

Métodos de Análise Transiente

Tópicos Avançados de Avaliação de Desempenho
Prof. Paulo Maciel / Prof. Ricardo Massa

Apresentação de:
Ana Carolina Veloso
Renata Pedrosa Dantas

- **Visão real das cadeias de Markov**
 - Modelo matemático
 - Processo aleatório
 - Discreto
 - Contínuo
 - Ausência de memória
 - Distribuição exponencial (CTMC)


Definição Formal

- A probabilidade de qualquer comportamento futuro do processo, quando o seu estado atual é conhecida, não é alterada pela conhecimento adicional sobre seu comportamento passado.
- Propriedade da cadeia de markov é dada da seguinte forma

$$\Pr(X_{n+1} = x | X_1 = x_1, X_2 = x_2 \dots, X_n = x_n) = \Pr(X_{n+1} = x | X_n = x_n).$$

- Vamos trabalhar apenas com o conjunto de índice discreto, assim notamos que a cadeia e markov é um processo de estados
- Definimos a probabilidade de transição de n-passos como:

$$p_{ij} = \Pr(X_{n+1} = j | X_n = i).$$




Geração da matriz de taxas



Matriz Q

-1	p	0	0
0	-1	(r+q)*s	q*t
0	0	-1	s
0	0	0	-1

Estado	Prob(X, t=2s)
0	0.1
1	0.2
2	0.6
3	0.1



$$\underline{P}(t) = \sum_{i=0}^{\infty} \underline{\Pi}(i) e^{-qt} \frac{(qt)^i}{i!}$$

$$\underline{\Pi}(i) = \underline{\Pi}(i-1) Q^*$$

- **Tipos possíveis de análise**

- É possível encontrar medidas

- Transientes (para um tempo t específico)

- Quantos servidores estarão ocupados após 1 hora do início do atendimento?

- Estacionárias (para um intervalo de tempo grande/ tendendo ao infinito)

- Qual a porcentagem de tempo em que meu sistema estará disponível ao longo do ano?

- O que representa a análise transiente?
- O que diferencia a análise transiente da análise estacionária?
- Quando é relevante usar a análise transiente?
- CTMCs ou DTMCs, onde é mais utilizada a análise transiente?

- O cálculo do vetor de probabilidade do estado transiente $\pi(t)$ para CTMCs é definido como:

$$\dot{\pi}(t) = \frac{d\pi(t)}{dt} = \pi(t)Q. \quad (2.53)$$

- Assim, para o cálculo do vetor de probabilidade $\pi(t)$, é necessário resolver a equação diferencial linear, dado o gerador infinitesimal da matriz Q e o vetor de probabilidade inicial $\pi(0)$:

$$\frac{d\pi(t)}{dt} = \pi(t)Q, \quad \pi(0) = (\pi_0(0), \pi_1(0), \dots). \quad (5.1)$$

- Mediadas tomadas a partir da probabilidade de estados transientes podem ser referidas como medidas instantâneas, no entanto, por vezes, as medidas baseadas em execuções cumulativas de um período de tempo $[0, t)$ podem ser mais relevantes, onde

$$\mathbf{L}(t) = \int_0^t \boldsymbol{\pi}(u) \, du$$

- Denota o vetor do tempo total esperado nos estados da CTMC durante o período de tempo indicado. Integrando a equação (2.53) obtem-se uma nova equação diferencial para $\mathbf{L}(t)$:

$$\frac{d\mathbf{L}(t)}{dt} = \mathbf{L}(t)\mathbf{Q} + \boldsymbol{\pi}(0), \quad \mathbf{L}(0) = \mathbf{0}. \quad (5.2)$$


- Assim, medidas cumulativas podem ser diretamente calculada a partir desta solução transiente.

Utilizando Métodos Exatos

1. A Pure Birth Process
2. A two-state CMTC
3. Solution Using Laplace Transforms
4. Numerical Solution Using Uniformization
5. Other Numerical Methods

A Pure Birth Process

- Considerando uma CTMC de estados infinitos, que representa um processo de nascimento puro onde as transições possíveis são de estado k para o $k + 1$, com taxa de λ , onde para qualquer λ finito não haverá uma solução estacionária



- Matriz infinitesimal Q

$$Q = \begin{pmatrix} -\lambda & \lambda & 0 & 0 & \dots \\ 0 & -\lambda & \lambda & 0 & \dots \\ 0 & 0 & -\lambda & \lambda & \dots \\ \vdots & \vdots & \vdots & \vdots & \ddots \end{pmatrix}.$$

A Pure Birth Process

- A partir da estrutura da matriz Q e do cálculo do vetor de probabilidade do estado transiente $\pi(t)$ para CTMCs, obtém-se um sistema de equações diferenciais:

$$\frac{d}{dt}\pi_0(t) = -\lambda\pi_0(t), \quad (5.3)$$

$$\frac{d}{dt}\pi_k(t) = -\lambda\pi_k(t) + \lambda\pi_{k-1}(t), \quad k \geq 1. \quad (5.4)$$

- Onde as probabilidades de estado iniciais são:

$$\pi_k(0) = \begin{cases} 1 & k = 0, \\ 0 & k \geq 1, \end{cases} \quad (5.5)$$

- Fazendo as integrações e diferenciações, obtém-se a fórmula fechada:

$$\pi_k(t) = \frac{(\lambda t)^k}{k!} e^{-\lambda t}, \quad k \geq 0. \quad (5.8)$$


- Por indução, um processo de nascimento de taxa constante dá origem a um Processo Poisson.

A Pure Birth Process

- Uma medida importante do processo de Poisson é a sua função valor médio $m(t)$, definida como o número esperado de nascimentos no intervalo $[0, t)$. Esta medida é calculada como:


$$\begin{aligned} m(t) &= \sum_{i=0}^{\infty} i \pi_i(t) = \sum_{i=0}^{\infty} i \frac{(\lambda t)^i}{i!} e^{-\lambda t} \\ &= e^{-\lambda t} \sum_{i=1}^{\infty} \frac{(\lambda t)^{i-1}}{(i-1)!} (\lambda t) = (\lambda t) e^{-\lambda t} \sum_{i=0}^{\infty} \frac{(\lambda t)^i}{i!} \\ &= (\lambda t) e^{-\lambda t} e^{\lambda t} = \lambda t. \end{aligned} \quad (5.9)$$

- Dada a cadeia de markov:



- Onde $\lambda = 0,2$.
- Numa análise para o tempo 5, determine a probabilidade para estado S2.
- Qual a $m(5)$.

- Significa a realização de análise transiente de fórmula fechada para CTMC de dois estados.



- A matriz geradora da CTMC

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

- A partir do sistema de equação diferencial de tempo homogêneo,

$$\frac{d \pi_j(t)}{d t} = \sum_{i \in S} q_{ij} \pi_i(t), \quad \forall j \in S, \quad (2.51)$$

- Obtém-se,

$$\begin{aligned} \frac{d}{d t} \pi_0(t) &= -\mu \pi_0(t) + \lambda \pi_1(t), \\ \frac{d}{d t} \pi_1(t) &= \mu \pi_0(t) - \lambda \pi_1(t). \end{aligned} \quad (5.10)$$

- Aplicando a lei de probabilidade, conclui-se,

$$\pi_0(t) = 1 - \pi_1(t),$$

- Sendo possível reescrever a equação na forma de:

$$\frac{d}{dt}\pi_1(t) = \mu(1 - \pi_1(t)) - \lambda\pi_1(t)$$

or:

$$\frac{d}{dt}\pi_1(t) + (\mu + \lambda)\pi_1(t) = \mu. \quad (5.11)$$

- Sendo padrão para a análise de método diferencial linear é usar o método de fatores de integração, onde todos os lados da equação são multiplicados pelo fator de integração:

$$e^{\int(\mu+\lambda) dt} = e^{(\mu+\lambda)t},$$

- A partir da multiplicação e reordenação, obtém-se:

$$\mu e^{(\mu+\lambda)t} = e^{(\mu+\lambda)t} \frac{d}{dt} \pi_1(t) + (\mu + \lambda) e^{(\mu+\lambda)t} \pi_1(t) \quad (5.12)$$

$$= \frac{d}{dt} (e^{(\mu+\lambda)t} \pi_1(t)). \quad (5.13)$$

- Observa-se que a expressão de soma no lado direito da equação é igual ao derivativo do produto dos subtermos de modo que se tem os resultados da Eq. (5.13). Integrando a Eq. (5.13) em ambos os lados tem-se como um passo intermediário:

$$\frac{\mu}{\mu + \lambda} e^{(\mu+\lambda)t} + c = e^{(\mu+\lambda)t} \pi_1(t). \quad (5.14)$$

- Multiplicando por:

$$e^{-(\mu+\lambda)t}$$

- Fornece o resultado pretendido:

$$\pi_1(t) = \frac{\mu}{\mu + \lambda} + c e^{-(\mu+\lambda)t} . \quad (5.15)$$

- Integração constante c reflete dependência das probabilidades de estado transiente no vetor de probabilidade inicial $\pi(0)$. Assumindo, por exemplo,

$$\pi^{(1)}(0) = (0, 1) ,$$

resulta em,

$$\begin{aligned} 1 &= \pi_1^{(1)}(0) = \frac{\mu}{\mu + \lambda} + c e^{-(\mu+\lambda)0} \\ &= \frac{\mu}{\mu + \lambda} + c . \end{aligned}$$


- As expressões finais das probabilidades de estado transiente neste caso resultam em:

$$\pi_1^{(1)}(t) = \frac{\mu}{\mu + \lambda} + \frac{\lambda}{\mu + \lambda} \left(e^{-(\mu + \lambda)t} \right), \quad (5.16)$$

$$\begin{aligned} \pi_0^{(1)}(t) &= 1 - \pi_1^{(1)}(t) \\ &= \frac{\mu + \lambda}{\mu + \lambda} - \frac{\mu + \lambda \left(e^{-(\mu + \lambda)t} \right)}{\mu + \lambda} \\ &= \frac{\lambda - \lambda \left(e^{-(\mu + \lambda)t} \right)}{\mu + \lambda} \\ &= \frac{\lambda}{\mu + \lambda} - \frac{\lambda}{\mu + \lambda} \left(e^{-(\mu + \lambda)t} \right). \end{aligned} \quad (5.17)$$

- Com uma expressão de forma fechada das probabilidades de estado transiente dadas, medida de desempenho pode ser facilmente derivada.

- Dada a cadeia de markov:



- Onde $\lambda = 100$ e $\mu = 1$.
- Numa análise para o tempo 1, determine a probabilidade para estados S_0 e S_1 .

Solution Using Laplace Transforms

- O Método de Laplace pode ser usado para a solução de equações diferenciais lineares, tais como:

$$\frac{d\pi(t)}{dt} = \pi(t)Q, \quad \pi(0) = (\pi_0(0), \pi_1(0), \dots), \quad (5.1)$$

$$\frac{dL(t)}{dt} = L(t)Q + \pi(0), \quad L(0) = \mathbf{0}. \quad (5.2)$$

- No entanto, sua aplicabilidade é limitada a domínios de problemas com espaços pequenos estados ou para aqueles que implicam uma estrutura de matriz regular. Visto que, existem muitas dificuldades em cálculos de raízes de um polinômio e no cálculo da Laplace Inversa.

Solution Using Laplace Transforms

- Com o dado vector probabilidade inicial $\pi(0)$, a transformada de Laplace

$$\frac{d}{dt}\pi_0(t) = -\lambda\pi_0(t), \quad (5.3)$$

produz a seguinte equação em termos de transformar a variável s :

$$s\pi(s) - \pi(0) = \pi(s)\mathbf{Q}. \quad (5.18)$$

Que pode ser resolvido para o vetor de probabilidade transformada $\pi(s)$:

$$\pi(s) = \pi(0)(s\mathbf{I} - \mathbf{Q})^{-1}. \quad (5.19)$$

- CTMC's lidam com sistemas de equações diferenciais, assim seu comportamento transiente pode ser calculado a partir da função exponencial, agora em termos de vetores e matrizes, onde:

$$\underline{p}(t) = \underline{p}(0)e^{\mathbf{Q}t}. \quad (15.38)$$

Que é igual a $\sum_{i=0}^{\infty} (\mathbf{Q}t)^i / i!$,

Não se mostra viável este cálculo direto, visto que:

- erros de arredondamento graves ocorrem normalmente devido ao fato de que a \mathbf{Q} contém positivo, bem como negativos;
- as matrizes $(\mathbf{Q}t)^i$ tornar-se não-esparsa o que requer maior capacidade de armazenamento.
- Para evitar estes problemas aplica-se o método chamado de uniformização (ou aleatorização - Randomization) também chamado de método de Jensen.

- Se λ é escolhido de tal forma que $\lambda \geq \max_i \{|q_{i,j}|\}$, e as entradas de \mathbf{P} são entre 0 e 1, e a linha de \mathbf{P} soma 1, \mathbf{P} é uma matriz estocástica e descreve uma DTMC. O valor λ é chamado de taxa de uniformização e pode ser derivado de \mathbf{Q} por inspeção.

$$\mathbf{P} = \mathbf{I} + \frac{\mathbf{Q}}{\lambda} \Rightarrow \mathbf{Q} = \lambda(\mathbf{P} - \mathbf{I}). \quad (15.39)$$

- Exemplo – uniformizando uma CTMC
 - Considere a CTMC dada por:

$$\mathbf{Q} = \begin{pmatrix} -4 & 2 & 2 \\ 1 & -2 & 1 \\ 6 & 0 & -6 \end{pmatrix}. \quad (15.40)$$

- e probabilidade inicial vector $\mathbf{P}(0) = (1, 0, 0)$. Para a taxa de uniformização encontramos por inspeção: $\lambda = 6$, de modo que o correspondente DTMC é dada por:

$$\mathbf{P} = \frac{1}{6} \begin{pmatrix} 2 & 2 & 2 \\ 1 & 4 & 1 \\ 6 & 0 & 0 \end{pmatrix}. \quad (15.41)$$

- Exemplo – uniformizando uma CTMC

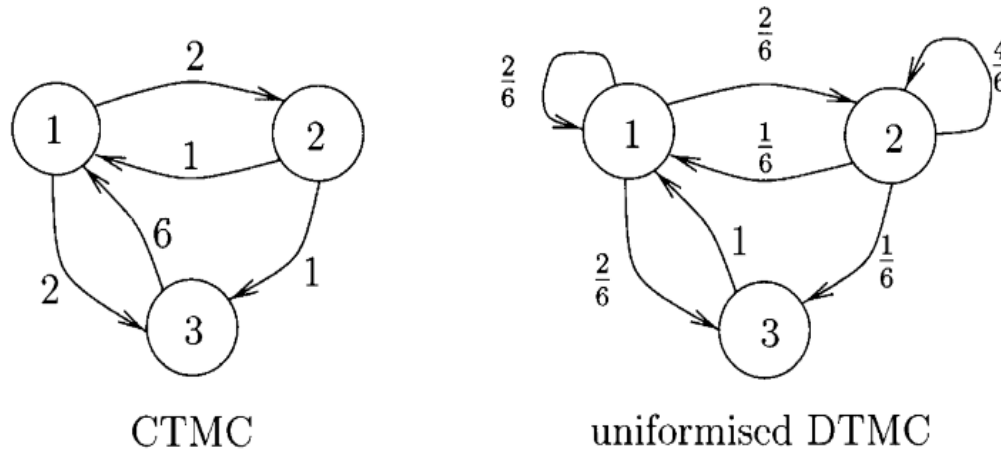


Figure 15.3: A small CTMC and the corresponding DTMC after uniformisation

- Exemplo – uniformizando uma CTMC
 - A uniformização de uma CTMC numa DTMC pode ser entendido como se segue.
 - Na CTMC, os tempos de permanência nos estados são exponencialmente distribuídos. O estado com menor tempo de permanência nos fornece o valor de λ . Para esse estado, uma época na DTMC corresponde a um atraso negativo exponencialmente distribuído com taxa λ , após o qual um dos estados sucessores é selecionada probabilisticamente. Para os estados do CTMC que têm total de taxa de saída λ , os estados correspondentes no DTMC não terão auto-loops. Para os estados do CTMC com uma distribuição de tempo de permanência no estado com uma taxa menor do que λ (os estados tendo em média um tempo de permanência maior do estado), uma época na DTMC pode não ser suficiente; Assim, na próxima época esses estados pode ser revista. Isto se torna possível pela definição de P , em que estes estados têm auto-loops, isto é, $p_{i,i} > 0$.

- Exemplo – uniformizando uma CTMC
 - Usando a matriz P , pode-se obter:

$$\underline{p}(t) = \underline{p}(0)e^{\mathbf{Q}t} = \underline{p}(0)e^{\lambda(\mathbf{P}-\mathbf{I})t} = \underline{p}(0)e^{-\lambda\mathbf{I}t}e^{\lambda\mathbf{P}t} = \underline{p}(0)e^{-\lambda t}e^{\lambda\mathbf{P}t}. \quad (15.42)$$

- Agora empregam uma expansão de séries de Taylor para a última matriz exponencial como segue

$$\underline{p}(t) = \underline{p}(0)e^{-\lambda t} \sum_{n=0}^{\infty} \frac{(\lambda t)^n \mathbf{P}^n}{n!} = \underline{p}(0) \sum_{n=0}^{\infty} \psi(\lambda t; n) \mathbf{P}^n, \quad (15.43)$$

where

$$\psi(\lambda t; n) = e^{-\lambda t} \frac{(\lambda t)^n}{n!}, \quad n \in \mathbb{N}, \quad (15.44)$$

- são probabilidades Poisson, ou seja, $\psi(\lambda t; n)$ é a probabilidade de n eventos ocorrendo em $[0, t)$ em um processo de Poisson com taxa λ . A matriz P , é uma matriz de probabilidade com todas as suas entradas entre 0 e 1, como são as probabilidades de Poisson.

- A uniformização permite um algoritmo de solução iterativa em que há a multiplicação de matrizes. Considerando a seguinte soma de vetores:

$$\underline{p}(t) = \sum_{n=0}^{\infty} \psi(\lambda t; n) (\underline{p}(0)\mathbf{P}^n) = \sum_{n=0}^{\infty} \psi(\lambda t; n)\underline{\pi}_n, \quad (15.45)$$

–Onde $\underline{\pi}_n$, é o vetor de distribuição de probabilidade de estado após n épocas na DTMC, com matriz de transição \mathbf{P} , sendo derivado de forma recursiva como:

$$\underline{\pi}_0 = \underline{p}(0) \quad \text{and} \quad \underline{\pi}_n = \underline{\pi}_{n-1}\mathbf{P}, \quad n \in \mathbb{N}^+. \quad (15.46)$$

–A soma infinita em (15.45) deve ser truncada depois de k_ϵ interações ou épocas na DTMC. iterações ou épocas no DTMC. Assim, calculando o vetor de probabilidade de estado $\tilde{p}(t)$, tem-se:

$$\underline{\tilde{p}}(t) = \sum_{n=0}^{k_\epsilon} \psi(\lambda t; n)\underline{\pi}_n. \quad (15.47)$$

- O número de termos que tem que ser adicionada para atingir uma precisão pré-especificado ϵ , *a priori*, pode agora ser calculado como se segue. A diferença entre o valor computado e o exato do vetor probabilidade transiente é delimitada como se segue:

$$\|\underline{p}(t) - \tilde{\underline{p}}(t)\| \leq 1 - \sum_{n=0}^{k_\epsilon} e^{-\lambda t} \frac{(\lambda t)^n}{n!}. \quad (15.48)$$

- Assim, temos que encontrar o valor de k_ϵ , tal que $1 - \sum_{n=0}^{k_\epsilon} e^{-\lambda t} (\lambda t)^n / n! \leq \epsilon$.

Precisa-se do menor valor de k , que satisfaça:

$$\sum_{n=0}^{k_\epsilon} \frac{(\lambda t)^n}{n!} \geq \frac{1 - \epsilon}{e^{-\lambda t}} = (1 - \epsilon)e^{\lambda t}. \quad (15.49)$$

- Voltando ao exemplo:

$$\mathbf{Q} = \begin{pmatrix} -4 & 2 & 2 \\ 1 & -2 & 1 \\ 6 & 0 & -6 \end{pmatrix}.$$

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

Para $\sum_{n=0}^{k_\epsilon} \frac{(\lambda t)^n}{n!} \geq \frac{1 - \epsilon}{e^{-\lambda t}} = (1 - \epsilon)e^{\lambda t}$.

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

- Voltando ao exemplo:

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

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

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

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

$$\frac{\sum_{n=0}^4 (0.6)^n}{n!} = 1,8214$$

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

- Voltando ao exemplo:

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

Dado $t=0.1$ $K\epsilon=5$

$$\underline{\tilde{p}}(t) = \sum_{n=0}^{k_\epsilon} \psi(\lambda t; n) \underline{\pi}_n.$$

$n \in \{0, 1, 2, 3, 4, 5\}$

Dado $P(0) = (1, 0, 0)$.

$\wedge P(0) = P(0) = (1, 0, 0)$, obtem-se:

$\wedge P(1), \wedge P(2), \wedge P(3), \wedge P(4), \wedge P(5)$, através de.

$\wedge P(n) = \wedge P_{(n-1)} p, n \in \{0, 1, 2, 3, 4, 5\}$.

- Voltando ao exemplo:

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

Dado $t=0.1$ $K\epsilon=5$

$$\tilde{p}(t) = \sum_{n=0}^{k_\epsilon} \psi(\lambda t; n) \pi_n.$$

$$n \in \{0, 1, 2, 3, 4, 5\}$$

$$\varphi(0,6,n) = [e^{-0,6} (0,6)^n] / n! , n \in \{0, 1, 2, 3, 4, 5\}$$

$$\wedge P(0.1) = \sum_{n=0}^5 \varphi(0,6,n) \wedge P(n)$$

- Voltando ao exemplo:

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

Dado $t=0.1$ $K\epsilon=5$

$$\varphi(0,6,n) = [e^{-0,6} (0,6)^n]/n! , n \in \{0, 1, 2, 3, 4, 5\}$$

$$\varphi(0,6,0) = [e^{-0,6} (0,6)^0]/0!$$

$$\varphi(0,6,1) = [e^{-0,6} (0,6)^1]/1!$$

$$\varphi(0,6,2) = [e^{-0,6} (0,6)^2]/2!$$

$$\varphi(0,6,3) = [e^{-0,6} (0,6)^3]/3!$$

$$\varphi(0,6,4) = [e^{-0,6} (0,6)^4]/4!$$

$$\varphi(0,6,5) = [e^{-0,6} (0,6)^5]/5!$$

- Voltando ao exemplo:

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

Dado $t=0.1$ $K\epsilon=5$

$$\hat{P}(0.1) = \sum_{n=0}^5 \varphi(0,6,n) \wedge P(n), n \in \{0, 1, 2, 3, 4, 5\}$$

$$\hat{P}(0.1) = (0.71, 0.1502, 0.1268)$$

- Voltando ao exemplo:

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

Dado $t=0.1$ $K\epsilon=5$




Figure 15.4: First two seconds in the evolution of the three-state CTMC computing via uniformisation

- Equações diferenciais Ordinárias
 - Técnica padrão para a solução de equações diferenciais ordinárias (ODE) pode ser utilizado para a solução numérica das equações diferenciais de Kolmogorov de uma CTMC. Tais métodos de solução discretizam o intervalo de solução para um número finito de intervalos de tempo $\{t_1, t_2, \dots, t_i, \dots, t_n\}$.

- Equações diferenciais Ordinárias

- Em um método explícito, a solução $\pi(t_i)$ é aproximada com base em valores $\pi(t_j)$ para $j < i$. Embora os métodos baseados em ODE explícitas geralmente proporcionam bons resultados para modelos não-“stiff”, eles são inadequados se modelos “stiff” precisam ser estudados. Note que “stiff” CTMCs são comumente encontradas na modelagem confiabilidade.

- Equações diferenciais Ordinárias

- Em um método implícito, a solução $\pi(t_i)$ é aproximada com base em valores $\pi(t_j)$ para $j \leq i$. Em cada passo de tempo uma solução de sistema linear é necessária, num método implícito. O aumento da sobrecarga é compensado por melhores propriedades de estabilidade e menor complexidade computacional em modelos “Stiff”.

- Runge-Kutta

- Ideia base é aproximar o vetor de função contínua que segue a partir da equação diferencial por uma função discreta com o tamanho de passos fixos.
- Métodos de Runge-Kutta são chamados de *single-step*
- Método de 4ª ordem ou RK4

$$\tilde{\pi}_{i+1} = \tilde{\pi}_i + \frac{h}{6}(k_1 + 2k_2 + 2k_3 + k_4),$$

$$\begin{cases} k_1 = \tilde{\pi}_i Q, \\ k_2 = (\tilde{\pi}_i + \frac{h}{2}k_1)Q, \\ k_3 = (\tilde{\pi}_i + \frac{h}{2}k_2)Q, \\ k_4 = (\tilde{\pi}_i + hk_3)Q. \end{cases}$$

Com o método clássico de Runge-Kutta de quarta ordem, com passos igual a 0,5 resolva o seguinte problema de valor inicial no intervalo de $X = 0$ a 2 e valor inicial de $y = 1$

$$\frac{dy}{dx} = yx^2 - 1.2y$$

Aggregation of Stiff Markov Chains

- Bobbio e Trivedi [BoTr86] introduziram um método aproximado para o cálculo das probabilidades de estado transitório de CTMCs finitos que pode ser considerado como uma extensão do método Courtois
- Não só proporciona uma técnica para uma computação eficiente aproximados das probabilidades de estado transitório de possivelmente grandes CTMCs, mas também é muitas vezes o caso em que outras técnicas numéricas transitórios falhar.

Aggregation of Stiff Markov Chains >> Outline and Basic Definitions

- Análise transiente é muitas vezes realizado por modelos que apresentam a chamada propriedade de *stiffness* [Bobbio e Trivedi]
- Estado *fast*(rápido)
- Estado *slow*(lento)
- O cálculo atual das probabilidades de estado transitório só é realizada para macroestados *slow* ou *aggregated*.

Aggregation of Stiff Markov Chains >> Outline and Basic Definitions

- Por definição, apenas transições lentas são possíveis entre esses subgrupos S_i e S_j . Uma aproximação para $\pi(t)$ é derivada, onde $\pi(t)$ é a solução da equação diferencial

$$\frac{d}{dt}\pi(t) = \pi(t)\mathbf{Q}, \quad \pi(0) = \left(\pi_{0_0}(0), \pi_{0_1}(0), \dots, \pi_{F_n F-1}(0)\right)$$

- A reorganização da matriz \mathbf{Q} forma a base para criar o gerador de macroestado matriz Σ pode ser realizada em 3 passos

Aggregation of Stiff Markov Chains >> Outline and Basic Definitions

- 1) Agregação dos subconjuntos recorrentes rápidas em macroestados e o correspondente adaptação das taxas de transição entre os macroestados e permanecendo rápido estados transitórios, resultando na matriz geradora intermediário $\tilde{\Sigma}$
- 2) os estados transitórios rápidos são eliminadas e as taxas de transição entre os restantes estados lentas são ajustadas, produzindo o último gerador matriz Σ
- 3) o estado de probabilidade vetor inicial $\pi(0)$ é condensada em $\sigma(0)$ de acordo com o padrão de agregação.

Aggregation of Stiff Markov Chains >> Outline and Basic Definitions

- Solução transiente de equação diferencial descrever as interações de longo prazo entre os macroestados:

$$\frac{d}{dt}\sigma(t) = \sigma(t)\Sigma,$$

$$\sigma(0) = (\sigma_{0_0}(0), \dots, \sigma_{0_{n_0-1}}(0), \sigma_1(0), \dots, \sigma_{F-1}(0))$$

Algoritmo

1. Inicialização
2. Análise estacionário de subconjuntos rápidos recorrentes
3. Construir a matrix geradora intermediaria
4. Agregação de estados transientes rápidos
5. Agregação do vetor de probabilidade inicial do estado $\sigma(0)$:
6. Cálculo do vetor de probabilidade transiente do macroestado $\sigma(t)$
7. As desagregações

Algoritmo

1. Inicialização

- Definir o valor limite taxa de transição, como uma função do horizonte de tempo T para o qual a análise transiente é para ser realizada.
- Particionar o espaço de estados S_0 em estados lento para que estados e rápidos $S - S_0$ em relação a
- Particionar os estados rápido $S-S_0$ mais rápidos em subconjuntos recorrentes $S_l, 1 \leq l \leq F - 1$ e, possivelmente, um subconjunto de estados transitórios rápidos S_F
- Organizar a infinitesimal matriz geradora Q acordo com a Eq. (5.35).

$$Q = \begin{pmatrix} \mathbf{A}_{00} & \mathbf{A}_{01} & \dots & \mathbf{A}_{0F} \\ \mathbf{A}_{10} & \mathbf{Q}_1 & \dots & \mathbf{A}_{1F} \\ \vdots & & \ddots & \vdots \\ \mathbf{A}_{(F-1)0} & \dots & \mathbf{Q}_{F-1} & \mathbf{A}_{(F-1)F} \\ \mathbf{A}_{F0} & \dots & \mathbf{A}_{F(F-1)} & \mathbf{A}_{FF} \end{pmatrix}$$

Algoritmo

2. Análise estacionário de subconjuntos rápidos recorrentes
 - As de submatrizes Q_I (Eq. (5.35)), obter gerador infinitesimal matrizes Q_I^* de acordo com a Eq. (5,38).
 - Calcule o condicional microestado vetores de probabilidade π_I^* de acordo com a Eq. (5,39).

$$Q_I^* = Q_I + D_I . \quad (5.38)$$

$$\pi_I^* Q_I^* = 0, \quad \pi_I^* \mathbf{1} = 1 \quad (5.39)$$

Algoritmo

3. Construir a matrix geradora intermediaria, como na Eq. (5.49)

$$\tilde{\Sigma} = \begin{pmatrix} \tilde{\Sigma}_{MM} & \tilde{\Sigma}_{MF} \\ \tilde{\Sigma}_{FM} & \tilde{\Sigma}_{FF} \end{pmatrix}. \quad (5.49)$$

- Use Q a partir da Eq. (5,35) e $\pi_l^* \mathbf{1}$, $1 < l < F - 1$ de Eq. (5,39) e aplicar operações a partir de Eq. (5,40) através da equação. (5,48).

$$\tilde{\Sigma}_{00} = \mathbf{A}_{00}, \quad [n_0 \times n_0]. \quad (5.40)$$

$$\begin{aligned} \tilde{\Sigma}_{II} &= - \sum_{J, I \neq J} \tilde{\Sigma}_{IJ}, \quad [1 \times 1] \\ &= - \left(\tilde{\Sigma}_{I0} \mathbf{1} + \sum_{J, J \geq 1, J \neq I} \tilde{\Sigma}_{IJ} + \tilde{\Sigma}_{IF} \mathbf{1} \right) \\ &= - \left(\pi_I^* \mathbf{A}_{I0} \mathbf{1} + \sum_{J, J \geq 1, J \neq I} \pi_I^* \mathbf{A}_{IJ} \mathbf{1} + \pi_I^* \mathbf{A}_{IF} \mathbf{1} \right). \end{aligned} \quad (5.48)$$

Algoritmo

4. Agregação de estados transientes rápidos:

- SE $S_f \neq 0$

- ENTÃO realizar a agregação de estados transientes rápidos e construa $\tilde{\Sigma}_{MM}$

- * Calcule o P_{FM} interruptor probabilística de acordo com a Eq. (5.57) de , de acordo com a Eq. (5,55) e Eq. (5.56) a partir de .

- * $\Sigma = \tilde{\Sigma}_{MM}$

- SE NÃO $\Sigma = \tilde{\Sigma}$

$$= \tilde{\sigma}_M^{\approx}(t) \left(\tilde{\Sigma}_{MM} - \tilde{\Sigma}_{MF} \tilde{\Sigma}_{FF}^{-1} \tilde{\Sigma}_{FM} \right) \quad (5.55)$$

$$= \tilde{\sigma}_M^{\approx}(t) \tilde{\Sigma}_{MM} . \quad (5.56)$$

$$P_{FM} = -\tilde{\Sigma}_{FF}^{-1} \tilde{\Sigma}_{FM} \quad (5.57)$$

Algoritmo

5. Agregação do vetor inicial do estado de probabilidade $\sigma(0)$:

- Acumule probabilidades iniciais de $\pi_{I_i}(0)$ de microestados $i \in S_I$ em $\tilde{\sigma}_I(0)$, $1 \leq I \leq F - 1$ de acordo com a Eq. (5.58)
- SE $S_F \neq \emptyset$
 - ENTÃO Calcule o vetor de probabilidade inicial do macroestado $\sigma(0) = \tilde{\sigma}_M^{\approx}(0)$ de acordo com a Eq. (5.59).
 - SE NÃO $\sigma(0) = \tilde{\sigma}(0)$ de acordo com a Eq. (5.58).

$$\tilde{\sigma}_I(0) = \pi_I(0)\mathbf{1}. \quad (5.58)$$

$$\tilde{\sigma}_M^{\approx}(0) = \tilde{\sigma}(0) + \pi_F(0)\mathbf{P}_{FM}. \quad (5.59)$$

Algoritmo

6. Cálculo do vetor de probabilidade transiente do macroestado $\sigma(t)$
 - Resolva Eq. (5,37).

$$\frac{d}{dt}\sigma(t) = \sigma(t)\Sigma, \quad (5.37)$$
$$\sigma(0) = (\sigma_{0_0}(0), \dots, \sigma_{0_{n_0-1}}(0), \sigma_1(0), \dots, \sigma_{F-1}(0)) .$$

Algoritmo

7. As desagregações

- Se $S_F \neq 0$

– ENTÃO

* Compute intermediário estado transitório probabilidade vetor $\sigma(t)$ de acordo com a Eq. (5,62).

* Calcule a probabilidade aproximada dos subvetores de micro-estado $\pi_I^{\approx}(t)$ por incondicionamento de π_I^* de acordo com a Eq. (5,64) para todos

$$1 \leq I \leq F - 1$$

– SE NÃO Calcule $\pi_I^{\approx}(t)$ por incondicionamento de acordo com a Eq. (5,63) para todo $1 \leq I \leq F - 1$

$$\tilde{\sigma}(t) \approx \tilde{\sigma}^{\approx(c)}(t) = \frac{1}{c} (\tilde{\sigma}_M^{\approx}(t), \tilde{\sigma}_F^{\approx}(t)) . \quad (5.62)$$

$$\pi_I(t) \approx \pi_I^{\approx}(t) = \left(\tilde{\sigma}_I^{\approx(c)}(t) \pi_I^* \right) . \quad (5.64)$$

$$\pi_I(t) \approx \pi_I^{\approx}(t) = (\sigma_I(t) \pi_I^*) . \quad (5.63)$$

Algoritmo

8. Resultado Final

- Componha o vetor de probabilidade transiente aproximado $\pi(t) \approx \pi^{\approx}(t)$ de acordo com a Eq. (5.65) se $S_F \neq \emptyset$ ou a Eq. (5.66) se $S_F = \emptyset$.

$$\begin{aligned}
 \pi(t) \approx \pi^{\approx}(t) &= \left(\tilde{\sigma}_{0_0}^{\approx(c)}(t), \dots, \tilde{\sigma}_{0_{n_0-1}}^{\approx(c)}(t), \right. \\
 &\quad \left. \tilde{\sigma}_1^{\approx(c)}(t)\pi_{1_0}^*, \dots, \tilde{\sigma}_{F-1}^{\approx(c)}(t)\pi_{F-1_{n_{F-1}-1}}^*, \right. \\
 &\quad \left. \tilde{\sigma}_{F_0}^{\approx(c)}(t), \dots, \tilde{\sigma}_{F_{n_F-1}}^{\approx(c)}(t) \right) \\
 &= \left(\tilde{\sigma}_0^{\approx(c)}(t), \pi_1^{\approx}(t), \dots, \pi_{F-1}^{\approx}(t), \tilde{\sigma}_F^{\approx(c)}(t) \right). \quad (5.65)
 \end{aligned}$$

$$\begin{aligned}
 \pi(t) \approx \pi^{\approx}(t) &= \left(\tilde{\sigma}_{0_0}(t), \dots, \tilde{\sigma}_{0_{n_0-1}}(t), \right. \\
 &\quad \left. \tilde{\sigma}_1(t)\pi_{1_0}^*, \dots, \tilde{\sigma}_{F-1}(t)\pi_{F-1_{n_{F-1}-1}}^* \right) \\
 &= \left(\tilde{\sigma}_0(t), \pi_1^{\approx}(t), \dots, \pi_{F-1}^{\approx}(t) \right). \quad (5.66)
 \end{aligned}$$



OBRIGADA!

FIM