



# Cadenas de Markov Tiempo Discreto

Modelado y Análisis de Redes  
de Telecomunicaciones




URUGUAY



# Motivación - Ejemplo 1



- Sea un enrutador al que arriban paquetes de otros (varios) routers



- Cuando más de un paquete llega a la misma vez a alguno de los puertos de salida, el último en llegar se almacena en un buffer
- Pregunta: ¿cómo dimensionar el buffer?





# Motivación – Ejemplo 2



- Sean un conjunto de usuarios de teléfono




- Cuando todas las líneas están siendo utilizadas, las nuevas llamadas son rechazadas
- Problema: ¿cuántas líneas contratar?



# Motivación – Ejemplo 3



- Sean un conjunto de páginas en una web cualquiera (la internet o un conjunto de ella)



¿Cuál es la importancia de cada página?

- ¿cantidad de páginas que apuntan a ella?
- ¿es lo mismo que el link venga de cualquier página?





# Motivación



- En ambos ejemplos, hacer un análisis determinístico no es una opción
  - Al ser un sistema asíncrono, los paquetes pueden llegar en cualquier momento y tienen un tamaño cualquiera (al menos dentro de cierto rango)
  - Las llamadas telefónicas pueden llegar en cualquier momento y su duración es totalmente arbitraria
  
- Sin embargo...
  - Los paquetes de 1500B son más frecuentes (o con **probabilidad** mayor) que los de 10B
  - Las llamadas largas son menos frecuentes (o con **probabilidad** menor) que las llamadas cortas
- Por lo tanto, un enfoque probabilístico del problema nos dará mejores resultados





# Proceso Estocástico



- Hay veces que lo importante no es un valor único, sino una sucesión temporal (aleatoria)
  - Cuántos paquetes hay en el buffer en cada instante  $t$
  - Cuántas llamadas están siendo cursadas en cada instante  $t$
- Un proceso estocástico le asigna a cada elemento del espacio muestral  $S$  una función en  $t$  (sucesión de variables aleatorias)
  - A cada elemento  $\omega$  de  $S$  se le asocia una función  $X_t(\omega)$ 
    - Para un valor de  $\omega$ ,  $X_t(\omega)$  es una función temporal
    - Para un valor de  $t$ ,  $X_t(\omega)$  es una variable aleatoria
    - Para un valor de  $t$  y  $\omega$ ,  $X_t(\omega)$  es un valor fijo
  - Generalmente la función  $X_t(\omega)$  para un  $\omega$  dado, es llamado realización del proceso o trayectoria





# Proceso Estocástico



- Espacio de estados
  - El conjunto de posibles valores que puede tomar  $X_t(\omega)$  (continuo o discreto)
  
- Espacio de parámetros
  - El conjunto de posibles valores que puede tomar  $t$  (continuo o discreto)
  
- Algunos parámetros de interés:
  - Distribución temporal: la distribución de la v.a.  $X_t$  para un  $t$  dado
  - Distribución estacionaria: la distribución de la v.a.  $X_t$  cuando  $t \rightarrow \infty$  (si existe)





# Proceso Estocástico



- Algunos parámetros de interés (cont...)
  - Estadísticas de orden  $n$  (o distribuciones finito-dimensionales)

$$F_{X_{t_1}, \dots, X_{t_n}}(x_1, \dots, x_n) = P(X_{t_1} \leq x_1, \dots, X_{t_n} \leq x_n)$$

para todos los posibles conjuntos  $\{t_1, \dots, t_n\}$

- Ejemplos:
  - Estadística de orden 1:
    - la distribución estacionaria
    - la esperanza para un  $t$  dado
  - Estadística de orden 2: la covarianza

$$R_{t,s} = E\{(X_t - \bar{X}_t)(X_s - \bar{X}_s)\}$$



# Procesos Estacionarios y Ergódicos

## ■ Proceso estacionario

- El proceso es estacionario cuando las estadísticas de todos los órdenes permanecen incambiadas por una traslación temporal

$$F_{X_{t_1+\tau}, \dots, X_{t_n+\tau}}(x_1, \dots, x_n) = F_{X_{t_1}, \dots, X_{t_n}}(x_1, \dots, x_n) \quad \forall n, \forall t_1, \dots, t_n$$

- Más sencillo de verificar es un proceso estacionario en el sentido amplio (la media y la covarianza son invariantes)

$$\bar{X}_t = \text{constante}, \quad R_{t+\tau, s+\tau} = R_{t, s} \quad \forall \tau$$

## ■ Proceso ergódico

- La estadística de  $X_t(\omega)$  para un  $\omega$  dado es la misma que la de  $X_t$  para un  $t$  dado
- Consecuencia práctica: con una única realización (infinita) del proceso puedo obtener toda la estadística de  $X_t(\omega)$





# Procesos de Markov



- Un proceso estocástico es de Markov si:

$$P(X_{t_{n+1}} \leq x_{n+1} | X_{t_n} = x_n, \dots, X_{t_1} = x_1) = P(X_{t_{n+1}} \leq x_{n+1} | X_{t_n} = x_n) \\ \forall n, \forall t_1 < \dots < t_n$$

- La condición se puede interpretar de varias maneras:
  - El futuro de un proceso de Markov depende únicamente del estado actual (y no de cómo se llegó a él)
  - El estado actual de un proceso de Markov es toda la información que se necesita para caracterizar el futuro
  - Dado el estado actual, el futuro y el pasado son independientes.
- ¿Se pueden analizar mediante procesos de Markov los ejemplos que dimos al comienzo?



# Cadena de Markov -Tiempo Discreto

- Una cadena de Markov en Tiempo Discreto (CMTD) es un proceso de Markov con:
  - Espacio de estados  $E$  discreto (finito o no)
    - Un sub-conjunto de los naturales
  - Espacio de parámetros discreto también ( $t = 0, 1, 2, \dots$ )

■ Es decir  $X = \{X_n : n = 0, 1, 2, \dots\}$

o

$X = X_n; n \in \mathcal{N}$  tal que  $X_n(w) \in \{0, 1, 2, \dots\}$

■ La condición resulta:

$$P(X_{n+1} = j | X_n = i_n, \dots, X_0 = i_0) = P(X_{n+1} = j | X_n = i_n)$$





# CMTD - Definición



- El proceso está caracterizado por las probabilidades de transición del estado  $i$  al  $j$  en el instante  $n$

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

- Estas probabilidades describen la evolución del sistema
- De aquí en adelante asumiremos homogeneidad:  $p_{ij}(n) = p_{ij}$
- Interesa estudiar  $P(X_n = i)$ 
  - Probabilidad de que el sistema se encuentre en el estado  $i$  en tiempo  $n$






# CMTD - Ejemplo



- Una persona navegando la web:
  - El usuario sólo hace click en los links que le aparecen en cada página (por ahora...)
  - En cada página, elige entre los links al azar sin recordar su elección anterior
  - ¿ $X_n = \{\text{página elegida por la persona}\}$  es una cadena de Markov?






# CMTD – Grafo Asociado



- La manera clásica de representar la cadena es mediante el denominado *grafo asociado*





# CMTD - Matriz de Transiciones



- Otra manera de representar la cadena es mediante una matriz, llamada matriz de transiciones:  
$$P = (p_{ij})$$

- Es una matriz estocástica :

$$P_{ij} \geq 0$$

$$\sum_{j \in E} P_{ij} = 1 \quad \forall i \in E$$

$$P = \begin{bmatrix} 0 & 1/2 & 1/2 & 0 & 0 & 0 \\ 0 & 0 & 1/2 & 1/2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1/2 & 1/2 \\ 0 & 0 & 1/2 & 0 & 0 & 1/2 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}$$

Fila  $i$ :  
probabilidades de pasar a los otros estados desde  $i$  (debe sumar 1)

Columna  $j$ :  
probabilidades de llegar a  $j$  por los otros estados





# CMTD – Distribución



- Se llama ley o distribución de  $X$  en el instante  $n$  al vector  $\pi_n$  (quizá infinito)  $\pi_n = (\pi_n(j))_{j \in E}$

$$\pi_n(j) = P(X_n = j), \quad j = 0, 1, \dots$$

- $\pi_n$  es un vector de probabilidad:  $\sum \pi_n(j) = 1$  y  $\pi_n(j) \geq 0$
- En particular se llama ley o distribución inicial a  $\pi_0$
- Conociendo la ley inicial y las probabilidades de transición queda completamente determinada la probabilidad de una trayectoria
  - En el ejemplo del navegador, si arranca en 6 queda ahí por siempre





# CMTD – Distribución



- ¿Cuánto vale  $\pi_{n+1}$ ?

$$\pi_{n+1}(j) = P(X_{n+1} = j) = \sum_i P(X_{n+1} = j | X_n = i) P(X_n = i)$$

$$\Rightarrow \pi_{n+1}(j) = \sum_i \pi_n(i) p_{ij}$$

$$\therefore \pi_{n+1} = \pi_n \mathbf{P}$$

- Por recurrencia vale:

$$\pi_n = \pi_0 \mathbf{P}^n$$

- Probabilidad de pasar de  $i$  a  $j$  en  $n$  pasos

$$p_{ij}^{(n)} = P(X_{m+n} = j | X_m = i) \Rightarrow P^n = \left( p_{ij}^{(n)} \right)_{ij \in E}$$

- Ecuaciones de Chapman-Kolmogorov

$$p_{ij}^{(n+m)} = \sum_{k \in E} p_{ik}^{(m)} p_{kj}^{(n)}$$






# CMTD -Distribución



- Tomemos la siguiente cadena sencilla:



$$\mathbf{P} = \begin{pmatrix} 0.666 & 0.333 \\ 0.2 & 0.8 \end{pmatrix}$$

$$\mathbf{P}^2 = \begin{pmatrix} 0.511 & 0.489 \\ 0.293 & 0.707 \end{pmatrix}$$

$$\mathbf{P}^3 = \begin{pmatrix} 0.439 & 0.561 \\ 0.337 & 0.663 \end{pmatrix}$$

...

$$\mathbf{P}^{10} = \begin{pmatrix} 0.375 & 0.625 \\ 0.375 & 0.625 \end{pmatrix}$$

Después de un cierto tiempo, la distribución de la cadena converge a un único valor sin importar la condición inicial

- ¿Esto es siempre verdad? Si no, ¿cuándo?
  - Veremos que tiene relación con la ergodicidad





# CMTD – Distribución Límite



- Se quiere estudiar el sistema (las leyes de probabilidad del sistema) al cabo de un tiempo largo
- En particular, saber si hay un “régimen asintótico”, es decir si

$$\lim_{n \rightarrow \infty} \pi_n = \mu$$

- $\mu$  es ley límite de  $X$  si existe  $\pi_0$  tal que

$$\mu = \lim_{n \rightarrow \infty} \pi_n = \lim_{n \rightarrow \infty} \pi_0 P^n$$

$$\mu(j) = \lim_{n \rightarrow \infty} \pi_n(j) = \lim_{n \rightarrow \infty} \sum_{i \in E} \pi_0(i) p_{ij}^{(n)}$$

- En principio las leyes límites (si existen) dependen de  $\pi_0$  y del comportamiento asintótico de  $P^n$
- Para  $E$  finito:
  - Si  $P^n$  converge término a término a  $M$ ,  $\mu = \pi_0 M$  es ley límite
  - Si  $\mu = \lim \pi_n$  entonces  $\mu$  es vector de probabilidad: puede no ser cierto en el caso infinito





# CMTD – Distribución Límite



- Ejemplo anterior (cadena sencilla): única distribución límite
- Ejemplo del navegador: si hubiera más de una página sin links (como 6) habría más de una distribución límite:
  - Dependerá de  $\pi_0$  y/o del azar

- Otro ejemplo:

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

- no existe  $\lim \mathbf{P}^n$  :

$$\mathbf{P}^{2n} = \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix} \quad \mathbf{P}^{2n+1} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

- pero sí existe ley límite para  $\pi_0 = (1/2 \ 1/2)$
- Entonces ¿bajo qué condiciones se puede asegurar que exista y que sea única? Y en ese caso ¿cómo se calcula?



# Clasificación de Estados



- Comunicación entre dos estados ( $i \leftrightarrow j$ )
  - Los estados  $i$  y  $j$  se comunican si existen  $m$  y  $n$  positivos tales que  $p_{ij}^{(m)} > 0$  y  $p_{ji}^{(n)} > 0$
  - Es decir, existe un recorrido que va de  $i$  a  $j$  en el grafo asociado y viceversa


- Ejemplo del navegador:

- $3 \leftrightarrow 5$

- La comunicación es una relación de equivalencia

- Reflexiva, simétrica y cumple la transitiva
- Se puede hacer una partición en conjuntos con la relación (cada conjunto se denomina clase de equivalencia)

- Si existe una única clase (todos se comunican entre sí), la cadena se dice **irreducible**






# Periodicidad



- Sea  $d(i) = \text{mcd}\{n: p_{ii}^{(n)} > 0\}$ . El estado  $i$  es **periódico** de período  $d(i)$  si  $d(i) > 1$ ; en caso contrario se dice que es **aperiódico**
- Ejemplos:
  - Se vuelve al estado después de 2, 4, 6, ... pasos, entonces es periódico de período 2
  - En el navegador existen periodicidades
- Si  $p_{ii} > 0$ , entonces  $i$  es aperiódico
- La periodicidad es propia de la clase





# Recurrencia



- Sea  $f_{ij}^n$  (o  $f_n(i)$ ) la probabilidad de, saliendo del estado  $i$ , volver a  $i$  por primera vez en  $n$  pasos
- La probabilidad  $f_{ii}$  de volver al estado  $i$  en tiempo finito es:

$$f(i) = \sum_{n \geq 1} f_n(i)$$

- El estado  $j$  es **recurrente** sii  $f_{jj} = 1$
- El estado  $i$  es **transitorio** sii  $f_{ii} < 1$ 
  - hay probabilidad no nula de nunca volver al estado  $i$
- Los estados transitorios son aperiódicos





# Recurrencia



- Si el espacio de estados es finito, siempre existe al menos un estado recurrente
- Si el espacio de estados es infinito, puede no haber estados recurrentes (e.g.  $p_{i,i+1}=1$ )
- En términos de las transiciones, un estado es recurrente si  $\sum p_{ij}^{(n)} = \infty$
- Si  $j$  es transitorio  $\sum p_{ij}^{(n)} < \infty$  para todo  $i$  y entonces

$$\lim_{n \rightarrow \infty} p_{ij}^{(n)} = 0$$





# Recurrencia Positiva o Nula



- Sea  $M(i)$  el tiempo medio de retorno al estado:

$$M(i) = \sum_{n \geq 1} n f_n(i)$$

- Si  $M(i) = \infty$  el estado se denomina **recurrente nulo**
- Si  $M(i) < \infty$  el estado se denomina **recurrente positivo**
- La recurrencia es propia de la clase (usando la caracterización anterior)
  - Por ejemplo, en una cadena irreducible, si un estado es recurrente positivo, todos los estados lo serán
- Este valor está relacionado con la distribución límite

Se da únicamente una de tres posibilidades:

1. Es transitoria:

$$\lim_{n \rightarrow \infty} p_{ij}^{(n)} = \lim_{n \rightarrow \infty} \pi_n(j) = 0$$

$$\text{Más aún } \sum_{n=1}^{\infty} p_{ij}^{(n)} < \infty \quad \forall i, j \in E$$

2. Es recurrente nula:

$$\lim_{n \rightarrow \infty} p_{ij}^{(n)} = \lim_{n \rightarrow \infty} \pi_n(j) = 0$$

$$\text{Más aún } \sum_{n=1}^{\infty} p_{ij}^{(n)} = \infty \quad \forall i, j \in E$$

3. Es recurrente positiva:

$$\lim_{n \rightarrow \infty} p_{ij}^{(n)} = \lim_{n \rightarrow \infty} \pi_n(j) = \frac{1}{M(j)}$$

- Obs: Si  $E$  es finito, siempre estoy en el caso 3.



# Ergodicidad



- Una cadena es ergódica si existe un único vector de probabilidad  $\pi_\infty$  tal que cualquiera sea la ley inicial  $\pi_0$  se cumple que:

$$\pi_\infty = \lim_{n \rightarrow \infty} \pi_n = \lim_{n \rightarrow \infty} \pi_0 \mathbf{P}^n$$

- Una cadena irreducible es ergódica sii todos sus estados son:
  - Recurrentes positivos
  - Aperiódicos
- Por ser irreducible basta verificar las condiciones en un solo estado



# Ergodicidad



- En una cadena ergódica, la porción de tiempo que la cadena está en el estado  $i$  es  $\pi_\infty(i)$
- Además, tiene la siguiente relación con el tiempo medio de retorno  $M(i)$

$$\pi_\infty(i) = 1/M(i)$$

Intuición: Cada vez que salgo del estado  $i$  vuelvo en  $M(i)$  instantes  $\Rightarrow$  estoy 1 de cada  $M(i)$  instantes en  $i$





# Ergodicidad – Caso $E$ Finito



- Si el espacio de estados  $E$  es finito entonces las siguientes son condiciones necesarias y suficientes

- $X$  es ergódica con distribución límite  $\pi_\infty$  sii

$$\lim_{n \rightarrow \infty} \mathbf{P}^n = \begin{bmatrix} \pi_\infty \\ \vdots \\ \pi_\infty \end{bmatrix}$$

- $X$  es ergódica sii  $\lambda=1$  es valor propio dominante de  $\mathbf{P}$  con multiplicidad 1 (y además el vector propio asociado es  $\pi_\infty$ )
  - Se puede probar tomando en cuenta que por la ecuación anterior,  $\pi_\infty$  debe cumplir

$$\pi_\infty = \lim_{n \rightarrow \infty} \mathbf{P}^{n+1} = \left( \lim_{n \rightarrow \infty} \mathbf{P}^n \right) \mathbf{P} = \pi_\infty \mathbf{P}$$

- Una manera de calcular  $\pi_\infty$  es resolviendo la ecuación anterior junto a la normalización  $\sum \pi_\infty(i)=1$





# Ergodicidad – Caso $E$ infinito



- Si el espacio de estados  $E$  es infinito, pero la cadena es irreducible y aperiódica
  - Si existe una distribución estacionaria de la cadena; i.e.

$$\pi_{\infty}(j) = \sum_{i \in E} p_{ij} \pi_{\infty}(i) \quad (\pi_{\infty} = \pi_{\infty} \mathbf{P})$$

entonces la cadena es recurrente positiva

- Por lo tanto, la distribución es única y la cadena es ergódica
- Consecuencia práctica: cómo probar ergodicidad
  - 1 – Verificar irreducibilidad y aperiodicidad
  - 2 – Tratar de encontrar una distribución estacionaria



# Ecuaciones de Balance



- Si  $\pi_\infty$  es la distribución límite entonces es invariante:

$$\pi_\infty(j) = \sum_{i \in E} p_{ij} \pi_\infty(i) \quad (\pi_\infty = \pi_\infty \mathbf{P})$$

- Además:


$$\sum_{i \in E} p_{ji} = 1$$

- Multiplicando las dos ecuaciones y eliminando el término repetido obtenemos:

$$\pi_\infty(j) \sum_{i \neq j} p_{ji} = \sum_{i \neq j} p_{ij} \pi_\infty(i)$$

# Ecuaciones de Balance

$$\pi_{\infty}(j) \sum_{i \neq j} p_{ji} = \sum_{i \neq j} p_{ij} \pi_{\infty}(i)$$



- Todo lo que sale (pesado por la probabilidad de estar ahí) es igual a lo que entra (también pesado por la probabilidad de estar ahí)

# Ecuaciones de Balance

- Las ecuaciones de balance se pueden extender a conjuntos  $S$  de estados
  - Se toma la ecuación

$$\pi_{\infty}(j) \sum_{i \in E} p_{ji} = \sum_{i \in E} p_{ij} \pi_{\infty}(i)$$

- Se suma en los estados pertenecientes a  $S$


$$\sum_{j \in S} \pi_{\infty}(j) \sum_{i \in E} p_{ji} = \sum_{j \in S} \sum_{i \in E} p_{ij} \pi_{\infty}(i)$$

- Y cancelando los términos repetidos resulta:

$$\sum_{j \in S} \pi_{\infty}(j) \sum_{i \notin S} p_{ji} = \sum_{i \notin S} \pi_{\infty}(i) \sum_{j \in S} p_{ij}$$

# Ecuaciones de Balance

$$\sum_{j \in S} \pi_{\infty}(j) \sum_{i \notin S} p_{ji} = \sum_{i \notin S} \pi_{\infty}(i) \sum_{j \in S} p_{ij}$$



- Es una ecuación sumamente útil para encontrar la distribución estacionaria
  - Escribimos todas las  $\pi_{\infty}(i)$  en función de un  $\pi_{\infty}(j)$  en particular, y luego normalizamos



# Bibliografía



- Esto no fue más que un vistazo a las cadenas de Markov en tiempo discreto. Por más info consultar la web del curso y/o el siguiente material:
- R. Gallager. Notas de su curso en línea “Discrete Stochastic Processes” o su libro “Stochastic Processes: Theory for applications”
- “Teoría de Probabilidad” de Valentín Petrov y Ernesto Mordecki, editorial DIRAC – Facultad de Ciencias, 2008.
- K. L. Chung. Markov chains with stationary transition probabilities. Springer, 1960-67.
- P. Brémaud. Markov chains. Springer, 1999.
- S. Resnick. Adventures in stochastic processes. Birkhäuser, 1994.
- W. Feller. Introducción a la teoría de probabilidades y sus aplicaciones. Vol 1. Limusa, 1986.

