

Algoritmos para Projeto de Redes de Telecomunicações: Introdução a Teoria de Filas

Programa de Pós-Graduação em Informática PPGIA - PUCPR

Prof. Marcelo E. Pellenz
<http://www.ppgia.pucpr.br/~marcelo>
marcelo@ppgia.pucpr.br

Introdução a Teoria de Filas

- A **teoria de filas** é uma importante área de aplicação da **teoria de probabilidades**, que estuda o fenômeno da formação de filas de solicitantes de serviços, fornecidos por um determinado recurso.
- **As filas surgem porque a demanda de serviço é maior que a capacidade de atendimento do sistema.**
- A **teoria de filas** é utilizada para análise e dimensionamento de **redes de comunicações** e **sistemas computacionais**.
- Permite estimar importantes medidas de desempenho de um sistema a partir de propriedades mensuráveis das filas.
- Permite dimensionar um determinado sistema segundo a demanda dos seus clientes, evitando desperdícios ou gargalos.
- As filas apresentam comportamento **estocástico**.

Introdução a Teoria de Filas

● Exemplos

- Compartilhamento de tempo em computadores:
 - Clientes: programas (processos)
 - Servidores: CPU, disco, dispositivos de I/O, barramento
- Multiplexadores estatísticos baseados em pacotes:
 - Clientes: pacotes (células)
 - Servidores: Enlaces (links)
- Comutadores por Circuito:
 - Clientes: Chamadas
 - Servidores: Canais

3

Introdução a Teoria de Filas

● Exemplos

- Redes de Múltiplo Acesso (Ethernet LAN / Wireless LAN)
 - Clientes: pacotes (frames)
 - Servidores: Meio Físico (fibra/par trançado/RF)
- Servidores Web
 - Clientes: requisições
 - Servidor

4

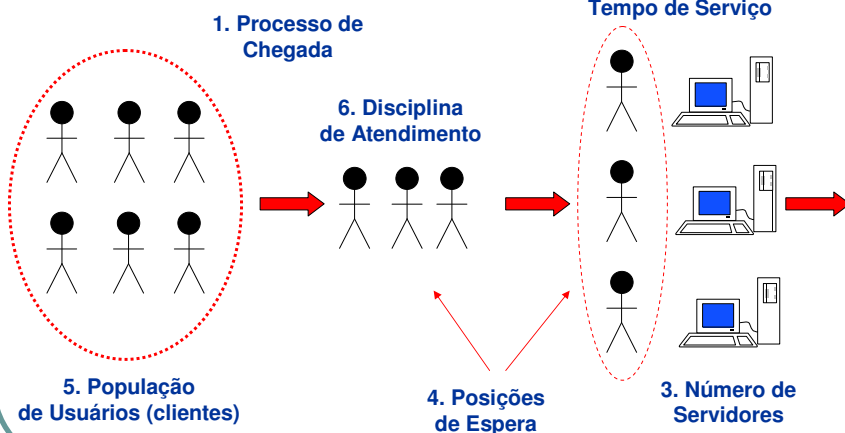
Introdução a Teoria de Filas

- **Sistemas de fila** em redes de comunicações:
 - Fila de **pacotes** aguardando por **transmissão**.
 - Fila de **pacotes** aguardando por **roteamento/comutação**.
 - Fila de **pacotes** recebidos na **placa de rede** de um terminal.
 - Fila de **chamadas** telefônicas **aguardando por linha** em um PABX.
 - Fila de **amostras de voz** recebidas em **um telefone IP**.

5

Introdução a Teoria de Filas

Componentes Básicos de um Sistema de Fila



6

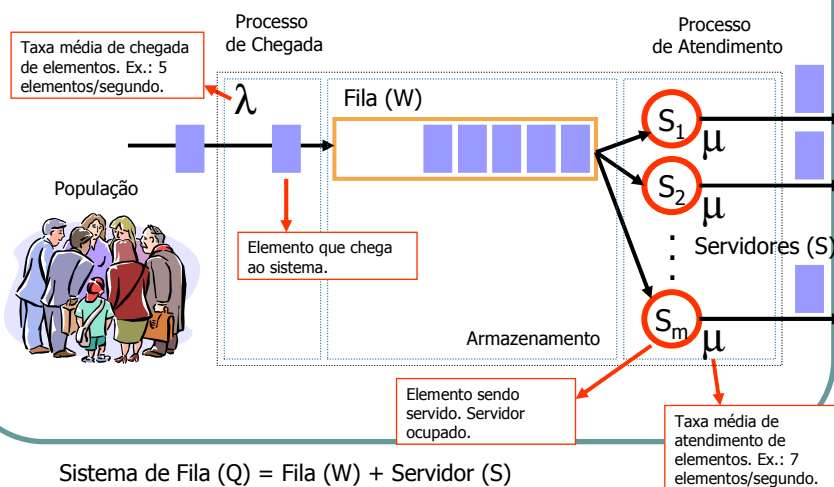
Introdução a Teoria de Filas

- Um **sistema de filas** (Q – *Queuing System*) é um sistema composto por:
 - Uma ou mais **filas** (W – *Waiting Line*) onde são armazenados os elementos que aguardam por atendimento.
 - Um ou mais **servidores** (S – *Servers*) que atendem os elementos.
 - Um **processo de chegada**, que define como os elementos chegam ao sistema.
 - Um **processo de atendimento**, que define como os elementos são atendidos pelo sistema.
 - O **tamanho da população** que gera os elementos.

7

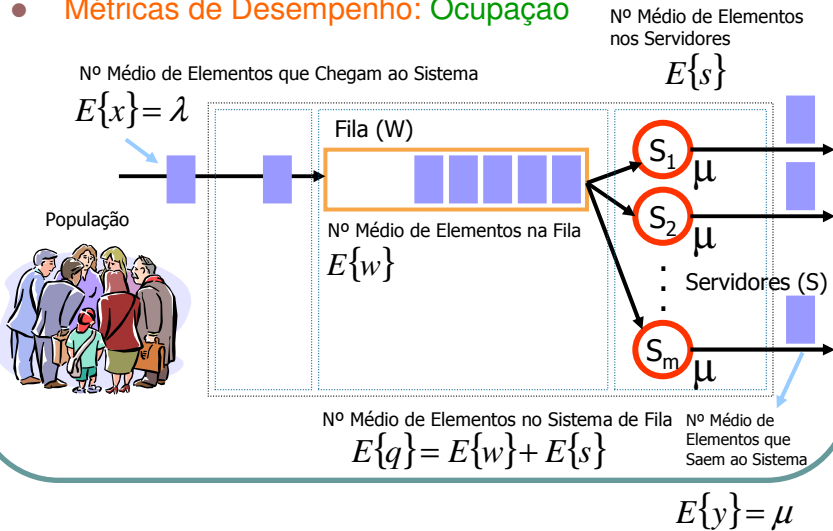
Introdução a Teoria de Filas

- Sistema de Filas com 1 **Fila** e vários **Servidores**



Introdução a Teoria de Filas

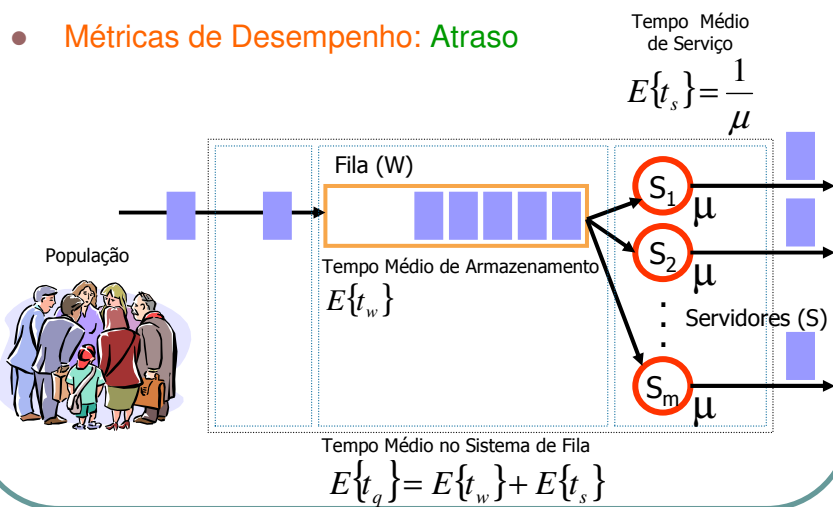
- Métricas de Desempenho: **Ocupação**



9

Introdução a Teoria de Filas


- Métricas de Desempenho: **Atraso**



10

Introdução a Teoria de Filas

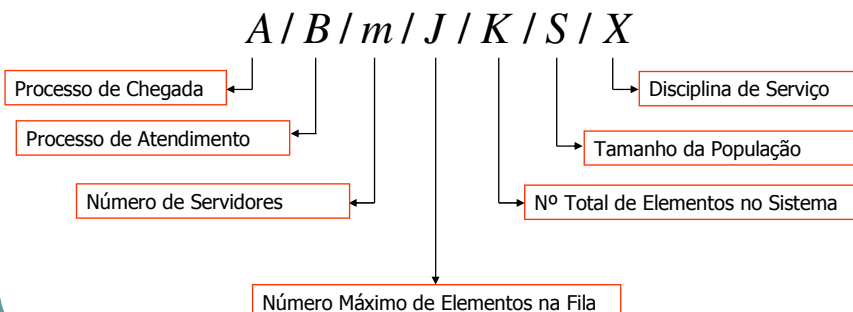
- A notação de Kendall foi desenvolvida em 1951 para descrever o comportamento de um sistema de fila em uma única frase:



11

Introdução a Teoria de Filas

- Notação de Kendall Expandida:



12

Introdução a Teoria de Filas

- **Processo de Chegada (A)**
 - Descreve o processo que modela as **chegadas de elementos** ao sistema.
 - Modelos clássicos utilizados:
 - **M – Markoviano**
 - Intervalo de tempo entre chegadas é exponencial.
 - **D – Determinístico**
 - Intervalo de tempo entre chegadas é constante.
 - **G – Genérico**
 - Intervalo de tempo entre chegadas é tratado de forma genérica, independente da distribuição.

13

Introdução a Teoria de Filas

- **Processo de Chegada (A)**
 - Apresenta um comportamento **estocástico**.
 - Instantes de chegada: t_1, t_2, \dots, t_j
 - Intervalo entre chegadas: $\tau_j = t_j - t_{j-1}$
 - É geralmente assumido que os intervalos entre chegadas formam uma sequência de variáveis aleatórias **independentes e identicamente distribuídas (iid)**.
 - O processo de chegada mais comum é o **processo de Poisson**, que significa que os intervalos entre chegadas são **iid e exponencialmente distribuídos**.

14

Introdução a Teoria de Filas

- **Processo de Atendimento (B)**
 - Descreve o processo que modela o **atendimento de elementos** no sistema.
 - Modelos clássicos utilizados:
 - **M – Markoviano**
 - O tempo de serviço de um elemento é exponencial.
 - **D – Determinístico**
 - O tempo de serviço de um elemento é constante.
 - **G – Genérico**
 - O tempo de serviço de um elemento é tratado de forma genérica, independente da distribuição.

15

Introdução a Teoria de Filas

- **Processo de Atendimento (B)**
 - É comum assumir que os **tempos de serviço** dos clientes também são variáveis aleatórias **independentes e identicamente distribuídas (iid)**.
 - Atendimentos Simples / Lote
 - Serviço Independente/Dependente do Estado


16

Introdução a Teoria de Filas

- **Tamanho da População (S)**
 - Descreve o tamanho da população que gera elementos para o sistema. Tipicamente é considerada como infinito.
- **Disciplina de Serviço (X)**
 - Os elementos que aguardam por serviço na fila podem ser selecionados de acordo com uma **regra** chamada **disciplina de serviço**. Dentre as principais disciplinas estão:
 - **FCFS – First Come First Served (FIFO)**
 - Primeiro elemento que chega é o primeiro a ser atendido.
 - **LCFS – Last Come First Served (LIFO)**
 - Último elemento que chega é o primeiro a ser atendido.
 - **SIRO – Service In a Random Order**
 - Elementos são atendidos em ordem aleatória.
 - **RR – Round Robin**
 - **WRR – Weighted Round Robin**

17

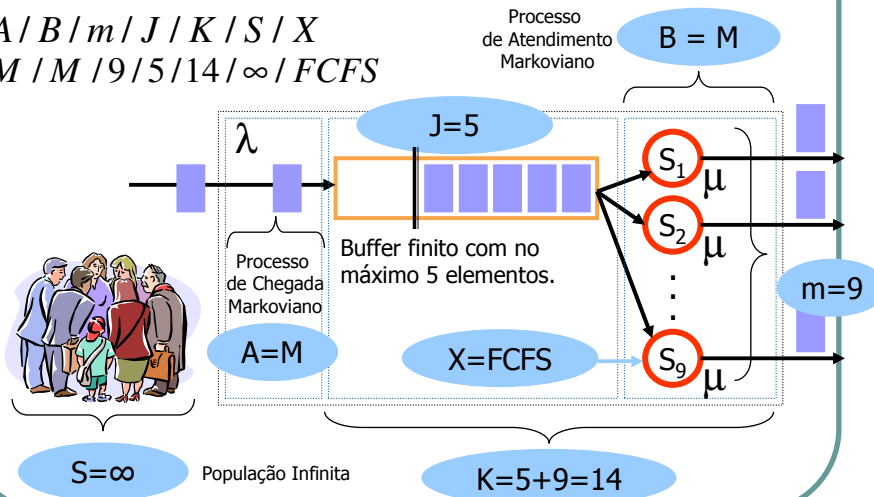
Introdução a Teoria de Filas



18

Introdução a Teoria de Filas

$A/B/m/J/K/S/X$
 $M/M/9/5/14/\infty/FCFS$



19

Introdução a Teoria de Filas

Exemplo - $M/M/3/20/1500/FCFS$

1. O tempo entre chegadas sucessivas é exponencialmente distribuído (M)
2. Os tempos de serviço são exponencialmente distribuídos (M)
3. Existem três servidores (3)
4. A fila possui um buffer para 20 clientes. Isso consiste de três lugares para clientes sendo servidos e 17 lugares para clientes a espera de serviço (20)
5. Existem um total de 1500 clientes que podem ser servidos (1500)
6. A disciplina de serviço é FIFO ($FCFS$)

20

Introdução a Teoria de Filas

- **Sistemas Simples de Filas:** são em geral utilizados para representar recursos compartilhados de rede.
- **Redes de Filas:** são geralmente utilizadas para representar outros tipos de redes.
 - Redes de Processos
 - Redes de Comutação

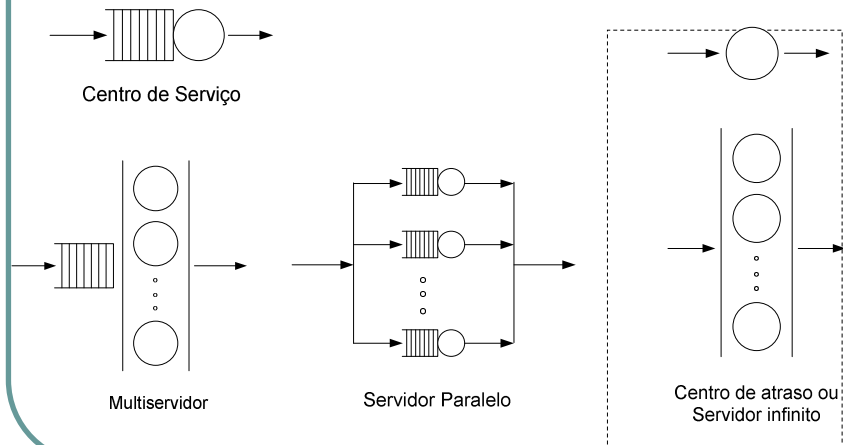
21

Introdução a Teoria de Filas

- **Fontes de Atraso na Rede**
 - Atraso de Processamento
 - Assuma que a velocidade de processamento não é uma restrição.
 - Atraso de Filas
 - Tempo de espera no *buffer* para transmissão.
 - Atraso de Transmissão
 - Atraso de Propagação
 - Tempo gasto no enlace – transmissão do sinal elétrico.
 - Independente do tráfego transportado pelo enlace.
- ➡ **Foco de Estudo: Filas + Atraso de Transmissão**

22

Introdução a Teoria de Filas



23

Distribuições de Probabilidade

- **Determinística (D)**
 - Implica que os tempos entre as chegadas ou de serviço são constantes.
 - Não há variância estatística.
 - Pelo menos uma das distribuições (chegada ou serviço) precisa ser aleatória, caso contrário o sistema de filas terá baixa aplicabilidade no mundo real.

24

Distribuições de Probabilidade

- Exponencial (M)
 - Para **Chegadas (A)**: o intervalo entre uma chegada e a próxima é completamente independente do período anterior.
 - Para **Tempos de Serviço (B)**: o tempo de serviço atual é independente do tempo de serviço anterior.
 - Esses processos são ditos “sem memória”, pois seus intervalos não estão correlacionados no tempo. Portanto, podem ser caracterizados por uma distribuição exponencial.

25

Distribuição Exponencial

- Uma V.A. contínua X segue a distribuição exponencial com parâmetro μ , se a sua função densidade de probabilidade é:

$$f_X(x) = \begin{cases} a \cdot e^{-ax} & x \geq 0 \\ 0 & x < 0 \end{cases}$$

- Função Distribuição (Acumulada) de Probabilidade:

$$F_X(x) = P\{X \leq x\} = \begin{cases} 1 - e^{-ax} & x \geq 0 \\ 0 & x < 0 \end{cases}$$

- Demonstração:

$$F_X(x) = \int_0^x a \cdot e^{-ay} dy \quad \int e^u du = e^u \quad \int e^{ax} dx = \frac{e^{ax}}{a}$$

26

Distribuição Exponencial

- Média e Variância:

$$E[X] = \frac{1}{a} \quad \sigma_X^2 = \text{Var}[X] = \frac{1}{a^2}$$

- ▶ Demonstração:

$$E[X] = \int_0^{\infty} x f_X(x) dx = \int_0^{\infty} x a e^{-ax} dx =$$

$$= -x e^{-ax} \Big|_0^{\infty} + \int_0^{\infty} e^{-ax} dx = \frac{1}{a}$$

$$E[X^2] = \int_0^{\infty} x^2 a e^{-ax} dx = -x^2 e^{-ax} \Big|_0^{\infty} + 2 \int_0^{\infty} x e^{-ax} dx = \frac{2}{a} E[X] = \frac{2}{a^2}$$

$$\text{Var}[X] = E[X^2] - (E[X])^2 = \frac{2}{a^2} - \frac{1}{a^2} = \frac{1}{a^2}$$

27

Distribuição Exponencial

- Integração:

$$\int x \cdot e^{ax} dx = \frac{e^{ax}}{a} \left(x - \frac{1}{a} \right)$$

$$\int e^{ax} dx = \frac{e^{ax}}{a}$$

$$\int x^n \cdot e^{ax} dx = \frac{x^n e^{ax}}{a} - \frac{n}{a} \int x^{n-1} e^{ax} dx$$

28

Propriedade da Ausência de Memória

- A história passada não influencia no futuro:

$$P\{X > x+t \mid X > t\} = P\{X > x\}$$

- ▶ Prova:

$$\begin{aligned} P\{X > x+t \mid X > t\} &= \frac{P\{X > x+t, X > t\}}{P\{X > t\}} = \frac{P\{X > x+t\}}{P\{X > t\}} \\ &= \frac{e^{-\mu(x+t)}}{e^{-\mu t}} = e^{-\mu x} = P\{X > x\} \end{aligned}$$

- A distribuição **exponencial** é a **única** distribuição contínua com a propriedade da ausência de memória.

29

Distribuições de Probabilidade

- **Uniforme (U)**
 - Os tempos de chegada estão limitados por algum valor finito ($a \leq x \leq b$)
 - A probabilidade de X assumir qualquer dos valores do intervalo é a mesma \rightarrow Média = $(a + b)/2$
- **Arbitrária ou Geral (G)**
 - Não é especificada uma distribuição de probabilidade para os tempos de chegada e serviço.
 - Resultados são válidos para todas as distribuições.

30

Processos Estocásticos

- Os *processos estocásticos* são funções ou seqüências aleatórias dependentes do tempo.
- Exemplos:
 - $n(t)$ – Número de processos rodando na CPU de um computador.
 - $w(t)$ – Tempo de espera em uma fila.
- Os *processos estocásticos* são úteis para representar o estado de sistemas com filas.

31

Tipos de Processos Estocásticos

1. Processos de Estados Discretos e Estados Contínuos:


- Discreto: Se o número de valores de estado possíveis é finito ou contável. Estes processos também são chamados de *cadeia estocástica*. Exemplo: O número de processos, $n(t)$, em uma CPU pode apenas assumir valores discretos 0,1,2,...

Contínuo: Os estados podem assumir qualquer valor real.
Exemplo: O tempo de espera na fila, $w(t)$


- ### 2. Processos de Markov:
- Se os estados futuros de um processo são independentes do passado e dependem exclusivamente do estado atual. Isso torna o processo mais fácil de ser analisado pois não é necessário relembrar toda a trajetória passada.
Um *processo de Markov de estados discretos* é chamado de *Cadeia de Markov*

32

Processo de Tráfego Telefônico



Processo de Tráfego de Dados



Tipos de Processos Estocásticos

3. **Processos de Nascimento e Morte:** processos de Markov de estados discretos em que as transições entre estados estão restritas a estados vizinhos.
Exemplo: Número de processos em um servidor único com chegadas individuais.




4. **Processos de Poisson:** Se os intervalos entre chegadas for *iid* e exponencialmente distribuído, o número de chegadas, n , em um dado intervalo $(t, t+x)$ terá uma distribuição de Poisson. O processo de chegadas é chamado de *Processo de Poisson*. As chegadas são “sem memória”, pois o tempo entre as chegadas é *iid* e exponencialmente distribuído.

Exemplo Tráfego de Vídeo MPEG

35

Tipos de Processos Estocásticos

- Relação entre Processos Aleatórios



36

Distribuição de Poisson

- Uma V.A. discreta X segue a distribuição de Poisson com parâmetro λ se a sua função densidade de probabilidade for:

$$P\{X = k\} = e^{-\lambda} \frac{\lambda^k}{k!}, \quad k = 0, 1, 2, \dots$$

- Média e Variância

$$E[X] = \lambda, \quad \text{Var}(X) = \lambda$$

- Ampla aplicabilidade na modelagem do número de eventos aleatórios que ocorrem durante um dado intervalo de tempo – *O Processo de Poisson*:
 - Clientes que chegam num posto de serviço durante um dia.
 - Chamadas telefônicas recebidas por engano durante uma semana.
 - Pacotes que chegam a um roteador da rede.

37

Aproximação de Poisson por Binomial

- Distribuição Binomial com parâmetros (n, p)

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

- Como $n \rightarrow \infty$ e $p \rightarrow 0$, com $np = \lambda$ moderado, a distribuição binomial converge para Poisson com parâmetro λ

38

Soma de Variáveis Aleatórias de Poisson

- $X_i, i=1, 2, \dots, n$, são variáveis aleatórias independentes
- X_i segue a distribuição de Poisson com parâmetro λ_i
- Soma parcial definida como:

$$S_n = X_1 + X_2 + \dots + X_n$$

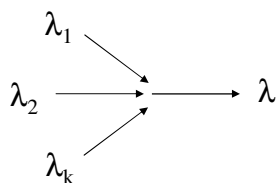
- S_n segue a distribuição de Poisson com parâmetro λ

$$\lambda = \lambda_1 + \lambda_2 + \dots + \lambda_n$$

39

Propriedades dos Fluxos de Poisson

- Superposição de Fluxos

$$\lambda = \sum_{i=1}^k \lambda_i$$


- A superposição de fluxos de Poisson dá como resultado um novo fluxo de Poisson cuja taxa de chegada é o somatório das taxas dos fluxos originais.

40

Amostrando uma V.A. de Poisson

- Considere um processo de Poisson, X , com taxa média λ
- Se o processo (fluxo) X for dividido em n sub-processos, onde a probabilidade do fluxo seguir o i -ésimo sub-fluxo é p_i , $i=1, 2, \dots, n$


$$p_1 + p_2 + \dots + p_n = 1$$

- X_i denota o número de chegadas do tipo i
- X_1, X_2, \dots, X_n são independentes
- X_i segue a distribuição de Poisson com taxa média $\lambda_i = \lambda p_i$

41

Propriedades dos Fluxos de Poisson

- Divisão de Fluxos




- Se um fluxo de Poisson for dividido em n sub-fluxos com probabilidade p_i de um usuário seguir o sub-fluxo i , então cada sub-fluxo é também um fluxo de Poisson com taxa média $p_i \lambda$

42

Propriedades dos Fluxos de Poisson

- Se as chegadas a uma fila com um servidor único e tempo de serviço exponencial forem Poisson com taxa média λ , então as partidas também serão Poisson, com a mesma taxa λ (desde que $\lambda < \mu$)




- $\lambda < \mu$: condição de equilíbrio do sistema

43

Propriedades dos Fluxos de Poisson

- Se as chegadas a uma fila com m servidores e tempos de serviço exponenciais forem Poisson com taxa média λ , então as partidas também serão Poisson, com a mesma taxa λ (desde que $\lambda < \sum \mu_i$)



44

Processo de Poisson

- $\{A(t); t \geq 0\}$ Processo de Contagem
 - $A(t)$ é o número de eventos (chegadas) que ocorreram desde instante 0 – quando $A(0)=0$ – até o instante t .
 - $A(t)-A(s)$ número de chegadas no intervalo $(s, t]$.
- O número de chegadas em intervalos disjuntos é independente.
- Número de chegadas em qualquer intervalo $(t, t+\tau]$ de tamanho τ .
 - Depende apenas do tamanho τ .
 - Segue a distribuição de Poisson com parâmetro $\lambda\tau$.

$$P\{A(t+\tau) - A(t) = n\} = e^{-\lambda\tau} \frac{(\lambda\tau)^n}{n!}, \quad n = 0, 1, \dots$$

- Número médio de chegadas $\lambda\tau$; λ é a taxa de chegada.

45

Intervalo Entre Chegadas

- Os intervalos entre chegadas para um processo de Poisson são independentes e seguem a **distribuição exponencial** com parâmetro λ
- t_n : tempo da n -ésima chegada;
- $\tau_n = t_{n+1} - t_n$: n -ésimo intervalo de chegada

$$P\{\tau_n \leq s\} = 1 - e^{-\lambda s}, \quad s \geq 0$$

Prova:

- Função distribuição de probabilidade

$$P\{\tau_n \leq s\} = 1 - P\{\tau_n > s\} = 1 - P\{A(t_n + s) - A(t_n) = 0\} = 1 - e^{-\lambda s}$$

- A independência vem da independência do número de chegadas em intervalos disjuntos

46