

# Teoría de colas

Modelado y Análisis de Redes de Telecomunicaciones

IIE - Facultad de Ingeniería



# Contenido

- 1 Proceso de Poisson
- 2 Teoría de colas
- 3 El proceso M/M/1
- 4 Los procesos M/M/\*
- 5 El proceso M/G/1
- 6 Redes de colas



# Proceso de conteo

- Un proceso estocástico  $\{N_t : t \geq 0\}$  es un proceso de conteo si:
  - $N_t$  es natural para todo  $t$ .
  - $N_0 = 0$ .
  - Si  $s < t$ , entonces  $N_s \leq N_t$ .
- $N_t$  cuenta el número total de eventos que ocurren en  $[0, t]$  y  $N_t - N_s$  cuenta el número de eventos en  $(s, t]$ .



# Incrementos independientes y estacionarios

- Un proceso de conteo  $N$  tiene incrementos independientes si son independientes

$$N_t - N_s, N_v - N_u \quad \forall 0 \leq s < t \leq u < v$$

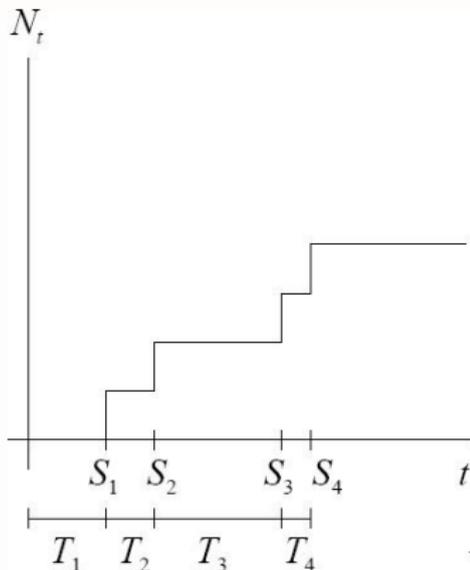
es decir que el número de eventos que ocurre en intervalos disjuntos son v.a. independientes.

- Un proceso de conteo  $N$  es estacionario si, para cualquier  $s < t$ , la distribución de  $N_t - N_s$  depende sólo de  $t - s$  (longitud del intervalo).



## Proceso de Poisson: definición

- $T_1, T_2, \dots$  i.i.d. con distribución exponencial de parámetro  $\lambda$
- Se define la v.a.  $S_n = \sum_{i=1}^n T_i$
- $N = \{N_t\}_{t \in \mathcal{R}}$  tal que  $N_t = \#\{n : S_n \leq t\}$  es un proceso de Poisson de parámetro  $\lambda$



# Propiedades del proceso de Poisson

- Es un proceso de conteo.
- Es estacionario y tiene incrementos independientes.
- $N_{t+s} - N_s$  tiene la misma distribución que  $N_t$  y es Poisson de parámetro  $\lambda_t$

$$P(N_{t+s} - N_s = k) = \frac{(\lambda t)^k e^{-\lambda t}}{k!}$$



# Definiciones equivalentes (1)

Un proceso  $N$  es un proceso de Poisson de parámetro  $\lambda$  si:

- es un proceso de conteo
- tiene incrementos independientes
- $N_t$  tiene distribución de Poisson de parámetro  $\lambda t$ .



## Definiciones equivalentes (2)

Un proceso  $N$  es un proceso de Poisson de parámetro  $\lambda$  si:

- es estacionario
- es un proceso de conteo
- tiene incrementos independientes
- se cumple que:
  - $P(N_h = 0) = 1 - \lambda h + o(h)$
  - $P(N_h = 1) = \lambda h + o(h)$
  - $P(N_h \geq 2) = o(h)$



# Suma de procesos de Poisson

Sean  $N^1, N^2, \dots, N^k$  procesos de Poisson independientes de parámetros  $\lambda_1, \lambda_2, \dots, \lambda_k$ . Entonces el proceso  $N$  definido por

$$N_t = \sum_{i=1}^k N_t^i$$

es un proceso de Poisson de parámetro

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



## División de un proceso de Poisson

- Sea  $\{N_t : t \geq 0\}$  un proceso de Poisson con parámetro  $\lambda$ .
- Supongamos que en cada tiempo que un evento ocurre, éste es clasificado como tipo I con probabilidad  $p$  y como tipo II con probabilidad  $1 - p$ , de manera independiente.
- Sean  $N_t^1$  y  $N_t^2$  respectivamente el número de eventos de tipo I y de tipo II hasta el tiempo  $t$ .
- Entonces,  $N^1$  y  $N^2$  son procesos de Poisson independientes con parámetros  $\lambda p$  y  $\lambda(1 - p)$ .



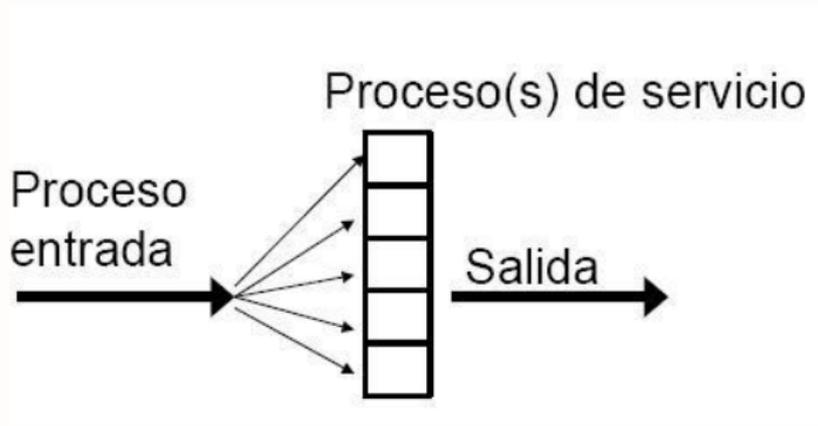
# Contenido

- 1 Proceso de Poisson
- 2 Teoría de colas**
- 3 El proceso M/M/1
- 4 Los procesos M/M/\*
- 5 El proceso M/G/1
- 6 Redes de colas



# Introducción

La teoría de colas se ocupa de estudiar sistemas con la siguientes características:



Nos interesará estudiar la cantidad de clientes en el sistema y/o en la cola, el retardo, tiempo de espera, pérdidas en el sistema, etc.

# Notación de Kendall

La primera letra indica el proceso de entrada , la segunda la distribución del tiempo de servicio y la tercera el número de servidores.

- M/M/1 Poisson/Exponencial/1 servidor (M = Poisson, sin memoria)
- M/G/1 Poisson/General/1 servidor
- D/G/ $n$  Determinístico/General/ $n$  servidores
- E/G/ $\infty$  Erlang/General/Infinitos servidores

Se puede agregar tamaño del buffer, disciplina de servicio, etc..



# Contenido

- 1 Proceso de Poisson
- 2 Teoría de colas
- 3 El proceso M/M/1**
- 4 Los procesos M/M/\*
- 5 El proceso M/G/1
- 6 Redes de colas



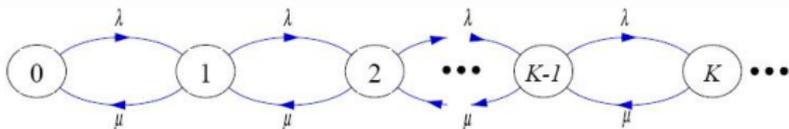
# Características

- Es el modelo más simple.
- Los clientes llegan de acuerdo a un proceso de Poisson de parámetro  $\lambda$  (tiempo entre llegadas exponencial).
- Son atendidos por un solo servidor donde el tiempo de servicio es exponencial de parámetro  $\mu$ .
- La disciplina es FIFO (First In First Out).
- Se puede pensar como un enlace con capacidad  $C$  constante al que arriban paquetes de tamaño exponencial de parámetro  $\mu/C$ , separados tiempos exponenciales de parámetro  $\lambda$ .



# Cadena asociada

- Vimos que no hay arribos simultáneos. Se prueba que tampoco hay arribos y partidas simultáneas.
- Sea  $X_t$  la cantidad de clientes en el sistema en el instante  $t$ .
- $X_t$  es una cadena de Markov homogénea en tiempo continuo con espacio de estados discreto (pero infinito).



# Generador infinitesimal

- El generador infinitesimal de la cadena es

$$P = \begin{pmatrix} -\lambda & \lambda & 0 & \dots & \dots \\ \mu & -(\mu + \lambda) & \lambda & 0 & \dots \\ 0 & \mu & -(\mu + \lambda) & \lambda & \dots \\ \dots & \dots & \dots & \dots & \dots \end{pmatrix}$$

- Las probabilidades de transición de la cadena incluida son

$$\overline{p_{i,i+1}} = \frac{\lambda}{\lambda + \mu} \quad \overline{p_{i,i-1}} = \frac{\mu}{\lambda + \mu}$$



# Ergodicidad

- $E$  es infinito. La cadena es irreducible y recurrente positiva (y por lo tanto ergódica) siempre que  $\lambda < \mu$ .
- En ese caso se dice que el sistema es estable y  $\rho = \frac{\lambda}{\mu}$  se interpreta como la carga del sistema.
- Existe una única distribución límite  $\pi_{est}$  que verifica  $\pi \mathbf{Q} = 0$  (i.e. las ecuaciones de balance)



# Ecuaciones de balance

Si  $\pi_{est}$  es la distribución invariante, planteando el sistema  $\pi_{est}Q = 0$  (ecuaciones de balance) y definiendo  $\rho = \frac{\lambda}{\mu}$  se tiene que

$$\pi_{est}(k) = \rho^k \pi_{est}(0)$$

y por normalización

$$\pi_{est}(0) = \frac{1}{\sum_{k=0}^{\infty} \rho^k}$$



# Distribución invariante

- Si la utilización  $\rho = \frac{\lambda}{\mu} < 1$  la serie converge y

$$\pi_{est}(0) = 1 - \rho$$

- La distribución invariante es

$$\pi_{est}(k) = (1 - \rho)\rho^k$$

- El número de clientes en estado estacionario tiene distribución Geométrica de parámetro  $\rho$ .



## Número medio de clientes

- Si  $N_{sist}$  es el número de clientes en el sistema en estado estacionario, el número medio de clientes en el sistema es

$$E(N_{sist}) = \sum_{k=0}^{\infty} k\pi_{est}(k) = \sum_{k=0}^{\infty} k(1-\rho)\rho^k$$

$$E(N_{sist}) = \frac{\rho}{1-\rho}$$

- Si  $N_{cola}$  es el número de clientes en la cola en estado estacionario, el número medio de clientes en la cola es

$$E(N_{cola}) = \sum_{k=1}^{\infty} (k-1)\pi_{est}(k) = \sum_{k=1}^{\infty} (k-1)(1-\rho)\rho^k$$

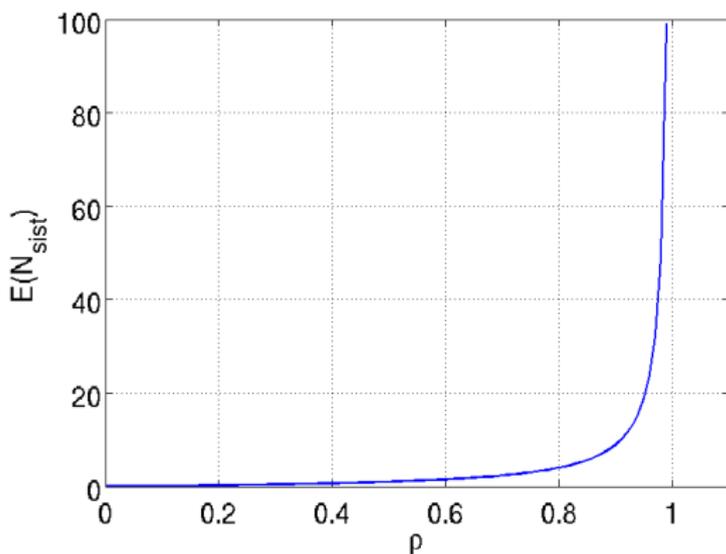
$$E(N_{cola}) = \frac{\rho^2}{1-\rho}$$



## Retardo vs utilización

El retardo medio en el sistema depende de la cantidad media de clientes

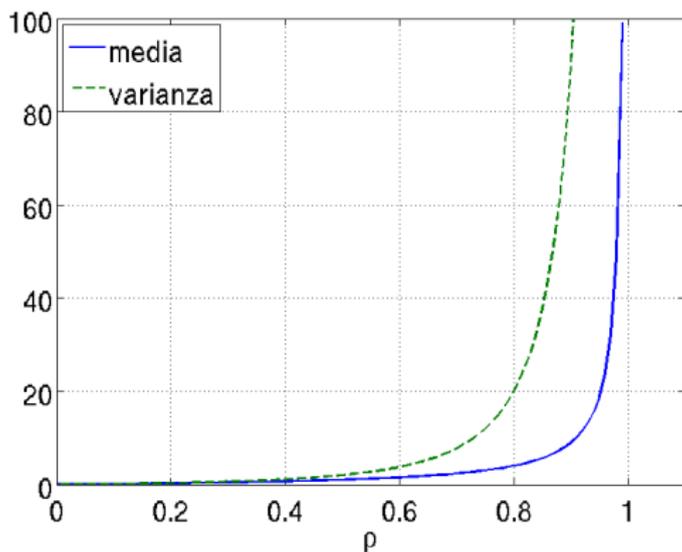
$$E(N_{sist}) = \frac{\rho}{1 - \rho}$$



## Jitter vs utilización

La varianza del número de clientes en el sistema es una medida del jitter

$$\text{Var}(N_{sist}) = \frac{\rho}{(1 - \rho)^2}$$



# Tiempo de espera en la cola

- Sea  $T_n$  el tiempo de espera en la cola del cliente  $n$  (tiempo entre que llega y comienza a ser atendido).
- Sea  $Y_n$  la cantidad de clientes en el sistema al momento del arribo del cliente  $n$ .
- Si  $Y_n \geq 1$  (si  $Y_n = 0$ ,  $T_n = 0$ ) entonces

$$T_n = \sum_{k=1}^{Y_n-1} S_k + \hat{S}_{n-Y_n}$$

donde  $S_k$  es el tiempo de servicio del cliente  $k$  y  $\hat{S}_{n-Y_n}$  es el tiempo residual del cliente que está siendo servido.



# Tiempo de espera en la cola

- Los tiempos de servicio y el tiempo residual son exponenciales de parámetro  $\mu$ , de donde:

$$T_n = \sum_{k=1}^{Y_n} S'_k$$

con  $S'_k \sim \exp(\mu)$  e independiente de  $Y_n$ , entonces:

$$E(T_{cola}) = E(T_n) = E(Y_n)E(S'_1) = \frac{\rho}{1 - \rho} \frac{1}{\mu}$$

- Observar que el tiempo medio en la cola y el número medio de clientes en la cola verifican

$$E(N_{cola}) = \lambda E(T_{cola})$$



## Tiempo en el sistema (Media)

- Sea  $T_{sist}$  el tiempo de espera en el sistema (tiempo entre que un cliente llega y sale del sistema).
- El tiempo medio en el sistema es:

$$E(T_{sist}) = E(T_{cola}) + E(T_{servicio})$$

Entonces:

$$E(T_{sist}) = \frac{\rho}{1 - \rho} \frac{1}{\mu} + \frac{1}{\mu} = \frac{1}{\mu(1 - \rho)} = \frac{1}{\mu - \lambda}$$

- Como antes, el tiempo medio en el sistema y el número medio de clientes en el sistema verifican:

$$E(N_{sist}) = \lambda E(T_{sist})$$

- Esta relación se conoce como **fórmula de Little** y es válida en contextos mucho más generales (tipo caja negra).
- Es fácil obtener la distribución del tiempo de estadía en el sistema.



## Tiempo en el sistema (Distribución)

- Además del valor medio se puede hallar la distribución del tiempo de espera:

$$T_{sist} = T_n + S_n = \sum_{k=1}^{Y_n+1} S'_k$$

donde  $Y_n \sim Geo(p)$  y  $S'_k \sim exp(\mu)$  independientes

- Entonces:

$$P(T_{sist} \leq t) = \sum_{N=0}^{\infty} P\left(\sum_{k=1}^{N+1} S_k \leq t\right) P(Y_n = N)$$

donde  $\sum_{k=1}^{N+1} S_k$  tiene distribución  $Erlang(N+1, \mu)$

- Se obtiene que  $T_{sist} \sim exp(\mu - \lambda)$
- Con las mismas ideas es posible obtener la distribución del tiempo de espera en la cola.



## Tamaño de paquetes vs eficacia

- El mismo volumen de información puede ser transmitido por paquetes de tamaño medio  $1/\mu$  y tasa de envío de paquetes  $\lambda$  o con paquetes de tamaño medio  $1/m\mu$  y tasa  $m\lambda$  ( $m > 1$ ).
- La utilización será la misma (mismo  $\rho$ ) y en consecuencia el número medio de paquetes en la cola será el mismo.
- Sin embargo los retardos son diferentes: paquetes de mayor tamaño implican retardos mayores.
- Paquetes de menor tamaño implican menor eficiencia (volumen de información útil vs. control).



# “PASTA” Poisson Arrivals See Time Averages.

- Se considera un sistema de colas en estado estacionario, con arribos según un proceso de Poisson.
- La probabilidad de que un cliente al llegar encuentre al sistema en el estado  $i$  es igual a la probabilidad estacionaria de que el sistema se encuentre en dicho estado.
- Sean  $\{A_n\}_{n=0,\dots,\infty}$  el conjunto de los momentos en que llegan los clientes. Entonces

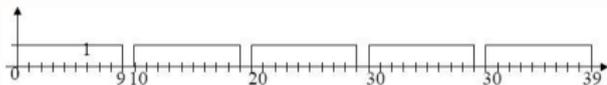
$$p(i) = P(N_{A_n^-} = i) = P(N_{sist} = i) = \pi_{est}(i)$$

- Ejemplos
  - La probabilidad de que al llegar un cliente encuentre el sistema vacío es la probabilidad de que el sistema esté vacío.
  - En un sistema con colas finitas, la probabilidad de que al llegar un cliente sea rechazado es la probabilidad de que el sistema se encuentre en el estado correspondiente a esa cantidad de clientes en espera.



## ¿Vale PASTA en otros casos?

- Supongamos arribos determinísticos cada 10 s y tiempo de servicio determinístico cada 9 s.



- Cuando un cliente arriba el sistema está siempre vacío, por lo tanto la probabilidad de que este observe un cliente en el sistema es  $p(1) = 0$ .
- Sin embargo la probabilidad de que exista un cliente en el sistema es  $\pi_{est}(1) = 0,9$
- Los promedios que ven los clientes no son necesariamente el promedio temporal.



# Contenido

- 1 Proceso de Poisson
- 2 Teoría de colas
- 3 El proceso M/M/1
- 4 Los procesos M/M/\***
- 5 El proceso M/G/1
- 6 Redes de colas



# Características

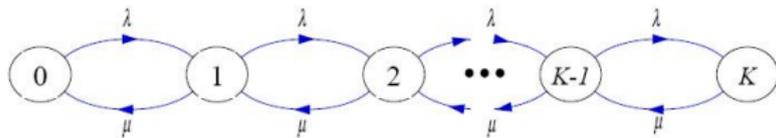
- Proceso de arribos Poisson de parámetro  $\lambda$ .
- Tiempos de servicio exponenciales de parámetro  $\mu$ .
- Tiempos de servicio y entre arribos independientes.
- $N_{sist}(t)$  número de clientes en el sistema en tiempo  $t$ .
- $\{N_{sist}(t) : t \geq 0\}$  es una cadena de Markov de tiempo continuo.
- Las transiciones entre estados dependen de  $\lambda$  y  $\mu$ .
- Vale la fórmula de Little: si  $T_{sist}$  y  $N_{sist}$  son el tiempo en el sistema y el número de clientes en estado estacionario

$$E(N_{sist}) = \lambda E(T_{sist})$$



# El proceso M/M/1/K

- Es un proceso M/M/1 con tamaño de buffer finito.
- A lo sumo hay  $K$  clientes en el sistema.
- Los clientes que arriban cuando el sistema está lleno ( $K$  clientes) son descartados.



# Distribución invariante y probabilidad de pérdida

- Aplicando las ecuaciones de balance del sistema (coinciden con las del sistema M/M/1), se obtiene la distribución invariante:

$$\pi_{est}(n) = \rho^n \pi_{est}(0), \quad n = 0, \dots, K$$

- Siempre existe distribución invariante (Geométrica truncada):

$$\pi_{est}(0) = \frac{1 - \rho}{1 - \rho^{K+1}}$$

- La probabilidad de pérdida (PASTA) es:

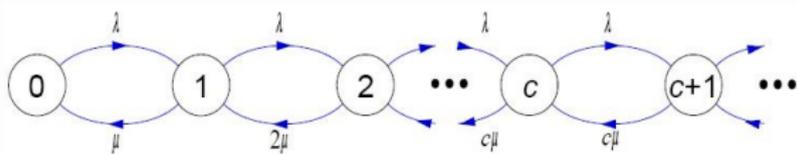
$$P(\text{pérdida}) = \pi_{est}(K) = \frac{(1 - \rho)\rho^K}{1 - \rho^{K+1}}$$

- Ejercicio: relación con la probabilidad de sobrepasar un umbral en un sistema M/M/1.



# El proceso M/M/C

- $C$  servidores.
- Si el cliente que arriba encuentra  $n$  clientes en el sistema entonces
  - si  $n < c$  es encaminado a cualquier servidor libre
  - si  $n \geq c$  va a la cola de espera



# Distribución invariante

- Distribución invariante: aplicando las ecuaciones de balance con  $\rho = \lambda/\mu$  se tiene

$$\pi_{est}(i) = \frac{\rho^i}{i!} \pi_{est}(0) \text{ si } i < C$$

$$\pi_{est}(i) = \left(\frac{\rho}{C}\right)^{i-C} \frac{\rho^C}{C!} \pi_{est}(0) \text{ si } i \geq C$$

- La distribución invariante existe si  $\lambda/C\mu < 1$ , con

$$\pi_{est}(0) = \left( \left[ \sum_{i=0}^{C-1} \frac{\rho^i}{i!} \right] - \frac{\rho^C}{C!} \left( \frac{1}{1 - \rho/C} \right) \right)^{-1}$$

- Expresión analítica pero no muy tratable...



# Fórmula Erlang-C

La probabilidad de, en estado estacionario, encontrar todos los servidores ocupados (Erlang-C) es:

$$\begin{aligned}P(\text{ocupado}) &= P(N_{sist} \geq C) \\&= \sum_{n=C}^{\infty} \pi_{est}(n) \\&= \frac{\rho^C}{C!} \left( \frac{1}{1 - \rho/C} \right) \pi_{est}(0)\end{aligned}$$



# Desempeño de la cola

- Si  $N_{cola}$  es el número de clientes en la cola

$$E(N_{cola}) = \sum_{i=C}^{\infty} (i - C) \pi_{est}(i) = \frac{\rho^{C+1}}{(C - \rho)^2 (C - 1)!} \pi_{est}(0)$$

- Si  $T_{cola}$  es el tiempo de espera en la cola, usando Little

$$E(T_{cola}) = \frac{\rho^{C+1}}{\lambda (C - \rho)^2 (C - 1)!} \pi_{est}(0)$$

- ¿Distribución del tiempo de espera en la cola?



# Desempeño del sistema

- Si  $T_{sist}$ ,  $T_{cola}$  y  $S$  son los tiempos de espera en el sistema, en la cola y el tiempo de servicio se tiene

$$E(T_{sist}) = E(T_{cola}) + E(S) = \frac{\rho^{C+1}}{\lambda(C-\rho)^2(C-1)!} \pi_{est}(0) + \frac{1}{\mu}$$

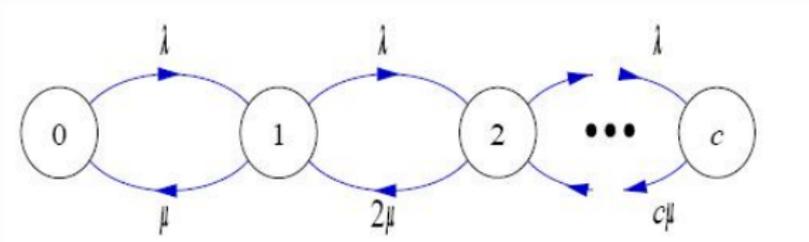
- El número medio de clientes en el sistema se obtiene usando Little

$$E(N_{sist}) = \frac{\rho^{C+1}}{(C-\rho)^2(C-1)!} + \rho$$



# El proceso M/M/C/C

- Es un proceso M/M/C con pérdidas.
- No hay espera, si el cliente llega y el sistema está lleno ( $C$  servidores ocupados) se descarta.



# Distribución invariante

- Aplicando las ecuaciones de balance del sistema (coinciden con las del sistema M/M/C), se obtiene la distribución invariante:

$$\pi_{est}(n) = \frac{\rho^n}{n!} \pi_{est}(0), \quad n = 0, \dots, C$$

- Siempre existe distribución invariante:

$$\pi_{est}(0) = \left( \sum_{k=0}^C \frac{\rho^k}{k!} \right)^{-1}$$

- Erlang B: la probabilidad de bloqueo o pérdida es  $\pi_{est}(C)$  (estamos usando PASTA).



# El proceso $M/M/\infty$

- ¡Ejercicio!



# Multiplexado de recursos

- Comparar el desempeño de los siguientes sistemas:
  1. Arribos Poisson de intensidad  $\lambda$  y dos servidores con tiempo de servicio exponencial de parámetro  $\mu$  y una sola cola.
  2. Arribos Poisson de intensidad  $\lambda$  y un servidor con tiempo de servicio exponencial de parámetro  $2\mu$  y una sola cola.
  3. Dos colas separadas con arribos de intensidad  $\lambda/2$  y tiempo de servicio exponencial de parámetro  $\mu$ .
- ¿Cuál es la carga de cada uno de los sistemas?
- ¿Número medio de clientes?
- ¿Tiempos de espera?



# Contenido

- 1 Proceso de Poisson
- 2 Teoría de colas
- 3 El proceso M/M/1
- 4 Los procesos M/M/\*
- 5 El proceso M/G/1**
- 6 Redes de colas



# Definición

- Proceso de arribos: Poisson de parámetro  $\lambda$ .
- Tiempos de servicio i.i.d. siguiendo una distribución cualquiera con media  $1/\mu$ .
- Los tiempos de servicio son independientes del proceso de arribos.
- Caso particular: M/D/1 (tiempo de servicio determinístico).



# Características

- La cantidad de clientes en el sistema en tiempo  $t$  ( $N(t)$ ) no es un proceso markoviano (por ejemplo si el tiempo de servicio es determinístico).
  - para pasar del estado  $n$  al estado  $n - 1$  (salida de un cliente) depende de cuánto tiempo hace que el cliente está en el sistema (no hay pérdida de memoria)
- No se puede calcular la distribución estacionaria en general.
- Calcularemos el tiempo medio de espera en la cola sin conocer la distribución estacionaria (fórmula de Pollaczek-Khinchin).



# Notación

- $W_i$  es el tiempo de espera del cliente  $i$ .
- $X_i$  es el tiempo de servicio del cliente  $i$ .
- $A_i$  es el número de arribos durante el tiempo de servicio  $X_i$  del cliente  $i$ .
- $Q_i$  es el número de clientes en la cola cuando arriba el cliente  $i$  (excluido el cliente en servicio).
- $R_i$  es el tiempo residual del cliente  $i$ .
- $D_t$  es el número de partidas del sistema en  $(0, t]$ .
- $A_t$  es el número de arribos al sistema en  $(0, t]$ .



# Fórmula de Pollaczek-Khinchin

- El tiempo de espera para el cliente  $i$  es

$$W_i = R_i + X_{i-1} + X_{i-2} + \cdots + X_{i-Q_i} = R_i + \sum_{k=i-Q_i}^{i-1} X_k$$

- Tomando valor esperado de ambos lados

$$E(W_i) = E(R_i) + E\left(\sum_{k=i-Q_i}^{i-1} X_k\right) = E(R_i) + E(X)E(Q_i)$$

- En estado estacionario y por PASTA

$$E(W) = E(R) + E(X)E(Q)$$



# Fórmula de Pollaczek-Khinchin

- Aplicando Little para la cola

$$E(Q) = \lambda E(W)$$

- Sustituyendo en la ecuación  $E(W) = E(R) + E(X)E(Q)$  se tiene

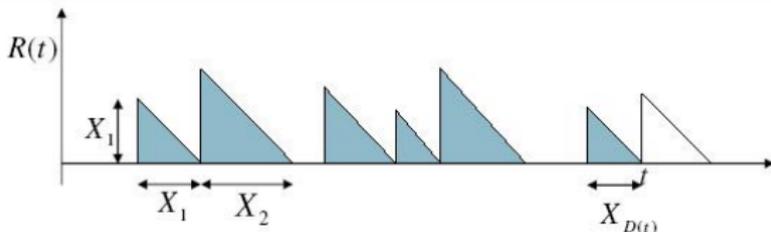
$$E(W) = E(R) + E(X)\lambda E(W) = E(R) + \rho E(W)$$

de donde

$$E(W) = \frac{E(R)}{1 - \rho}$$



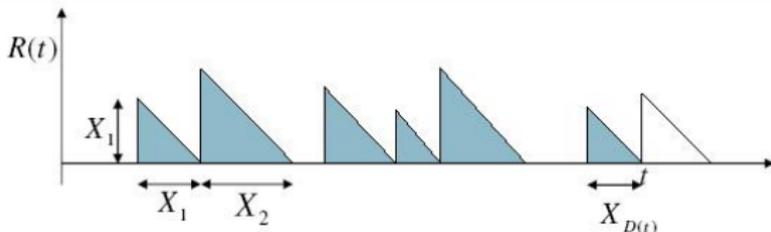
# Tiempo residual medio



- $R_t$  tiempo residual en función del tiempo.
- Consideremos  $t$  tal que  $R_t = 0$  (cola vacía). Sea  $D_t$  el número de partidas en  $(0, t]$  y asumimos que  $R_0 = 0$ .
- En estado estacionario se cumple que

$$E(R) = \lim_{t \rightarrow \infty} \frac{1}{t} \int_0^t R_s ds$$

# Tiempo residual medio



- De la gráfica

$$\frac{1}{t} \int_0^t R_s ds = \frac{1}{t} \sum_{i=1}^{D_t} \frac{X_i^2}{2}$$

- Entonces

$$E(R) = \frac{1}{2} \lim_{t \rightarrow \infty} \frac{D_t}{t} \frac{1}{D_t} \sum_{i=1}^{D_t} X_i^2$$

# Tiempo residual medio

- Por conservación de la masa se cumple:

$$\lim_{t \rightarrow \infty} \frac{D_t}{t} = \lim_{t \rightarrow \infty} \frac{A_t}{t} = \lambda$$

- Además

$$\lim_{t \rightarrow \infty} \frac{1}{D_t} \sum_{i=1}^{D_t} X_i^2 = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n X_i^2 = E(X^2)$$

- Entonces el tiempo residual medio es

$$E(R) = \frac{1}{2} \lambda E(X^2)$$

- De donde:

$$E(W) = \frac{\lambda E(X^2)}{2(1 - \rho)}$$

- No depende solo de la media sino también de la varianza:  
tiempos de servicio muy dispares producen mayores retardos



# Desempeño del sistema y de la cola: tiempos

- Sea  $W$  el tiempo en la cola y  $X$  el tiempo de servicio.  
Probamos que:

$$E(W) = \frac{\lambda E(X^2)}{2(1-\rho)} = \frac{\rho}{1-\rho} \frac{1}{\mu} \frac{1 + C_v^2}{2}$$

- Sea  $T$  es el tiempo en el sistema. Entonces el tiempo medio en el sistema es

$$E(T) = E(W) + E(X) = \frac{\lambda E(X^2)}{2(1-\rho)} + \frac{1}{\mu}$$

- Comparar con los resultados obtenidos para una M/M/1.



# Desempeño del sistema y de la cola: número de clientes

- Se obtienen a partir de la fórmula de Little
- Sea  $Q$  el número de clientes en la cola.

$$E(Q) = \lambda E(W) = \frac{\lambda^2 E(X^2)}{2(1 - \rho)}$$

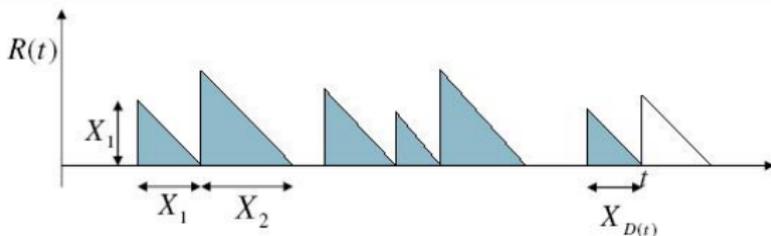
- Sea  $N$  el número de clientes en el sistema.

$$E(N) = \lambda E(T) = \frac{\lambda^2 E(X^2)}{2(1 - \rho)} + \rho$$



# Distribución estacionaria: Método de la cadena incluida

- Sea  $N_t$  el número de clientes en la cola:  $N_t$  no es un proceso de Markov.
- Sea  $\tau_k$  el instante de partida del sistema del  $k$ -ésimo cliente y  $N_k = N_{\tau_k}$ .
- El número de clientes  $N_k$  en el sistema inmediatamente después de la partida del  $k$ -ésimo cliente es una cadena de Markov en tiempo discreto (depende de  $N_k$  pero no de los que se fueron antes).



# Distribución estacionaria de la cadena incluida

- La distribución estacionaria de  $N_t$  coincide con la distribución estacionaria  $\pi_{est}$  de  $N_k$  (arribos y partidas vienen de a pares).
- $\pi_k(n) = P(N_k = n)$  es la probabilidad de que haya  $n$  clientes en el sistema al partir el  $k$ -ésimo cliente y

$$\pi_{est} = \lim_{k \rightarrow \infty} \pi_k(n)$$

- Se tiene que  $N_{k+1} = \begin{cases} N_k - 1 + V_{k+1} & N_k \geq 1 \\ V_{k+1} & N_k = 0 \end{cases}$  donde  $V_k$  es la cantidad de arribos durante el servicio del cliente  $k$ .
- Se pueden calcular las probabilidades de transición (o al menos estimarlas numéricamente).
- También se puede obtener la transformada  $z$  de  $\pi_{est}$ :

$$\Pi(z) = \frac{(1 - \rho)L(\lambda - \lambda z)(1 - z)}{L(\lambda - \lambda z) - z}$$

donde  $\rho = \lambda/\mu$  y  $L$  es la transformada de la Laplace del tiempo de servicio.



# Processor Sharing

- El servidor divide su capacidad equitativamente entre todos los clientes presentes.
- Versión idealizada de Round Robin: el servidor reparte slots de tiempo de tamaño  $\delta$  a cada cliente
  - si hay  $N$  clientes el tiempo residual de cada uno de ellos decrece a tasa  $1/N$
- PS y FIFO tienen la misma capacidad ( $\rho$ ), mismo número medio de clientes y el mismo tiempo medio de espera
- Sin embargo la distribución de los tiempos de espera son diferentes
  - El PS penaliza clientes con tiempos de servicio largos y la penalidad es proporcional al tiempo de servicio (*fairness*)



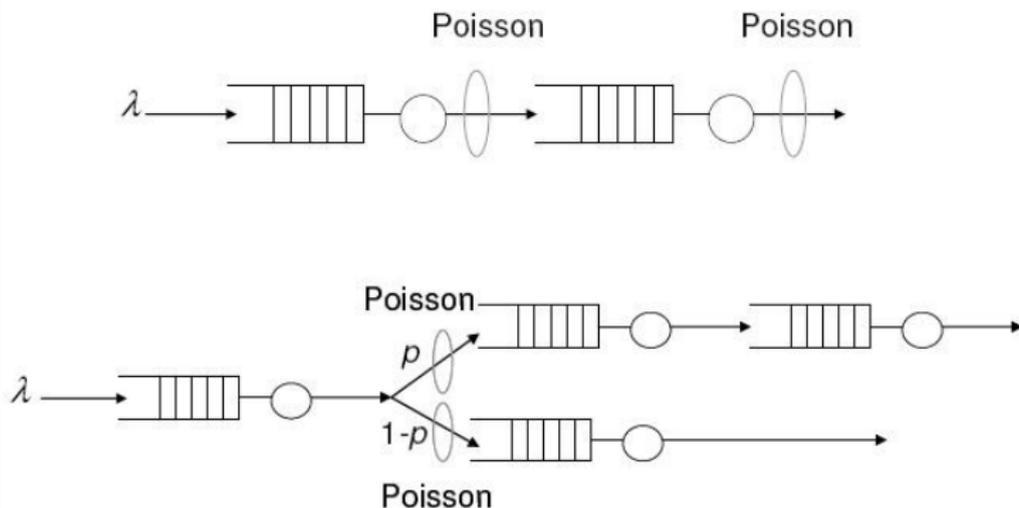
# Contenido

- 1 Proceso de Poisson
- 2 Teoría de colas
- 3 El proceso M/M/1
- 4 Los procesos M/M/\*
- 5 El proceso M/G/1
- 6 Redes de colas**



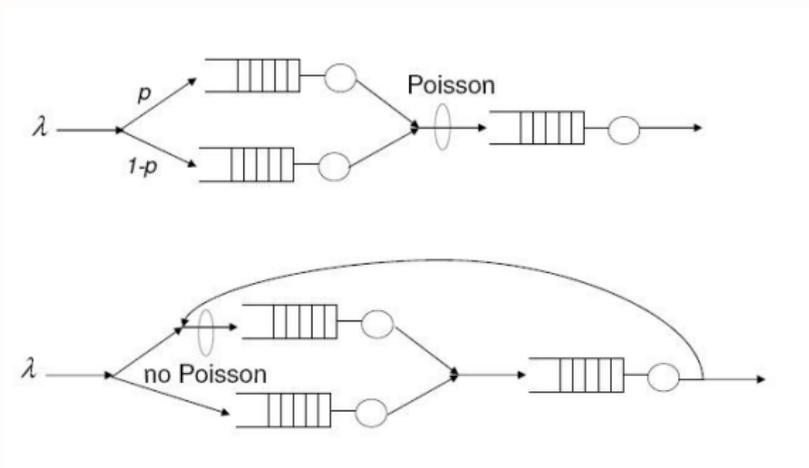
# Redes de Colas

- Se considera un sistema M/M/1 o M/M/C, con tasa de arribos  $\lambda$ , en estado estacionario. Entonces:
  - El proceso de partida es Poisson con tasa  $\lambda$ .
  - En cada tiempo  $t$ , el número de clientes en el sistema es independiente de la cantidad de partidas anteriores a  $t$ .



# Redes de Colas

- Se considera un sistema M/M/1 o M/M/C, con tasa de arribos  $\lambda$ , en estado estacionario. Entonces:
  - El proceso de partida es Poisson con tasa  $\lambda$ .
  - En cada tiempo  $t$ , el número de clientes en el sistema es independiente de la cantidad de partidas anteriores a  $t$ .



# Reversibilidad

- Para el análisis hay que observar el proceso  $\bar{X}_t = X_{T-t}$  para un  $T$  fijo.
- Se dice que  $X_t$  es reversible si  $\bar{X}_t$  tiene la misma distribución que  $X_t$ .
- Las probabilidades de transición para  $\bar{X}_t$  son:

$$\bar{p}_{ij}(t) = p_{ji}(t) \frac{\pi_j}{\pi_i}$$

$$\bar{q}_{ij}(t) = q_{ji} \frac{\pi_j}{\pi_i}$$

- Observar que no depende de  $T$ :  $\bar{X}_t$  se puede definir  $\forall \in \mathbf{R}$ .
- $X_t$  es reversible si y solo si  $\pi_i q_{ij} = \pi_j q_{ji}$  (ecuaciones de balance detalladas).



# Reversibilidad

- Ecuaciones de balance global ( $\pi \mathbf{Q} = 0$ ):

$$\sum_{j \neq i} \pi_j q_{ji} = \pi_i \sum_{j \neq i} q_{ij}$$

- Si se verifican las ecuaciones de balance detalladas, se verifican las globales.
- Los procesos M/M/\*/\* son reversibles y se cumple el siguiente resultado:

**Teorema de Burke:** el proceso de partidas  $D = \{D_t\}$  donde  $D_t$  es el número de clientes que abandonan el sistema en el intervalo  $[0, t]$  es un proceso de Poisson de parámetro  $\lambda$ . Además  $X_t$  es independiente de  $D_s$  para todo  $s < t$ .



# Reversibilidad

- La clave para estudiar las redes de colas es el siguiente resultado:
  - Sea  $X$  CMTC con generador infinitesimal  $\mathbf{Q} = (q_{ij})_{ij \in E}$  y  $\pi$  un vector de probabilidad en  $E$ . Se define  $\bar{\mathbf{Q}} = (\bar{q}_{ij})$  como  $\bar{q}_{ij} = q_{ij} \frac{\pi_j}{\pi_i}$ . Si se cumple:

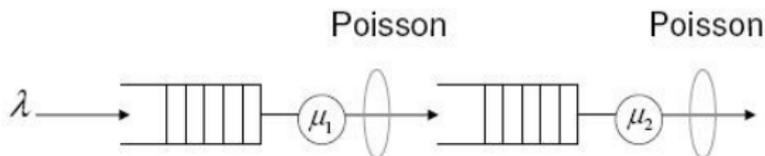
$$\sum_{i \neq j} \bar{q}_{ij} = \sum_{i \neq j} q_{ij} \quad (1)$$

entonces:

- $\pi$  es la distribución estacionaria de  $X$
  - $\bar{\mathbf{Q}}$  es el generador infinitesimal del proceso  $\bar{X}$
- Si se tiene un candidato a distribución, basta verificar la ecuación (1).



# M/M/1 en tándem



- Proceso de arribos: Poisson de parámetro  $\lambda$ .
- Tiempos de servicio: exponenciales independientes de parámetro  $\mu_i$ ,  $i = 1, 2$ .
- Condición de estabilidad:  $\rho_i = \lambda/\mu_i < 1$ .
- $N$  número de clientes en el sistema,  $N = (N_1, N_2)$  donde  $N_i$  es el número de clientes en la cola  $i$ .

## M/M/1 en tándem

- ¿Cuál es la distribución en estado estacionario de  $N_1$  y  $N_2$ ?

$$\pi_{est}(n_1, n_2) = (1 - \rho_1)\rho_1^{n_1}(1 - \rho_2)\rho_2^{n_2} = \pi_{est}^1(n_1)\pi_{est}^2(n_2)$$

- $N_2(t)$  depende de los arribos a la cola 2 anteriores a  $t$  (i.e. las salidas de la cola 1 antes de  $t$ ) y por lo tanto son independientes de  $N_1(t)$ .
- En general, la distribución estacionaria para el caso de  $m$  colas en cascada de tipo M/M/1, con tiempos de servicio independientes entre sí, es:

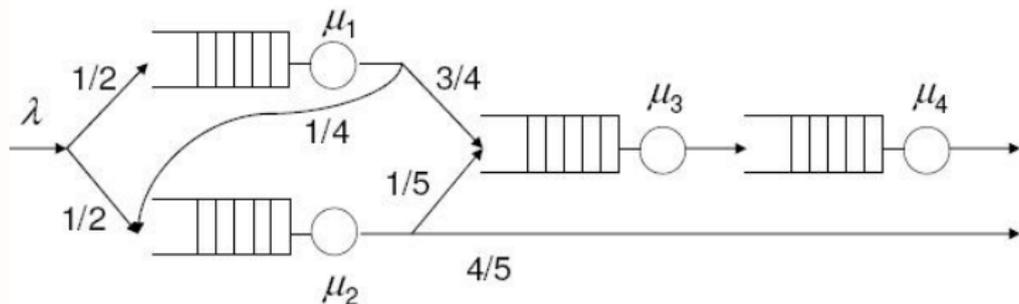
$$\pi_{est}(n_1, n_2, \dots, n_m) = \prod_{i=1}^m (1 - \rho_i)\rho_i^{n_i} = \prod_{i=1}^m \pi_{est}^i(n_i)$$

- Los tiempos de espera en cada fila también son independientes



## Redes de Jackson abiertas

- Los clientes arriban desde el exterior.
- Una sola clase de clientes.
- Proceso de arribos: Poisson de parámetro  $\lambda$ .
- Cantidad de nodos:  $m$ .
- Un solo servidor en cada nodo con tiempos de servicio exponenciales independientes, sin pérdidas (cola infinita).
- Ruteo probabilístico.



# Ecuación de flujo

- Sea  $p_{jk}$  la probabilidad de un cliente que termina su servicio en el nodo  $j$  se dirija al nodo  $k$ ,  $j, k = 1, \dots, m$ .
- Sea  $p_{0k}$  la probabilidad de un cliente que arriba lo haga al nodo  $k$ .
- La tasa de arribos al nodo  $i$  es:

$$\lambda_i = \lambda p_{0i} + \sum_{k=1}^m \lambda_k p_{ki}$$

- La ecuación anterior (“ecuación de flujo”) tiene una única solución positiva.



# Teorema de Jackson

- Sea  $N_t^i$  el número de clientes en el instante  $t$  en el nodo  $i$ .
- El proceso de Markov  $N$ , tal que  $N_t = (N_t^1, \dots, N_t^m)$  describe la cantidad de clientes en el sistema.
- Teorema de Jackson: Si  $(\lambda_1, \dots, \lambda_m)$  es la solución de la ecuación de flujo, y el sistema es estable ( $\lambda_i < \mu_i$ ), el proceso  $N$  tiene una distribución invariante dada por:

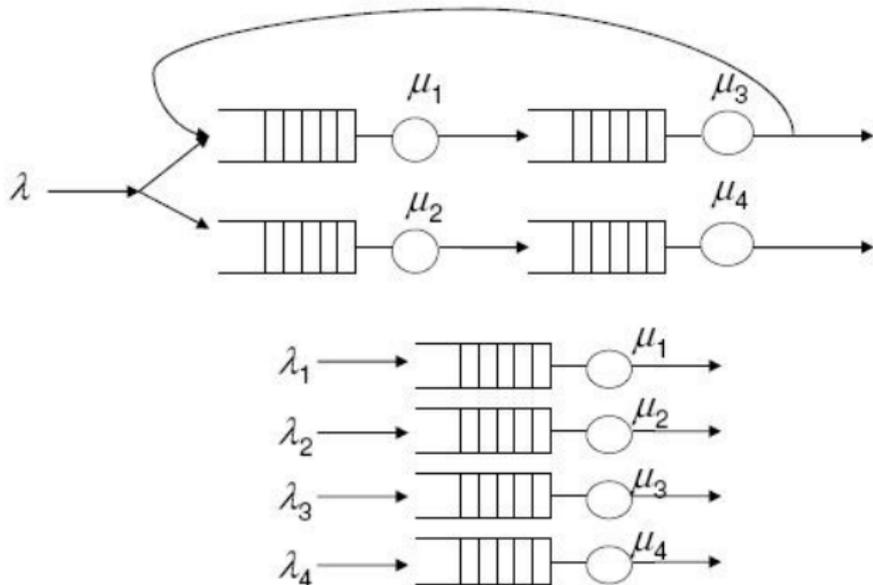
$$\pi_{est}(n_1, n_2, \dots, n_m) = \prod_{i=1}^m (1 - \rho_i) \rho_i^{n_i} = \prod_{i=1}^m \pi_{est}^i(n_i)$$

donde  $\pi_{est}^i$  es la distribución invariante de una fila M/M/1 con tasa de arribo  $\lambda_i$  y tasa de servicio  $\mu_i$ .



# Teorema de Jackson

El sistema es equivalente a un conjunto de colas M/M/1.



## Desempeño de cada nodo

- El tiempo medio de espera en el nodo  $i$  es

$$E(T^i) = \frac{1}{(1 - \rho_i)\mu_i} = \frac{1}{\mu_i - \lambda_i}$$

- Luego en el sistema es

$$E(N) = \sum_{i=1}^m E(N^i) = \sum_{i=1}^m \frac{\rho_i}{1 - \rho_i}$$

- Por Little número medio de clientes en el nodo  $i$  es

$$E(N^i) = \lambda_i E(T^i) = \frac{\rho_i}{1 - \rho_i}$$

- Y en el sistema es

$$E(T) = \frac{E(N)}{\lambda} = \frac{1}{\lambda} \sum_{i=1}^m \frac{\rho_i}{1 - \rho_i}$$



# Otros ejemplos

- Redes de Jackson cerradas: el número de clientes en el sistema es constante (no hay arribos ni partidas del exterior)
  - Hay solución de la ecuación de flujo pero no es única. Las filas no se pueden tratar como independientes.
  - Mean Value Analysis: expresar los parámetros de performance (en media) del sistema con  $N$  clientes en función de los mismos parámetros para un sistema con  $N - 1$  clientes.
    - Se basa en que la distribución del estado de la red en el momento de una transición coincide con la distribución de la misma red con un cliente menos.
- Redes de Whittle: insensibilidad a la distribución del tiempo de servicio.

