2	State4	Loss	1,000,000	0,00
4	Transition4	State4	State2	Loss	5,000,000	20,00
5	Transition5	State1	State4	Loss	1,000,000	0,00
6	Transition6	State4	State1	Loss	1,000,000	40,00

Continuous Time Markov Chain

Ready State Results:

Result	Value
Availability	0,857143
Cost Per Unit Time	765,714286
MTTR	0,166667

Results at time 1000,000000:

Result	Value
Availability	0,857143
Cost Per Unit Time	765,714286
Failure Rate	NA
Mean Availability	0,857143
Mean Cost	765,714286
Mean Unavailability	0,142857
Reliability	0,000000
Total Cost	765744,807972
Total Downtime	142,857143
Total Uptime	857,142857
Unreliability	1,000000

Time	Availability	Cost Per Unit Time	Failure Rate	Mean Availability	Mean Cost	Mean Unavailability	Reliability	Total Cost	Total Downtime	Total Uptime	Unavailability
0	1,000000	0,000000	0,000000	1,000000	0,000000	0,000000	1,000000	0,000000	0,000000	0,000000	0,000000
100,00	0,857143	765,714286	NA	0,857143	765,714286	0,142857	0,000000	76571,4286	142,857143	857,142857	0,142857
200,00	0,857143	765,714286	NA	0,857143	765,714286	0,142857	0,000000	153142,8571	285,714286	1714,285714	0,285714
300,00	0,857143	765,714286	NA	0,857143	765,714286	0,142857	0,000000	229714,2857	428,571429	2571,428571	0,428571
400,00	0,857143	765,714286	NA	0,857143	765,714286	0,142857	0,000000	306285,7143	571,428571	3428,571429	0,571429
500,00	0,857143	765,714286	NA	0,857143	765,714286	0,142857	0,000000	382857,1429	714,285714	4285,714286	0,714286
600,00	0,857143	765,714286	NA	0,857143	765,714286	0,142857	0,000000	459428,5714	857,142857	5142,857143	0,857143
700,00	0,857143	765,714286	NA	0,857143	765,714286	0,142857	0,000000	536000,0000	1000,000000	6000,000000	1,000000
800,00	0,857143	765,714286	NA	0,857143	765,714286	0,142857	0,000000	612571,4286	1142,857143	6857,142857	1,000000
900,00	0,857143	765,714286	NA	0,857143	765,714286	0,142857	0,000000	689142,8571	1285,714286	7714,285714	1,000000
1000,00	0,857143	765,714286	NA	0,857143	765,714286	0,142857	0,000000	765714,2857	1428,571429	8571,428571	1,000000

Continuous Time Markov Chain

State Transition Rate Diagram

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

$$\begin{cases} \sum_{i \in S} \pi_i = 1 \\ \Pi Q = 0 \\ (\pi_0, \pi_1, \pi_2) Q = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} \end{cases}$$

$$\begin{cases} -\lambda \pi_0 + \mu \pi_2 = 0 \\ \lambda \pi_0 - \lambda \pi_1 = 0 \\ -\lambda \pi_1 - \mu \pi_2 = 0 \\ \pi_0 + \pi_1 + \pi_2 = 1 \end{cases}$$

$$\begin{cases} \pi_0 = \pi_1 = \mu / (2\mu + \lambda) \\ \pi_2 = \lambda / (2\mu + \lambda) \end{cases}$$

Continuous Time Markov Chain

State Transition Rate Diagram

$$Q = \begin{bmatrix} -\lambda & \lambda & 0 & 0 \\ 0 & -(\gamma + \mu) & \mu & 0 \\ \delta & 0 & -\delta & 0 \\ \sigma & 0 & 0 & -\sigma \end{bmatrix}$$

$$\begin{cases} \sum_{i \in S} \pi_i = 1 \\ \Pi Q = 0 \\ (\pi_0, \pi_1, \pi_2, \pi_3) Q = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \end{bmatrix} \end{cases}$$

$$T = 1 / (\pi_0 \times \lambda) \text{ - Tempo médio}$$

Continuous Time Markov Chain

Métricas - Métricas de interesse pode ser calculadas através da soma ponderada das probabilidades de estado.

- Reward rate em estado estacionário

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

- Reward rate instantânea

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

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

Continuous Time Markov Chain

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

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

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

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

Discrete Time Markov Chain

O comportamento de uma rede estocástica é representado por DTMC

Matriz de Probabilidades de Próximo Estados

$$P = \begin{bmatrix} p_{00} & p_{01} \\ p_{10} & p_{11} \end{bmatrix}$$

Discrete Time Markov Chain

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

Discrete Time Markov Chain

- Estado recorrente não nulo (*recurrent non null*): um estado é classificado como recorrente não nulo se $M_i < \infty$, caso contrário é classificado como recorrente nulo (*recurrent null*).
- Se um estado é recorrente e $\pi_{ii}(n) > 0$, e seja d o período. Se $d = 1$ o estado é aperiódico, se $d > 1$ é periódico.

Discrete Time Markov Chain

- Soluções para *Steady-States*

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

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

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

Discrete Time Markov Chain

- Soluções para Transiente

$$\begin{aligned} \Pi(1) &= \Pi(0) P, \\ \Pi(2) &= \Pi(1) P = \Pi(0) P^2 \end{aligned}$$

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

Continuos Time Markov Chain

- Soluções Transientes

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

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

Métodos de Solução:

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

Continuos Time Markov Chain

- Soluções Transientes

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

Uma solução formal para o sistema acima é:

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

Pela série de Taylor/MacLaurin, temos:

$$\begin{aligned} e^{Qt} &= I + Qt/1! + (Qt)^2/2! + (Qt)^3/3! + \dots \\ &= \sum_{k=0}^{\infty} (Qt)^k/k! \end{aligned}$$

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-esparso o que requer capacidade muito maior.

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

Continuos Time Markov Chain

Uniformização



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

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

Sabe-se também que:

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

Considere que tomemos uma taxa uniforme $\lambda \geq \Lambda(i)$ onde:
 $\lambda = q_{ij} + q_{ik} + v$ ($\lambda - \Lambda(i) = v$)
 e $v \geq 0$ é a taxa de arbitrária de um evento fictício que não muda o estado i .

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

Continuos Time Markov Chain

Uniformização



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

Sabe-se também que:


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

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

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

Continuos Time Markov Chain

Uniformização



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

Sabe-se também que:


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

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

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

Continuos Time Markov Chain

Uniformização



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

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

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

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

Continuos Time Markov Chain

Uniformização



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

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

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

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

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.

Continuos Time Markov Chain


Uniformização

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

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

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

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



Continuos Time Markov Chain

Soluções Transientes

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

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

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

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

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

Continuos Time Markov Chain

Soluções Transientes

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

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

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

Continuos Time Markov Chain

Soluções Transientes

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

Uma solução iterativa:

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

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

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

Continuos Time Markov Chain

Soluções Transientes

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

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

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

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

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

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:

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

Do slide anterior, tem-se:

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

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

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)

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

- $P = I + Q/\lambda$
- $Q = \lambda(P - I)$
- $\lambda \geq \max_{i \in S} \{|q_{ij}|\}$

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



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

Solução Transiente (exemplo)

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

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

Para $t = 0,1$, tem-se: $(1 - \epsilon) e^{\lambda t} = (1 - 10^{-4}) e^{0,6} = 1,8219$

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

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

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

Continuos Time Markov Chain

Solução Transiente (exemplo)

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

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

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

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

Continuos Time Markov Chain

Solução Transiente (exemplo)

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

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

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

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

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

Continuos Time Markov Chain

Solução Transiente (exemplo)

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

Para $t=0.1 \Rightarrow ke=5$

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

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

Continuos Time Markov Chain

Solução Transiente (exemplo)

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

Para $t=0.1 \Rightarrow ke=5$

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

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

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

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

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

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

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

Continuos Time Markov Chain

Solução Transiente (exemplo)

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

Para $t=0.1 \Rightarrow ke=5$

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

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

Continuos Time Markov Chain

Solução Transiente (exemplo)

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


Para $t=0.1 \Rightarrow ke=5$

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

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

Continuos Time Markov Chain

Solução Transiente (exemplo)



Semi-Markovian Chain (SMC)

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

- Este modelo é denominado SMC.

Semi-Markovian Chain (SMC)

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

Semi-Markovian Chain (SMC)

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

Semi-Markovian Chain (SMC)

- Solução Estacionária
 - Encontre a solução estacionária para DTMC embutida (caracterizada por P):
 - $\Omega P = \Omega$
 - $\sum_{i \in S} \omega_i = 1$
 - Calcule o tempo médio de permanência (h_i) em cada estado i :
 - $h_i = \int_0^{\infty} t f_i(t) dt$


Semi-Markovian Chain (SMC)

- Solução Estacionária
 - A probabilidade de estado estacionário da SMC é obtida por:
 - $\pi_i = (\omega_i \times h_i) / (\sum_{j \in S} \omega_j \times h_j), \forall i$
 - Em muitas aplicações, h_i é fornecido diretamente.
- Solução transiente é mais sofisticada.

Semi-Markovian Chain (SMC)

■ Solução Estacionária

– Exemplo:



- $\Omega P = \Omega$
- $\sum_{i \in S} \omega_i = 1$
- $h_0 = 10, h_1 = 5$

Tempo médio de permanência

Semi-Markovian Chain (SMC)

■ Solução Estacionária

– Exemplo:



Matriz de Probabilidades de Próximo Estados

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

- $\Omega P = \Omega$
 - $\sum_{i \in S} \omega_i = 1$
 - $h_0 = 10, h_1 = 5$
- $\begin{cases} \omega_0 = 0,5385 \\ \omega_1 = 0,4615 \end{cases}$

Semi-Markovian Chain (SMC)

Solução Estacionária Matriz de Propabilidades de Próximo Estados

Exemplo:

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

$\omega_0 = 0,5385$
 $\omega_1 = 0,4615$

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

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

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

Semi-Markovian Chain (SMC)

Solução Estacionária Matriz de Propabilidades de Próximo Estados

Exemplo:

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

$\pi_0 = \frac{(0,5385 \times 10)}{(0,5385 \times 10) + (0,4615 \times 5)} = 0,7$
 $\pi_1 = \frac{(0,4615 \times 5)}{(0,5385 \times 10) + (0,4615 \times 5)} = 0,3$

Redes com Prioridade

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

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

P, T, I, O definidos como usualmente.

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

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

Redes com Prioridade

PN = (P, T, I, O, H, Π , M_0)

Structural Causal relation

Indirect Conflict

Structural Conflict

Extended Conflict Set - $ECS = \{t_1, t_n, t_j, t_k\}$

Redes com Prioridade

PN = (P, T, I, O, H, Π , M_0)

Structural Causal relation

Structural Conflict

Remoção da Confusão

- $\pi_l = \pi_k$
- $\pi_{t_n}, \pi_{t_j}, \pi_{t_k} > \pi_k$

Redes Estocásticas

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

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


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

Redes Estocásticas

Definição:


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

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




Redes Estocásticas

Rede Estocástica



Grafo de Marcações / CTMC



Redes Estocásticas

Semântica de Disparo de Transição

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

– Regras de habilitação

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

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



– *Enabling memory, resampling, age memory*

- Regras de disparo

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

Redes Estocásticas

Conflito




Redes Estocásticas


Definição:

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

$$W: T \rightarrow \mathcal{R}^+ \cup \{0\}$$



Grafo de Marcações




Redes Estocásticas


Definição:

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

$$W: T \rightarrow \mathcal{R}^+ \cup \{0\}$$




Grafo de Marcações




Redes Estocásticas

Definição:
 $SPN=(P,T,I,O,W,M_0)$
 $W : T \rightarrow \mathfrak{R}^+ \cup \{0\}$




Grafo de Marcações




Redes Estocásticas

Definição:
 $SPN=(P,T,I,O,W,M_0)$
 $W : T \rightarrow \mathfrak{R}^+ \cup \{0\}$




Grafo de Marcações




Redes Estocásticas

Definição:
 $SPN=(P,T,I,O,W,M_0)$
 $W : T \rightarrow \mathfrak{R}^+ \cup \{0\}$




Grafo de Marcações




Redes Estocásticas

Definição:
 $SPN=(P,T,I,O,W,M_0)$
 $W : T \rightarrow \mathfrak{R}^+ \cup \{0\}$




Grafo de Marcações




Redes Estocásticas

Definição:
 $SPN=(P,T,I,O,W,M_0)$
 $W : T \rightarrow \mathfrak{R}^+ \cup \{0\}$






Grafo de Marcações



Redes Estocásticas

Semântica de Temporização



Redes Estocásticas

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

Redes Estocásticas

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

$$Q_{ij} = \begin{cases} \sum_{t_k \in e_j(M_i)} \omega_k & i \neq j \\ -q_i & i = j \end{cases}$$

onde $Q = [Q_{ij}]$ gerador infinitesimal (matriz de taxas)

$$q_i = \sum_{t_k \in e_i(M_i)} \omega_k$$

ω_k é a taxa de disparo de t_k .

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

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

Redes Estocásticas Generalizada (GSPN)

Definição: $P, T, I, O, H, \Pi, W, M_0$ definidos como usualmente.

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

$\Pi: T \rightarrow \mathbb{R}^+$ se t for temporizada (Prioridade) \mathbb{R}^+ se t for imediata

$W: T \rightarrow \mathbb{R}^+$ (ou $W: T \times M \rightarrow \mathbb{R}^+$) é

- uma função que associa taxas de distribuição exponencial às transições temporizadas e
- pesos usados na computação das probabilidades de disparo das transições imediatas

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

Redes Estocásticas Generalizada (GSPN)

Semântica de Disparo de Transição

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


Redes Estocásticas Generalizada (GSPN)

Reachability Set


- $RS = VS \cup TS$
- $VS \cap TS = \emptyset$
- VS – Vanishing set:** Marcações em que as transições disparáveis são imediatas.
- TS – Tangible set:** Marcações onde as transições habilitadas são temporizadas.
-

Redes Estocásticas Generalizada (GSPN)

Grafo de Marcações



Redes Estocásticas Generalizada (GSPN)



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

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

ω_k é a taxa de disparo de t_k .
 $e(M_j)$ conjunto de transições habilitadas em M_j .

Quando a marcação é *vanishing*, ω_k é um peso (transição imediata).

Quando a marcação é *tangible*, ω_k é a taxa.

Redes Estocásticas Generalizada (GSPN)

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

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

Contudo, transições de diferentes ECS são concorrentes.

Redes Estocásticas Generalizada (GSPN)

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

Quando transições de um único ECS são as únicas imediatas

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

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

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

Redes Estocásticas Generalizada (GSPN)

Reachability Set

$$RS = VS \cup TS$$


$$VS \cap TS = \emptyset$$

VS – Vanishing set:

Marcações em que as transições disparáveis são imediatas.


TS – Tangible set:

Marcações onde as transições habilitadas são temporizadas.



Redes Estocásticas Generalizada (GSPN)

■ Grafo de Marcações



Redes Estocásticas

■ Para garantir a existência de probabilidade estacionária, a rede deve ser:

- limitada (*bounded*)
- reversível e
- livre de bloqueio (*deadlock-free*)
- $\prod Q = 0, \sum_{M_i \in RS(N)} \pi_i = 1$

Probabilidade estacionária de uma marcação M_i

$$(\pi_1, \dots, \pi_i, \dots, \pi_n) \quad Q = (0, \dots, 0, \dots, 0)$$

$$\sum_1^n \pi_i = 1$$

Redes Estocásticas

- Soluções Transientes

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

Uma solução formal para o sistema acima é:

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

Redes Estocásticas

- Dadas $M_j \in \mathcal{TS}(N)$, a probabilidade de se disparar t_k 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

- Dadas $M_j \in \mathcal{VS}(N)$, a probabilidade de se disparar t_k em M_j é:

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

$$\omega_k(M_j) = \sum_{t_j \in \{ECS(t_k) \cap M_j[t >]\}} \omega_j$$

$ECS(t_k)$ – Extended Conflict Set

$\omega_k(M_j)$ o peso associado à transição t_k na marcação M_j .

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

Redes Estocásticas

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

$$tm_j = 1/\lambda_j$$

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

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

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

$$p(p_j, k) = \sum_{i=1}^k p_i$$

$$S_i = \{1 \leq \{1, 2, \dots, S\} \mid M(p_j) \geq k\}$$

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

$x=1$

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

Redes Estocásticas

- Throughput rate de uma transição temporizada

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

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

- 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 disparo de uma transição

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


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

- 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

- Throughput rate de uma transição imediata

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



Redes Estocásticas

- Little's law

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

$E[X]$ - tamanho médio da fila.

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

λ - taxa de chegada

Redes Estocásticas

- Tempo médio de espera em um lugar


$$Wait(p_i) = \frac{Em(p_i)}{\sum_{t_j \in O(p_i)} TR(t_j)} = \frac{Em(p_i)}{\sum_{t_j \in O(p_i)} TR(t_j)}$$

- $Em(p_i)$ é o número médio de marcas no lugar p_i .
- $TR(t_j)$ throughput da transição t_j .

Redes Estocásticas

Exemplo - Banco

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




Redes Estocásticas


Análise Qualitativa

Estimate Statespace Output	Estimate Statespace Result of estimation (based on state equation with backtracking): Statespace = 1368 Time passed with computation: 7.11 s Removing temporary files Estimate Statespace finished.
Traps Output	Removing temporary files Calculation of Traps: Time passed with computation: 0.14 s No. of traps = 3 MARKING: 2 (Servers_Available Servers_Out_of_Service Client_Being_Served) MARKING: 1 (Client_Client_Arrive_to_Bank Client_Cannot_Enter_the_Bank) MARKING: 75 (Queue_Queue_Capacity) Traps finished.
Siphons Output	Removing temporary files Calculation of Siphons: Time passed with computation: 0.17 s No. of siphons = 3 MARKING: 2 (Servers_Available Servers_Out_of_Service Client_Being_Served) MARKING: 1 (Client_Client_Arrive_to_Bank Client_Cannot_Enter_the_Bank) MARKING: 75 (Queue_Queue_Capacity) Siphons finished.
Structural Analysis Output	STRUCTURAL ANALYSIS ... ECOS: Does_Not_Enter_Start_Serving Warning: inner confusion between Start_Serving and Does_Not_Enter Warning: direct external (pre)confusion between Start_Serving and Does_Not_Enter The net contains 3 P-invariants. Queue = Queue_Capacity = QS Servers_Available + Servers_Out_of_Service + Client_Being_Served = NS Client + Client_Arrive_to_Bank + Client_Cannot_Enter_the_Bank = NC All places are covered by P-invariants. EXTENDED CONFLICT SET Priority Immediate Transitions 1 Enter 1 Does_Not_Enter_Start_Serving Removing temporary files Structural Analysis finished.


Redes Estocásticas




Redes Estocásticas




Redes Estocásticas




Redes Estocásticas




Redes Estocásticas




Redes Estocásticas




Redes Estocásticas




Redes Estocásticas



Redes Estocásticas



Redes Estocásticas




Redes Estocásticas



Redes Estocásticas

Exemplo – Sevidor Central



Do livro MODELLING WITH GENERALISED STOCHASTIC PETRI NETS Marsan et al.

Redes Estocásticas

Aproximando Outras Distribuições

– Variáveis Suplementares

– Aproximação por Fases

– *Moment Matching*

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

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

Redes Estocásticas

Aproximação por Fases

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

– **Qualidade da aproximação:** quanto mais próximo for a distribuição por fase da distribuição real, melhor.

– Medidas de aproximação:

– *Moment matching*

– Encontrar um pdf (ou cdf) que seguem a pdf real numa determinada região de interesse.

Redes Estocásticas

Aproximação por Fases

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

– **Número de Estados da Aproximação:** é importante fazer com que o número de estados seja o menor possível.

– **Facilidade da obtenção do modelo markoviano resultante:** pode ser possível obter uma aproximação que gere excelentes resultados. No entanto, pode não ser fácil a integração no modelo markoviano resultante.

Redes Estocásticas

Aproximação por Fases

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

– **Facilidade de obtenção dos parâmetros da aproximação:** quanto mais parâmetros sejam necessários para especificar a aproximação, mais difícil se torna para encontrá-los.

Redes Estocásticas

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 .


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



Redes Estocásticas

Distribuição Especificada (empírica)

• *Moment Matching*



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

Redes Estocásticas

Distribuição Especificada (empírica)

- Moment Matching**

μ_D
 σ_D
 λ
 γ

- Se $\mu_D/\sigma_D = x \neq 1, x \in \mathbb{Z}$
 $\gamma = (\mu_D/\sigma_D)^2 = x^2, \lambda = \gamma/\mu_D = x^2/\mu_D$

Redes Estocásticas

- Aproximação por Fases**
- Distribuição de Hiperexponencial**

μ_H
 σ_H
 λ

$f\tau(t) = r_1 f\tau_1(t) + r_2 f\tau_2(t), t \geq 0$
 $\sum_{j=1}^n r_j = 1$

Parâmetros:
 Valor Esperado: $\mu_H = \sum_j r_j / \lambda_j$
 Variância: $2 \sum_j r_j / \lambda_j^2 - \mu_H^2$

Redes Estocásticas

Distribuição Especificada (empírica)

- Moment Matching**

μ_D
 σ_D
 λ

$\mu_H = r_1/\lambda_H$ (para esta Hiperexponencial)
 $\sigma_H = [\text{sqrt}(2 r_1 - r_1^2)]/\lambda_H$
 - Se $\mu_D/\sigma_D < 1$ ($c = \sigma_D/\mu_D > 1$)

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

Redes Estocásticas

Distribuição Especificada (empírica)

- Moment Matching**

μ_D
 σ_D
 λ

- Se $\mu_D/\sigma_D > 1$ e $\mu_D/\sigma_D \notin \mathbb{Z}$
 $(\mu_D/\sigma_D)^2 - 1 \leq \gamma < (\mu_D/\sigma_D)^2$

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

Redes Estocásticas

Distribuição Especificada (empírica)

- Moment Matching**

μ_D
 σ_D
 λ

$\mu_H = r_1/\lambda_H$ (para esta Hiperexponencial)
 $\sigma_H = [\text{sqrt}(2 r_1 - r_1^2)]/\lambda_H$
 - Se $\mu_D/\sigma_D < 1$ ($c = \sigma_D/\mu_D > 1$)

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

Redes Estocásticas

Distribuição Determinística

- Moment Matching**

Aproxima-se, fazendo-se σ_D pequeno
 $\Rightarrow \gamma$ torna-se grande.


μ_D
 σ_D
 λ

- 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 de Cox

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



Nestes slides μ_k são taxas (diferentemente dos anteriores)


Redes Estocásticas

Distribuição de Cox

Nestes slides μ é taxa (diferentemente dos anteriores)

Simplificamos em dois casos particulares:

- Caso $CV_X \leq 1$



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

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

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

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

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

$$k = \left\lceil \frac{1}{c_X^2} \right\rceil \quad \text{Número de fases}$$

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

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


Redes Estocásticas

Distribuição de Cox

Nestes slides μ_1 e μ_2 são taxas (diferentemente dos anteriores)

Simplificamos em dois casos particulares:

- Caso $CV_X > 1$



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

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

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


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

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

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

Redes Estocásticas


- Exemplo – Servidor Central



Do livro MODELLING WITH GENERALISED STOCHASTIC PETRINETTS Marsan et al.

Redes Estocásticas


- Exemplo – Servidor Central com Interrupção



Do livro MODELLING WITH GENERALISED STOCHASTIC PETRINETTS Marsan et al.

Modelando Políticas de Memória

- Erlang com 3 Fases



DSPN – Deterministic and Stochastic PN

- Definição
- DSPN = $(P, T, I, O, H, \Pi, M_0, D, W)$ - Marsan, Chiola 1987
 - P é o conjunto de lugares,
 - $T = T_{im} \cup T_{exp} \cup T_{det}$,
 - I, O, H denotam funções (vetores de funções) de entrada, saídas e de inibição que mapeiam transições em multi-conjuntos de lugares:
 - $i_k(t_j): P \times T \rightarrow \mathbb{N}, \forall p_k \in P, \forall t_j \in T$
 - $o_k(t_j): P \times T \rightarrow \mathbb{N}, \forall p_k \in P, \forall t_j \in T$
 - $h_k(t_j): P \times T \rightarrow \mathbb{N}, \forall p_k \in P, \forall t_j \in T$
 - $\Pi: T_{im} \rightarrow \mathbb{N}$,
 - M_0 é marcação inicial,


DSPN – Deterministic and Stochastic PN

- DSPN = $(P, T, I, O, H, \Pi, M_0, D, W)$
 - $D: T_{exp} \cup T_{det} \rightarrow \mathbb{R}^+ \cup \{0\}$ atribui um tempo médio às transições estocásticas e um tempo constante às transições determinísticas,
 - $W: T_{exp} \rightarrow \mathbb{R}^+ \cup \{0\}$ atribui um peso às transições imeditadas.
- Quando $T_{det} = \emptyset$ a DSPN é uma GSPN.
- Embora seja possível a análise de modelos com mais de uma transição determinística simultaneamente habilitadas, as ferramentas, normalmente, somente implementam métodos que considerem apenas uma transição determinística habilitada por marcação.

DSPN – Deterministic and Stochastic PN

Exemplo:

- $T_{im} = \{t_1\}$
- $T_{exp} = \{t_3, t_4\}$
- $T_{det} = \{t_2\}$



EDSPN – Extended Deterministic and Stochastic PN


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

EDSPN – Extended Deterministic and Stochastic PN

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

EDSPN – Extended Deterministic and Stochastic PN

Exemplo:




Modelo em DSPN para limpar p_1 .

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

EDSPN – *Extended Deterministic and Stochastic PN*

- Tempos dependentes da carga



Redes Estocásticas

- Considerações
 - ⊗ Redes de Petri estocásticas são uma representação compacta de alto nível das CTMC
 - ⊗ Equivalência com CTMC
 - ⊗ Análise quantitativa
 - ⊗ Análise qualitativa
 - ⊗ Modelagem de sistemas concorrentes, não-determinísticos e assíncronos. Modelagem de sincronismo, escolha, mútua exclusão etc

Redes Estocásticas

- Algumas Referências:
 - ⊗ Modelling with Generalized Stochastic Petri Nets, A. Marsan et al, John Wiley & Sons, 1995.
 - Performance Modelling with Deterministic and Stochastic Petri Nets, C. Lindermann, John Wiley & Sons, 1998.
- <http://www.daimi.au.dk/PetriNets>