



Introducción a los modelos probabilísticos en grafos

24 y 26/10/2023 - Dep. de Ciencia de la Computación - UCSP, Arequipa, Perú




Parte 1 - Modelos probabilísticos y paseos aleatorios en grafos




Prof. Dr. Pablo M. Rodriguez
Departamento de Estadística - UFPE
<https://www.pablo-rodriguez.org/>

Organización del curso


- ▶ Motivación: modelos probabilísticos.
- ▶ Revisión de probabilidad y variables aleatorias.
- ▶ Breve introducción a las cadenas de Markov a tiempo discreto.
- ▶ Paseos aleatorios: recurrencia y transitoriedad.
- ▶ Procesos de ramificación: supervivencia y extinción.
- ▶ Modelos de percolación.
- ▶ Tópicos especiales.




Motivación!




El paseo aleatorio en \mathbb{Z}




El paseo aleatorio en \mathbb{Z}




El paseo aleatorio en \mathbb{Z}




El paseo aleatorio en \mathbb{Z}




El paseo aleatorio en \mathbb{Z}




El paseo aleatorio en \mathbb{Z}




El paseo aleatorio en \mathbb{Z}




El paseo aleatorio en \mathbb{Z}



El paseo aleatorio en \mathbb{Z}



El paseo aleatorio en \mathbb{Z}




¿Hay alguna chance de que la partícula nunca vuelva al punto de partida?


Proceso de ramificación




Proceso de ramificación




Proceso de ramificación



¿El proceso continuará sin parar, o no?



Probabilidad



Espacio de probabilidad: (Ω, \mathcal{F}, P)

conjunto arbitrario $\left\{ \mathcal{P}(\Omega) \text{ es el conjunto de partes de } \Omega \right\}$

$$P : \mathcal{F} \subset \mathcal{P}(\Omega) \longrightarrow [0, 1]$$

medida de probabilidad

$$\left\{ \begin{array}{l} P(A) > 0 \\ P(\Omega) = 1 \\ P\left(\bigcup_{n=1}^{\infty} A_n\right) = \sum_{n=1}^{\infty} P(A_n) \end{array} \right\}$$

(para $A_i \cap A_j = \emptyset$ se $i \neq j$)

$$\left\{ \begin{array}{l} \Omega \in \mathcal{F} \\ A \in \mathcal{F} \implies A^c \in \mathcal{F} \\ A_n \in \mathcal{F}, n \geq 1 \implies \bigcup_{n=1}^{\infty} A_n \in \mathcal{F} \end{array} \right\}$$

σ -álgebra de subconjuntos de Ω

Propiedades

A seguir (Ω, \mathcal{F}, P) es espacio de probabilidad y $A, A_i \in \mathcal{F}$, $i \in \mathbb{N}$.

1. $P(\emptyset) = 0$.

► *Prueba:* Note que $P(\emptyset) = P(\emptyset \cup \emptyset) \stackrel{\text{A3}}{=} 2P(\emptyset)$.

2. $P(A^c) = 1 - P(A)$.

► *Prueba:* $1 \stackrel{\text{A2}}{=} P(\Omega) = P(A \cup A^c) \stackrel{\text{A3}}{=} P(A) + P(A^c)$.

3. Se $A_1 \subset A_2$ entonces $P(A_1) \leq P(A_2)$.

► *Prueba:* Como $A_1 \subset A_2$ entonces $A_2 = A_1 \cup (A_2 \cap A_1^c)$. Luego,

$$P(A_2) = P(A_1 \cup (A_2 \cap A_1^c)) \stackrel{\text{A3}}{=} P(A_1) + \underbrace{P(A_2 \cap A_1^c)}_{\geq 0 \text{ por A1}} \geq P(A_1).$$

Propiedades

4. $P(A_1 \cup A_2) = P(A_1) + P(A_2) - P(A_1 \cap A_2)$.

► *Prueba:* Resulta de observar que

$$P(A_1) \stackrel{\text{A3}}{=} P(A_1 \cap A_2) + P(A_1 \cap A_2^c),$$

$$P(A_2) \stackrel{\text{A3}}{=} P(A_2 \cap A_1) + P(A_2 \cap A_1^c), e$$

$$P(A_1 \cup A_2) \stackrel{\text{A3}}{=} P(A_1 \cap A_2^c) + P(A_1 \cap A_2) + P(A_1^c \cap A_2).$$

Fórmula de inclusión-exclusión:

$$\begin{aligned} P\left(\bigcup_{i=1}^n A_i\right) &= \sum_{i=1}^n P(A_i) - \sum_{1 \leq i < j \leq n} P(A_i \cap A_j) \\ &+ \sum_{1 \leq i < j < k \leq n} P(A_i \cap A_j \cap A_k) - \dots \end{aligned}$$

$$(-1)^{n+1} P\left(\bigcap_{i=1}^n A_i\right). \quad \textit{Prueba:} \text{ por inducción!}$$

Propiedades

$$5. P\left(\bigcup_{i=1}^{\infty} A_i\right) \leq \sum_{i=1}^{\infty} P(A_i).$$

► *Prueba:* Vamos a reescribir $\bigcup_{i=1}^{\infty} A_i$ como una unión de eventos mutuamente exclusivos. Sea $B_1 := A_1$ y para cada $i \geq 2$ defina:

$$B_i := A_i \cap \left\{ \bigcup_{k=1}^{i-1} A_k \right\}^c.$$

Así, $B_i \cap B_j = \emptyset$ para $i \neq j$ y $\bigcup_{i=1}^{\infty} A_i = \bigcup_{i=1}^{\infty} B_i$. entonces,

$$P\left(\bigcup_{i=1}^{\infty} A_i\right) = P\left(\bigcup_{i=1}^{\infty} B_i\right) \stackrel{A3}{=} \sum_{i=1}^{\infty} P(B_i) \leq \sum_{i=1}^{\infty} P(A_i).$$

por construcción de los B_i !

verifique!

Sucesiones monótonas de eventos

Decimos que una sucesión de eventos $\{A_n\}_{n \in \mathbb{N}}$ es:

(i) no-decreciente, denotamos por $A_n \nearrow$, si

$$A_1 \subset A_2 \subset \cdots \subset A_n \subset A_{n+1} \subset \cdots$$

En este caso,

$$\lim_{n \rightarrow \infty} A_n = \bigcup_{n=1}^{\infty} A_n \quad \text{o sea} \quad A_n \nearrow \bigcup_{n=1}^{\infty} A_n.$$

(ii) No-creciente, denotamos por $A_n \searrow$, se

$$A_1 \supset A_2 \supset \cdots \supset A_n \supset A_{n+1} \supset \cdots$$

En este caso,

$$\lim_{n \rightarrow \infty} A_n = \bigcap_{n=1}^{\infty} A_n \quad \text{o sea} \quad A_n \searrow \bigcap_{n=1}^{\infty} A_n.$$

Continuidad de la probabilidad

Teorema 2.1

Sea $\{A_n\}_{n \in \mathbb{N}}$ una sucesión de eventos aleatorios.

(i) Si $A_n \nearrow$ entonces

$$P\left(\bigcup_{n=1}^{\infty} A_n\right) = \lim_{n \rightarrow \infty} P(A_n).$$

(i) Si $A_n \searrow$ entonces

$$P\left(\bigcap_{n=1}^{\infty} A_n\right) = \lim_{n \rightarrow \infty} P(A_n).$$

Prueba del Teorema 2.1 (i). Suponga que $A_n \nearrow$, sea $B_1 := A_1$ y

$$B_n := A_n \cap A_{n-1}^c \text{ para todo } n \geq 2.$$

De esta forma $B_i \cap B_j = \emptyset$ si $i \neq j$ y $\bigcup_{i=1}^{\infty} A_i = \bigcup_{i=1}^{\infty} B_i$. Luego,

$$P\left(\bigcup_{i=1}^{\infty} A_i\right) = P\left(\bigcup_{i=1}^{\infty} B_i\right)$$

$$\stackrel{\text{A3}}{=} \sum_{i=1}^{\infty} P(B_i)$$

$$= \lim_{n \rightarrow \infty} \sum_{i=1}^n P(B_i)$$

$$= \lim_{n \rightarrow \infty} \left\{ P(A_1) + \sum_{i=2}^n (P(A_i) - P(A_{i-1})) \right\}$$

$$= \lim_{n \rightarrow \infty} P(A_n).$$

Observación

Para (ii) note que $A_n \searrow$ implica que $A_n^c \nearrow$. Después use (i).

Probabilidad condicional

Recuerde!

A seguir se considera un espacio de probabilidad (Ω, \mathcal{F}, P) .

Sea $A \in \mathcal{F}$ y $B \in \mathcal{F}$ tal que $P(B) > 0$.

A probabilidad condicional de A dado B es definida por

$$P(A|B) = \frac{P(A \cap B)}{P(B)}.$$

Observación

Sea $B \in \mathcal{F}$ tal que $P(B) > 0$. Si $P_B : \mathcal{F} \rightarrow [0, 1]$ es definida por

$$P_B(A) := P(A|B),$$

para todo $A \in \mathcal{F}$ entonces P_B es una probabilidad en \mathcal{F} . De hecho:

- ▶ Verifique **A1** y **A2** para P_B .
- ▶ **A3** vale pues si $A_n \in \mathcal{F}$, para $n \in \mathbb{N}$, y $A_i \cap A_j = \emptyset$ si $i \neq j$, entonces

$$P_B \left(\bigcup_{n=1}^{\infty} A_n \right) = \frac{P \left(\left\{ \bigcup_{n=1}^{\infty} A_n \right\} \cap B \right)}{P(B)} = \frac{P \left(\bigcup_{n=1}^{\infty} \{A_n \cap B\} \right)}{P(B)}.$$

Luego

$$P_B \left(\bigcup_{n=1}^{\infty} A_n \right) = \sum_{n=1}^{\infty} \frac{P(A_n \cap B)}{P(B)} = \sum_{n=1}^{\infty} P_B(A_n).$$

Teorema de la multiplicación

Si $A_i \in \mathcal{F}$, para todo $i \in \{1, \dots, n\}$. entonces,

$$P\left(\bigcap_{i=1}^n A_i\right) = P(A_1)P(A_2|A_1)P(A_3|A_1 \cap A_2) \cdots P\left(A_n \mid \bigcap_{i=1}^{n-1} A_i\right).$$

Observación

Para $A, B \in \mathcal{F}$ el teorema dice que $P(A \cap B) = P(A|B)P(B) = P(B|A)P(A)$.

Prueba del teorema: Por inducción en n . Verificado para $n = 2$, note que

$$P\left(\bigcap_{i=1}^n A_i\right) = P\left(A_n \cap \left\{\bigcap_{i=1}^{n-1} A_i\right\}\right) = P\left(\bigcap_{i=1}^{n-1} A_i\right) P\left(A_n \mid \bigcap_{i=1}^{n-1} A_i\right).$$

Teorema da probabilidad total

Si $A_i \in \mathcal{F}$, $i \in \mathbb{N}$, y la sucesión forma una partición de Ω , entonces


$$P(A) = \sum_{i=1}^{\infty} P(A|A_i)P(A_i),$$

para todo $A \in \mathcal{F}$.


Observación

Para una partición formada por n eventos aleatorios, el resultado se obtiene haciendo $A_i = \emptyset$ para todo $i > n$.


Prueba del Teorema de la probabilidad total:




Prueba del Teorema de la probabilidad total:




Prueba del Teorema de la probabilidad total:




Prueba del Teorema de la probabilidad total:



Prueba del Teorema de la probabilidad total:



Prueba del Teorema de la probabilidad total:



Como $\{A_i\}_{i \in \mathbb{N}}$ es una partición de Ω , entonces $A = \bigcup_{i=1}^{\infty} \{A \cap A_i\}$ y la unión es sobre eventos mutuamente exclusivos. Luego,

$$P(A) = P\left(\bigcup_{i=1}^{\infty} \{A \cap A_i\}\right) = \sum_{i=1}^{\infty} P(A \cap A_i) = \sum_{i=1}^{\infty} P(A|A_i)P(A_i).$$

Teorema de Bayes

Si $A_i \in \mathcal{F}$, $i \in \mathbb{N}$, y la sucesión forma una partición de Ω , entonces para todo $A \in \mathcal{F}$ vale que

$$P(A_i|A) = \frac{P(A|A_i)P(A_i)}{\sum_{i=1}^{\infty} P(A|A_i)P(A_i)},$$

para todo $i \in \mathbb{N}$.

Prueba. Note que:

$$P(A_i|A) = \frac{P(A \cap A_i)}{P(A)}$$

aplique T. de la multiplicación!

aplique T. de la probabilidad total!

Independencia

Sea $A \in \mathcal{F}$ y $B \in \mathcal{F}$.

Los eventos aleatorios A y B son independientes si:

$$P(A \cap B) = P(A)P(B).$$

Observación

Si $A \in \mathcal{F}$ y $P(A) \in \{0, 1\}$ entonces A es independiente de B para todo $B \in \mathcal{F}$.

De forma general

- ▶ Los eventos aleatorios A_1, \dots, A_n son independientes si:

$$P(A_{i_1} \cap A_{i_2} \cap \dots \cap A_{i_k}) = P(A_{i_1})P(A_{i_2}) \cdots P(A_{i_k}),$$

para todo $k \in \{2, \dots, n\}$ y $1 \leq i_1 < i_2 < \dots < i_k \leq n$.

- ▶ $(A_n)_{n \in \mathbb{N}}$ es una sucesión de eventos independientes si:

A_1, \dots, A_n son independientes para todo $n \geq 2$.

Observación

No confundir con sucesiones de eventos independientes 2 a 2, para las cuales vale apenas que $P(A_i \cap A_j) = P(A_i)P(A_j)$ si $i \neq j$.

Variables aleatorias


Una variable aleatoria X es una función $X : \Omega \rightarrow \mathbb{R}$ tal que

$$\{X \leq x\} \in \mathcal{F}, \text{ para todo } x \in \mathbb{R}$$

Observación!

Usamos la siguiente notación: $\{X \leq a\} = \{\omega \in \Omega : X(\omega) \leq a\}$.

El paseo aleatorio en \mathbb{Z}




El paseo aleatorio es la sucesión

$$X_0, X_1, X_2, \dots, X_n, \dots$$

denotada $(X_n)_{n \geq 0}$, con $X_n =$ posición de la partícula después del n -ésimo salto.

Proceso de ramificación



El proceso de ramificación es la sucesión $(Z_n)_{n \geq 0}$, con $Z_n = \#$ de partículas en la n -ésima generación.

2da generación

Tipos de variables aleatorias

Una variable aleatoria X es:

- ▶ **discreta** si $X(\omega) \in \mathcal{S} \subset \mathbb{R}$ para todo $\omega \in \Omega$, para algún conjunto \mathcal{S} finito o numerable. En este caso


$$p(i) := P(X = i), i \in \mathcal{S},$$

es la función de probabilidad de X .


- ▶ **(absolutamente) continua** si existe $f(x) \geq 0$ tal que

$$F(x) = P(X \leq x) = \int_{-\infty}^x f(t) dt, \quad \text{para todo } x \in \mathbb{R}.$$

En este caso f es la función densidad de probabilidad de X .



Modelos básicos



Distribución Bernoulli

X tiene *distribución de Bernoulli* con parámetro $p \in (0, 1)$ si:

$$p(1) = p = 1 - p(0).$$

Notación: $X \sim \text{Bernoulli}(p)$.

Observación!

Un experimento con apenas dos resultados posibles, suceso o fracaso, se llama ensayo de Bernoulli.

Ejemplo 2.1

Sea X la variable aleatoria indicadora del evento A con $P(A) = p$:

$$X = \begin{cases} 1, & \text{si } A \text{ ocurre,} \\ 0, & \text{si } A \text{ no ocurre.} \end{cases}$$

entonces $X \sim \text{Bernoulli}(p)$.

Distribución Binomial

X tiene *distribución Binomial* con parámetros $n \in \mathbb{N}$ y $p \in (0, 1)$ si:

$$p(i) = \binom{n}{i} p^i (1-p)^{n-i}, \text{ para } i \in \{0, 1, \dots, n\}.$$

Notación: $X \sim B(n, p)$.

Observación!

X es interpretada como el número de sucesos obtenidos cuando n ensayos independientes de Bernoulli, con probabilidad de suceso p , son realizados.

Observación!

Dos variables aleatorias X_1 e X_2 son independientes si para todo $B_1 \in \mathcal{B}$ y $B_2 \in \mathcal{B}$, los eventos aleatorios $\{X_1 \in B_1\}$ y $\{X_2 \in B_2\}$ son independientes.

Note que, para $i \in \{0, 1, \dots, n\}$, por ejemplo la configuración

$$\sigma : \begin{array}{cccccccccccc} \checkmark & \times & \checkmark & \times & \checkmark & \dots & \times & \checkmark & \times & \checkmark \\ \hline 1 & 2 & 3 & 4 & 5 & & n-3 & n-2 & n-1 & n \end{array} \quad \begin{array}{l} i \text{ sucesos } (\checkmark) \\ n - i \text{ fracasos } (\times) \end{array}$$

es favorable para la ocurrencia de $\{X = i\}$. Como tenemos $\binom{n}{i}$ formas diferentes de obtener una configuración de estas e como

$$P(\sigma) = p^i (1 - p)^{n-i}, \quad \text{por independencia!}$$

concluimos que

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

Si $X \sim B(n, p)$ podemos escribir

$$X = \sum_{i=1}^n X_i,$$

en que X_1, \dots, X_n son i.i.d. con $X_1 \sim \text{Bernoulli}(p)$.

Observación!

La notación i.i.d. es usada para decir que las variables son independientes e idénticamente distribuidas.

Distribución de Poisson

X tiene *distribución de Poisson* con parámetro $\lambda \in (0, \infty)$ si:

$$p(i) = \frac{e^{-\lambda} \lambda^i}{i!}, \text{ para } i \in \{0, 1, \dots\}.$$

Notación: $X \sim \text{Poisson}(\lambda)$.

Observación!

X puede ser interpretada como una aproximación para el número de sucesos obtenidos cuando n ensayos independientes de Bernoulli, con probabilidad de suceso p , son realizados, asumiendo valores grandes de n e pequeños de p .

Aproximación de la Binomial para la Poisson

Sea $X \sim B(n, p)$, n grande, y sea $Y \sim \text{Poisson}(\lambda)$ con $\lambda = np$.

$$P(X = i) = \binom{n}{i} p^i (1-p)^{n-i} = \frac{n!}{(n-i)! i!} \left(\frac{\lambda}{n}\right)^i \left(1 - \frac{\lambda}{n}\right)^{n-i}$$

que podemos reescribir:

$$P(X = i) = \left\{ \frac{n(n-1)(n-2) \cdots (n - \{i-1\})}{n^i} \right\} \left(\frac{\lambda^i}{i!}\right) \frac{\left(1 - \frac{\lambda}{n}\right)^n}{\left(1 - \frac{\lambda}{n}\right)^i}.$$

Aproximación de la Binomial para la Poisson

Como

$$1 - \frac{j}{n} \approx 1, \quad \left(1 - \frac{\lambda}{n}\right)^n \approx e^{-\lambda}, \quad \left(1 - \frac{\lambda}{n}\right)^i \approx 1,$$

concluimos que

$$P(X = i) \approx \frac{e^{-\lambda} \lambda^i}{i!} = P(Y = i).$$

Distribución Geométrica

X tiene *distribución geométrica* con parámetro $p \in (0, 1)$ si:

$$p(i) = p(1 - p)^{i-1}, \text{ para } i \in \mathbb{N}.$$

Notación: $X \sim \text{Geom}(p)$.

Observación!

X es interpretada como el número de ensayos independientes de Bernoulli, con probabilidad de suceso p , que deben ser realizados hasta obtener el primer suceso.

Pensando en la interpretación de X , note que si

$$X_i = \begin{cases} 1, & \text{si el } i\text{-ésimo ensayo resulta en suceso,} \\ 0, & \text{caso contrario,} \end{cases}$$

para todo $i \in \mathbb{N}$, entonces:

$$P(X = i) = P\left(\left\{\bigcap_{k=1}^{i-1} \{X_k = 0\}\right\} \cap \{X_i = 1\}\right) \stackrel{\text{por independencia!}}{=} (1-p)^{i-1}p.$$

Problema de la colección de cupones

Asuma que haya n tipos de cupones y que cada vez que un cupón es conseguido, este tiene la misma probabilidad de ser de cualquier tipo. Los cupones se coleccionan de a uno por vez. Si X es el número de cupones que precisan ser coleccionados hasta obtener una colección completa de al menos un cupón de cada tipo, entonces:

$$X = \sum_{i=1}^n T_i,$$

donde T_1, T_2, \dots, T_n son variables aleatorias independientes con

$$T_i \sim \text{Geom} \left(\frac{n - i + 1}{n} \right),$$

para $i \in \{1, \dots, n\}$.

Distribución Exponencial

X tiene *distribución exponencial* con parámetro $\lambda \in (0, \infty)$ si:

$$f(x) = \begin{cases} \lambda e^{-\lambda x}, & \text{si } x > 0, \\ 0, & \text{caso contrario.} \end{cases}$$

Notación: $X \sim \text{Exp}(\lambda)$.

Observación!

Usualmente usada para describir el tiempo hasta la ocurrencia de un evento de interés.

Si $X \sim \text{Exp}(\lambda)$ entonces $F(x) = 1 - e^{-\lambda x}$.

Perdida de memoria

Proposición 2.1

Si $X \sim \text{Exp}(\lambda)$ entonces

$$P(X > t + s | X > s) = P(X > t), \quad \text{para } s, t \in (0, \infty).$$

Prueba. Note que

$$P(X > t + s | X > s) = \frac{P(\{X > t + s\} \cap \{X > s\})}{P(X > s)}$$

pero $\{X > t + s\} \subset \{X > s\}$, entonces

$$P(X > t + s | X > s) = \frac{P(X > t + s)}{P(X > s)} = \frac{e^{-\lambda(t+s)}}{e^{-\lambda s}} = e^{-\lambda t} = P(X > t).$$

Mínimo de exponenciales independientes

Proposición 2.2

Si X_1, \dots, X_n son independientes con $X_i \sim \text{Exp}(\lambda_i)$, $i \in \{1, \dots, n\}$, entonces


$$\min\{X_1, \dots, X_n\} \sim \text{Exp}\left(\sum_{i=1}^n \lambda_i\right)$$

Prueba. Note que

$$P(\min\{X_1, \dots, X_n\} > a) = \prod_{i=1}^n P(X_i > a) = e^{-(\sum_{i=1}^n \lambda_i)a}.$$

Proceso de Poisson de parámetro λ

El proceso:



Observación!

Si T_1, T_2, \dots, T_n son i.i.d. con $T_1 \sim \text{Exp}(\lambda)$ entonces $\sum_{i=1}^n T_i \sim \text{Gama}(n, \lambda)$.

Esperanza de una v.a. discreta

La esperanza de una v.a. discreta X , con valores en \mathcal{S} y función de probabilidad $p(x)$, es dada por

$$E(X) := \sum_{x \in \mathcal{S}} x p(x) = \sum_{x \in \mathcal{S}: x < 0} x p(x) + \sum_{x \in \mathcal{S}: x \geq 0} x p(x),$$

... desde que al menos una de las sumas sea finita. Caso contrario, decimos que la esperanza de X no existe.

Observación!


Note que ambas sumas son finitas si $\sum_{x \in \mathcal{S}} |x| p(x) < \infty$.

► Si $X \sim \text{Poisson}(\lambda)$ entonces

$$E(X) = \sum_{n=0}^{\infty} n \left\{ e^{-\lambda} \frac{\lambda^n}{n!} \right\} = \lambda e^{-\lambda} \sum_{n=1}^{\infty} \frac{\lambda^{n-1}}{(n-1)!} = \lambda e^{-\lambda} \sum_{k=0}^{\infty} \frac{\lambda^k}{k!} = \lambda.$$

Observación!

Considere un Proceso de Poisson de parámetro λ :



Cuál es el papel de λ ?

Recuerde que $N(a, b) \sim \text{Poisson}(\lambda(b - a))$.

Ejemplo 2.2

Sea X una variable aleatoria discreta con valores en $\mathbb{Z} \setminus \{0\}$ tal que

$$p(i) = \frac{C}{i^2}, \quad i \in \mathbb{Z} \setminus \{0\}, \quad \text{con } C = \left\{ \frac{1}{2} \sum_{i=1}^{\infty} \frac{1}{i^2} \right\}^{-1}.$$

entonces $E(X)$ no existe pues:

$$- \sum_{i \in \mathbb{Z}_-} i p(i) = \sum_{i \in \mathbb{Z}_+} i p(i) = C \sum_{i=1}^{\infty} \frac{1}{i} = \infty$$

Observación!

A seguir, consideramos variables aleatorias tales que su esperanza existe.

1. Si $X = c$ entonces $E(X) = c$.
2. Si $X \leq Y$ entonces $E(X) \leq E(Y)$.

3. Linealidad.

$$E(cX + Y) = cE(X) + E(Y),$$

si c es una constante, cuando los términos a la derecha tienen sentido.

En general, se X_1, \dots, X_n son v.a. y c_1, \dots, c_n son constantes, entonces:

$$E\left(\sum_{i=1}^n c_i X_i\right) = \sum_{i=1}^n c_i E(X_i).$$

El paseo aleatorio en \mathbb{Z}

Ejemplo 2.3

Considere el paseo aleatorio en \mathbb{Z} . Definimos:

$Y_n =$ posición de la partícula después del n –ésimo salto,
para $n \in \{0, 1, 2, \dots\}$, y suponemos que $Y_0 = 0$. Podemos escribir

$$Y_n = \sum_{i=1}^n X_i,$$

donde X_1, X_2, \dots son v.a. i.i.d. tales que


$$P(X_i = 1) = p = 1 - P(X_i = -1).$$

... continuación del Ejemplo 2.3. Note que


$$E(Y_n) = E(X_1 + X_2 + \cdots + X_n) = n E(X_1) = n(2p - 1).$$

Luego,

$$\lim_{n \rightarrow \infty} E(Y_n) = \begin{cases} +\infty, & \text{si } p > 1/2; \\ 0, & \text{si } p = 1/2; \\ -\infty, & \text{si } p < 1/2. \end{cases}$$



Cadenas de Markov



Proceso estocástico

Un proceso estocástico a tiempo discreto é una sucesión de variables aleatorias:

$$X_1, X_2, \dots, X_n, \dots$$

o

$$(X_n)_{n \geq 0}, n \in \mathbb{N},$$

definidas en el mismo espacio de probabilidad y tomando valores en algún conjunto numerable S .

Observación

*El conjunto S se llama **espacio de estados** del proceso y cada uno de sus elementos se llama **estado**.*

Suponemos que para todo $i, j \in \mathcal{S}$ y para todo $n \geq 0$ las probabilidades

$$p(i, j) := P(X_{n+1} = j | X_n = i),$$

llamadas **probabilidades de transición** no dependen de n . En este caso decimos que la cadena de Markov es homogénea.

Note que $p(i, j) \in [0, 1]$ y que

$$\sum_{j \in \mathcal{S}} p(i, j) = 1.$$

Una cadena de Markov puede ser completamente determinada por las probabilidades de transición y por la distribución de su estado inicial:

$$\text{si } P(X_0 = i) = \alpha_i, \text{ para todo } i \in \mathcal{S}, \text{ con } \alpha_i \in [0, 1] \text{ y } \sum_{i \in \mathcal{S}} \alpha_i = 1,$$

entonces

$$P(X_0 = i_0, X_1 = i_1, \dots, X_n = i_n) = \alpha_{i_0} p(i_0, i_1) p(i_1, i_2) \dots p(i_{n-1}, i_n).$$

Ejemplo: el proceso de ramificación


Considere una variable aleatoria discreta X con función de probabilidad

$$P(X = i) = p_i,$$

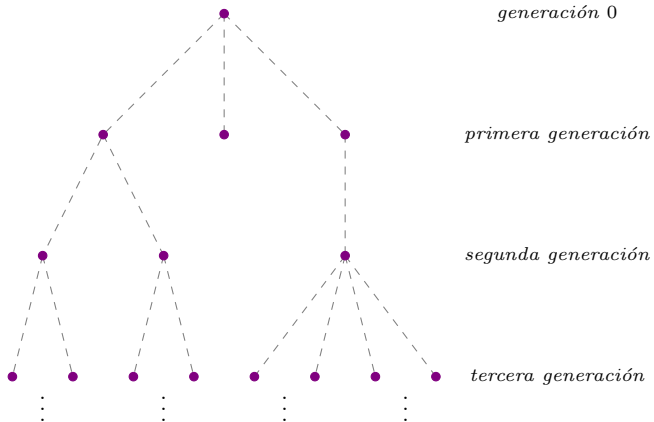
para $i \in \mathbb{N} \cup \{0\}$.

A seguir, todas las variables son copias independientes de X .

Proceso de ramificación: idea



Proceso de ramificación: generaciones



Proceso de ramificación: la cadena de Markov

Considere, para cada $n \geq 0$, la variable aleatoria:

$Z_n = \#$ de partículas de la n -ésima generación,


y note que para todo $n \geq 1$ tenemos:

$$Z_{n+1} = \sum_{i=1}^{Z_n} X_i,$$

donde X_1, X_2, \dots son i.i.d. a la v.a. X . La sucesión $(Z_n)_{n \geq 0}$ se llama de proceso de ramificación o proceso de Galton-Watson y es una cadena de Markov con espacio de estados $\mathbb{N} \cup \{0\}$ y probabilidades de transición:

$$p(i, j) = P(Z_{n+1} = j | Z_n = i) = \begin{cases} P\left(\sum_{r=1}^i X_r = j\right), & \text{para } i \geq 1 \text{ y } j \geq 0, \\ 0, & \text{para } i = 0 \text{ y } j > 0, \\ 1, & \text{para } i = 0 \text{ y } j = 0. \end{cases}$$

Ejemplo: paseo aleatorio en \mathbb{Z}



El paseo aleatorio en \mathbb{Z}

Consideramos la sucesión de v.a. i.i.d. X_1, X_2, X_3, \dots tal que

$$P(X_1 = 1) = p = 1 - P(X_1 = -1).$$

Si Y_n denota la posición de la partícula en el n -ésimo instante de tiempo, entonces

$$Y_n = Y_{n-1} + X_n, \quad \text{para todo } n \in \{1, 2, \dots\}.$$

La sucesión $(Y_n)_{n \geq 0}$ se llama paseo aleatorio en \mathbb{Z} y es una cadena de Markov con espacio de estados \mathbb{Z} y probabilidades de transición:

$$p(i, j) = P(Y_{n+1} = j | Y_n = i) = \begin{cases} p, & \text{para } j = i + 1, \\ 1 - p, & \text{para } j = i - 1, \\ 0, & \text{para } j \neq i \pm 1. \end{cases}$$

Primeras consideraciones: la población





Figura: Grafo completo K_{15} .

Primeras consideraciones: tipos de individuos



Propagadores
(Spreaders)



Neutros
(Stiflers)



Ignorantes
(Ignorants)

Modelo de Daley-Kendall a tiempo discreto

Para cada $n \geq 0$, consideramos las variables aleatorias:

- ▶ X_n = número de ignorantes en el tiempo n ,
- ▶ Y_n = número propagadores en el tiempo n ,
- ▶ Z_n = número de neutros en el tiempo n .

Suponemos que $X_0 = N - 1$, $Y_0 = 1$, $Z_0 = 0$ y que

$$X_n + Y_n + Z_n = N$$

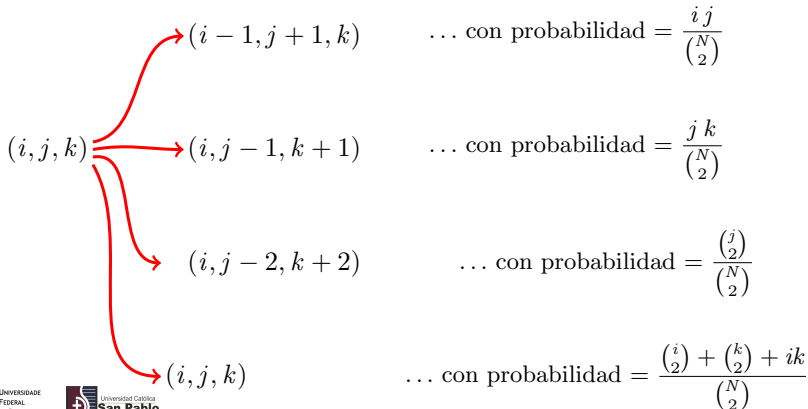
para todo $n \geq 0$, lo que representa que la población es cerrada.

Modelo de Daley-Kendall a tiempo discreto

El modelo de Daley-Kendall a tiempo discreto es la CMTD $(V_n)_{n \geq 0}$,

$$V_n := (X_n, Y_n, Z_n),$$

con espacio de estados $\mathcal{S} = \{0, 1, \dots, N\}^3$ y transiciones dadas por:



En otras palabras:

$$P((X_{n+1}, Y_{n+1}, Z_{n+1}) = (i-1, j+1, k) | (X_n, Y_n, Z_n) = (i, j, k)) = \frac{i j}{\binom{N}{2}};$$

$$P((X_{n+1}, Y_{n+1}, Z_{n+1}) = (i, j-1, k+1) | (X_n, Y_n, Z_n) = (i, j, k)) = \frac{j k}{\binom{N}{2}};$$

$$P((X_{n+1}, Y_{n+1}, Z_{n+1}) = (i, j-2, k+2) | (X_n, Y_n, Z_n) = (i, j, k)) = \frac{\binom{j}{2}}{\binom{N}{2}}.$$


$$P((X_{n+1}, Y_{n+1}, Z_{n+1}) = (i, j, k) | (X_n, Y_n, Z_n) = (i, j, k)) = \frac{\binom{i}{2} + \binom{k}{2} + ik}{\binom{N}{2}}.$$

Observación


Para crear la versión discreta a partir de la continua note que si X_1, \dots, X_n son i.i.d. con distribución $\text{Exp}(\lambda)$ entonces $P(X_i < \min_{j \neq i} \{X_j\}) = 1/n$.




Ejemplo: paseo aleatorio en un grafo finito




Ejemplo: paseo aleatorio en un grafo finito




Ejemplo: paseo aleatorio en un grafo finito



Ejemplo: paseo aleatorio en un grafo finito



Ejemplo: paseo aleatorio en un grafo finito



El paseo aleatorio en un grafo finito dirigido

Si Y_n denota la posición de la partícula en el n -ésimo paso de tiempo, ... entonces la sucesión $(Y_n)_{n \geq 0}$ se llama paseo aleatorio en el grafo considerado y es una cadena de Markov con espacio de estados $\{0, 1, 2, 3, 4\}$ y probabilidades de transición:


$$p(i, j) = P(Y_{n+1} = j | Y_n = i) = \begin{cases} p_i, & \text{para } j = i + 1 \text{ y } i \in \{0, 1, 2, 3\}, \\ 1 - p_i, & \text{para } j = 0 \text{ y } i \in \{0, 1, 2, 3\}, \\ 1, & \text{para } j = 0 \text{ y } i = 4, \\ 0, & \text{en otro caso.} \end{cases}$$

Representación gráfica de una cadena de Markov

Considere la CMTD $(X_n)_{n \geq 0}$ con espacio de estados $\{0, 1\}$ y matriz de transición dada por

$$P = \begin{bmatrix} 1/2 & 1/2 \\ 1/5 & 4/5 \end{bmatrix}.$$

Podemos representar:




Representación gráfica de una cadena de Markov

Considere la CMTD $(X_n)_{n \geq 0}$ con espacio de estados $\{0, 1\}$ y matriz de transición dada por

$$P = \begin{bmatrix} 1/2 & 1/2 \\ 1/5 & 4/5 \end{bmatrix}.$$

Podemos representar:




$$X_0 = 0$$

Representación gráfica de una cadena de Markov

Considere la CMTD $(X_n)_{n \geq 0}$ con espacio de estados $\{0, 1\}$ y matriz de transición dada por

$$P = \begin{bmatrix} 1/2 & 1/2 \\ 1/5 & 4/5 \end{bmatrix}.$$

Podemos representar:




$$X_0 = 0$$

Representación gráfica de una cadena de Markov

Considere la CMTD $(X_n)_{n \geq 0}$ con espacio de estados $\{0, 1\}$ y matriz de transición dada por

$$P = \begin{bmatrix} 1/2 & 1/2 \\ 1/5 & 4/5 \end{bmatrix}.$$

Podemos representar:




$$X_1 = 1$$

Representación gráfica de una cadena de Markov

Considere la CMTD $(X_n)_{n \geq 0}$ con espacio de estados $\{0, 1\}$ y matriz de transición dada por

$$P = \begin{bmatrix} 1/2 & 1/2 \\ 1/5 & 4/5 \end{bmatrix}.$$

Podemos representar:




$$X_1 = 1$$

Representación gráfica de una cadena de Markov

Considere la CMTD $(X_n)_{n \geq 0}$ con espacio de estados $\{0, 1\}$ y matriz de transición dada por

$$P = \begin{bmatrix} 1/2 & 1/2 \\ 1/5 & 4/5 \end{bmatrix}.$$

Podemos representar:




$$X_2 = 1$$

Representación gráfica de una cadena de Markov

Considere la CMTD $(X_n)_{n \geq 0}$ con espacio de estados $\{0, 1\}$ y matriz de transición dada por

$$P = \begin{bmatrix} 1/2 & 1/2 \\ 1/5 & 4/5 \end{bmatrix}.$$

Podemos representar:




$$X_2 = 1$$

Representación gráfica de una cadena de Markov

Considere la CMTD $(X_n)_{n \geq 0}$ con espacio de estados $\{0, 1\}$ e matriz de transición dada por

$$P = \begin{bmatrix} 1/2 & 1/2 \\ 1/5 & 4/5 \end{bmatrix}.$$

Podemos representar:



$$X_3 = 0$$

Note que $P(X_1 = 1, X_2 = 1, X_3 = 0 | X_0 = 0) = p(0, 1)p(1, 1)p(1, 0) = 2/25$.

Otra forma de definir una cadena de Markov

Sea $(X_n)_{n \geq 0}$ un proceso con valores en \mathcal{S} . Si existe una sucesión de variables aleatorias i.i.d.

$$U_1, U_2, \dots$$

con distribución común uniforme en el intervalo $(0, 1)$ y una función

$$f : \mathcal{S} \times (0, 1) \rightarrow \mathcal{S}$$

tal que

$$X_{n+1} = f(X_n, U_n),$$

para todo $n \geq 0$, decimos que $(X_n)_{n \geq 0}$ es una cadena de Markov a tiempo discreto.

Ejemplo 2.4

Considere el paseo aleatorio en \mathbb{Z} , $(Y_n)_{n \geq 0}$. Si U_1, U_2, \dots son i.i.d. con $U_1 \sim \text{Uniforme}(0, 1)$ entonces podemos escribir

$$Y_{n+1} = f(Y_n, U_n),$$

donde la función $f : \mathbb{Z} \times (0, 1) \rightarrow \mathbb{Z}$ es dada por

$$f(i, u) := \begin{cases} i + 1, & \text{si } u < p, \\ i - 1, & \text{si } u \geq p. \end{cases}$$

Probabilidades de transición en n pasos

Sea $(X_n)_{n \geq 0}$ una CMTD con espacio de estados \mathcal{S} . Se llama **probabilidades de transición en n pasos** a las probabilidades


$$p_n(i, j) := P(X_{m+n} = j | X_m = i),$$

para todo $m, n \geq 0$ y $i, j \in \mathcal{S}$. En este caso


$$p_1(i, j) = p(i, j)$$

y por convención suponemos que

$$p_0(i, j) = \begin{cases} 1, & \text{si } i = j, \\ 0, & \text{si } i \neq j. \end{cases}$$



Recurrencia del PA



Recurrencia e transitoriedad

Sea $(X_n)_{n \geq 0}$ una CMTD con espacio de estados \mathcal{S} . Para $i \in \mathcal{S}$ sea

$$\tau_i := \inf\{n \geq 1 : X_n = i\},$$

con $\tau_i := \infty$ si el ínfimo no existe. Si

$$\mathbb{P}(\tau_i < \infty | X_0 = i) = 1$$

decimos que i es un estado recurrente. Si i no es recurrente decimos que es transitorio; es decir, si


$$\mathbb{P}(\tau_i = \infty | X_0 = i) > 0$$

decimos que i es transitorio.

Castillo de cartas

Ejemplo 2.5

Considere la CMTD dada por:



Dado que $X_0 = 0$, $\tau_0 \sim \text{Geometrica}(1-p)$. Como $p \in (0, 1)$ tenemos que

$$P(\tau_0 < \infty | X_0 = 0) = 1.$$

Es decir, el estado 0 es recurrente!

Teorema 2.2

Sea $(X_n)_{n \geq 0}$ una CMTD con espacio de estados \mathcal{S} y probabilidades de transición $p(i, j)$ para $i, j \in \mathcal{S}$. Entonces

$i \in \mathcal{S}$ es recurrente si, y solamente si, $\sum_{n=0}^{\infty} p_n(i, i) = \infty$.

Prueba do Teorema 2.2. Para cada $n \geq 1$ considere la variable indicadora

$$I_n := \begin{cases} 1, & \text{se } X_n = i, \\ 0, & \text{se } X_n \neq i, \end{cases}$$

y observe que $\sum_{n=0}^{\infty} I_n$ es el número de visitas del proceso al estado i .

(\Rightarrow) Suponga que i es recurrente. Entonces

$$P(\tau_i < \infty | X_0 = i) = 1 \quad \text{y} \quad E\left(\sum_{n=0}^{\infty} I_n \mid X_0 = i\right) = \infty.$$

Pero

$$E\left(\sum_{n=0}^{\infty} I_n \mid X_0 = i\right) = \sum_{n=0}^{\infty} \mathbb{E}(I_n | X_0 = i) = \sum_{n=0}^{\infty} P(X_n = i | X_0 = i) = \sum_{n=0}^{\infty} p_n(i, i).$$

Prueba do Teorema 2.2. (\Leftarrow) Para probar la vuelta suponga que i es transitorio. En este caso

$$\left(\sum_{n=0}^{\infty} I_n \mid X_0 = i \right) \sim Geom(p_i)$$


donde $p_i := P(\tau_i = \infty \mid X_0 = i) > 0$ y por lo tanto

$$\sum_{n=0}^{\infty} p_n(i, i) = E \left(\sum_{n=0}^{\infty} I_n \mid X_0 = i \right) = \frac{1}{p_i} < \infty.$$

El paseo aleatorio en \mathbb{Z}

Recuerde que el paseo aleatorio en \mathbb{Z} es la cadena de Markov $(Y_n)_{n \geq 0}$ con espacio de estados \mathbb{Z} y probabilidades de transición:

$$p(i, j) = P(Y_{n+1} = j | Y_n = i) = \begin{cases} p, & \text{para } j = i + 1, \\ 1 - p, & \text{para } j = i - 1, \\ 0, & \text{para } j \neq i \pm 1. \end{cases}$$



Teorema 2.3

El paseo aleatorio en \mathbb{Z} es recurrente si, y solamente si, $p = 1/2$.

Prueba. Vamos a analizar $\sum_{n=0}^{\infty} p_n(i, i)$. Note que $p_{2n-1}(0, 0) = 0$ para $n \geq 1$ mientras que

$$p_{2n}(0, 0) = \binom{2n}{n} p^n (1-p)^n.$$

De hecho, dado $X_0 = 0$, para $X_{2n} = 0$, una configuración favorable es:

$$\sigma : \begin{array}{cccccccccccc} \leftarrow & \rightarrow & \leftarrow & \rightarrow & \leftarrow & \dots & \rightarrow & \leftarrow & \rightarrow & \leftarrow & & \\ \hline 1 & 2 & 3 & & & & & & 2n-1 & 2n & & \end{array} \quad \begin{array}{l} n \text{ a izquierda } (\leftarrow) \\ n \text{ a derecha } (\rightarrow) \end{array}$$

Pero hay $\binom{2n}{n}$ formas diferentes de obtener una configuración de estas y

$$P(\sigma) = p^n (1-p)^n, \quad \text{por independencia!}$$

Denotamos $q := 1 - p$. entonces

$$p_{2n}(0, 0) = \left\{ \frac{(2n)!}{(n!)^2} \right\} (p q)^n$$

y usamos la fórmula de Stirling:

$$n! \sim n^n e^{-n} \sqrt{2\pi n}$$

representando


$$\lim_{n \rightarrow \infty} \frac{n!}{n^n e^{-n} \sqrt{2\pi n}} = 1,$$

para obtener


$$p_{2n}(0, 0) \sim \frac{(4pq)^n}{\sqrt{\pi n}}.$$

Pero

$$\sum_{n=1}^{\infty} \frac{(4pq)^n}{\sqrt{\pi n}} = \infty \text{ si, y solamente si, } p = \frac{1}{2}.$$



Extensiones!



Para encontrar una aproximación de

$$p_{2n}(\mathbf{0}, \mathbf{0}) = \sum_{i=0}^n \frac{(2n)!}{i! i! (n-i)! (n-i)!} \left(\frac{1}{4}\right)^{2n},$$

note que

$$\sum_{i=0}^n \frac{(2n)!}{i! i! (n-i)! (n-i)!} = \binom{2n}{n} \sum_{i=0}^n \binom{n}{i} \binom{n}{n-i} = \binom{2n}{n}^2.$$

entonces,

$$p_{2n}(\mathbf{0}, \mathbf{0}) = \binom{2n}{n}^2 \left(\frac{1}{4}\right)^{2n}$$

y por la fórmula de Stirling concluimos que

$$p_{2n}(\mathbf{0}, \mathbf{0}) \sim \frac{1}{\pi n_{\infty}}.$$

Como $\sum_{n=1}^{\infty} \frac{1}{n} = \infty$, entonces $\sum_{n=1}^{\infty} p_{2n}(\mathbf{0}, \mathbf{0}) = \infty$.

El paseo aleatorio simétrico en \mathbb{Z}^d , $d \geq 3$

El P.A.S. en \mathbb{Z}^3 es la cadena de Markov $(Y_n)_{n \geq 0}$ con estados en \mathbb{Z}^3 y probabilidades de transición dadas por: para $u = (u_1, u_2, u_3) \in \mathbb{Z}^3$

$$p(u, v) = \begin{cases} \frac{1}{6}, & \text{se } v \in \{(u_1, u_2 \pm 1, u_3), (u_1 \pm 1, u_2, u_3), (u_1, u_2, u_3 \pm 1)\}, \\ 0, & \text{caso contrario.} \end{cases}$$

Sabemos que el P.A.S. en \mathbb{Z}^3 es **transitorio!**

Si denotamos $\mathbf{0} = (0, 0, 0)$, tenemos que $p_{2n-1}(\mathbf{0}, \mathbf{0}) = 0$, $n \geq 1$ y

$$p_{2n}(\mathbf{0}, \mathbf{0}) = \sum_{\substack{i, j, k \geq 0 \\ i+j+k=n}} \frac{(2n)!}{i! i! j! j! k! k!} \left(\frac{1}{6}\right)^{2n}, \text{ para } n \geq 1.$$

Por otro lado, como

$$\sum_{\substack{i, j, k \geq 0 \\ i+j+k=n}} \frac{(2n)!}{i! i! j! j! k! k!} = \binom{2n}{n} \sum_{\substack{i, j, k \geq 0 \\ i+j+k=n}} \binom{n}{i, j, k}^2$$

tenemos

$$p_{2n}(\mathbf{0}, \mathbf{0}) = \binom{2n}{n} \left(\frac{1}{2}\right)^{2n} \sum_{\substack{i, j, k \geq 0 \\ i+j+k=n}} \left\{ \binom{n}{i, j, k} \left(\frac{1}{3}\right)^n \right\}^2.$$

Note que

$$\sum_{\substack{i,j,k \geq 0 \\ i+j+k=n}} \left\{ \binom{n}{i,j,k} \left(\frac{1}{3}\right)^n \right\}^2 \leq C_{n,3} \left(\frac{1}{3}\right)^n \left\{ \sum_{\substack{i,j,k \geq 0 \\ i+j+k=n}} \binom{n}{i,j,k} \left(\frac{1}{3}\right)^n \right\},$$

máximo de los coeficientes \curvearrowright $= 1$

La suma es igual a uno pues en el experimento de distribuir al azar n bolas distintas en 3 urnas distintas, tenemos que, para $i, j, k \geq 0$ con $i + j + k = n$, entonces

$$\binom{n}{i,j,k} \left(\frac{1}{3}\right)^n$$

es la probabilidad de que i, j y k bolas sean colocadas, resp., en la primera, segunda y tercera urna.

Así, conseguimos

$$p_{2n}(\mathbf{0}, \mathbf{0}) \leq \binom{2n}{n} \left(\frac{1}{2}\right)^{2n} C_{n,3} \left(\frac{1}{3}\right)^n.$$

Haciendo $n = 3m$, tenemos que

$$\binom{3m}{i \ j \ k} \leq \binom{3m}{m \ m \ m} \quad (1)$$

para todo i, j, k tal que $i + j + k = 3m$. De hecho, fije i, j, k y sin pérdida de generalidad suponga que $i < m$ y que $j \geq m + 1$. Note que $i + 1 < j$ y así:

$$\binom{3m}{i \ j \ k} = \frac{(3m)!}{i! j! k!} \leq \left\{ \frac{j}{i+1} \right\} \left\{ \frac{(3m)!}{i! j! k!} \right\} \leq \frac{(3m)!}{(i+1)! (j-1)! k!}.$$

Repetidas realizaciones de este argumento nos lleva a la desigualdad (1).

Luego,

$$p_{6m}(\mathbf{0}, \mathbf{0}) \leq \binom{6m}{3m} \left(\frac{1}{2}\right)^{6m} \binom{3m}{m \ m \ m} \left(\frac{1}{3}\right)^{3m} \sim \frac{1}{2(m\pi)^{3/2}}.$$

Como $\sum_{m=1}^{\infty} \frac{1}{m^{3/2}} < \infty$, entonces $\sum_{m=1}^{\infty} p_{6m}(\mathbf{0}, \mathbf{0}) < \infty$. Además, note que

$$p_{6m}(\mathbf{0}, \mathbf{0}) \geq \left(\frac{1}{6}\right)^2 p_{6m-2}(\mathbf{0}, \mathbf{0}) \quad \text{e} \quad p_{6m}(\mathbf{0}, \mathbf{0}) \geq \left(\frac{1}{6}\right)^4 p_{6m-4}(\mathbf{0}, \mathbf{0}).$$

Por lo tanto $\sum_{n=1}^{\infty} p_{2n}(\mathbf{0}, \mathbf{0}) < \infty$.

En general


Teorema 2.4

El PA simétrico en \mathbb{Z}^d es recurrente si, y solamente si, $d \in \{1, 2\}$.

Sobre la prueba:

- ▶ Para más detalles de las pruebas para $d \in \{1, 2, 3\}$ usando los argumentos de estos slides ver:
 - ▶ Sección I.8 de R. Schinazi. Classical and Spatial Stochastic Processes, Birkhäuser, 1999.
 - ▶ o Sección 1.6 de J. Norris. Markov Chains, Cambridge, 1997.
- ▶ Para una prueba para $d \in \{2, 3\}$ usando una relación entre paseos aleatorios y redes eléctricas ver Sección 1.5 de G. Grimmett. Probability on Graphs, Cambridge, 2010.
- ▶ Para $d \geq 4$: usando argumentos de acoplamiento se prueba que transitoriedad en $d = 3$ implica transitoriedad para $d \geq 4$.


El modelo de los sapos: idea



○ : sapo dormido

● : sapo despierto

El modelo de los sapos: idea



○ : sapo dormido

● : sapo despierto

Recurrencia para el modelo de los sapos

¿El 0 es visitado infinitas veces con probabilidad 1?

¡Si $p = 1/2$ volvemos al resultado del paseo aleatorio simétrico!

Condiciones ...

- ▶ Configuración inicial dada por $(\eta_x)_{x \in \mathbb{Z}}$ y $p \in (1/2, 1)$, donde


$\eta_x = \#$ de sapos dormidos en x en el instante 0.

- ▶ El modelo es recurrente si, y solamente si,

$$\sum_{j=1}^{\infty} \eta_j \left(\frac{1-p}{p} \right)^j = \infty.$$

Ver: Recurrence for the frog model with drift on Z (2009).

*N. Gantert and P. Schmidt. Markov Processes and Related Fields **15**, pp. 51-58.*



Muchas gracias!

