

# Procesos estocásticos

Contenidos adaptados del libro «Probabilidad y estadística para informáticos, segunda edición, M. Baron» (Capítulo 6)

# Contenido

1. Objetivos
2. Definiciones y clasificaciones
  - 2.1 Definición de proceso estocástico
  - 2.2 Clasificación de los procesos estocásticos
3. Procesos de Markov y cadenas de Markov
  - 3.1 Cadenas de Markov
  - 3.2 Enfoque matricial
  - 3.3 Distribución estacionaria
4. Procesos de conteo
  - 4.1 Proceso binomial
  - 4.2 Proceso de Poisson
5. Resumen

# 1. Objetivos

- Familiarizarse con los conceptos y herramientas para manejar procesos estocásticos (RA5).
- Distinguir tipos de procesos estocásticos dependiendo de los instantes de observación y de los resultados observados (RA5).
- Conocer las propiedades básicas de las cadenas de Markov en tiempo Discreto (RA5).
- Clasificar los estados de las cadenas Markov (RA5).
- Conocer las propiedades y características más relevantes del Proceso de Poisson y de otros procesos en tiempo continuo (RA6).

## 2. Definiciones y clasificaciones

- 2.1 Definición de proceso estocástico
- 2.2 Clasificaciones de procesos estocásticos

## 2.1 Definición de *proceso estocástico*

- Un proceso estocástico es una variable aleatoria que también depende del tiempo.
- Por lo tanto, es una función con dos argumentos,  $X(t, \omega)$ 
  - $t \in T$  es el tiempo, siendo  $T$  un conjunto de tiempos posibles, normalmente  $[0, \infty)$ ,  $(-\infty, \infty)$ ,  $\{0, 1, 2, \dots\}$ , o  $\{\dots, -2, -1, 0, 1, 2, \dots\}$
  - $\omega \in \Omega$  es el resultado de un experimento aleatorio, donde  $\Omega$  es todo el espacio muestral.
- Los valores de  $X(t, \omega)$  se denominan estados.
- Por simplicidad, normalmente no escribiremos  $\omega$  como un argumento de  $X(t, \omega)$ 
  - $X(t, \omega) = X(t)$

## 2.1 Definición de *proceso estocástico*

### Ejemplo 6.1 (Uso de CPU)

- El uso de la CPU de un ordenador es un proceso estocástico
- Observando el uso pasado de la CPU de un ordenador, podemos tener una realización de este proceso hasta el momento actual (Figura 6.1.a)
- Sin embargo, el comportamiento futuro del proceso no está claro, es un proceso aleatorio y puede desarrollarse de diferentes maneras o trayectorias (Figura 6.1b)

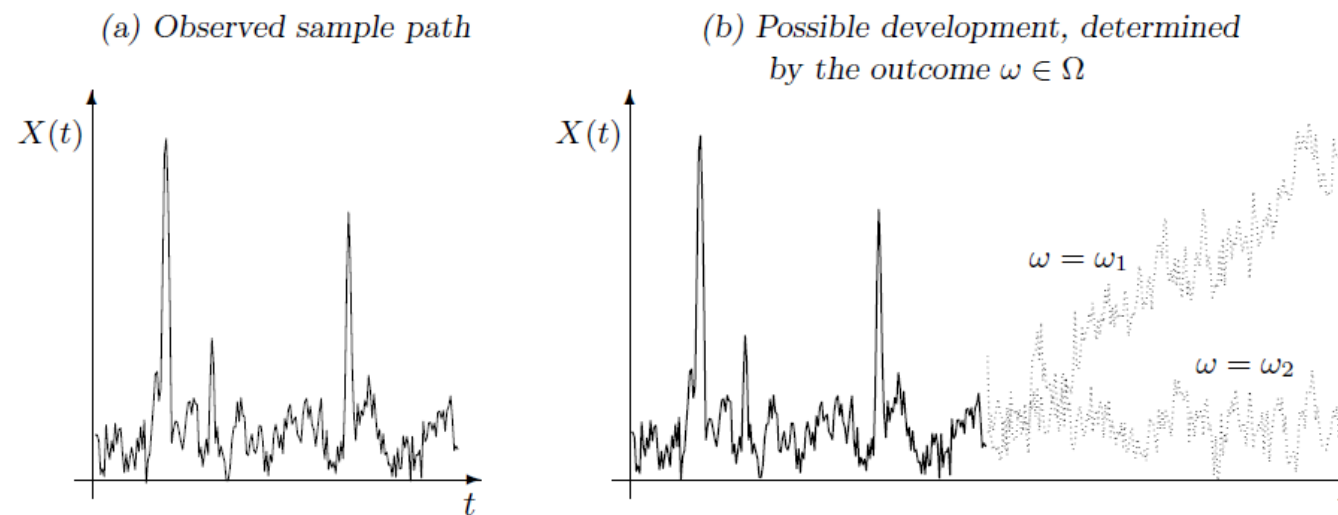


FIGURE 6.1: Sample paths of CPU usage stochastic process.

## 2.2 Clasificaciones de procesos estocásticos

- Clasificación según estado
  - a) El proceso estocástico  $X(t, \omega)$  es un **proceso de estado discreto** si la variable  $X_t(\omega)$  es discreta para cada instante  $t$ .
  - b) Se trata de un **proceso de estado continuo** si  $X_t(\omega)$  es continua.
- Clasificación según el tiempo
  - a) El proceso estocástico  $X(t, \omega)$  es un **proceso de tiempo discreto** si el conjunto de instantes  $T$  es discreto, es decir, consiste en puntos separados y aislados.
  - b) Es un **proceso de tiempo continuo** si  $T$  es continuo, posiblemente sin límites.

## 2.2 Clasificaciones de procesos estocásticos

### Ejemplos

- Ejemplo 6.2.
  - El proceso de uso de la CPU, en porcentajes, es un proceso de **estado continuo y tiempo continuo**.
- Ejemplo 6.3.
  - La temperatura del aire  $X(t, \omega)$  en el instante  $t$  es un proceso de **estado continuo y tiempo continuo**.
  - Sin embargo, la temperatura  $Y(t, \omega)$  registrada en una zona cada 10 minutos es un proceso de **tiempo discreto**. Además, dado que la temperatura registrada generalmente se redondea al grado más cercano, también es un proceso de **estado discreto**.
- Ejemplo 6.4.
  - En una imprenta, si  $X(n, \omega)$  es la cantidad de tiempo necesaria para imprimir el  $n$ -ésimo trabajo, se trata de proceso de **tiempo discreto y estado continuo**, porque  $n = 1, 2, 3, \dots$ , y  $X \in (0, \infty)$ .
  - Si  $Y(n, \omega)$  es el número de páginas del trabajo de impresión  $n$ -ésimo, y por tanto  $Y$  puede tener valores  $1, 2, 3, \dots$ , se trata de un proceso de **tiempo discreto y estado discreto**.



# 3. Procesos de Markov y cadenas de Markov

- 3.1 Cadenas de Markov
- 3.2 Enfoque matricial
- 3.3 Distribución estacionaria (steady state)

# 3. Procesos de Markov y cadenas de Markov

## Definición

- Un proceso estocástico  $X(t)$  es de Markov si para cualquier  $t_1 < \dots < t_n < t$  y cualquier conjunto  $A; A_1 \dots A_n$ , se cumple:
  - $P \{X(t) \in A \mid X(t_1) \in A_1, \dots, X(t_n) \in A_n\} = P \{X(t) \in A \mid X(t_n) \in A_n\}$
- Significa que la distribución condicional de  $X(t)$  es la misma bajo dos condiciones diferentes:
  - (1) dadas observaciones del proceso  $X$  en varios momentos en el pasado;
  - (2) dada solo la última observación de  $X$ .
- Conociendo el presente, no usamos información del pasado:
  - $P \{\text{futuro} \mid \text{pasado, presente}\} = P \{\text{futuro} \mid \text{presente}\}$
- Entonces, para el desarrollo futuro de un proceso de Markov, sólo es importante su estado actual, y no importa cómo el proceso llegó a este estado.

# 3. Procesos de Markov y cadenas de Markov

## Ejemplo del proceso de Markov

- Ejemplo 6.5 (Conexiones a Internet).
  - $X(t)$  es el número total de conexiones a Internet registradas por algún proveedor de servicios de Internet en el instante  $t$ .
  - Por lo general, las personas se conectan a Internet en momentos aleatorios, independientemente de cuántas conexiones ya se hayan hecho.
  - Por lo tanto, el número de conexiones en un minuto solo dependerá del número actual.
  - Por ejemplo, si se han registrado 999 conexiones a las 10:00, entonces su número total superará las 1000 durante el minuto siguiente, independientemente de cuándo y cómo se hicieron estas 999 conexiones en el pasado.
  - **Este proceso es de Markov.**

# 3. Procesos de Markov y cadenas de Markov

## Ejemplo de proceso no Markov

- Ejemplo 6.6 (Precios de stock).
  - $Y(t)$  es el valor de alguna acción o algún índice de mercado en el instante  $t$ .
  - Si conocemos  $Y(t)$ , ¿también necesitamos conocer  $Y(t-1)$  para predecir  $Y(t+1)$ ?
  - Se puede argumentar que si  $Y(t-1) < Y(t)$ , entonces el mercado está subiendo, y es probable (pero no seguro) que  $Y(t+1)$  exceda  $Y(t)$ .
  - Por otro lado, si  $Y(t-1) > Y(t)$ , podemos concluir que el mercado está cayendo y podemos esperar  $Y(t+1) < Y(t)$ .
  - Parece que conocer el pasado además del presente nos ayuda a predecir el futuro.
  - **Este proceso no es de Markov.**

## 3.1 Cadenas de Markov

- Una cadena de Markov es un proceso estocástico de Markov de tiempo discreto y estado discreto.
  - El tiempo es discreto, así que podemos definir el conjunto de instantes de tiempo como  $T = \{0, 1, 2, \dots\}$ .
  - Podemos considerar una cadena de Markov como una secuencia de variables aleatorias  $\{X(0), X(1), X(2), \dots\}$
  - El conjunto de estados también es discreto, así que enumeramos los estados como  $1, 2, \dots, n$ .
  - Normalmente se comienza la enumeración desde el estado 0.
  - En algunos casos, el número de estados posibles es infinito ( $n = \infty$ ).
  - En las cadenas de Markov sólo importa el valor de  $X(t)$  para predecir  $X(t+1)$

## 3.1 Cadenas de Markov

### Distribución de una cadena de Markov

- La distribución de probabilidad de una cadena de Markov es la función de masa de probabilidad de  $X(t)$ 
  - $P_t(x) = P\{X(t) = x\}$  para  $x \in \{1, 2, \dots, n\}$  y  $t \in \{0, 1, 2, \dots, \infty\}$
- La distribución inicial de una cadena de Markov es la función de masa de probabilidad de  $X(0)$ 
  - $P_0(x) = P\{X(0) = x\}$  para  $x \in \{1, 2, \dots, n\}$

# 3.1 Cadenas de Markov

## Probabilidad de transición

- La probabilidad  $p_{ij}(t)$  se llama **probabilidad de transición**
  - $p_{ij}(t) = P\{X(t+1) = j \mid X(t) = i\}$
  - Es la probabilidad de que la cadena de Markov  $X$  haga una transición del estado  $i$  al estado  $j$  a partir del instante  $t$
  - Es decir, la probabilidad de que en el instante  $t+1$  el estado sea  $j$ , sabiendo que en el instante  $t$  el estado era  $i$
- La probabilidad  $p_{ij}^{(h)}(t)$  se denomina **probabilidad de transición en  $h$  pasos**
  - $p_{ij}^{(h)}(t) = P\{X(t+h) = j \mid X(t) = i\}$
  - Es la probabilidad de pasar del estado  $i$  al estado  $j$ , mediante  $h$  transiciones desde el instante  $t$

# 3.1 Cadenas de Markov

## Cadena de Markov homogénea y regular

- Una cadena de Markov es homogénea si todas sus probabilidades de transición son independientes de  $t$ .
- Ser homogénea implica que la transición del estado  $i$  al estado  $j$  tiene la misma probabilidad en cualquier instante  $t$ , y entonces se puede simplificar la notación eliminando "t".
  - $p_{ij}(t) = p_{ij}$
  - $p_{ij}^{(h)}(t) = p_{ij}^{(h)}$
- Una cadena de Markov es regular si para todos los valores de  $i$  y  $j$ , se cumple que  $p_{ij}^{(h)} > 0$  para algún instante  $h$ .
  - Ejemplo: si en una cadena la probabilidad  $p_{21}^{(3)} = 0$  ya no haría falta comprobar nada más, porque hay un caso en el instante  $h=3$  en el que la probabilidad no es  $>0$ .
  - Ejemplo 2: si en otra cadena  $p_{21}^{(3)} = 0$  pero en  $h=4$  todos los valores son  $>0$ , es regular, porque hemos encontrado un instante  $h$  en el que no hay ninguna probabilidad de transición cero.
- Ser regular significa que la cadena tiene una distribución estacionaria, y es posible calcular las probabilidades para un valor infinito de  $h$ , es decir  $p_{ij}^{(\infty)}$ .



## 3.1 Cadenas de Markov

### Ejemplo 6.7: Previsiones meteorológicas

- En una ciudad, cada día es soleado o lluvioso.
- Un día soleado es seguido por otro día soleado con probabilidad 0.7, mientras que un día lluvioso es seguido por un día soleado con probabilidad 0.4.
- Si llueve el lunes, realizar un pronóstico para
  - a) Martes
  - b) Miércoles
  - c) Jueves

# 3.1 Cadenas de Markov

## Ejemplo 6.7 (solución)

- Las condiciones climáticas en este problema representan una cadena de Markov homogénea con 2 estados:
  - estado 1 = “soleado” y estado 2 = “lluvioso”.
- Las probabilidades de transición son:
  - $p_{11} = 0,7$ ,  $p_{12} = 1-0,7 = 0,3$ ,  $p_{21} = 0,4$ ,  $p_{22} = 1-0,4 = 0,6$
- El siguiente diagrama de transición refleja el comportamiento de esta cadena de Markov.
  - Las flechas representan todas las transiciones posibles en un solo paso, junto con las probabilidades correspondientes.





FIGURE 6.2: Transition diagram for the Markov chain in Example 6.7.


# 3.1 Cadenas de Markov

## Ejemplo 6.7 (solución) (a)

a) Pronóstico para el martes (probabilidades de transición en 1 paso)

- Soleado:
  - Si llueve el lunes, entonces el martes será soleado con probabilidad  $p_{21} = 0.4$  (haciendo una transición de un día lluvioso a un día soleado)
- Lluvioso:
  - Si llueve el lunes, entonces el martes será lluvioso con probabilidad  $p_{22} = 0.6$  (haciendo una transición de un día lluvioso a un día lluvioso)
  - Nota: Podría calcularse mediante la regla del complemento:  $1 - 0,4 = 0.6$

- Podemos predecir un 60% de probabilidad de lluvia



# 3.1 Cadenas de MarkovEjemplo

## 6.7 (solución) (b)

### b) Pronóstico para el miércoles (probabilidades de transición en 2 pasos, h=2)

- Tiempo: Lunes: t=0, martes: t=1, Miércoles: t=2
- Estados: Soleado = 1, Lluvioso = 2
- $P\{\text{Miércoles soleado} \mid \text{Lunes es lluvioso}\} = p_{21}^{(2)}$
- Uso de la Ley de Probabilidad Total (Bayes)
  - $A = \{\text{Miércoles soleado} \mid \text{Lunes lluvioso}\}$
  - $B_1 = \{\text{Martes soleado} \mid \text{Lunes lluvioso}\}$
  - $B_2 = \{\text{Martes lluvioso} \mid \text{Lunes lluvioso}\}$
  - $P\{A\} = P\{A \mid B_1\} P\{B_1\} + P\{A \mid B_2\} P\{B_2\}$
- $p_{21}^{(2)} = P\{X(2)=1 \mid X(1)=1\} \cdot P\{X(1)=1\} + P\{X(2)=1 \mid X(1)=2\} \cdot P\{X(1)=2\}$
- $p_{21}^{(2)} = p_{21} p_{11} + p_{22} p_{21} = (0.4)(0.7) + (0.6)(0.4) = 0,52$
- Podemos predecir un 52% de probabilidad de sol el miércoles, y 48% de lluvia
  - $p_{22}^{(2)} = 1 - p_{21}^{(2)} = 1 - 0,52 = 0,48$

# 3.1 Cadenas de Markov

## Ejemplo 6.7 (solución) (c)

### c) Pronóstico para el jueves (probabilidades de transición en 3 pasos, h=3)

- Tiempo: Lunes: t=0, martes: t=1, Miércoles: t=2, jueves: t=3
- Estados: Soleado = 1, Lluvioso = 2
- $P \{ \text{Jueves soleado} \mid \text{Lunes lluvioso} \} = p_{21}^{(3)}$
- $p_{21}^{(3)} = p_{21}^{(2)} p_{11} + p_{22}^{(2)} p_{21} = (0.52)(0.7) + (0.48)(0.4) = 0,556$
- Podemos predecir un 55,6% de probabilidad de sol el jueves, y un 44,4% de lluvia
  - $p_{22}^{(3)} = 1 - p_{21}^{(3)} = 1 - 0,56 = 0,444$
- *NOTA: Cuando h (pasos) es alto, es más fácil aplicar un enfoque matricial*

## 3.2 Enfoque matricial

- Todas las probabilidades de transición en un solo paso  $p_{ij}$  se pueden escribir en una matriz ( $P$ ) de probabilidades de transición con rango  $n \times n$
- Propiedades:
  - En cada fila la suma es 1:  $p_{i1} + p_{i2} + \dots + p_{in} = 1$
  - Pero no en cada columna
- Esta matriz se llama matriz estocástica

$$P = \begin{array}{c|cccc} & \begin{array}{c} \text{From} \\ \text{state:} \\ 1 \\ 2 \\ \vdots \\ n \end{array} \\ \hline \begin{array}{c} \text{To state:} \\ 1 \\ 2 \\ \cdots \\ n \end{array} & \begin{pmatrix} p_{11} & p_{12} & \cdots & p_{1n} \\ p_{21} & p_{22} & \cdots & p_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ p_{n1} & p_{n2} & \cdots & p_{nn} \end{pmatrix} & & \end{array}$$

## 3.2 Enfoque matricial

### Matriz de probabilidades de transición en h pasos

- Del mismo modo, las probabilidades de transición en h pasos se pueden escribir en una matriz de probabilidades de transición en h pasos
- También es una matriz estocástica
- $P^{(h)} = P \cdot P \cdot P \dots = P^h$

$$P^{(h)} = \begin{pmatrix} p_{11}^{(h)} & p_{12}^{(h)} & \cdots & p_{1n}^{(h)} \\ p_{21}^{(h)} & p_{22}^{(h)} & \cdots & p_{2n}^{(h)} \\ \vdots & \vdots & \vdots & \vdots \\ p_{n1}^{(h)} & p_{n2}^{(h)} & \cdots & p_{nn}^{(h)} \end{pmatrix}$$

# Recordar el producto de dos matrices

## Caso 1

- Rangos iguales:  $(N \times N) \cdot (N \times N) = (N \times N)$

$$A \cdot B = \begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{pmatrix} \begin{pmatrix} b_{11} & b_{12} & b_{13} \\ b_{21} & b_{22} & b_{23} \\ b_{31} & b_{32} & b_{33} \end{pmatrix} =$$

$$= \begin{pmatrix} a_{11}b_{11} + a_{12}b_{21} + a_{13}b_{31} & a_{11}b_{12} + a_{12}b_{22} + a_{13}b_{32} & a_{11}b_{13} + a_{12}b_{23} + a_{13}b_{33} \\ a_{21}b_{11} + a_{22}b_{21} + a_{23}b_{31} & a_{21}b_{12} + a_{22}b_{22} + a_{23}b_{32} & a_{21}b_{13} + a_{22}b_{23} + a_{23}b_{33} \\ a_{31}b_{11} + a_{32}b_{21} + a_{33}b_{31} & a_{31}b_{12} + a_{32}b_{22} + a_{33}b_{32} & a_{31}b_{13} + a_{32}b_{23} + a_{33}b_{33} \end{pmatrix}$$



# Recordar el producto de dos matrices

## Caso 2

- Rangos diferentes:  $(N \times M) \cdot (M \times S) = (N \times S)$ 
  - Ejemplo:  $(3 \times 2) (2 \times 3) = (3 \times 3)$


$$A \cdot B = \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \\ a_{31} & a_{32} \end{pmatrix} \begin{pmatrix} b_{11} & b_{12} & b_{13} \\ b_{21} & b_{22} & b_{23} \end{pmatrix} =$$

$$= \begin{pmatrix} a_{11}b_{11} + a_{12}b_{21} & a_{11}b_{12} + a_{12}b_{22} & a_{11}b_{13} + a_{12}b_{23} \\ a_{21}b_{11} + a_{22}b_{21} & a_{21}b_{12} + a_{22}b_{22} & a_{21}b_{13} + a_{22}b_{23} \\ a_{31}b_{11} + a_{32}b_{21} & a_{31}b_{12} + a_{32}b_{22} & a_{31}b_{13} + a_{32}b_{23} \end{pmatrix}$$

# 3.2 Enfoque matricial

## Ejemplo 6.7 (Previsiones meteorológicas)

- Si llueve el lunes, pronósticos para
  - Martes: Sol =  $p_{21} = 0,4$ , Lluvia =  $p_{22} = 0,6$
  - Miércoles: Sol =  $p_{21}^{(2)} = 0,52$ , Lluvia =  $p_{22}^{(2)} = 0,48$
  - Jueves: Sol =  $p_{21}^{(3)} = 0,556$ , Lluvia =  $p_{22}^{(3)} = 0,444$



$$P = \begin{pmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{pmatrix} = \begin{pmatrix} 0.7 & 0.3 \\ \mathbf{0.4} & \mathbf{0.6} \end{pmatrix}$$

$$P^{(2)} = P \cdot P = \begin{pmatrix} 0.7 & 0.3 \\ 0.4 & 0.6 \end{pmatrix} \begin{pmatrix} 0.7 & 0.3 \\ 0.4 & 0.6 \end{pmatrix} = \begin{pmatrix} 0.61 & 0.39 \\ \mathbf{0.52} & \mathbf{0.48} \end{pmatrix}$$

$$P^{(3)} = P^{(2)} \cdot P = \begin{pmatrix} 0.61 & 0.39 \\ 0.52 & 0.48 \end{pmatrix} \begin{pmatrix} 0.7 & 0.3 \\ 0.4 & 0.6 \end{pmatrix} = \begin{pmatrix} 0.583 & 0.417 \\ \mathbf{0.556} & \mathbf{0.444} \end{pmatrix}$$

## 3.2 Enfoque matricial

### Ejemplo 6.9 (Dispositivo compartido)

- Un ordenador es compartido por 2 usuarios que envían tareas a un ordenador remoto y trabajan de forma independiente.
- En cualquier momento, cualquier usuario conectado puede desconectarse con probabilidad 0.5, y cualquier usuario desconectado puede conectarse con probabilidad 0.2.
- $X(t)$  es el número de usuarios simultáneos en el tiempo  $t$  (minutos)
  - Es una cadena de Markov con 3 estados: 0, 1, y 2.
- Obtener:
  - a) La matriz de probabilidades de transición en 1 paso
  - b) La matriz de probabilidades de transición en 2 pasos

## 3.2 Enfoque matricial

### Ejemplo 6.9 (solución). Calcular de $p_{00}$

- Necesitamos calcular  $p_{00}, p_{01}, p_{02}, p_{10}, \dots, p_{22}$
- Tenemos:
  - $P \{\text{Desconectar usuario conectado}\} = 0.5$
  - $P \{\text{No desconectar usuario conectado}\} = 1 - 0.5 = 0.5$
  - $P \{\text{Conectar usuario desconectado}\} = 0.2$
  - $P \{\text{No conectar usuario desconectado}\} = 1 - 0.2 = 0.8$

$$P = \begin{pmatrix} p_{00} & p_{01} & p_{02} \\ p_{10} & p_{11} & p_{12} \\ p_{20} & p_{21} & p_{22} \end{pmatrix}$$

- Calcular  $p_{00}$ 
  - $X(0)=0$ , Ningún usuario conectado en  $t=0$
  - $X(1)$  es el número de nuevas conexiones dentro del minuto siguiente ( $t=1$ )
  - $X(1)$  es una variable aleatoria con distribución binomial  $B(n,p)=B(2,0.2)$

- $p_{00} = P\{X(1) = 0 \mid X(0) = 0\} = \binom{2}{0} 0.2^0 0.8^2 = 0.8^2 = 0.64$

$$P(x) = P\{X = x\} = \binom{n}{x} p^x q^{n-x}$$

- Otro método:
  - $p_{00} = P \{(\text{No conectar usuario A desconectado}) \text{ AND } (\text{No conectar usuario B desconectado})\} = 0.8 \cdot 0.8 = 0.64$

## 3.2 Enfoque matricial

### Ejemplo 6.9 (solución). Calcular $p_{01}$ , $p_{02}$

- Calcular  $p_{01}$

- Método Binomial:

- $p_{01} = \binom{2}{1} 0.2^1 0.8^1 = 2 \cdot 0.2 \cdot 0.8 = 0.32$

$$P = \begin{pmatrix} p_{00} & p_{01} & p_{02} \\ p_{10} & p_{11} & p_{12} \\ p_{20} & p_{21} & p_{22} \end{pmatrix}$$

- Otro método:

- $p_{01} = P \{[(\text{Conectar usuario A desconectado}) \text{ AND } (\text{No conectar usuario B desconectado})] \text{ OR } [(\text{No conectar usuario A desconectado}) \text{ AND } (\text{Conectar usuario B desconectado})]\} = (0.2 \cdot 0.8) + (0.8 \cdot 0.2) = 0.32$

- Calcular  $p_{02}$

- Método Binomial:

- $p_{02} = \binom{2}{2} 0.2^2 0.8^0 = 1 \cdot 0.2^2 \cdot 1 = 0.04$

$$P(x) = P\{X = x\} = \binom{n}{x} p^x q^{n-x}$$

- Otro método:

- $p_{02} = P \{(\text{Conectar usuario A desconectado}) \text{ AND } (\text{Conectar usuario B desconectado})\} = 0.2 \cdot 0.2 = 0.04$

## 3.2 Enfoque matricial

Ejemplo 6.9 (solución). Calcular  $p_{10}$ ,  $p_{11}$ ,  $p_{12}$

- Calcular  $p_{10}$ 
  - $p_{10} = P \{(\text{No conectar usuario desconectado}) \text{ AND } (\text{Desconectar usuario conectado})\} = 0.8 \cdot 0.5 = 0.40$
- Calcular  $p_{11}$ 
  - $p_{11} =$   
 $(P \{[(\text{Conectar usuario desconectado}) \text{ AND } (\text{Desconectar usuario conectado})] \text{ OR } [(\text{No conectar usuario desconectado}) \text{ AND } (\text{No desconectar usuario conectado})]\}) = 0.2 \cdot 0.5 + 0.8 \cdot 0.5 = 0.50$
- Calcular  $p_{12}$ 
  - $p_{12} = P \{(\text{Conectar usuario desconectado}) \text{ AND } (\text{No desconectar usuario conectado})\} = 0.2 \cdot 0.5 = 0.10$

## 3.2 Enfoque matricial

Ejemplo 6.9 (solución). Calcular  $p_{20}$ ,  $p_{21}$ ,  $p_{22}$

- Calcular  $p_{20}$ 
  - $p_{20} = P \{(\text{Desconectar usuario A conectado}) \text{ AND } (\text{Desconectar usuario B conectado})\} = 0.5 \cdot 0.5 = 0.25$
- Calcular  $p_{21}$ 
  - $p_{21} =$   
 $(P \{[(\text{Desconectar usuario A conectado}) \text{ AND } (\text{No desconectar usuario B conectado})] \text{ OR } [(\text{No desconectar usuario A conectado}) \text{ AND } (\text{Desconectar usuario B conectado})]\}) = 0.5 \cdot 0.5 + 0.5 \cdot 0.5$   
 $= 0.50$
- Calcular  $p_{22}$ 
  - $p_{22} = P \{(\text{No desconectar usuario A conectado}) \text{ AND } (\text{No desconectar usuario B conectado})\} = 0.5 \cdot 0.5 = 0.25$

## 3.2 Enfoque matricial

### Ejemplo 6.9 (solución). Matrices

- Matriz de probabilidades de transición en un paso

$$P = \begin{pmatrix} p_{00} & p_{01} & p_{02} \\ p_{10} & p_{11} & p_{12} \\ p_{20} & p_{21} & p_{22} \end{pmatrix} = \begin{pmatrix} 0.64 & 0.32 & 0.04 \\ 0.40 & 0.50 & 0.10 \\ 0.25 & 0.50 & 0.25 \end{pmatrix}$$

- Matriz de probabilidades de transición en 2 pasos

$$P^{(2)} = P \cdot P = \begin{pmatrix} 0.5476 & 0.3848 & 0.0676 \\ 0.4810 & 0.4280 & 0.0910 \\ 0.4225 & 0.4550 & 0.1225 \end{pmatrix}$$




FIGURE 6.3: Transition diagram for the Markov chain in Example 6.9.



## 3.2 Enfoque matricial

### Cálculo de la distribución de $X(h)$ (1)

- La distribución de los estados después de  $h$  transiciones, o la función de masa de probabilidad de  $X(h)$ , se puede obtener en forma de una matriz  $P_h$  de rango  $1 \times n$ 
  - $P_h = (P_h(1), P_h(2), \dots, P_h(n))$
  - Donde:
    - $P_h(1) = P\{X(h) = 1\}$
    - $P_h(2) = P\{X(h) = 2\}$
    - ...
    - $P_h(n) = P\{X(h) = n\}$

## 3.2 Enfoque matricial

### Cálculo de la distribución de $X(h)$ (2)

- Aplicando la Ley de Probabilidad Total (ver libro)

- $P_h = P_0 P^h$

- Donde  $P_0$  es la distribución inicial

- $P_0 = (P_0(1), P_0(2), \dots, P_0(n))$

- Y  $P^h$  es la matriz de probabilidades en  $h$  pasos

$$P^{(h)} = \begin{pmatrix} p_{11}^{(h)} & p_{12}^{(h)} & \cdots & p_{1n}^{(h)} \\ p_{21}^{(h)} & p_{22}^{(h)} & \cdots & p_{2n}^{(h)} \\ \vdots & \vdots & \vdots & \vdots \\ p_{n1}^{(h)} & p_{n2}^{(h)} & \cdots & p_{nn}^{(h)} \end{pmatrix}$$

- Por tanto, cada elemento de  $P_h$  se calcula como

- $P_h(j) = (P_0(1) \quad \dots \quad P_0(n)) \begin{pmatrix} p_{1j}^{(h)} \\ \dots \\ p_{1n}^{(h)} \end{pmatrix} = P_0(1)p_{1j}^{(h)} + \dots + P_0(n)p_{1n}^{(h)}$

## 3.2 Enfoque matricial

### Ejemplo 6.10 (Dispositivo compartido)

Continuación del ejemplo 6.9

- a) Si sabemos que hay 2 usuarios conectados a las 10:00,
  - obtener la probabilidad de que haya 1 usuario conectado a las 10:02, después de  $h = 2$  transiciones, es decir  $P\{X(2)=1\}$
- b) Si no sabemos cuántos usuarios hay conectados a las 10:00, pero sabemos que todos los estados (0, 1 o 2 usuarios) son igualmente probables a las 10:00,
  - obtener la probabilidad de que haya 1 usuario conectado a las 10:02, después de  $h = 2$  transiciones, es decir  $P\{X(2)=1\}$

## 3.2 Enfoque matricial

### Ejemplo 6.10 (solución) (a)

- Necesitamos obtener  $P\{X(2) = 1\}$ , es decir  $P_2(1)$
- A las 10:00 hay dos usuarios conectados, por lo que  $P_0 = (0 \ 0 \ 1)$ 
  - Porque  $P_0(0)=0$ ,  $P_0(1)=0$ ,  $P_0(2)=1$
- Del ejemplo 6.9 tenemos  $P^2$

$$P^2 = \begin{pmatrix} 0.5476 & 0.3848 & 0.0676 \\ 0.4810 & 0.4280 & 0.0910 \\ 0.4225 & 0.4550 & 0.1225 \end{pmatrix}$$

- Calculamos  $P_2$

$$P_2 = P_0 P^2 = (0 \ 0 \ 1) \begin{pmatrix} 0.5476 & 0.3848 & 0.0676 \\ 0.4810 & 0.4280 & 0.0910 \\ 0.4225 & 0.4550 & 0.1225 \end{pmatrix} = (0.4225 \ \mathbf{0.4550} \ 0.1225)$$

- Como  $P_2 = (P_2(0), P_2(1), P_2(2))$ , entonces la respuesta es:
- $P\{X(2) = 1\} = P_2(1) = \mathbf{0.4550}$

## 3.2 Enfoque matricial

### Ejemplo 6.10 (solución) (b)

- Necesitamos obtener  $P\{X(2) = 1\}$ , es decir  $P_2(1)$
- A las 10:00 sabemos que todos los estados (0, 1 o 2 usuarios) son igualmente probables, por lo que
  - $P_0 = \begin{pmatrix} \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \end{pmatrix}$
  - Porque  $P_0(0)=1/3$ ,  $P_0(1)=1/3$ ,  $P_0(2)=1/3$

- Del ejemplo 6.9 tenemos  $P^2$

$$P^2 = \begin{pmatrix} 0.5476 & 0.3848 & 0.0676 \\ 0.4810 & 0.4280 & 0.0910 \\ 0.4225 & 0.4550 & 0.1225 \end{pmatrix}$$

- Calculamos  $P_2$

$$P_2 = P_0 P^2 = \begin{pmatrix} \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \end{pmatrix} \begin{pmatrix} 0.5476 & 0.3848 & 0.0676 \\ 0.4810 & 0.4280 & 0.0910 \\ 0.4225 & 0.4550 & 0.1225 \end{pmatrix} = (0.4837 \quad \mathbf{0.4226} \quad 0.0937)$$

- Como  $P_2 = (P_2(0), P_2(1), P_2(2))$ , entonces la respuesta es:
- $P\{X(2) = 1\} = P_2(1) = \mathbf{0.4226}$

## 3.2 Enfoque matricial Ejercicios propuestos

- Ejercicios 6.1, 6.2 y 6.3 del libro
  - Las respuestas de 6.1 y 6.3 están disponibles en el libro

## 3.3 Distribución estacionaria de una cadena de Markov

- Una distribución estacionaria de una cadena de Markov es la distribución de probabilidad de los estados de la cadena de Markov después de un gran número de transiciones.
- Es decir, es el conjunto de probabilidades
  - $P_h(1), P_h(2), \dots, P_h(n)$  cuando  $h \rightarrow \infty$
- En lugar de utilizar  $P_h$  se usa la notación  $\pi$ 
  - $\pi_1, \pi_2, \dots, \pi_n$
- Donde
  - $\pi_1 = \lim_{h \rightarrow \infty} P_h(1)$
  - ..
  - $\pi_n = \lim_{h \rightarrow \infty} P_h(n)$
  - $\pi_1 + \pi_2 + \dots + \pi_n = 1$

# 3.3 Distribución estacionaria

## Cálculo matricial

- La distribución en estado estacionario  $\pi$  se calcula como una solución de

- $$\begin{cases} \pi P = \pi \\ \sum_{x=1}^n \pi_x = 1 \end{cases}$$

- Donde

- $P$  es la matriz de probabilidades de transición de la cadena de Markov (rango  $n \times n$ )
  - $\pi$  es la matriz que representa la distribución estacionaria, es decir las probabilidades de los estados cuando  $h$  tiende a infinito (rango  $1 \times n$ )

$$P = \begin{pmatrix} p_{11} & p_{12} & \dots & p_{1n} \\ p_{21} & p_{22} & \dots & p_{2n} \\ \dots & \dots & \dots & \dots \\ p_{n1} & p_{n2} & \dots & p_{nn} \end{pmatrix}$$

$$\pi = (\pi_1 \quad \pi_2 \quad \dots \quad \pi_n)$$



## 3.3 Distribución estacionaria

### Existencia de una distribución estacionaria


- No todas las cadenas de Markov tienen una distribución estacionaria
- Si una cadena de Markov es regular tiene una distribución estacionaria
- Hay que comprobar si es regular
- Una cadena de Markov es regular si no hay ningún valor cero en la matriz de transiciones de probabilidad de algún paso, es decir todas las transiciones de cualquier estado a cualquier estado son posibles en ese paso.

# 3.3 Distribución estacionaria

## Ejemplo 6.15 (Cadena regular)

- Una cadena de Markov tiene como matriz de probabilidades de transición P

$$\bullet P = \begin{pmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 0.9 & 0 & 0 & 0.1 \end{pmatrix}$$



- La matriz P contiene ceros, al igual que P<sup>2</sup>, P<sup>3</sup>, P<sup>4</sup>, y P<sup>5</sup>. Pero la matriz del paso 6 no contiene ceros, lo que demuestra la regularidad de esta cadena de Markov

$$\bullet P^{(6)} = \begin{pmatrix} 0.009 & 0.090 & 0.900 & 0.001 \\ 0.001 & 0.009 & 0.090 & 0.900 \\ 0.810 & 0.001 & 0.009 & 0.180 \\ 0.162 & 0.810 & 0.001 & 0.027 \end{pmatrix}$$


## 3.3 Distribución estacionaria

### Ejemplo 6.16(a) (Cadena irregular)

- Una cadena de Markov tiene como matriz de probabilidades de transición  $P$

$$P = \begin{pmatrix} p_{11} & p_{12} & p_{13} & p_{14} \\ p_{21} & p_{22} & p_{23} & 0 \\ p_{31} & p_{32} & p_{33} & p_{34} \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

- No hay salida del estado 4, es un *estado absorbente*
  - Porque  $p_{44}=1$
  - La distribución estacionaria es  $\pi = (0 \ 0 \ 0 \ 1)$
  - Entonces  $\pi_4 = 1$ , a largo plazo sólo estará en el estado 4
- La cadena de Markov es irregular



## 3.3 Distribución estacionaria

### Ejemplo 6.11 (Previsión meteorológica)

- Es una continuación del ejemplo 6.7
- Obtener la probabilidad de que el futuro (a largo plazo) los días sean soleados, y la probabilidad de que los días sean lluviosos.




FIGURE 6.2: *Transition diagram for the Markov chain in Example 6.7.*

# 3.3 Distribución estacionaria

## Ejemplo 6.11 (solución)

- De la solución del ejemplo 6.7 tenemos la matriz  $P$ 

$$P = \begin{pmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{pmatrix} = \begin{pmatrix} 0.7 & 0.3 \\ 0.4 & 0.6 \end{pmatrix}$$
  - Estado 1 = sol, Estado 2=lluvia
- El cálculo de la distribución estacionaria para esta cadena de Markov es

$$\begin{cases} \pi P = \pi \\ \sum_{x=1}^n \pi_x = 1 \end{cases} \Rightarrow \begin{cases} (\pi_1 \quad \pi_2) \begin{pmatrix} 0.7 & 0.3 \\ 0.4 & 0.6 \end{pmatrix} = (\pi_1 \quad \pi_2) \\ \pi_1 + \pi_2 = 1 \end{cases} \Rightarrow \begin{cases} (0.7\pi_1 + 0.4\pi_2 \quad 0.3\pi_1 + 0.6\pi_2) = (\pi_1 \quad \pi_2) \\ \pi_1 + \pi_2 = 1 \end{cases}$$

$$\Rightarrow \begin{cases} 0.7\pi_1 + 0.4\pi_2 = \pi_1 \\ 0.3\pi_1 + 0.6\pi_2 = \pi_2 \\ \pi_1 = 1 - \pi_2 \end{cases} \Rightarrow 0.3(1 - \pi_2) + 0.6\pi_2 = \pi_2 \Rightarrow -0.3\pi_2 + 0.6\pi_2 - \pi_2 = -0.3 \Rightarrow \pi_2 = \frac{0.3}{0.7} = \mathbf{0.43}$$

$$\pi_1 = 1 - \pi_2 \Rightarrow \pi_1 = 1 - \frac{3}{7} = \mathbf{0.57}$$

- En el futuro, el 57 % de los días serán soleados, y el 43 % lluviosos.

## 3.3 Distribución estacionaria

### Ejercicios propuestos

- Ejercicios 6.4, 6.5, 6.6, 6.7 y 6.8 del libro
  - Las respuestas de 6.4 y 6.5 están disponibles en el libro

# 4. Procesos de conteo

- 4.1 Proceso binomial
- 4.2 Proceso de Poisson

# 4. Procesos de conteo

## Definición

- Un proceso estocástico  $X$  es un proceso de conteo si  $X(t)$  representa un número de elementos contados en el instante  $t$
- Los valores son enteros no negativos,  $X(t) \in \{0, 1, 2, 3, \dots\}$ .
- Todos los procesos de conteo son de estado discreto
- Ejemplos: recuentos de trabajos recibidos, llegados, tareas completadas, mensajes transmitidos, errores detectados, goles marcados, ...
- Se estudiarán dos tipos de procesos de conteo:
  - Proceso binomial (tiempo discreto y estado discreto)
  - Proceso de Poisson (tiempo continuo y estado discreto)



## 4.1 Proceso binomial

- Un proceso binomial  $X(n)$  es el número de éxitos en  $n$  ensayos independientes de Bernoulli, donde  $n = 0, 1, 2, \dots$
- Es un proceso estocástico de conteo de tiempo discreto y estado
- Es una cadena de Markov

# 4.1 Proceso binomial

## VARIABLES ALEATORIAS

- En un proceso de conteo binomial, hay dos variables aleatorias implicadas
  - $X(n)$  = número de éxitos (llegadas) en  $n$  ensayos, con distribución binomial  $B(n,p)$
  - $Y$  = número de ensayos entre éxitos consecutivos (llegadas), con distribución geométrica  $G(p)$

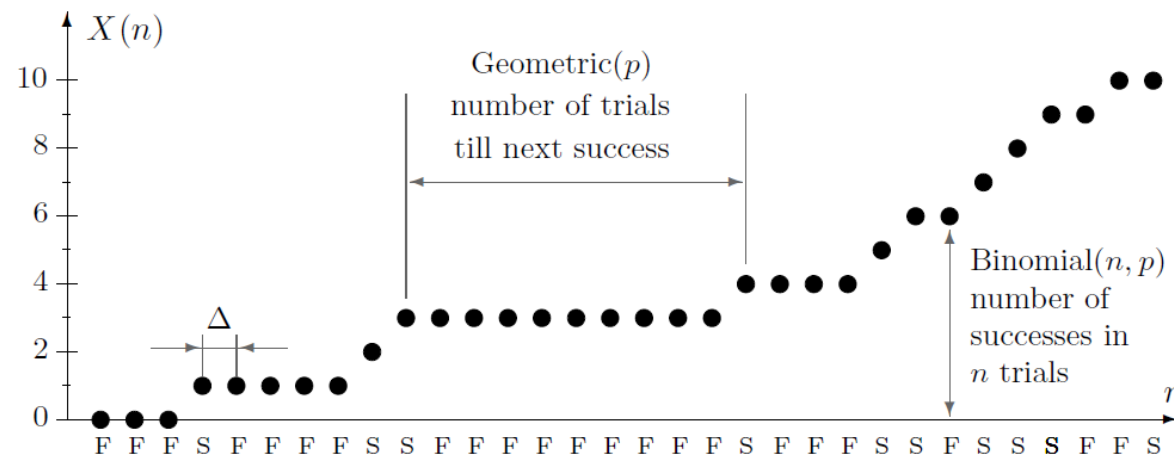


FIGURE 6.7: Binomial process (sample path). Legend: S = success, F=failure.

# 4.1 Proceso binomial

## Cadena de Markov irregular

- Un proceso binomial es una cadena de Markov irregular porque  $X(n)$  no disminuye, por lo que una vez que obtenemos un éxito, el número de éxitos nunca volverá a cero.
- El proceso binomial no tiene distribución estacionaria.




FIGURE 6.8: *Transition diagram for a Binomial counting process.*

## 4.1 Proceso binomial

### Matriz de transiciones de probabilidad

- La matriz de transiciones de probabilidad tiene filas y columnas, porque  $X(n)$  puede alcanzar cualquier valor grande para  $n$  suficientemente grande.

$$\bullet P = \begin{pmatrix} 1-p & p & 0 & 0 & \dots \\ 0 & 1-p & p & 0 & \dots \\ 0 & 0 & 1-p & p & \dots \\ 0 & 0 & 0 & 1-p & \dots \\ \dots & \dots & \dots & \dots & \dots \end{pmatrix}$$

- Es más fácil calcular probabilidades usando la fórmula binomial en lugar de matrices

## 4.2 Proceso de Poisson

- Un proceso de conteo de Poisson es un proceso estocástico en tiempo continuo obtenido de un proceso de conteo binomial cuando el tiempo entre ensayos se aproxima a 0.
- Es un proceso estocástico de tiempo continuo y estado discreto.
  - Es un proceso de Markov de tiempo continuo
  - Pero no es una cadena de Markov,
  - Al ser un proceso de Markov, sólo se necesita el valor más reciente del proceso para predecir sus probabilidades futuras.
- Un proceso de Poisson es adecuado si las llegadas son eventos raros (eventos Poissonianos)
  - Estos eventos ocurren en momentos aleatorios.
  - La probabilidad de que llegue un nuevo evento durante un corto intervalo de tiempo es proporcional a la longitud de este intervalo.
  - La probabilidad de que lleguen más de 1 evento durante ese tiempo es mucho menor en comparación con la longitud de dicho intervalo.
  - Ejemplos de eventos raros incluyen llamadas telefónicas, ataques de virus, errores en software, accidentes de tráfico, desastres naturales, apagones de red, llegadas de mensajes, ...

## 4.2 Proceso de Poisson

### Variables aleatorias

- En un proceso de conteo de Poisson, hay tres variables aleatorias implicadas
  - $X(t)$ :  $\text{Poisson}(\lambda t)$  = Número de llegadas hasta el instante  $t$  (desde el instante 0)
  - $T$ :  $\text{Exponencia}(\lambda)$  = Tiempo entre llegadas consecutivas
  - $T_k$ :  $\text{Gamma}(k, \lambda)$  = Tiempo en el que se produce la  $k$ -ésima llegada

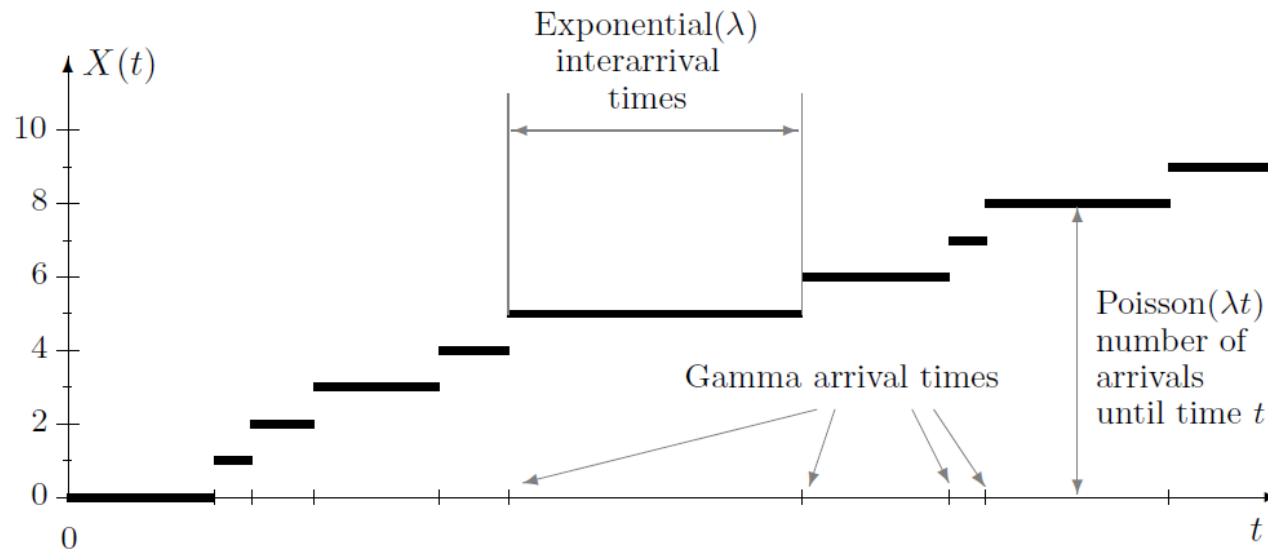


FIGURE 6.10: Poisson process (sample path).

## 4.2 Proceso de Poisson

### Variable aleatoria $X(t)$

- $X(t)$  = Número de llegadas hasta el tiempo  $t$
- Es una variable aleatoria discreta de Poisson( $\lambda t$ )
  - $\lambda$  = número medio de llegadas por unidad de tiempo
- $f(x) = P\{X(t) = x\} = e^{-\lambda t} \frac{(\lambda t)^x}{x!}$
- $F(x) = P\{X(t) \leq x\} = \sum_{k=0}^x \frac{e^{-\lambda t} (\lambda t)^k}{k!}$  (Tabla A3 del libro)
- $E(X(t)) = \lambda t$
- $Var(X(t)) = \lambda t$
- Propiedad importante: tiene incrementos independientes
  - $P\{[X(t+s) - X(s)] = x\} = e^{-\lambda t} \frac{(\lambda t)^x}{x!}$  para cualquier  $s$

## 4.2 Proceso de Poisson

### Variable aleatoria T

- Tiempo entre llegadas consecutivas
- Se trata de una variable aleatoria Exponencial continua.
- $P\{T \leq t\} = 1 - e^{-\lambda t}$
- $P\{T > t\} = e^{-\lambda t}$
- $E(T) = \frac{1}{\lambda}$
- $Var(T) = \frac{1}{\lambda^2}$



## 4.2 Proceso de Poisson

### Variable aleatoria $T_k$

- Tiempo en el que se produce la  $k$ -ésima llegada
- Es una variable aleatoria continua Gamma( $k, \lambda$ )
- $P\{T_k \leq t\} = P\{k\text{-th llegada ocurra antes o en el tiempo } t\}$   
 $= P\{X(t) \geq k\}$
- Al ser variables continuas, se cumple:  $P\{T_k > t\} = P\{X(t) < k\}$
- $E(T_k) = \frac{k}{\lambda}$
- $Var(T_k) = \frac{k}{\lambda^2}$

## 4.2 Proceso de Poisson

### Ejemplo 6.20 (Accesos al sitio web)

- El número de visitas a un determinado sitio web sigue un proceso de Poisson con una frecuencia media de 7 visitas por minuto.
  - a) En promedio, ¿cuánto tiempo se necesita para obtener 10000 visitas?
  - b) ¿Cuál es la probabilidad de que esto suceda en un plazo de 24 horas?

## 4.2 Proceso de Poisson

### Ejemplo 6.20 (Solución)

a) En promedio, ¿cuánto tiempo se necesita para obtener 10000 visitas?

- $T_{10000}$  = Tiempo (minuto) en el que llega la visita número 10000, desde el inicio
- Es una variable Gamma( $k, \lambda$ ), con  $k=10000$  y  $\lambda=7$  visitas/minuto
- $E(T_{10000}) = \frac{k}{\lambda} = \frac{10000}{7} = 1428.6$  minutos o 23.81 horas

b) ¿Cuál es la probabilidad de que esto suceda en 24 horas?

- 24 horas =  $24 \cdot 60 = 1440$  minutos
- $P\{T_{10000} \leq 1440\} = \mathbf{0.7881}$
- Por el Teorema Central del Límite podemos aproximar a una variable Normal estándar

$$\bullet \mu = 1428.6, \sigma = \sqrt{\frac{k}{\lambda^2}} = \sqrt{\frac{10000}{49}} = 14.3$$

$$\bullet P\{T_k \leq 1440\} = P\left\{\frac{T_k - \mu}{\sigma} \leq \frac{1440 - 1428.6}{14.3}\right\} = P\{Z \leq 0.80\} = 0.7881$$

## 4.2 Proceso de Poisson

### Ejemplo 6.20 (Ordenador central)

- Se envían trabajos a un ordenador central, son una frecuencia media de 2 trabajos por minuto.
  - a) ---
  - b) Calcular la probabilidad de que lleguen más de 3 trabajos durante un minuto.
  - c) Calcular la probabilidad de que lleguen más de 30 trabajos durante 10 minutos.
  - d) ¿Cuál es el tiempo promedio entre dos llegadas y cuál es la varianza?
  - e) Calcular la probabilidad de que el próximo trabajo no llegue durante los próximos 30 segundos.

## 4.2 Proceso de Poisson

### Ejemplo 6.20 b) (Solución) (b)

b) Calcular la probabilidad de que lleguen más de 3 trabajos durante un minuto.

- Proceso de Poisson:  $X(t)$  = Número de llegadas hasta el tiempo  $t$
- $X(1)$  es una variable Poisson( $\lambda t$ ), con  $\lambda=2\text{min}^{-1}$ ,  $t=1\text{min}$ ,  $\lambda t=2$
- $P\{X(1) > 3\} = 1 - P\{X(1) \leq 3\} = 1 - 0.857 = \mathbf{0.143}$ 
  - Usando la tabla A3 de libro

## 4.2 Proceso de Poisson

### Ejemplo 6.20 (Solución) (c, d)

- c) Calcular la probabilidad de que lleguen más de 30 trabajos durante 10 minutos.
- Proceso de Poisson:  $X(t)$  = Número de llegadas hasta el tiempo  $t$
  - $X(10)$  es una variable Poisson( $\lambda t$ ), con  $\lambda=2\text{min}^{-1}$ ,  $t=10\text{min}$ ,  $\lambda t=20$
  - $P\{X(10) > 30\} = 1 - P\{X(10) \leq 30\} = 1 - 0.987 = \mathbf{0.013}$ 
    - Usando la tabla A3 de libro
- d) ¿Cuál es el tiempo promedio entre dos llegadas y cuál es la varianza?
- $T$  = Tiempo entre llegadas consecutivas
  - $T$  es una variable aleatoria Exponencial( $\lambda$ ), con  $\lambda=2\text{min}^{-1}$
  - $E(T) = \frac{1}{\lambda} = \frac{1}{2} = \mathbf{0.5 \text{ min}}$
  - $Var(T) = \frac{1}{\lambda^2} = \frac{1}{4} = \mathbf{0.25 \text{ min}^2}$

## 4.2 Proceso de Poisson

### Ejemplo 6.20 (Solución) (e)

e) Calcular e la probabilidad de que el próximo trabajo no llegue durante los próximos 30 segundos (0.5 minutos).

- Proceso de Poisson:  $X(t)$  = Número de llegadas hasta el tiempo  $t$
- $X(0.5)$  es una variable Poisson( $\lambda t$ ), con  $\lambda=2\text{min}^{-1}$ ,  $t=0.5$  min,  $\lambda t=1$

- $P\{X(0.5) = 0\} = \frac{e^{-1}(1)^0}{0!} = e^{-1} = 2.72^{-1} = \mathbf{0.368}$

- Se puede resolver también usando la variable  $T$
- $T$  = Tiempo entre llegadas consecutivas
- $T$  es una variable aleatoria Exponencial( $\lambda$ ), con  $\lambda=2\text{min}^{-1}$

- $P\{T > 0.5\} = 1 - P\{T \leq 0.5\} = 1 - (1 - e^{-2 \cdot 0.5}) = 2.72^{-1} = \mathbf{0.368}$

## 4.2 Proceso de Poisson

### Ejercicios propuestos

- Ejercicios 6.17, 6.20, 6.21, 6.22, 6.23 y 6.24 del libro
  - Las respuestas de 6.20, 6.22 y 6.23 están disponibles en el libro



# 5. Resumen

- Los procesos estocásticos son variables aleatorias que cambian, evolucionan y se desarrollan en el tiempo.
- Hay procesos de tiempo discreto y tiempo continuo, estados discretos y estados continuos, dependiendo de sus tiempos y valores posibles.
- Un proceso de Markov es un proceso de estado discreto, donde solo se necesita el valor más reciente del proceso para predecir sus probabilidades futuras.
- Una cadena de Markov es un proceso de Markov en tiempo discreto y estado discreto.
  - Una cadena de Markov se describe completamente por su distribución inicial de probabilidad y por sus probabilidades de transición
  - Si una cadena de Markov es regular, se pueden calcular sus probabilidades a largo plazo mediante una distribución estacionaria
- Los procesos de conteo binomial y Poisson son procesos de Markov, de tiempo discreto y continuo, respectivamente.
- Los procesos de conteo de tiempo continuo se pueden considerar como el límite de algunos procesos de tiempo discreto, cuando el tiempo entre eventos a contar tiende a cero.