

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

## Modelos Temporizados

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


## Modelagem para Análise de Desempenho

### ■ Algumas Medidas

- Tempo de 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 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



$v(p0) = 3$

## Redes Temporizadas - PTPN -

### ■ Regra de Disparo




$v(p0) = 3$

Instante=0

## Redes Temporizadas - PTPN -

### ■ Regra de Disparo




$v(p0) = 3$

Instante=1

## Redes Temporizadas - PTPN -

### ■ Regra de Disparo




$v(p0) = 3$

Instante=2

## Redes Temporizadas - PTPN -

### ■ Regra de Disparo



$v(p0) = 3$

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 *delays* 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*

p0

ta

p1



## Redes de Petri Temporizadas

- Tempo Associado às Transições -

### ■ Conceitos Básicos:

#### - *Infinite-server firing semantics*

p0

ta


p1



## Redes de Petri Temporizadas - Tempo Associado às Transições -

### Conceitos Básicos:

- *Multiple-server firing semantics*  $k=2$



## Redes Temporizadas com Transições Temporizadas

### Time Petri Nets (Merlin76)

- Definição:  $TPN=(P,T,F,W,M_0,I)$ , 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 -  $M_0: \mathbb{N}^P$
- $I: T \rightarrow (D_{\min}, D_{\max})$
- $D_{\min}: (\mathbb{R}^+ \cup \{0\})^T, D_{\max}: (\mathbb{R}^+ \cup \{0\})^T$ , onde  $I(t_i) = (d_{\min}^i, d_{\max}^i), d_{\max}^i \geq d_{\min}^i$

## Redes Temporizadas com Transições Temporizadas

- *Resampling* (Merlin76) / *Enabling Memory* (Starke87)
- Definição- Conjunto de Transições Habilitadas:  $TPN=(P,T,F,W,M_0,I)$ , onde  $ET(M_i) = \{t \in T \mid M_i \geq W(p_j, t), \forall p_j \in P\}$
- Definição - *Timer Clock* -:  $TC: T \rightarrow \mathbb{R}$  é uma função parcial que associa às transições uma variável de tempo (*timer clock*).
- OU
- Definição - *Timer Clock* -:  $TC: ET(M_i) \rightarrow \mathbb{R}$  é uma função que associa às transições habilitadas em uma marcação  $M_i$  uma variável de tempo (*timer clock*).

## Redes Temporizadas com Transições Temporizadas

### Time Petri Nets

- Definição- Intervalo Dinâmico de Disparo -: Seja uma  $TPN=(P,T,F,W,M_0,I)$ .
- $I_D: T \rightarrow (DLB, DUB)$
- $DLB: (\mathbb{R}^+ \cup \{0\})^T, DUB: (\mathbb{R}^+ \cup \{0\})^T$
- Definição- Geração do  $I_D(t)$
- $I_D(t) = (\max\{0, D_{\min} - TC(t)\}, D_{\max} - TC(t))$

## Redes Temporizadas com Transições Temporizadas

- *Time Petri Nets*
- Definição- Conjunto de Estados -: Seja uma  $TPN=(P,T,F,W,M_0,I)$ .  $S \subseteq M \times \mathbb{R}^{|ET(M)|}$  define o espaço de estados de uma TPN, onde  $s = (M, ET(M), TC)$ .  $s \in S$ .
- Definição- Conjunto de Transições Disparáveis -: Seja um estado  $s' \in S$ . O Conjunto de transições disparáveis em  $s'$  é definido por:
- $FT(s') = \{t \mid t \in ET(M') \wedge DLB(t) \leq \min\{DUB(t_k), \forall t_k \in ET(M)\}\}$  - Transições que serão eleitas para disparo quando as restrições temporais forem satisfeitas.

## Redes Temporizadas com Transições Temporizadas

### Time Petri Nets

- Definição- Conjunto de Transições Disparáveis -: Seja um estado  $s' \in S$ . O Conjunto de transições disparáveis em  $s'$  é definido por:
- $FT(s') = \{t \mid t \in ET(M') \wedge DLB(t) \leq \min\{DUB(t_k), \forall t_k \in ET(M)\}\}$ .
- Definição- Domínio de Disparo:
- $FD_s(t) = [DLB(t), \min\{DUB(t_k), \forall t_k \in ET(M)\}]$

# Redes Temporizadas com Transições Temporizadas

## Time Petri Nets

**Definition 2.5 (Time Petri net)** A time Petri net is defined by a tuple  $(N, I)$ , where  $N$  is the underlying Petri net, and  $I : T \rightarrow \mathbb{N} \times \mathbb{N}$  represents the timing constraints, such that  $I(t) = (EFT(t), LFT(t)) \forall t \in T, EFT(t) \leq LFT(t)$ .  $EFT(t)$  is the Earliest Firing Time, and  $LFT(t)$  is the Latest Firing Time.

**(Enabled Transitions)** A set of enabled transitions, at marking  $m_i$ , is denoted by:  $ET(m_i) = \{t \in T \mid m_i(p_j) \geq W(p_j, t), \forall p_j \in P\}$

The time elapsed, since the respective transition enabling, is denoted by a clock vector  $c \in (\mathbb{N} \cup \{\#\})^{|T|}$ , where  $\#$  represents the undefined value for not enabled transitions. As an example, the clock

# Redes Temporizadas com Transições Temporizadas

## Time Petri Nets

A transition  $t \in T$  is enabled, if each input place  $p \in P$  contains at least  $W(p, t)$  tokens. The time elapsed, since the respective transition enabling, is denoted by a clock vector  $c \in (\mathbb{N} \cup \{\#\})^{|T|}$ , where  $\#$  represents the undefined value for not enabled transitions. As an example, the clock

Dynamic Upper Bound. The dynamic firing interval is computed in the following way:  $J_H(t) = [DLB(t), DUB(t)]$ , where  $DLB(t) = \max\{0, EFT(t) - c(t)\}$ ,  $DUB(t) = LFT(t) - c(t)$ . Whenever  $DLB(t) = 0$ ,  $t$  can fire, and, when  $DUB(t) = 0$ ,  $t$  must fire, since strong firing mode is adopted.

**Definition 2.6 (States)** Let  $\mathcal{P}_T$  be a time Petri net,  $M \subseteq \mathbb{N}^{|P|}$  be the set of reachable markings of  $\mathcal{P}_T$ , and  $C \subseteq (\mathbb{N} \cup \{\#\})^{|T|}$  be the set of clock vectors. The set of states  $S$  of  $\mathcal{P}_T$  is given by  $S \subseteq (M \times C)$ , that is, a state is defined by a marking, and the respective clock vector.

**Definition 2.7 (Firable Transitions)** Let  $\mathcal{P}_T$  be a time Petri net, the set of firable transitions at state  $s \in S$  is defined by:  $FT(s) = \{t \in ET(m) \mid DLB(t_s) \leq \min\{DUB(t_s), \forall t_s \in ET(m)\}\}$ .

**Definition 2.8 (Firing Domain)** The firing domain for a transition  $t$  at state  $s$ , is defined by the interval:  $FD_t(s) = [DLB(t_s), \min\{DUB(t_s)\}]$ ,  $\forall t_s \in ET(m)$ .

# Redes Temporizadas com Transições Temporizadas

## Time Petri Nets

**Definition 2.9 (Reachable States)** Let  $\mathcal{P}_T$  a time Petri net, and  $s_i = (m_i, c_i)$  a reachable state.  $s_{i+1} = \text{fire}(s_i, (t, \theta))$  denotes that firing a transition  $t$  at time  $\theta$  from the state  $s_i$ , the reached state  $s_{i+1} = (m_{i+1}, c_{i+1})$  is obtained from:

- $\forall p \in P, m_{i+1}(p) = m_i(p) - W(p, t) + W(t, p)$ ;

- $\forall t_j \notin ET(m_{i+1}), c_{i+1}(t_j) = \#$ ;
- $\forall t_k \in ET(m_{i+1}), c_{i+1}(t_k) = \begin{cases} 0, & \text{if } (t_k = t) \\ 0, & \text{if } (t_k \in ET(m_{i+1}) - ET(m_i)) \\ C_i(t_k) + \theta, & \text{else} \end{cases}$

# Redes Temporizadas com Transições Temporizadas

## Time Petri Nets

# Redes Temporizadas com Transições Temporizadas

## Time Petri Nets

$Tc(t_0) = Tc(t_1) = Tc(t_2) = 1$   
 $DLB(t_0) = 1, DUB(t_0) = 3$   
 $DLB(t_1) = 1, DUB(t_1) = 5$   
 $DLB(t_2) = 2, DUB(t_2) = 4$   
 $FT(s') = \{t \mid t \in ET(M) \wedge DLB(t) \leq \min\{DUB(t_k), \forall t_k \in ET(M)\}\}$ .  
 $FT(s_0) = \{t_0, t_1, t_2\}$

# Redes Temporizadas com Transições Temporizadas

## Time Petri Nets

- $ID(t) = (\max\{0, 2-0\}, 4-0) = (2, 4) \quad \tau=0$
- $ID(t) = (\max\{0, 2-1\}, 4-1) = (1, 3) \quad \tau=1$
- $ID(t) = (\max\{0, 2-2\}, 4-2) = (0, 2) \quad \tau=2, \text{ disparável}$
- $ID(t) = (\max\{0, 2-3\}, 4-3) = (0, 1) \quad \tau=3, \text{ disparável}$
- $ID(t) = (\max\{0, 2-4\}, 4-4) = (0, 0) \quad \tau=4, \text{ disparável}$

## Redes Temporizadas com Transições Temporizadas

### Semântica de Disparo de Transição

- Uma transição  $t_i$  é **disparável** se estiver **habilitada**

– Regras de habilitação

$$M[t_i > , \quad M(pi) \geq I(pi, t_i) \\ \forall pi \in P$$

**durante** o intervalo  $I(t_i) = (d_{\min}, d_{\max})$ ,

Ou seja,  $t_i$  só será disparável se  $tc(t_i) \geq d_{\min}$

- e **terá** que disparar até  $tc(t_i) \geq d_{\max}$  (*strong semantics*)

OU

- e **poderá** disparar até  $tc(t_i) \geq d_{\max}$  (*weak semantics*)


- Resampling* (Merlin76) / *Enabling Memory* (Starke87)

- Regras de disparo


Se  $M[t_i > M'$

$$M'(pi) = M0(pi) - I(pi, t_i) + O(pi, t_i), \quad \forall pi \in P$$


## Redes Temporizadas com Transições Temporizadas



## Redes Temporizadas com Transições Temporizadas




## Redes Temporizadas com Transições Temporizadas




$t_0$  pode disparar

## Redes Temporizadas com Transições Temporizadas




$t_0$  pode disparar


## Redes Temporizadas com Transições Temporizadas



## Redes Temporizadas com Transições Temporizadas



## Redes Temporizadas com Transições Temporizadas



**t1 pode disparar**

## Redes Temporizadas com Transições Temporizadas




## Redes Temporizadas com Transições Temporizadas




## Redes Temporizadas com Transições Temporizadas




## Redes Temporizadas com Transições Temporizadas




## Redes Temporizadas com Transições Temporizadas




## Redes Temporizadas com Transições Temporizadas



## Redes Temporizadas com Transições Temporizadas



## Redes Temporizadas com Transições Temporizadas



t1 tem que disparar (*strong semantics*)  
 t1 pode disparar até este momento (*weak semantics*)


## Redes Temporizadas com Transições Temporizadas




## Redes Temporizadas com Transições Temporizadas




## Redes Temporizadas com Transições Temporizadas




## Redes Temporizadas com Transições Temporizadas




## Redes Temporizadas com Transições Temporizadas




## Redes Temporizadas com Transições Temporizadas



## Redes Temporizadas com Transições Temporizadas



## Redes Temporizadas com Transições Temporizadas



## Grafo de Alcançabilidade - Untimed Model -

- Definição: Grafo de Alcançabilidade- seja uma rede marcada  $N=(R, M_0)$ .  $RG(R, M_0)=(RS, ARCS)$  define o grafo de alcançabilidade (*Reachability Graph*), onde  $RS$  é o conjunto de vértice e representa o conjunto de alcançabilidade.  $ARCS \subseteq RS \times T \times RS$  é uma relação representando os arcos.

## Redes Temporizadas com Transições Temporizadas


- Definição: **Grafo de Alcançabilidade Temporizado**- seja uma rede marcada  $TN=(R, M_0, I)$ .  $TRG(TN)=(S, \Sigma, ARCS, s_0)$  define o grafo de alcançabilidade temporal (*Time Reachability Graph*), onde  $S$  é o conjunto de vértice e representa o conjunto de alcançabilidade.  $ARCS \subseteq S \times \Sigma \times S$  é uma relação representando os arcos.  $s = (M, ET(M), TC)$  ( $s \in S$ ), onde  $M: \mathbb{N}^P$  e  $TC: ET(M) \rightarrow \mathbb{N}$  é uma função parcial que associa às transições um *timer clock*, que representa o tempo passado (desde a sua habilitação) até atingir-se  $M$ .  $\Sigma \subseteq T \times \mathbb{N}$ , onde  $(t, \theta) \in \Sigma$  é um par ordenado representando o disparo de uma transição  $t$  no instante  $\theta$ .  $s_0 = (M_0, ET(M_0), TC)$ ,  $TC(t) = 0, \forall t \in ET(M_0)$ .

## Redes Temporizadas com Transições Temporizadas

- Uma transição de estado  $(s_i, (t, \theta), s_j) \in ARCS$  representa a alcançabilidade do estado  $s_j$  a partir de  $s_i$  pelo disparo de  $t$  no instante  $\theta$ .  
 $s_j = (M_j, ET(M_j), TC_j)$ 
  - $M_j = M_i - W(p, t) + W(p, t), \forall p \in P$
  - $TC_j(t_k) = \begin{cases} 0, & \text{se } t_k = t \\ 0, & \text{se } t_k \in ET(M_j) - ET(M_i) \\ TC_i(t_k) + \theta & \text{caso contrário} \end{cases}$


## Redes Temporizadas com Transições Temporizadas

- Time Petri Nets:**  $s_0 = (M_0, ET_0(M_0), TC_0)$   
 $Tc(t_0) = Tc(t_1) = Tc(t_2) = 0$   
 $DLB(t_0) = 2, DUB(t_0) = 4$   
 $DLB(t_1) = 2, DUB(t_1) = 6$   
 $DLB(t_2) = 3, DUB(t_2) = 5$   
 $FT(s') = \{t \mid t \in ET(M') \wedge DLB(t) \leq \min\{DUB(t_k), \forall t_k \in ET(M)\}\}$ .  
 $FT(s_0) = \{t_0, t_1, t_2\}$   
 $FD_s(t) = [DLB(t), \min\{DUB(t_k), \forall t_k \in ET(M)\}]$



## Redes Temporizadas com Transições Temporizadas

- Time Petri Nets:**  $s_0 = (M_0, ET_0(M_0), TC_0)$   
 $Tc(t_0) = Tc(t_1) = Tc(t_2) = 0$   
 $DLB(t_0) = 2, DUB(t_0) = 4$   
 $DLB(t_1) = 2, DUB(t_1) = 6$   
 $DLB(t_2) = 3, DUB(t_2) = 5$   
 $FT(s_0) = \{t_0, t_1, t_2\}$   
 $FD_s(t_0) = [2, 4]$   
 $FD_s(t_1) = [2, 4]$   
 $FD_s(t_2) = [3, 4]$



## Redes Temporizadas com Transições Temporizadas

- Time Petri Nets**
- Definição: **Grafo de Alcançabilidade Temporizado**- seja uma rede marcada  $TN=(R, M_0, I)$ .  $TRG(TN)=(S, ARCS)$  define o grafo de alcançabilidade temporal (*Time Reachability Graph*), onde  $S$  é o conjunto de vértice e representa o conjunto de alcançabilidade.  $ARCS \subseteq S \times S$  é uma relação representando os arcos.  $S = (M, TC)$ , onde  $M: \mathbb{N}^P$  e  $TC: T \rightarrow \mathbb{N}$  é uma função parcial que associa as transições um *timer clock*, que representa o tempo passado (desde a sua habilitação) até atingir-se  $M$ .
- $S \subseteq RS$

## Redes Temporizadas com Transições Temporizadas


- **Timed Petri Nets** (Ramchandani74)
- Definição:  $TPN=(P,T,F, W,M_0, D)$ , 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 -  $M_0: P \rightarrow \mathbb{N}$
  - $D: T \rightarrow \mathbb{R}^+ \cup \{0\}$  – Duração.

## Redes Temporizadas com Transições Temporizadas

- **Timed Petri Nets** (Zuberek87)
- Definição:  $TPN=(P,T,F, W,M_0,c,D)$ , onde
  - $D: T \rightarrow \mathbb{R}^+ \cup \{0\}$
  - $c: T \rightarrow [0,1]$  função de probabilidade de escolha, tal que:
    - $\sum_{t \in T_i} c(t) = 1, \forall T_i \in \text{Free}(T)$ , onde  $\text{Free}(T) = \{T_1, \dots, T_n\}$  conjunto de conjuntos de transições *free-choice*.
  - $T_i = \{t_j \mid \exists p \in P : p \in {}^*t_j, \forall t_j \in T_i\}$

## Redes Temporizadas com Transições Temporizadas

$TPN=(P,T,F, W,M_0,c,D)$ ,



## Redes Temporizadas com Transições Temporizadas

- **Timed Petri Nets**
- Definição: **Estado** - Seja  $TPN=(P,T,F, W,M_0,c,D)$  uma *Timed Petri net*. Um estado é definido por uma tupla  $s=(m_1, m_2, r)$ , onde
  - $M_1: P \rightarrow \mathbb{N}$  é a marcação
  - $M_2: T \rightarrow \mathbb{N}$  é uma função que mapeia cada transição em natural, onde este natural representa o número de vezes que aquela transição está sendo disparada naquele estado  $s$ .  $s \in S$  (conjunto de estado).

## Redes Temporizadas com Transições Temporizadas

- **Timed Petri Nets**
- Definição: **Passo Simples Habilitado** - Seja  $TPN=(P,T,F, W,M_0,c,D)$  uma *Timed Petri net*. Um passo  $st_i^j$  habilitado no estado  $s_i \in S$  é definido por:  $st_i^j = (t_i \mid M_1(p_i) \geq |p_i^* \cap st_i^j|)$ .
- Definição: **Passo Habilitado** - Seja  $TPN=(P,T,F, W,M_0,c,D)$  uma *Timed Petri net*. Um passo  $st_i^j$  habilitado no estado  $s_i \in S$  é definido por:  $st_i^j: T \rightarrow \mathbb{N}$   $M_1(p_i) \geq \sum_{t \in p_i^*} st_i^j(t)$ .
- Definição: **Conjunto de Passos Habilitados** - Seja  $TPN=(P,T,F, W,M_0,c,D)$  uma *Timed Petri net* e  $st_i^j$  um passo habilitado no estado  $s_i \in S$ .  $EST_i = \{st_i^j\}$  define o conjunto de passos habilitados no estado  $s_i$ .

## Redes Temporizadas com Transições Temporizadas

- **Timed Petri Nets**
- Definição: **Passo Máximo Habilitado** - Seja  $TPN=(P,T,F, W,M_0,c,D)$  uma *Timed Petri net* e  $EST_i = \{st_i^j\}$  o conjunto de passos habilitados no estado  $s_i$ . Seja  $T \supseteq stm^i$ , se  $\exists st_i^j \in EST_i, st_i^j \neq stm^i$ , tal que  $st_i^j \supseteq stm^i$ ,  $stm^i$  é denominado passo máximo habilitado.



## Redes Temporizadas com Transições Temporizadas

- Definição: **Regra de Habilitação e Disparo – Passo** - Seja  $TPN=(P,T,F, W, M_0, c, D)$  uma *Timed Petri net* e  $s=(m_1, m_2, r)$  um estado em algum instante  $\beta \in \mathbb{R}^+ \cup \{0\}$ .  
Um *step*  $st: T \rightarrow \mathbb{K}$  está habilitado se  $m_i(pi) \geq \sum_{t \in T} st(t) \cdot W(pi, t), \forall pi \in P$   
Se um *step*  $st$  está habilitado em um instante  $\beta$  (vamos tratar nos  $\mathbb{K}$ ), dispara-se  $st$  em  $\beta$ .  
Em  $\beta+1$ , tem-se:  $m'_1(pi) = m_1(pi) - \sum_{t \in C_0} st(t) \cdot W(pi, t) + \sum_{t \in C_1} st(t) \cdot W(t, pi) + \sum_{t \in C_2} m_2(t) \cdot W(t, pi), \forall pi \in P$ , onde  
 $C_0 = \{t \in T \mid st(t) > 0\}$   
 $C_1 = \{t \in T \mid st(t) > 0 \wedge D(t) = 1\}$   
 $C_2 = \{t \in T \mid r_i(t) = 1\}, 0 < i < K$


## Redes Temporizadas com Transições Temporizadas

- Timed Petri Nets (passo, enabling memory)**
- Definição: **Estado** - Seja  $TPN=(P,T,F, W, M_0, c, D)$  uma *Timed Petri net*. Um estado é definido por uma tupla  $s=(m_1, m_2, r)$ , onde
- Definição: **Tempo de Permanência** – Seja um estado  $s=(m_1, m_2, r)$ , o  $h: S \rightarrow \mathbb{R}^+ \cup \{0\}$  é uma função que associa o *holding time* a cada estado  $s_i=(m_1, m_2, r)$ , onde  $h(s_i) = \min_{t \in T \wedge m_2(t) > 0} (r_i(t)[1])$


## Redes Temporizadas com Transições Temporizadas

- $m'_2(t) = m_2(t) - m_{2, \beta+1}(t)$ ,  $m_{2, \beta+1}(t)$  representa que "sairam" da transição no instante  $\beta+1$   
 $r'_i(t) = r_i(t) - 1, m_2(t) \neq 0 \vee t \in st$  (transições pertencentes ao *step*  $st$  ou as que já se encontravam "dentro" ( $m_2$ ) das transições)

## Redes Temporizadas com Transições Temporizadas




## Redes Temporizadas com Transições Temporizadas




No instante  $\beta=1$ ,  
 $r_1(t_0) = 1, m_2(t_0) = 1$

## Redes Temporizadas com Transições Temporizadas




- No instante  $\beta=1$ ,  
 $r_1(t_0) = 1, m_2(t_0) = 1$
- No instante  $\beta=2$ ,  
 $r_1(t_1) = 2, m_2(t_1) = 1$   
 $r_1(t_2) = 3, m_2(t_2) = 1$

## Redes Temporizadas com Transições Temporizadas




- No instante  $\beta=1$ ,  
 $r_1(t_0) = 1, m_2(t_0) = 1$
- No instante  $\beta=2$ ,  
 $r(t_1) = 2, m_2(t_1) = 1$   
 $r(t_2) = 3, m_2(t_2) = 1$

## Redes Temporizadas com Transições Temporizadas




- No instante  $\beta=1$ ,  
 $r_1(t_0) = 1, m_2(t_0) = 1$
- No instante  $\beta=2$ ,  
 $r(t_1) = 2, m_2(t_1) = 1$   
 $r(t_2) = 3, m_2(t_2) = 1$
- No instante  $\beta=3$ ,  
 $r(t_1) = 1, m_2(t_1) = 1$   
 $r(t_2) = 2, m_2(t_2) = 1$

## Redes Temporizadas com Transições Temporizadas




- No instante  $\beta=1$ ,  
 $r_1(t_0) = 1, m_2(t_0) = 1$
- No instante  $\beta=2$ ,  
 $r(t_1) = 2, m_2(t_1) = 1$   
 $r(t_2) = 3, m_2(t_2) = 1$
- No instante  $\beta=3$ ,  
 $r(t_1) = 1, m_2(t_1) = 1$   
 $r(t_2) = 2, m_2(t_2) = 1$
- No instante  $\beta=4$ ,  
 $r(t_2) = 1, m_2(t_2) = 1$

## Redes Temporizadas com Transições Temporizadas




- No instante  $\beta=1$ ,  
 $r_1(t_0) = 1, m_2(t_0) = 1$
- No instante  $\beta=2$ ,  
 $r(t_1) = 2, m_2(t_1) = 1$   
 $r(t_2) = 3, m_2(t_2) = 1$
- No instante  $\beta=3$ ,  
 $r(t_1) = 1, m_2(t_1) = 1$   
 $r(t_2) = 2, m_2(t_2) = 1$
- No instante  $\beta=4$ ,  
 $r(t_2) = 1, m_2(t_2) = 1$
- No instante  $\beta=5$ ,  
 $r(t_3) = 3, m_2(t_3) = 1$

## Redes Temporizadas com Transições Temporizadas




- No instante  $\beta=1$ ,  
 $r_1(t_0) = 1, m_2(t_0) = 1$
- No instante  $\beta=2$ ,  
 $r(t_1) = 2, m_2(t_1) = 1$   
 $r(t_2) = 3, m_2(t_2) = 1$
- No instante  $\beta=3$ ,  
 $r(t_1) = 1, m_2(t_1) = 1$   
 $r(t_2) = 2, m_2(t_2) = 1$
- No instante  $\beta=4$ ,  
 $r(t_2) = 1, m_2(t_2) = 1$
- No instante  $\beta=5$ ,  
 $r(t_3) = 3, m_2(t_3) = 1$

## Redes Temporizadas com Transições Temporizadas




- No instante  $\beta=1$ ,  
 $r_1(t_0) = 1, m_2(t_0) = 1$
- No instante  $\beta=2$ ,  
 $r(t_1) = 2, m_2(t_1) = 1$   
 $r(t_2) = 3, m_2(t_2) = 1$
- No instante  $\beta=3$ ,  
 $r(t_1) = 1, m_2(t_1) = 1$   
 $r(t_2) = 2, m_2(t_2) = 1$
- No instante  $\beta=4$ ,  
 $r(t_2) = 1, m_2(t_2) = 1$
- No instante  $\beta=5$ ,  
 $r(t_3) = 3, m_2(t_3) = 1$
- No instante  $\beta=8$ ,  
 $m_1(p_5) = 1$

## Redes Temporizadas com Transições Temporizadas




## Redes Temporizadas com Transições Temporizadas

- No instante  $\beta=1$ ,  
 $r_1(t_0) = 1, m_2(t_0) = 1$




## Redes Temporizadas com Transições Temporizadas

- No instante  $\beta=1$ ,  
 $r_1(t_0) = 1, m_2(t_0) = 1$
- No instante  $\beta=2$ ,




## Redes Temporizadas com Transições Temporizadas

- No instante  $\beta=1$ ,  
 $r_1(t_0) = 1, m_2(t_0) = 1$
- No instante  $\beta=2$ ,  
 $r_1(t_1) = 2, m_2(t_1) = 1$   
 $r_2(t_2) = 3, m_2(t_2) = 1$




## Redes Temporizadas com Transições Temporizadas

- No instante  $\beta=1$ ,  
 $r_1(t_0) = 1, m_2(t_0) = 1$
- No instante  $\beta=2$ ,  
 $r_1(t_1) = 2, m_2(t_1) = 1$   
 $r_2(t_2) = 3, m_2(t_2) = 1$
- No instante  $\beta=3$ ,  
 $r_1(t_1) = 1, m_2(t_1) = 1$   
 $r_2(t_2) = 2, m_2(t_2) = 1$




## Redes Temporizadas com Transições Temporizadas

- No instante  $\beta=1$ ,  
 $r_1(t_0) = 1, m_2(t_0) = 1$
- No instante  $\beta=2$ ,  
 $r_1(t_1) = 2, m_2(t_1) = 1$   
 $r_2(t_2) = 3, m_2(t_2) = 1$
- No instante  $\beta=3$ ,  
 $r_1(t_1) = 1, m_2(t_1) = 1$   
 $r_2(t_2) = 2, m_2(t_2) = 1$
- No instante  $\beta=4$ ,  
 $r_2(t_2) = 1, m_2(t_2) = 1$




## Redes Temporizadas com Transições Temporizadas




- No instante  $\beta=1$ ,  $r_1(t_0) = 1, m_2(t_0) = 1$
- No instante  $\beta=2$ ,  $r_1(t_1) = 2, m_2(t_1) = 1$   
 $r_2(t_2) = 3, m_2(t_2) = 1$
- No instante  $\beta=3$ ,  $r_1(t_1) = 1, m_2(t_1) = 1$   
 $r_2(t_2) = 2, m_2(t_2) = 1$
- No instante  $\beta=4$ ,  $r_2(t_2) = 1, m_2(t_2) = 1$
- No instante  $\beta=5$ ,  $r_2(t_2) = 1, m_2(t_2) = 1$   
 $r_3(t_3) = 3, m_2(t_3) = 1$

## Redes Temporizadas com Transições Temporizadas




- No instante  $\beta=1$ ,  $r_1(t_0) = 1, m_2(t_0) = 1$
- No instante  $\beta=2$ ,  $r_1(t_1) = 2, m_2(t_1) = 1$   
 $r_2(t_2) = 3, m_2(t_2) = 1$
- No instante  $\beta=3$ ,  $r_1(t_1) = 1, m_2(t_1) = 1$   
 $r_2(t_2) = 2, m_2(t_2) = 1$
- No instante  $\beta=4$ ,  $r_2(t_2) = 1, m_2(t_2) = 1$
- No instante  $\beta=5$ ,  $r_2(t_2) = 1, m_2(t_2) = 1$   
 $r_3(t_3) = 3, m_2(t_3) = 1$

## Redes Temporizadas com Transições Temporizadas



- No instante  $\beta=1$ ,  $r_1(t_0) = 1, m_2(t_0) = 1$
- No instante  $\beta=2$ ,  $r_1(t_1) = 2, m_2(t_1) = 1$   
 $r_2(t_2) = 3, m_2(t_2) = 1$
- No instante  $\beta=3$ ,  $r_1(t_1) = 1, m_2(t_1) = 1$   
 $r_2(t_2) = 2, m_2(t_2) = 1$
- No instante  $\beta=4$ ,  $r_2(t_2) = 1, m_2(t_2) = 1$
- No instante  $\beta=5$ ,  $r_2(t_2) = 1, m_2(t_2) = 1$   
 $r_3(t_3) = 3, m_2(t_3) = 1$
- No instante  $\beta=8$ ,  $m_1(p_5) = 1$



## Redes Temporizadas com Transições Temporizadas







### Timed Petri Nets

- Definição: **Grafo de Alcançabilidade Temporizado**- seja uma rede marcada  $TPN=(P, T, F, W, M_0, c, D)$ .  $TRG(TPN)=(S, A, h, q)$  define o grafo de estados temporal (*Timed State Graph*), onde  $S$  é o conjunto de vértice e representa o conjunto de estados.  $A \subseteq S \times S$  é uma relação representando arcos dirigidos.  $h : S \rightarrow \mathbb{R}^+ \cup \{0\}$  é uma função que associa o *holding time* a cada estado  $s_i=(m_1, m_2, r)$ , onde  $h(s_i)=\min_{t \in T \wedge m_2(t) > 0} (r_i(t)[1])$

## Redes Temporizadas com Transições Temporizadas

### Timed Petri Nets

- Definição: **Grafo de Alcançabilidade Temporizado**- seja uma rede marcada  $TPN=(P, T, F, W, M_0, c, D)$ .  $TRG(TPN)=(S, A, h, q)$  e  $q : A \rightarrow [0,1]$  é uma função que associa uma probabilidade aos arcos do grafo.



### Redes Temporizadas com Transições Temporizadas

$s_i$	$M_1$	$M_2$	$h(s_i)$	$M'_2$	$s_j$	$c$
1	p=0	t1=1	0	t2=t5=1	2	1
2	p=0	t2=t5=1	10	t4=1	3	0,9
				t3=1	4	0,1
3	p=0	t4=t5=1	5	t1=1	5	1
4	p=0	t3=t5=1	0	t=0	6	1
5	p6=1	t1=t5=1	0	t2=t5=1	7	1
6	p=0	t5=1	10	t7=1	8	1
7	p6=1	t2=1, t5=2	5	t6=1	9	1
8	p=0	t7=1	0	t1=1	1	1
9	p=0	t2=t5=1	0	t=0	10	1
			t6=1			
10	p=0	t2=t5=1	5	t4=1	3	0,9
				t3=1	4	0,1

### Redes Temporizadas com Transições Temporizadas

$s_i$	$M_1$	$M_2$	$h(s_i)$	$M'_2$	$s_j$	$c$
1	p=0	t1=1	0	t2=t5=1	2	1
2	p=0	t2=t5=1	10	t4=1	3	0,9
				t3=1	4	0,1
3	p=0	t4=t5=1	5	t1=1	5	1
4	p=0	t3=t5=1	0	t=0	6	1
5	p6=1	t1=t5=1	0	t2=t5=1	7	1
6	p=0	t5=1	10	t7=1	8	1
7	p6=1	t2=1, t5=2	5	t6=1	9	1
8	p=0	t7=1	0	t1=1	1	1
9	p=0	t2=t5=1	0	t=0	10	1
			t6=1			
10	p=0	t2=t5=1	5	t4=1	3	0,9
				t3=1	4	0,1

### Redes Temporizadas com Transições Temporizadas

- Tempo de Execução
  - Análise do grafo de estados + Algoritmo de Procura de Caminhos
    - (Redes Genéricas)
  - Métodos Estrutural
    - (sub-classes: grafo-marcado)

### Redes Temporizadas com Transições Temporizadas

$s_i$	$M_1$	$M_2$	$h(s_i)$	$M'_2$	$s_j$	$c$
1	p=0	t1=1	0	t2=t5=1	2	1
2	p=0	t2=t5=1	10	t4=1	3	0,9
				t3=1	4	0,1
3	p=0	t4=t5=1	5	t1=1	5	1
4	p=0	t3=t5=1	0	t=0	6	1
5	p6=1	t1=t5=1	0	t2=t5=1	7	1

•  $D(s1,s5) = 0 + 10 + 5 + 0 = 15$


### Redes Temporizadas com Transições Temporizadas

- Métodos Algébricos Aplicados aos Grafos Marcados
  - $C_{in} = \max_k \{D_k/N_k\}$   $k=1, \dots, q$ 
    - $q$  é o número de circuitos
    - $D_k$  é a soma dos tempos associados às transições do circuito  $k$
    - $N_k$  é o somatório de marcas no circuito  $k$

### Redes Temporizadas com Transições Temporizadas

- P-minimum semiflows:
  - SP1={A,C,E,G}
  - SP2={A,D,F,G}
  - SP3={B,C,E}
  - SP4={B,D,F}
- Circuito:
  - c1={t1,t2,t4,t5}
  - c2={t1,t3,t4,t5}
  - c3={t1,t2,t4}
  - c4={t1,t3,t4}

## Redes Temporizadas com Transições Temporizadas



## Redes Temporizadas com Transições Temporizadas

- Estendendo o Método Anterior para Redes *Free-Choice* sem Compartilhamento de Recursos
- Seja  $N=(P,T,I,O,M_0,D)$  uma rede e  $SN_i=(p^{SN_i}, T^{SN_i}, I^{SN_i}, O^{SN_i}, M_0^{SN_i}, D^{SN_i})$  e uma rede  $SN_i \subseteq N$  obtida pelos *p-minimum semiflows*. Seja  $SN_k=(p^{SN_k}, T^{SN_k}, I^{SN_k}, O^{SN_k}, M_0^{SN_k}, D^{SN_k})$  uma rede tal que  $SN_k \subseteq SN_i$  onde  $T^{SN_k}$  pertence a um único *t-minimum semiflows*.


## Redes Temporizadas com Transições Temporizadas

- Tempo do Caminho Crítico
  - $CT_m = \max_k \{D_k/N_k\} \quad k=1, \dots, q$
  - $q$  é o número de sub-redes  $SN_k$
  - $D_k$  é a soma dos tempos associados às transições da sub-rede  $k$ .
  - $N_k$  é o somatório de marcas no circuito  $k$

## Redes Temporizadas com Transições Temporizadas

- Tempo Mínimo
  - $MT_m = \max_k \{ \min \{D_j/N_j\}, D_i/N_i \} \quad i=1, \dots, q, \quad j=1, \dots, r$
  - $q$  é o número de sub-redes  $SN_i$  obtidas diretamente dos *p-minimum semiflows* e cujos  $T^{SN_i}$  pertence a um único *t-minimum semiflows*.
  - $r$  é o número de sub-redes  $SN_j$  obtidas dos *p-minimum semiflows* e por sua decomposição tal que  $T^{SN_j}$  pertence a um único *t-minimum semiflows*.
  - $D_i$  é a soma dos tempos associados às transições da sub-rede  $k$ .
  - $N_k$  é o somatório de marcas no circuito  $k$


## Redes Temporizadas com Transições Temporizadas



## Redes Temporizadas com Transições Temporizadas

- T-minimum semiflows*
  - $St_0 = \{t_0, t_2, t_6, t_7, t_8, t_9, t_{10}, t_{11}, t_{12}, t_{13}, t_{14}, t_{15}, t_{17}\}$
  - $St_1 = \{t_0, t_2, t_6, t_7, t_8, t_9, t_{10}, t_{11}, t_{12}, t_{13}, t_{14}, t_{16}, t_{18}\}$

## Redes Temporizadas com Transições Temporizadas



## Redes Temporizadas com Transições Temporizadas

### $\boxtimes$ P-minimum semiflows

- $\boxtimes sp_1 = \{p_0, p_1, p_5, p_8, p_{16}, p_{18}\}$
- $\boxtimes sp_2 = \{p_0, p_3, p_1, p_{15}, p_{17}, p_{18}, p_{19}, p_{20}\}$
- $\boxtimes sp_3 = \{p_0, p_1, p_5, p_{10}, p_{18}\}$
- $\boxtimes sp_4 = \{p_0, p_2, p_9, p_{10}, p_{18}\}$
- $\boxtimes sp_5 = \{p_0, p_2, p_8, p_9, p_{16}, p_{18}\}$
- $\boxtimes sp_6 = \{p_0, p_3, p_{11}, p_{13}, p_{14}, p_{17}, p_{18}\}$

## Redes Temporizadas com Transições Temporizadas

### $\boxtimes$ Transition paths

- $\boxtimes sn_1 = \{t_0, t_2, t_6, t_7, t_{13}, t_{14}\}$
- $\boxtimes sn_2 = \{t_0, t_{10}, t_{11}, t_{12}, t_{13}, t_{14}, t_{16}, t_{17}, t_{18}\}$
- $\boxtimes sn_3 = \{t_0, t_2, t_6, t_{13}, t_{14}\}$
- $\boxtimes sn_4 = \{t_0, t_6, t_8, t_{13}, t_{14}\}$
- $\boxtimes sn_5 = \{t_0, t_6, t_7, t_8, t_{13}, t_{14}\}$
- $\boxtimes sn_6 = \{t_0, t_9, t_{10}, t_{12}, t_{13}, t_{14}, t_{15}\}$

## Redes Temporizadas com Transições Temporizadas

### $\boxtimes$ Decomposição dos Caminhos

- $\boxtimes sn_2 = \{t_0, t_{10}, t_{11}, t_{12}, t_{13}, t_{14}, t_{16}, t_{17}, t_{18}\}$
- $\square sn_{21} = \{t_0, t_{10}, t_{11}, t_{12}, t_{13}, t_{14}, t_{17}\}$
- $\square sn_{22} = \{t_0, t_{10}, t_{12}, t_{13}, t_{14}, t_{16}, t_{18}\}$

## Redes Temporizadas com Transições Temporizadas

### $\boxtimes$ Tempo do Caminho Crítico

$$\boxtimes CT(N) = \max \{T(sn_1), T(sn_{21}), T(sn_{22}), T(sn_3), T(sn_4), T(sn_5), T(sn_6)\} = 22$$

### $\boxtimes$ Tempo Mínimo

$$\boxtimes MT(N) = \max \{T(sn_1), \min \{T(sn_{21}), T(sn_{22})\}, T(sn_3), T(sn_4), T(sn_5), T(sn_6)\} = 20$$


## Redes Temporizadas com Transições Temporizadas

### $\boxtimes$ Redução de Transição em Sequência

Seja uma rede  $N=(P,T,I,O,M_0,D)$ ,  $p_i \in P$  um lugar, onde  $I(p_j)=\{t_j\}$   $O(p_i)=\{t_k\}$ .  $N$  pode ser transformada em  $N'=(P',T',I',O',M'_0,D')$  pela fusão de  $t_j$  e  $t_k$  e eliminação de  $p_i$ . A transição  $t_{j/k} \in T'$  representa as transições fundidas tal que  $I(t_{j/k}) = I(t_j)$  e  $O(t_{j/k}) = O(t_k)$  e  $d_{j/k} = d_j + d_k$

## Redes Temporizadas com Transições Temporizadas

### Redução de Transição em Sequência




## Redes Temporizadas com Transições Temporizadas

### Redução de Transição de um Escolha

Seja uma rede  $N=(P,T,I,O,M_0,D)$ ,  $p_i, p_l \in P$  lugares, onde  $O(p_i)=[t_j, t_k]$  e  $I(p_l)=[t_j, t_k]$ .  $N$  pode ser transformada em  $N'=(P',T',I',O',M'_0,D')$  pela fusão de  $t_j$  e  $t_k$ . A transição  $t_{j/k} \in T'$  representa as transições fundidas tal que  $I(t_{j/k}) = I(t_j)$  e  $O(t_{j/k}) = O(t_k)$  e o tempo mínimo é  $d_{j/k} = \min\{d_j, d_k\}$  e o tempo máximo é  $d_{j/k} = \max\{d_j, d_k\}$

## Redes Temporizadas com Transições Temporizadas

### Redução de Transição de um Escolha



## Redes Temporizadas com Transições Temporizadas

### Redução de Laço

Seja uma rede  $N=(P,T,I,O,M_0,D)$ ,  $p_i, p_h \in P$  lugares, onde  $O(p_i)=[t_j, t_k]$  e  $O(t_j)=[p_i]$ ,  $I(p_h)=[t_k]$ .  $N$  pode ser transformada em  $N'=(P',T',I',O',M'_0,D')$  pela eliminação de  $t_j$ . O tempo associado a transição  $t_k \in T'$  é  $d_k^{N'} = m \times d_j + d_k$ .

## Redes Temporizadas com Transições Temporizadas

### Redução de Laço




## Redes Temporizadas com Transições Temporizadas

### Redução de Transições Paralelas

Seja uma rede  $N=(P,T,I,O,M_0,D)$ ,  $t_i, t_j, t_h, t_l \in T$  transições, onde  $I(I(t_i))=I(I(t_j))$  e  $O(O(t_i))=O(O(t_j))$ .  $N$  pode ser transformada em  $N'=(P',T',I',O',M'_0,D')$  pela eliminação da estrutura  $SN=(P^{SN},T^{SN},I^{SN},O^{SN},M_0^{SN},D^{SN})$ , onde  $P^{SN}=\{I(t_i), I(t_j)\}$ ,  $O(t_i), O(t_j)$ ,  $T'=\{t_i, t_j, I(I(t_i)), O(O(t_i))=t_h\}$ ,  $t_{h/l} \in T'$  representa a estrutura reduzida, tal que  $I(t_{h/l})=I(I(I(t_i)))=I(I(I(t_j)))$ ,  $O(O(O(t_i)))=O(O(O(t_j)))$  e  $d_{l/j}^{N'} = d_{I(I(t_i))} + \max\{d_i, d_j\} + d_{O(O(t_i))}$ .

## Redes Temporizadas com Transições Temporizadas

### ■ Redução de Transições Paralelas



## Classificação da Técnicas de Avaliação de Desempenho



## Modelagem para Análise de Desempenho

### ■ Algumas Medidas

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

## Redes Temporizadas Estocásticas

### ■ Modelagem para Análise de Desempenho

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

## Redes Temporizadas Estocásticas

- **Variáveis Aleatórias** é uma função que confere um número real a cada resultado (do espaço amostral) de um experimento aleatório.
- **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.

## Redes Temporizadas Estocásticas

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

## 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 ( $f(X)$ ) é uma variável aleatória ( $Y$ ) com Valor Esperado
      - $E[f(X)] = \sum_{\forall k} f(k) \cdot P(X=k)$

## Variáveis Aleatórias Resumo

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

## Variáveis Aleatórias Resumo

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

## Variáveis Aleatórias Resumo

- Discreta
  - Bernoulli
    - Parâmetros:  $p$ ; Valor Esperado:  $p$
    - Variância:  $p(1-p)$ ; Coeficiente de variação:  $(1-p)/p$
  - Binomial
    - Parâmetros:  $n, p$ ; Valor Esperado:  $np$
    - Variância:  $np(1-p)$ ; Coeficiente de variação:  $(1-p)/np$

## Variáveis Aleatórias Resumo

- Discreta
  - Geométrica
    - Parâmetros:  $p$ ; Valor Esperado:  $1/p$
    - Variância:  $(1-p)/p^2$ ; Coeficiente de variação:  $(1-p)$

## 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)
    - $f_X(x) = dF_X(x) / dx$
    - $f_X(x) \geq 0$
    - $\int_{-\infty}^{+\infty} f_X(x) dx = 1$
    - $P(x_1 \leq X \leq x_2) = \int_{x_1}^{x_2} f_X(x) dx$
    - $P(X=x) = \int_x^x f_X(x) dx = 0$

## 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
    - $c_x = \sigma / \bar{X}$

## Redes Temporizadas Estocásticas

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



## Distribuição Exponencial

### Variável Aleatória Exponencial

- fdp exponencial
  - $f_X(t) = \mu e^{-\mu t}$
  - $FD(t) = 1 - e^{-\mu t}$
  - Valor Esperado  $E(X) = \frac{1}{\mu}$
  - Propriedade: Não possui memória



FD - Função de Distribuição

## Distribuição Exponencial

### Variável Aleatória Exponencial

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



## Variáveis Aleatórias Resumo

### Contínua

#### Exponencial

- Parâmetros:  $\mu$ ; Valor Esperado:  $1/\mu$
- Variância:  $1/\mu^2$ ;
- Coefficiente de variação: 1

## Variáveis Aleatórias Resumo

### Contínua

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

#### Hiperexponencial

- Parâmetros:  $k, \mu_j, q_j$ ; Valor Esperado:  $1/\mu$

$$\bar{X} = \sum_{j=1}^k q_j / \mu_j = 1/\mu$$

- Coefficiente de variação:  $\sqrt{2\mu^2 \sum_{j=1}^k (q_j / \mu_j^2 - 1)} \geq 1$
- Variância:  $2 \sum_{j=1}^k (q_j / \mu_j^2 - 1 / \mu^2)$

## Variáveis Aleatórias Resumo

### Contínua

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

#### Hiperexponencial

- Parâmetros:  $k=2, \mu_1, \mu_2, q_1, q_2$ : Valor  
 $\mu_1 = 1/\bar{X} \cdot (1 - \sqrt{(q_2/q_1 \cdot (c^2 - 1)/2)})^{-1}$   
 $\mu_2 = 1/\bar{X} \cdot (1 + \sqrt{(q_1/q_2 \cdot (c^2 - 1)/2)})^{-1}$   
 $q_1 + q_2 = 1, q_1, q_2 \geq 0, \mu_1, \mu_2 > 0$

## Variáveis Aleatórias Resumo

### Contínua

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

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

#### Erlang-k

- Parâmetros:  $k, \mu$ ; Valor Esperado:  $1/\mu$
- Variância:  $1/k\mu^2$
- Coefficiente de variação:  $1/\sqrt{k} \leq 1$

## Variáveis Aleatórias Resumo

### Contínua

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

#### Erlang-k

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

## Variáveis Aleatórias Resumo

### Contínua

- Hipo-exponencial é uma generalização da distribuição de Erlang quando admite-se 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

- Contínua
  - Hipo-exponencial Parâmetros:  $k, \mu$ ;  
Valor Esperado:  $1/\mu_1 + 1/\mu_2$   
Variância:  $1/\mu_1^2 + 1/\mu_2^2$
  - Coeficiente de variação:  $[\text{sqrt}(\mu_1^2 + \mu_2^2) / (\mu_1 + \mu_2)] < 1$


## Variáveis Aleatórias Resumo

- Contínua
- Uma distribuição desconhecida de  $\bar{X}$  com valor esperado  $\bar{X}$  e  $0.5 \leq c \leq 1$  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



## 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

## 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  $\forall s_i \in S, \forall s_j \notin S, p_{ij} = 0$ .
  - 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  $s_i$  é alcançável de qualquer estado  $s_j$ ).

## 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.

## Discrete Time Markov Chain

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



Matriz de Propabilidades de Próximo Estados

$$P = \begin{bmatrix} \alpha & \lambda \\ \mu & \beta \end{bmatrix} \begin{matrix} \alpha + \lambda & \alpha + \lambda \\ \beta + \mu & \beta + \mu \end{matrix} \begin{matrix} 0 \\ 1 \end{matrix}$$

## Discrete Time Markov Chain

- Soluções para *Steady-States*

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

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

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

## Discrete Time Markov Chain

- Soluções para Transiente

$$\Pi(1) = \Pi(0) P,$$

$$\Pi(2) = \Pi(1) P = \Pi(0) P^2$$

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

## 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  $p_{ij}(s,t) = P\{X(t)=j \mid X(s)=i\}$ . Pode ser representada na forma matricial por  $H(s,t) = [p_{ij}(s,t)]$   
 A equação de Chapman-Kolmogorov  

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

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

## Continuous Time Markov Chain

- Equação de Chapman-Kolmogorov

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

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

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

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

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

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

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

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

## Continuous Time Markov Chain

- Equação de Chapman-Kolmogorov

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

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

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

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

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

## Continuous Time Markov Chain

- Equação de Chapman-Kolmogorov

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

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

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

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

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

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

## Continuous Time Markov Chain

- Equação de Chapman-Kolmogorov

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

Para cadeias homogêneas, tem-se:

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

## Continuous Time Markov Chain

- Steady State Analysis

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

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

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

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

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

## Continuous Time Markov Chain

- Soluções para Steady-States

$$\Pi Q = 0$$

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

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

- Soluções Transientes

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

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

## Continuos Time Markov Chain

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

## Continuos Time Markov Chain

- Soluções para *Steady-States*

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

- 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

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



## Continuos Time Markov Chain

- State Transition Rate Diagram*

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

$$\begin{aligned} \sum_{s_i \in S} \pi_{s_i} &= 1 \\ \Pi Q &= 0 \\ (\pi_0, \pi_1, \pi_2) Q &= (0, 0, 0) \end{aligned}$$

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

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

## Continuos Time Markov Chain

- State Transition Rate Diagram*



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

$$\begin{aligned} \sum_{s_i \in S} \pi_{s_i} &= 1 \\ \Pi Q &= 0 \\ (\pi_0, \pi_1, \pi_2, \pi_3) Q &= (0, 0, 0, 0) \end{aligned}$$

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

## 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 no 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:

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

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

## 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 ocorrem em Q.

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



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

Sabe-se também que:

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

Considere uma taxa uniforme  $\lambda$  onde:

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

e  $v \geq 0$  é a taxa de arbitrária de um evento fictício que se deseja introduzir e que não muda de estado  $i$ .

## Continuos Time Markov Chain

### Uniformização



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

Sabe-se também que:

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

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

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

## Continuos Time Markov Chain

### Uniformização



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

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



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

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

## Continuos Time Markov Chain


### Uniformização

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

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

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

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



## Continuos Time Markov Chain

### Soluções Transientes

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

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

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

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

## Continuos Time Markov Chain

### Soluções Transientes

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

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

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

## 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  $\epsilon$ .

## Continuos Time Markov Chain

### Soluções Transientes

Portanto:

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

$$\| \Pi(t) - \Pi(t) \| = \left\| \left[ \Pi(0) e^{-\lambda t} \sum_{n=0}^{\infty} (\lambda P t)^n / n! \right] - \right.$$

$$\left. \left[ \Pi(0) e^{-\lambda t} \sum_{n=0}^{kp} (\lambda P t)^n / n! \right] \right\| = \epsilon$$

Sabemos que  $\Pi(0) e^{-\lambda t} \sum_{n=0}^{\infty} (\lambda P t)^n / n! = 1$

## Continuos Time Markov Chain

### Soluções Transientes

Portanto:

$$\| \Pi(t) - \Pi(t) \| = 1 - \Pi(0) e^{-\lambda t} \sum_{n=0}^{kp} (\lambda P t)^n / n! = \epsilon$$

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

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

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

## Continuos Time Markov Chain

### Solução Transiente (exemplo)


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

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

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

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

■ Considere  $\epsilon = 10^{-4}$



## Continuos Time Markov Chain

### Solução Transiente (exemplo)

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

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

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

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

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

$\hat{\Pi}(0) = \Pi(0) = (1, 0, 0)$  obtêm-se:  
 $\hat{\Pi}(1), \hat{\Pi}(2), \hat{\Pi}(3), \hat{\Pi}(4), \hat{\Pi}(5)$  através de  
 $\hat{\Pi}(n) = \hat{\Pi}(n-1)P, n \in \{1, 2, 3, 4, 5\}$

## 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  $t=0.1 \Rightarrow ke = 5$

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

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

## Redes com Prioridade

### Definição:

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

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


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

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

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

## Redes com Prioridade

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



Remoção da Confusão

- $\pi_i = \pi_k$
- $\pi_h, \pi_i, \pi_j > \pi_k$

## Redes Estocásticas

### Definição:

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


$P$  é o conjunto de lugares,  
 $T$  o conjunto de transições,

$I: P \times T \rightarrow \mathcal{K}$  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


$W: T \rightarrow \mathbb{R}$  (ou  $W: T \times M \rightarrow \mathbb{R}$ ) é uma função que associa taxas de distribuição exponencial às transições

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



## Redes Estocásticas

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



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


## Redes Estocásticas

### Semântica de Disparo de Transição

- Uma transição  $t_j$  é **disparável se estiver habilitada**
  - Regras de habilitação  
 $M[t_j >, M(pi) \geq I(pi, t_j) \forall pi \in P$
- Transições com **delays menores** disparam primeiro (*Race*)
- Enabling Memory, resampling, age memory*
- Regras de disparo  
 Se  $M[t_j > M'$   
 $M'(pi) = M_0(pi) - I(pi, t_j) + O(pi, t_j), \forall pi \in P$

## Redes Estocásticas

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




### Grafo de Marcações




## Redes Estocásticas

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




### Grafo de Marcações




## Redes Estocásticas

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




### Grafo de Marcações




## Redes Estocásticas

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




### Grafo de Marcações




## Redes Estocásticas

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




- Grafo de Marcações




## Redes Estocásticas

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




- Grafo de Marcações




## Redes Estocásticas

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



- Grafo de Marcações



## 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  $s_j$  ( $M_j$ ) é obtido pela soma de todas as *firing rates* associadas às transições que estão habilitadas em  $M_i$  e cujo disparo leva a  $M_j$ .

## Redes Estocásticas

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

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

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

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

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


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

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

## Redes Estocásticas Generalizada (GSPN)

- Definição:  
 $GSPN=(P,T,I,O,H,\Pi,W,M_0)$

$P, T, I, O$  definidos como usualmente.  
 $H : P \times T \rightarrow \mathbb{R}$  é a função de mapeamento de que representam os arcos inibidores



$\Pi : T \rightarrow \begin{cases} 0 & \text{se } t \text{ for temporizada (Prioridade)} \\ \mathbb{R}^+ & \text{se } t \text{ for imediata} \end{cases}$

$W : T \rightarrow \mathbb{R}^+$  (ou  $W : T \times M \rightarrow \mathbb{R}^+$ ) é uma função que associa **taxas de distribuição exponencial** às transições temporizadas e **2 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

- Uma transição  $t$  é **disparável se estiver habilitada**
  - Regras de habilitação
 
$$M[t_j > , \quad M(p_i) \geq I(p_i, t_j) \quad \forall p_i \in P$$
- Transições com **delays menores** disparam primeiro (*Race*)
- Transições **imediatas** disparam **instantaneamente** com **prioridades sobre as temporizadas**
- Diferentes **níveis de prioridade** são associados às **transições imediatas**.
- Transições **imediatas** com **mesmo nível de prioridade** associada **disparam** de acordo com o **peso associado** a cada uma.
- Enabling Memory, resampling, age memory**
- Regras de disparo
 
$$\text{Se } M[t_j > M' \quad M'(p_i) = M_0(p_i) - I(p_i, t_j) + O(p_i, t_j), \quad \forall p_i \in P$$

## Redes Estocásticas Generalizada (GSPN)

### Reachability Set

$$RS = VS \cup TS$$


$$VS \cap TS = \emptyset$$

**VS – Vanishing set:**

Marcações em que as transições disparáveis são imediatas.


**TS – Tangible set:**

Marcações onde as transições habilitadas são temporizadas.



## Redes Estocásticas Generalizada (GSPN)

### Grafo de Marcações



## Redes Estocásticas

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

∞ **limitada** (*bounded*)

∞ **reversível** e

∞ **livre de bloqueio** (*deadlock-free*)

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

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

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

dt

Uma solução formal para o sistema acima é:

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

## Redes Estocásticas

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

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

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

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

## Redes Estocásticas

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

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

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

$ECS(t_k)$  – *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

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

$$tm_i = \min_{t_j \in T_i} (1/\lambda_j)$$

$$T_i = \{t_j \mid M_i[t_j >]\}$$

## Redes Estocásticas

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

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

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

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

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

## Redes Estocásticas

- Throughput rate* de uma transição

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

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

- $p_i$  é a probabilidade estacionária de uma marcação  $M_i$  que habilita  $t_j$
- $\lambda(t_j)$  é a taxa associada a transição

## Redes Estocásticas

- Tempo médio de disparo de uma transição

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

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

- $p_i$  é a probabilidade estacionária de uma marcação  $M_i$  que habilita  $t_j$
- $\lambda(t_j)$  é a taxa associada a transição

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



## 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



- 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

$f_T(t) = r_1 f_{T_1}(t) + r_2 f_{T_2}(t), t \geq 0$   
 $\sum_{j=1}^n r_j = 1$

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*

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

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

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

## Redes Estocásticas

Distribuição Especificada (empírica)

- *Moment Matching*

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

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

## Redes Estocásticas

Distribuição Especificada (empírica)

- *Moment Matching*

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

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

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

## Redes Estocásticas

Distribuição Determinística

- *Moment Matching*

Aproxima-se, fazendo-se  $\sigma_D$  pequeno

$\Rightarrow \gamma$  torna-se grande.

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

## Redes Estocásticas

- Conclusões

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

## Redes Estocásticas

- Extensões às SPN
- ⊗ GSPN (Marsan et al.)
- ⊗ DSPN (Lindermann, Ciardo)

## Redes Estocásticas

- Bibliografia
- ⊗ 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>