

Conceptes fonamentals de xarxes de computadores. Un enfocament analític.

J.M. Barceló, Ll. Cerdà, J. García.

Temario:

- Cadenas de Markov y teoría de colas.
Ll. Cerdà, 9 horas.
- Traffic models.
J.M. Barceló , 6 horas.
- Complex Networks.
J.M. Barceló, 3 horas.
- No Markovian models.
J. García , 3 horas.
- IP lookup and packet classification.
J. García , 3 horas.
- Output scheduling.
J. García , 3 horas.

1

Ll. Cerdà.

Tema 1: Cadenas de Markov y teoría de colas

- Cadenas de Markov en tiempo discreto.
- Cadenas de Markov en tiempo continuo.
- Teoría de colas.
 - M/M/1.
 - M/G/1.
 - Reversibilidad en el tiempo (Burke).
 - Redes de Jackson y redes cerradas.

2

Ll. Cerdà.

Espacio de probabilidad

- Espacio muestral (Ω) = conjunto de todos los posibles sucesos (ω)
- Evento aleatorio: conjunto de sucesos que cumplen una cierta condición (es un subconjunto de Ω).

$$A = \{ \omega \in \Omega : \omega \text{ cumple una cierta condición} \}$$

- Espacio de probabilidad: es una tripleta (Ω, F, P) donde:
 - F es una familia de eventos aleatorios.
 - P asigna una probabilidad a cada evento aleatorio de F .

3

Familia de eventos y definición de probabilidad

- La familia de eventos aleatorios F ha de cumplir:
 - Tiene el evento Ω ,
 - Si los eventos A y B son de F , también lo son $A+B, AB, A^c, B^c$.
 - Si los eventos $A_i, i=1,2,\dots$ son de F , también lo son ΣA_i i ΠA_i
- Las probabilidades asignadas a los eventos de F han de cumplir (definición axiomática de probabilidad):
 - $P[A] \geq 0$
 - $P[\Omega] = 1$
 - Si $A_i A_j = \emptyset, i \neq j, P[\Sigma A_i] = \Sigma P[A_i]$
 - Si A_i es una partición de $A, P[A] = \Sigma P[A_i]$

4

Ejemplo

- Experimento: lanzar una moneda tres veces.
- Espacio muestral: $\Omega = \{CCC, CCX, CXC, CXX, XCC, XCX, XXC, XXX\}$
- Ejemplos de posibles eventos:
 - $A = \{\text{sale una cara}\} = \{CXX, XCX, XXC\}$
 - $B = \{\text{salen al menos dos caras}\} = \{CCC, CCX, CXC, XCC\}$
- Ejemplo de una familia de eventos:
 - $F = \{\Omega, \emptyset, A, B, A+B, A^c, B^c, (A^c+B)^c\}$
- A menudo F no se da explícitamente porque se deduce del modelo.

5

Variable aleatoria (VA)

- Es una función definida sobre el espacio muestral Ω de un espacio de probabilidad (Ω, F, P) .
- Asigna un número real $X(\omega)$ a cada posible suceso $\omega \in \Omega$.
- Para cada número x , $\{\omega \mid X(\omega) \leq x\}$ es un evento de F .
- Normalmente se suprime la dependencia funcional con ω y se escribe X en lugar de $X(\omega)$ y $\{X \leq x\}$ en lugar de $\{\omega \mid X(\omega) \leq x\}$.
- Una VA puede ser discreta o continua.

6

Ejemplo

- Experimento: lanzar una moneda tres veces.
- Espacio muestral: $\Omega = \{CCC, CCX, CXC, CXX, XCC, XCX, XXC, XXX\}$
- Definimos la VA $X =$ nombre de caras en el primer y último lanzamiento:
 - $\{X = 0\} = \{XCX, XXX\}$
 - $\{X = 1\} = \{CXX, CCX, XXC, XCC\}$
 - $\{X = 2\} = \{CXC, CCC\}$

7

Proceso estocastico

- Es un conjunto de VAs: $\{X(t) : t \in \Gamma\}$ definidas en un mismo espacio de probabilidad.
- Normalmente el índice t representa un tiempo y $X(t)$ el estado del proceso estocástico en el instante t .
- El proceso puede ser de tiempo discreto o continuo si Γ es discreto o continuo.
- Si el proceso es de tiempo discreto, usamos enteros para representar el índice: $\{X_1, X_2, \dots\}$

8

Ejemplo: cola con un único servidor



Podemos definir los procesos estocásticos:

- $A(t)$: número de llegadas hasta el instante t .
- $D(t)$: número de salidas hasta el instante t .
- $N(t)$: número de usuarios en el instante t .
- $V(t)$: tiempo necesario para servir los $N(t)$ usuarios que hay en el sistema (tiempo de espera virtual o trabajo remanente “*unfinished work*”).
- ...

9

Diferencia entre proceso i VA

- Podemos imaginar un proceso como una secuencia de sucesos (*epochs*) que ocurren cada cierto intervalo (*inter-epoch times*).
- Por ejemplo, se dice que un proceso $X(t)$ es de poisson de parámetro λ , cuando la VA igual al nombre de sucesos que han ocurrido en un tiempo t , tiene una distribución de poisson de parámetro λt :

$$P[X(t) = i] = \frac{(\lambda t)^i}{i!} e^{-\lambda t}$$

10

Cadenas de Markov

- En muchas ocasiones se puede representar el comportamiento de un sistema describiendo todos los distintos estados que el sistema puede ocupar e indicando las transiciones del sistema de un estado a otro.
- Si las transiciones de un estado a otro cumplen ciertos requisitos de independencia (ausencia de memoria) el sistema puede describirse mediante una Cadena de Markov (MC).
- Podemos distinguir entre MC de tiempo continuo y de tiempo discreto.

11

Cadenas de Markov de tiempo discreto

- ¿Qué propiedades debe cumplir un proceso estocástico para ser una MC de tiempo discreto?
 - Los estados deben formar un conjunto numerable (En caso contrario se habla de un *proceso de Markov*).
 - Si $X(t)$ es el evento {En el instante t el sistema se encuentra en estado i } se debe cumplir:


$$P\{X(t) = i \mid X(t-1) = j, X(t-2) = k, \dots\} = P\{X(t) = i \mid X(t-1) = j\}$$
 - Si $P\{X(t) = i \mid X(t-1) = j\} = P\{X(1) = i \mid X(0) = j\}$ para todo t tenemos una *MC de tiempo discreto homogénea*. Nosotros consideraremos solamente MC homogéneas.

NOTA: Algunos autores usan el termino cadena / proceso según si el tiempo (y no el estado) es discreto / continuo, y asumen que el estado es discreto.

12

Cadenas de Markov de tiempo discreto

- Posible evolución de una MC de tiempo discreto:




13

Ll. Cerdà.

Cadenas de Markov de tiempo discreto

- Tiempo de permanencia en un estado k (*Sojourn or holding time*): Es la V.A. H_k igual al número de saltos que la cadena permanece en el estado k :



- La propiedad de Markov implica:

$$H_i(n) = P\{H_i = n\} = p_{ii}^{n-1} (1-p_{ii}), n \geq 1$$

Distribución geométrica de media $E\{H_i\} = 1 / (1 - p_{ii})$


NOTA: permitimos que $p_{ii}=0$, $H_i(n) = \delta(n-1)$, y $p_{ii}=1$, $H_i = \infty$.

14

Ll. Cerdà.

Cadenas de Markov de tiempo discreto

- Representación gráfica de una MC de tiempo discreto:



- $X(t) = i$: En el instante t , el sistema está en estado i .
- p_{ij} se llaman probabilidades de transición en un paso.

15

Ll. Cerdà.

Cadenas de Markov de tiempo discreto

- Matriz de probabilidades de transición en un paso:
 - El conjunto de probabilidades p_{ij} , $i=1\dots, j=1\dots$ definen la evolución del sistema. Se pueden representar como una matriz, que se conoce como **matriz de probabilidades de transición en 1 paso**:


$$\mathbf{P} = \begin{pmatrix} p_{11} & p_{12} & \dots \\ p_{21} & p_{22} & \dots \\ \dots & \dots & \dots \end{pmatrix}$$

16

Ll. Cerdà.

Cadenas de Markov de tiempo discreto

- Ejemplo:
- Un terminal puede estar en 3 estados:
 - Estado 1: Inactivo
 - Estado 2: Activo sin enviar datos
 - Estado 3: Activo enviando datos



$$\mathbf{P} = \begin{pmatrix} 0.8 & 0.15 & 0.05 \\ 0.7 & 0.2 & 0.1 \\ 0.5 & 0.3 & 0.2 \end{pmatrix}$$

Cadenas de Markov de tiempo discreto

- Probabilidades de transición en n pasos:
 - La probabilidad de transición en 1 paso:

$$p_{ij} = P\{X(1) = j \mid X(0) = i\}$$

se generaliza en n pasos a:

$$p_{ij}^{(n)} = P\{X(n) = j \mid X(0) = i\}$$

NOTA: en los pasos intermedios 1..n-1 puede que $X(t)$ también esté en el estado j .

Matriz de probabilidades de transición en n pasos:

$$\mathbf{P}^{(n)} = \begin{pmatrix} p_{11}^{(n)} & p_{12}^{(n)} & \dots \\ p_{21}^{(n)} & p_{22}^{(n)} & \dots \\ \dots & \dots & \dots \end{pmatrix}$$

Cadenas de Markov de tiempo discreto


- Ecuaciones de Chapman-Kolmogorov:

$$p_{ij}^{(n)} = \sum_k p_{ik}^{(m)} p_{kj}^{(n-m)}$$

- Demostración:

$$\begin{aligned} p_{ij}^{(n)} &= P\{X(n) = j \mid X(0) = i\} = \sum_k P\{X(n) = j, X(m) = k \mid X(0) = i\} = \\ &= \sum_k P\{X(n) = j \mid X(m) = k, X(0) = i\} P\{X(m) = k \mid X(0) = i\} = \\ &= \sum_k P\{X(n) = j \mid X(m) = k\} P\{X(m) = k \mid X(0) = i\} = \sum_k p_{ik}^{(m)} p_{kj}^{(n-m)} \end{aligned}$$

- Interpretación:



Cadenas de Markov de tiempo discreto

- Ecuaciones de Chapman-Kolmogorov en forma matricial:

$$p_{ij}^{(n)} = \sum_k p_{ik}^{(m)} p_{kj}^{(n-m)}$$

$$\Downarrow$$

$$\mathbf{P}^{(n)} = \mathbf{P}^{(m)} \mathbf{P}^{(n-m)}$$

- En particular:


$$\mathbf{P}^{(n)} = \mathbf{P}^{(1)} \mathbf{P}^{(n-1)} = \mathbf{P} \mathbf{P}^{(n-1)} = \mathbf{P}^{(n-1)} \mathbf{P}$$

- Iterando obtenemos:

$$\mathbf{P}^{(n)} = \mathbf{P}^n$$

Cadenas de Markov de tiempo discreto

- Ejemplo:



$$\mathbf{P} = \begin{pmatrix} 0.8 & 0.15 & 0.05 \\ 0.7 & 0.2 & 0.1 \\ 0.5 & 0.3 & 0.2 \end{pmatrix}$$

$$\mathbf{P}^2 = \begin{pmatrix} 0.770 & 0.165 & 0.065 \\ 0.750 & 0.175 & 0.075 \\ 0.710 & 0.195 & 0.095 \end{pmatrix}$$

$$\mathbf{P}^\infty = \begin{pmatrix} 0.76250 & 0.16875 & 0.06875 \\ 0.76250 & 0.16875 & 0.06875 \\ 0.76250 & 0.16875 & 0.06875 \end{pmatrix} = \begin{pmatrix} p_1 & p_2 & p_3 \\ p_1 & p_2 & p_3 \\ p_1 & p_2 & p_3 \end{pmatrix}$$

21

Ll. Cerdà.

Cadenas de Markov de tiempo discreto

- Clasificación de los estados:
 - **Estados recurrentes:** estados que tienen una probabilidad > 0 de volver al estado (se visitan un número infinito de veces).
 - **Estados transitorios:** estados que tienen una probabilidad > 0 de no volver nunca al estado (se visitan un número finito de veces).
- Para tener criterios que nos permitan clasificar los estados, empezamos estudiando las distribuciones del número de pasos que tardamos de ir de un estado i a un estado j ...

22


Ll. Cerdà.

Cadenas de Markov de tiempo discreto

- Definición:

$$f_{jj}^{(n)} = P\{\text{volver por primera vez al estado } j \text{ en } n \text{ pasos partiendo de } j\}$$

- Ejemplo: vuelta por primera vez al estado j en 5 pasos:



- No confundir con la prob. de volver a j en n pasos habiendo salido de j , aunque entre medio visitemos j : $p_{ij}^{(n)}$

Cadenas de Markov de tiempo discreto

- $f_{jj}^{(n)}$ i $p_{jj}^{(n)}$ cumplen:

$$p_{jj}^{(n)} = \sum_{l=1}^n f_{jj}^{(l)} p_{jj}^{(n-l)} \quad n \geq 1$$

- La probabilidad de volver por primera vez en cualquier número de pasos a j habiendo partido de j es:

$$f_{jj} = \sum_{n=1}^{\infty} f_{jj}^{(n)}$$

Cadenas de Markov de tiempo discreto

- Si $f_{jj} = 1$ decimos que j es un estado *recurrente*
- Si $f_{jj} < 1$ decimos que j es un estado *transitorio*
- Cuando $f_{jj} = 1$, definimos el *tiempo medio de recurrencia* M_{jj} como:

$$M_{jj} = \sum_{n=1}^{\infty} n f_{jj}^{(n)}$$

Es decir, M_{jj} es el número medio de pasos que hay que dar para volver al estado j por primera vez después de dejarlo.


- Clasificación de los estados recurrentes:
 - Si $M_{jj} = \infty$ es estado es *recurrente nulo*.
 - Si $M_{jj} < \infty$ es estado de *recurrente positivo*.

25

Cadenas de Markov de tiempo discreto

- Propiedad: En las MC con un número finito de estados, los estados son recurrentes positivos o transitorios. Al menos un estado debe ser positivo recurrente. No puede haber estados recurrentes nulos.

- Ejemplo:



26

Cadenas de Markov de tiempo discreto

- Análogamente podemos definir los tiempos de primer paso del estado i a estado j (f_{ij}). Evidentemente:

$$p_{ij}^{(n)} = \sum_{l=1}^n f_{ij}^{(l)} p_{ij}^{(n-l)}$$

- El tiempo medio del primer paso del estado i a estado j M_{ij} vale:

$$M_{ij} = \sum_{n=1}^{\infty} n f_{ij}^{(n)}$$

27


Cadenas de Markov de tiempo discreto

- Estados periódicos y aperiódicos:
 - Se dice que un estado j es **periódico** de periodo k ($k > 1$) si después de dejar el estado j sólo es posible volver a él en un número de saltos que es un múltiplo entero de k .
 - Si $k = 1$ el estado es **aperiódico**.

28

Cadenas de Markov de tiempo discreto

- Ejemplo:



$$\mathbf{P} = \begin{pmatrix} 0,7 & 0,2 & 0,1 \\ 0 & 0 & 1 \\ 0 & 1 & 0 \end{pmatrix}$$

$$f_{11}^{(n)} = 0,7 \delta(n-1) \Rightarrow$$

$$f_{22}^{(n)} = f_{33}^{(n)} = \delta(n-2)$$

$$f_{23}^{(n)} = f_{32}^{(n)} = \delta(n-1)$$

$$f_{13}^{(n)} = \begin{cases} 0,1 & , n = 1 \\ 0,7^{n-1}0,1 + 0,7^{n-2}0,2, & n > 1 \end{cases}$$

$$f_{32}^{(n)} = \begin{cases} 0,2 & , n = 1 \\ 0,7^{n-1}0,2 + 0,7^{n-2}0,1, & n > 1 \end{cases}$$

$$\mathbf{M} = (M_{ij}) = \begin{pmatrix} \infty & 11/3 & 12/3 \\ \infty & 2 & 1 \\ \infty & 1 & 2 \end{pmatrix}$$

$$\Downarrow$$

El estado 1 es transitorio. Los estados 2 y 3 son recurrentes positivos y son periódicos.

29

Ll. Cerdà.

Cadenas de Markov de tiempo discreto


- Una cadena es **irreducible** si cada estado puede ser alcanzado desde cualquier otro estado, es decir, si existe un entero m para el cual $p_{ij}^{(m)} > 0$ para cada par de estados i y j .
- Un subconjunto de estados C es **cerrado** si no es posible alcanzar desde un estado de C ningún otro estado fuera de ese conjunto, sino sólo estados de C .
- Si un conjunto cerrado tiene un sólo estado, este se llama **absorbente**.
- Consecuencia:** Si el conjunto de todos los estados de la cadena es cerrado y no contiene ningún otro subconjunto cerrado, la cadena es irreducible.

30

Ll. Cerdà.

Cadenas de Markov de tiempo discreto

- Ejemplo:



- El estado 4 es absorbente.
- Los estados 2 y 3 son un conjunto cerrado.
- La cadena no es irreducible.

31

Ll. Cerdà.

Cadenas de Markov de tiempo discreto

- Definiciones:

- Si un estado es positivo recurrente y aperiódico se dice que es un estado *ergódico*.
- Si todos los estados de una cadena son ergódicos, decimos que la cadena es *ergódica*.

- Teoremas:

- Las cadenas finitas, aperiódicas e irreducibles son ergódicas.
- Si una cadena es irreducible se cumple una de las tres propiedades siguientes:
 - Todos los estados son positivos recurrentes.
 - Todos los estados son recurrentes nulos.
 - Todos los estados son transitorios.
 - Además todos los estados son o aperiódicos o periódicos con el mismo periodo.

32

Ll. Cerdà.

Cadenas de Markov de tiempo discreto

- Probabilidad de estar en un estado: en general usaremos la notación $\pi_i(t) = P\{X(t) = i\}$. En forma vectorial (vector fila) $\boldsymbol{\pi}(t) = (\pi_1(t), \pi_2(t), \dots)$.
- La evolución de la cadena depende de las probabilidades iniciales $\boldsymbol{\pi}(0)$ (condiciones iniciales).
- Cuando estudiemos el régimen transitorio del sistema estaremos interesados en $\boldsymbol{\pi}(t)$.
- Cuando estudiemos el régimen permanente del sistema estaremos interesados la *distribución límite*:

$$\boldsymbol{\pi}(\infty) = (\pi_1(\infty), \pi_2(\infty), \dots) = \boldsymbol{\pi} = (\pi_1, \pi_2, \dots)$$

(si el límite existe).

33

Ll. Cerdà.

Cadenas de Markov de tiempo discreto

- Cálculo de la distribución límite:

	en forma matricial	
$\pi_i(t) = \sum_k p_{ki} \pi_k(t-1)$	\Rightarrow	$\boldsymbol{\pi}(1) = \boldsymbol{\pi}(0)\mathbf{P}$ $\boldsymbol{\pi}(2) = \boldsymbol{\pi}(0)\mathbf{P}^2$... $\boldsymbol{\pi} = \boldsymbol{\pi}(\infty) = \boldsymbol{\pi}(0)\mathbf{P}^\infty$

Si existe la distribución límite $\Rightarrow \mathbf{P}^\infty = \begin{pmatrix} \boldsymbol{\pi} \\ \boldsymbol{\pi} \\ \boldsymbol{\pi} \end{pmatrix}$ \mathbf{P}^∞ se llama matriz límite y $\boldsymbol{\pi}$ es la distribución límite.

34

Ll. Cerdà.

Cadenas de Markov de tiempo discreto

- Ejemplo

$$\mathbf{P} = \begin{pmatrix} 0.8 & 0.15 & 0.05 \\ 0.7 & 0.2 & 0.1 \\ 0.5 & 0.3 & 0.2 \end{pmatrix}$$

$$\mathbf{P}^2 = \begin{pmatrix} 0.764 & 0.168 & 0.068 \\ 0.760 & 0.170 & 0.070 \\ 0.752 & 0.174 & 0.074 \end{pmatrix}$$

$$\mathbf{P}^4 = \begin{pmatrix} 0.7628 & 0.1686 & 0.0686 \\ 0.7620 & 0.1690 & 0.0690 \\ 0.7604 & 0.1698 & 0.0698 \end{pmatrix} \quad \mathbf{P}^8 = \begin{pmatrix} 0.762500 & 0.168750 & 0.068750 \\ 0.762499 & 0.168750 & 0.068750 \\ 0.762497 & 0.168752 & 0.068752 \end{pmatrix}$$

...

$$\Rightarrow \boldsymbol{\pi} = (0.76250, 0.16875, 0.06875)$$

35

Cadenas de Markov de tiempo discreto

- Distribución en estado estacionario:

$$\pi_i(t) = \mathbf{P}\{X(t) = i\} = \sum_k \mathbf{P}\{X(t) = i \mid X(t-1) = k\} \mathbf{P}\{X(t-1) = k\},$$

$$\pi_i(t) = \sum_k p_{ki} \pi_k(t-1)$$

- En forma matricial: $\boldsymbol{\pi}(t) = \boldsymbol{\pi}(t-1) \mathbf{P}$
- Suponiendo que existe el límite: $\lim_{t \rightarrow \infty} \pi_i(t) = \pi_i$
- Llamamos π_i la probabilidad en régimen estacionario de estar en el estado i , y $\boldsymbol{\pi} = (\pi_1, \pi_2, \dots)$, el vector de probabilidades en régimen estacionario.
- En forma matricial (“*Global balance equations*”):

$$\boldsymbol{\pi} = \boldsymbol{\pi} \mathbf{P}$$

$$\boldsymbol{\pi} \mathbf{e} = \mathbf{1}, \mathbf{e} = (1, 1, \dots)^T$$

36

Cadenas de Markov de tiempo discreto

- Ejemplo

$$\mathbf{P} = \begin{pmatrix} 0.8 & 0.15 & 0.05 \\ 0.7 & 0.2 & 0.1 \\ 0.5 & 0.3 & 0.2 \end{pmatrix} \quad \begin{array}{l} \boldsymbol{\pi} = \boldsymbol{\pi} \mathbf{P} \\ \boldsymbol{\pi} \mathbf{e} = \mathbf{1}, \mathbf{e} = (1, 1, \dots)^T \end{array}$$

Solución usando octave:

Resolución de la ecuación $\boldsymbol{\pi} (\mathbf{I} - \mathbf{P}) = \mathbf{0}$ cambiando la última ecuación por $\boldsymbol{\pi} \mathbf{e} = \mathbf{1}$:


```
octave:1> P=[0.8,0.15,0.05;0.7,0.2,0.1;0.5,0.3,0.2];
octave:2> s=size(P,1); # number of rows.
octave:3> [zeros(1,s-1),1] / ...
> [eye(s,s-1)-P(1:s,1:s-1), ones(s,1)]
ans =
    0.762500    0.168750    0.068750
```

NOTA: he puesto octave en: abiell# /users/scratch/llorenc/bin

37

Cadenas de Markov de tiempo discreto

- No confundir la **distribución límite** $\boldsymbol{\pi}(\infty)$ y la **distribución estacionaria** $\boldsymbol{\pi}$, solución de la ecuación: $\boldsymbol{\pi} = \boldsymbol{\pi} \mathbf{P}$, $\boldsymbol{\pi} \mathbf{e} = \mathbf{1}$
- En general $\boldsymbol{\pi}$ y $\boldsymbol{\pi}(\infty)$ NO tienen por que ser iguales:



En esta caso $\boldsymbol{\pi}(\infty)$ NO existe (\mathbf{P}^∞ no converge) y $\boldsymbol{\pi} = (1/3, 1/3, 1/3)$.

38

Cadenas de Markov de tiempo discreto

Teoremas para **cadenas ergódicas** (irreducibles y aperiódicas):

- $\pi = \pi(\infty)$
- El tiempo medio que estamos en un estado j durante un tiempo t se puede calcular como $t \cdot \pi_j$ (π_j es la porción de tiempo que la cadena está en el estado j).
- Definimos v_{ij} , la tasa de visitas, como el número medio de visitas al estado i entre dos visitas sucesivas al estado j . Tenemos que $v_{ij} = \pi_i / \pi_j$.
- $M_{ii} = 1 / \pi_i$ (tiempo medio entre visitas sucesivas al estado j). Esta propiedad se cumple para cadenas irreducibles y recurrentes positivas, aunque sean periódicas (y por lo tanto no ergódicas).

39


Cadenas de Markov de tiempo discreto

Cadenas absorbentes.

Sea la matriz $\mathbf{P}_{\{r,r\}}$ de una cadena con r estados: s estados transitorios y $r-s$ estados absorbentes. En forma canónica:

$$\mathbf{P}_{\{r,r\}} = \begin{pmatrix} \mathbf{Q}_{\{s,s\}} & \mathbf{R}_{\{s,r-s\}} \\ \mathbf{0}_{\{r-s,s\}} & \mathbf{I}_{\{r-s,r-s\}} \end{pmatrix}$$

• Ejemplo:



$$\mathbf{P} = \begin{matrix} & \begin{matrix} b & c & d \end{matrix} & \begin{matrix} a & e \end{matrix} \\ \begin{matrix} b \\ c \\ d \\ a \\ e \end{matrix} & \begin{pmatrix} 0 & 0,1 & 0 & 0,9 & 0 \\ 0 & 0 & 0,8 & 0 & 0,2 \\ 0,3 & 0 & 0,7 & 0 & 0 \\ \hline 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix} \end{matrix}$$

40

Cadenas de Markov de tiempo discreto

Cadenas absorbentes.

$$\mathbf{P}_{\{r,r\}} = \begin{pmatrix} \mathbf{Q}_{\{s,s\}} & \mathbf{R}_{\{s,r-s\}} \\ \mathbf{0}_{\{r-s,s\}} & \mathbf{I}_{\{r-s,r-s\}} \end{pmatrix}$$

Resultados.

- Definimos la V.A. $n_{ij} = \{\text{número de visitas al estado } j \text{ antes de la absorción, partiendo del estado } i\}$.

$$\{E[n_{ij}]\} = \mathbf{N} = (\mathbf{I} - \mathbf{Q})^{-1}.$$

- $\{\text{Var}[n_{ij}]\} = \mathbf{N} (2 \mathbf{N}_{\text{diag}} - \mathbf{I}) - \mathbf{N}_{\text{sqr}}$. Donde $\mathbf{N}_{\text{sqr}} = \{E[n_{ij}]^2\}$.
- Definimos la V.A. $t_i = \{\text{número de visitas a un estado transitorio antes de la absorción, partiendo del estado } i\}$:

$$\{E[t_i]\} = \boldsymbol{\tau} = \mathbf{N} \mathbf{e}. \quad \{\text{Var}[t_i]\} = (2 \mathbf{N} - \mathbf{I}) \boldsymbol{\tau} - \boldsymbol{\tau}_{\text{sqr}}.$$

- Definimos b_{ij} como la probabilidad de ser absorbido por el estado j ($j \in \{\text{absorbentes}\}$) partiendo del estado i ($i \in \{\text{transitorios}\}$):

$$\{b_{ij}\} = \mathbf{B} = \mathbf{N} \mathbf{R}.$$

41

Ll. Cerdà.

Cadenas de Markov de tiempo discreto

Demostración (I).

- $\mathbf{N} = (\mathbf{I} - \mathbf{Q})^{-1}$.

$$E[n_{ij}] = \delta_{ij} + \sum_{k \in T} p_{ik} E[n_{kj}] \Rightarrow \{E[n_{ij}]\} = \mathbf{N} = \mathbf{I} + \mathbf{Q}\mathbf{N} \Rightarrow \mathbf{N} = (\mathbf{I} - \mathbf{Q})^{-1}.$$

(T es el conjunto de estados transitorios)

- $\{\text{Var}[n_{ij}]\} = \mathbf{N} (2 \mathbf{N}_{\text{diag}} - \mathbf{I}) - \mathbf{N}_{\text{sqr}}$.

$$\text{Var}[n_{ij}] = E[n_{ij}^2] - E[n_{ij}]^2 \Rightarrow \{\text{Var}[n_{ij}]\} = \{E[n_{ij}^2]\} - \mathbf{N}_{\text{sqr}}$$

$$E[n_{ij}^2] = \sum_{k \in A} p_{ik} \delta_{ij} + \sum_{k \in T} p_{ik} E[(n_{kj} + \delta_{ij})^2] =$$

$$\sum_{k \in A} p_{ik} \delta_{ij} + \sum_{k \in T} p_{ik} (E[n_{kj}^2] + 2 E[n_{kj}] \delta_{ij} + \delta_{ij}) =$$

$$\delta_{ij} + \sum_{k \in T} (p_{ik} E[n_{kj}^2] + 2 p_{ik} E[n_{kj}] \delta_{ij}) \Rightarrow$$

$$\{E[n_{ij}^2]\} = \mathbf{I} + \mathbf{Q} \{E[n_{ij}^2]\} + 2 (\mathbf{Q} \mathbf{N})_{\text{diag}} = (\mathbf{I} - \mathbf{Q})^{-1} (\mathbf{I} + 2 (\mathbf{Q} \mathbf{N})_{\text{diag}}) =$$

$$\mathbf{N} (\mathbf{I} + 2 (\mathbf{N} - \mathbf{I})_{\text{diag}}) = \mathbf{N} (2 \mathbf{N}_{\text{diag}} - \mathbf{I})$$

(A es el conjunto de estados absorbentes)

42

Ll. Cerdà.

Cadenas de Markov de tiempo discreto

Demostración (II).

- $\{E[t_i]\} = \boldsymbol{\tau} = \mathbf{N} \mathbf{e}$.

$$E[t_i] = \sum_{k \in T} E[n_{ik}] \Rightarrow \{E[t_i]\} = \boldsymbol{\tau} = \mathbf{N} \mathbf{e}.$$

- $\{\text{Var}[t_i]\} = (2 \mathbf{N} - \mathbf{I}) \boldsymbol{\tau} - \boldsymbol{\tau}_{\text{sqr}}$.

$$\text{Var}[t_i] = E[t_i^2] - E[t_i]^2 \Rightarrow \{\text{Var}[t_i]\} = \{E[t_i^2]\} - \boldsymbol{\tau}_{\text{sqr}}$$

$$E[t_i^2] = \sum_{k \in A} p_{ik} + \sum_{k \in T} p_{ik} E[(t_k + 1)^2] =$$

$$\sum_{k \in A} p_{ik} + \sum_{k \in T} p_{ik} (E[t_k^2] + 2 E[t_k] + 1) =$$

$$1 + \sum_{k \in T} (p_{ik} E[t_k^2] + 2 p_{ik} E[t_k]) \Rightarrow$$

$$\{E[t_i^2]\} = \mathbf{e} + \mathbf{Q} \{E[t_i^2]\} + 2 \mathbf{Q} \boldsymbol{\tau} = (\mathbf{I} - \mathbf{Q})^{-1} (\mathbf{e} + 2 \mathbf{Q} \boldsymbol{\tau}) =$$

$$\mathbf{N} (\mathbf{e} + 2 \mathbf{Q} \boldsymbol{\tau}) = \boldsymbol{\tau} + 2 \mathbf{N} \mathbf{Q} \boldsymbol{\tau} = \boldsymbol{\tau} + 2 (\mathbf{N} - \mathbf{I}) \boldsymbol{\tau} = (2 \mathbf{N} - \mathbf{I}) \boldsymbol{\tau}$$

- $\{b_{ij}\} = \mathbf{B} = \mathbf{N} \mathbf{R}$.

$$b_{ij} = p_{ij} + \sum_{k \in T} p_{ik} b_{kj}, j \in A \Rightarrow \{b_{ij}\} = \mathbf{B} = \mathbf{R} + \mathbf{Q} \mathbf{B} = (\mathbf{I} - \mathbf{Q})^{-1} \mathbf{R} = \mathbf{N} \mathbf{R}.$$

43

Ll. Cerdà.

Cadenas de Markov de tiempo discreto

Observación.

Si en vez de partir del estado i partimos con una distribución inicial $\boldsymbol{\pi}_0$, siendo $\boldsymbol{\pi}_0^{(T)}$ las componentes de los estados transitorios y $\boldsymbol{\pi}_0^{(A)}$ las componentes de los estados absorbentes:

- $n_j(\boldsymbol{\pi}_0) = \{\text{número de visitas al estado } j \text{ antes de la absorción}\}$:

$$E[n_j(\boldsymbol{\pi}_0)] = \boldsymbol{\pi}_0^{(T)} \mathbf{N}.$$

$$\{\text{Var}[n_j(\boldsymbol{\pi}_0)]\} = \boldsymbol{\pi}_0^{(T)} \mathbf{N} (2 \mathbf{N}_{\text{diag}} - \mathbf{I}) - (\boldsymbol{\pi}_0^{(T)} \mathbf{N})_{\text{sqr}}.$$

- $t(\boldsymbol{\pi}_0) = \{\text{número de visitas a un estado transitorio antes de la absorción}\}$:

$$\{E[t(\boldsymbol{\pi}_0)]\} = \boldsymbol{\pi}_0^{(T)} \boldsymbol{\tau}. \quad \{\text{Var}_{\boldsymbol{\pi}}[t_i]\} = \boldsymbol{\pi}_0^{(T)} (2 \mathbf{N} - \mathbf{I}) \boldsymbol{\tau} - (\boldsymbol{\pi}_0^{(T)} \boldsymbol{\tau})_{\text{sqr}}.$$

- $b_j(\boldsymbol{\pi}_0) = \{\text{probabilidad de ser absorbido por el estado } j\}$:

$$\{b_j(\boldsymbol{\pi}_0)\} = \boldsymbol{\pi}_0^{(T)} \mathbf{B} + \boldsymbol{\pi}_0^{(A)} = \boldsymbol{\pi}_0^{(T)} (\mathbf{N} \mathbf{R}) + \boldsymbol{\pi}_0^{(A)}.$$

44

Ll. Cerdà.

Cadenas de Markov de tiempo discreto

Extensión de los resultados.

Un conjunto S se llama abierto si desde cualquier estado se puede alcanzar un estado de S^c . Sea \mathbf{Q} la submatriz de \mathbf{P} correspondiente a un conjunto cerrado. Sea \mathbf{R} la submatriz $\mathbf{R} = \{p_{ij}, i \in S, j \in S^c\}$. Supongamos que el proceso parte de $i \in S$:

- Definimos la V.A. $n_{ij} = \{\text{número de visitas al estado } j \text{ antes de salir de } S\}$: $\{E[n_{ij}]\} = \mathbf{N} = (\mathbf{I} - \mathbf{Q})^{-1}$ y $\{\text{Var}[n_{ij}]\} = \mathbf{N} (2 \mathbf{N}_{\text{diag}} - \mathbf{I}) - \mathbf{N}_{\text{sqr}}$.
- Definimos la V.A. $t_i = \{\text{número de visitas a un estado } \in S \text{ antes de salir de } S\}$: $\{E[t_i]\} = \boldsymbol{\tau} = \mathbf{N} \mathbf{e}$. $\{\text{Var}[t_i]\} = (2 \mathbf{N} - \mathbf{I}) \boldsymbol{\tau} - \boldsymbol{\tau}_{\text{sqr}}$.
- Definimos b_{ij} como la probabilidad de ir a $j \in S^c$: $\{b_{ij}\} = \mathbf{B} = \mathbf{N} \mathbf{R}$.