



FACULTAD DE
INGENIERÍA



UNIVERSIDAD
DE LA REPÚBLICA
URUGUAY

Aprendizaje Automático para Datos en Grafos

Modelos de Grafos Aleatorios - Parte I

Federico 'Larroca' La Rocca

Muy basado en transparencias de **Gonzalo Mateos**

`flarroca@fing.edu.uy`

`http://iie.fing.edu.uy/personal/flarroca`



Modelos de Grafos Aleatorios

- 1 Introducción
- 2 Grafos Aleatorios
- 3 Configuration models
- 4 Network-growth models
- 5 Modelos Small-world
- 6 Exponential random graph models

¿Para qué modelar estadísticamente grafos?

- Los modelos de grafos aleatorios tienen varios usos:
 - 1) ¿Qué mecanismos pueden explicar propiedades que observamos en grafos reales?
Ejemplo: los efectos tipo small-world, o distribuciones de grado con ley de potencia

¿Para qué modelar estadísticamente grafos?

- Los modelos de grafos aleatorios tienen varios usos:
 - 1) ¿Qué mecanismos pueden explicar propiedades que observamos en grafos reales?
Ejemplo: los efectos tipo small-world, o distribuciones de grado con ley de potencia
 - 2) Crear un modelo nulo para testear propiedades de un grafo
Ejemplo: ¿El valor del coeficiente de clustering de mi grafo es raro?

¿Para qué modelar estadísticamente grafos?

- Los modelos de grafos aleatorios tienen varios usos:
 - 1) ¿Qué mecanismos pueden explicar propiedades que observamos en grafos reales?
Ejemplo: los efectos tipo small-world, o distribuciones de grado con ley de potencia
 - 2) Crear un modelo nulo para testear propiedades de un grafo
Ejemplo: ¿El valor del coeficiente de clustering de mi grafo es raro?
 - 3) Evaluación de factores que puedan predecir relaciones entre los nodos
Ejemplo: ¿En este grafo hay efectos transitivos o de reciprocidad?

¿Para qué modelar estadísticamente grafos?

- Los modelos de grafos aleatorios tienen varios usos:
 - 1) ¿Qué mecanismos pueden explicar propiedades que observamos en grafos reales?
Ejemplo: los efectos tipo small-world, o distribuciones de grado con ley de potencia
 - 2) Crear un modelo nulo para testear propiedades de un grafo
Ejemplo: ¿El valor del coeficiente de clustering de mi grafo es raro?
 - 3) Evaluación de factores que puedan predecir relaciones entre los nodos
Ejemplo: ¿En este grafo hay efectos transitivos o de reciprocidad?
 - 4) Generación de grafos
Ejemplo: ¿Grafos para evaluar mi algoritmo de aprendizaje en condiciones “controladas”?

¿Para qué modelar estadísticamente grafos?

- Los modelos de grafos aleatorios tienen varios usos:
 - 1) ¿Qué mecanismos pueden explicar propiedades que observamos en grafos reales?
Ejemplo: los efectos tipo small-world, o distribuciones de grado con ley de potencia
 - 2) Crear un modelo nulo para testear propiedades de un grafo
Ejemplo: ¿El valor del coeficiente de clustering de mi grafo es raro?
 - 3) Evaluación de factores que puedan predecir relaciones entre los nodos
Ejemplo: ¿En este grafo hay efectos transitivos o de reciprocidad?
 - 4) Generación de grafos
Ejemplo: ¿Grafos para evaluar mi algoritmo de aprendizaje en condiciones “controladas”?
- Nos vamos a enfocar en la construcción de varios de los modelos más populares, algunas propiedades y su uso. Quedará mucho por el camino (ver el EVA para más material).

Modelos de Grafos Aleatorios

■ **Definición:** Un modelo de grafos aleatorios es una colección

$$\{P_{\theta}(G), G \in \mathcal{G} : \theta \in \Theta\}$$

- \mathcal{G} es el conjunto de grafos posibles bajo este modelo
- $P_{\theta}(\cdot)$ es la distribución de probabilidad sobre \mathcal{G} (casi siempre va a figurar como $P(\cdot)$ directamente)
- θ es el vector de parámetros del modelo, perteneciente a cierto espacio Θ

Modelos de Grafos Aleatorios

■ **Definición:** Un modelo de grafos aleatorios es una colección

$$\{P_{\theta}(G), G \in \mathcal{G} : \theta \in \Theta\}$$

- \mathcal{G} es el conjunto de grafos posibles bajo este modelo
 - $P_{\theta}(\cdot)$ es la distribución de probabilidad sobre \mathcal{G} (casi siempre va a figurar como $P(\cdot)$ directamente)
 - θ es el vector de parámetros del modelo, perteneciente a cierto espacio Θ
- La riqueza y la utilidad del modelo dependen de **cómo especifiquemos $P_{\theta}(\cdot)$**
⇒ Como veremos en estas clases, los métodos van de lo simple a lo complejo

Especificación del modelo

1) $P(\cdot)$ **uniforme** en \mathcal{G} , tomando en cuenta restricciones estructurales sobre los grafos en \mathcal{G}

Ejemplo: Grafos tipo Erdős-Renyi o el denominado modelo Configurational

Especificación del modelo

1) $P(\cdot)$ **uniforme** en \mathcal{G} , tomando en cuenta restricciones estructurales sobre los grafos en \mathcal{G}

Ejemplo: Grafos tipo Erdős-Renyi o el denominado modelo Configurational

2) **Inducir** $P(\cdot)$ a través de la aplicación de un modelo **generativo**

Ejemplo: small world, preferential attachment, copying models, deep generative models

Especificación del modelo

- 1) $P(\cdot)$ **uniforme** en \mathcal{G} , tomando en cuenta restricciones estructurales sobre los grafos en \mathcal{G}
Ejemplo: Grafos tipo Erdős-Renyi o el denominado modelo Configurational
- 2) **Inducir** $P(\cdot)$ a través de la aplicación de un modelo **generativo**
Ejemplo: small world, preferential attachment, copying models, deep generative models
- 3) Modelar propiedades estructurales y sus efectos sobre la topología de G
Ejemplo: exponential random graph models

Especificación del modelo

- 1) $P(\cdot)$ **uniforme** en \mathcal{G} , tomando en cuenta restricciones estructurales sobre los grafos en \mathcal{G}
Ejemplo: Grafos tipo Erdős-Renyi o el denominado modelo Configurational
- 2) **Inducir** $P(\cdot)$ a través de la aplicación de un modelo **generativo**
Ejemplo: small world, preferential attachment, copying models, deep generative models
- 3) Modelar propiedades estructurales y sus efectos sobre la topología de G
Ejemplo: exponential random graph models
- 4) Modelar la tendencia de los nodos a conectarse mediante **variables latentes**
Ejemplo: stochastic block models, graphons, random dot product graphs

Especificación del modelo

- 1) $P(\cdot)$ **uniforme** en \mathcal{G} , tomando en cuenta restricciones estructurales sobre los grafos en \mathcal{G}
Ejemplo: Grafos tipo Erdős-Renyi o el denominado modelo Configurational
 - 2) **Inducir** $P(\cdot)$ a través de la aplicación de un modelo **generativo**
Ejemplo: small world, preferential attachment, copying models, deep generative models
 - 3) Modelar propiedades estructurales y sus efectos sobre la topología de G
Ejemplo: exponential random graph models
 - 4) Modelar la tendencia de los nodos a conectarse mediante **variables latentes**
Ejemplo: stochastic block models, graphons, random dot product graphs
- **Costo computacional de algoritmos de inferencia y generación son aspectos importantes**

Modelos de Grafos Aleatorios

- 1 Introducción
- 2 Grafos Aleatorios**
- 3 Configuration models
- 4 Network-growth models
- 5 Modelos Small-world
- 6 Exponential random graph models

Grafos Aleatorios Clásicos

- Se le asigna la misma probabilidad a todos los grafos (no-dirigidos) de cierto orden y tamaño

Grafos Aleatorios Clásicos

- Se le asigna la misma probabilidad a todos los grafos (no-dirigidos) de cierto orden y tamaño
 - Se especifica la colección \mathcal{G}_{N_v, N_e} como aquellos grafos $G(V, E)$ con $|V| = N_v$, $|E| = N_e$
 - $P(G) = \binom{N}{N_e}^{-1}$ para cada $G \in \mathcal{G}_{N_v, N_e}$, donde $N = |V^{(2)}| = \binom{N_v}{2}$

Grafos Aleatorios Clásicos

- Se le asigna la misma probabilidad a todos los grafos (no-dirigidos) de cierto orden y tamaño
 - Se especifica la colección \mathcal{G}_{N_v, N_e} como aquellos grafos $G(V, E)$ con $|V| = N_v$, $|E| = N_e$
 - $P(G) = \binom{N}{N_e}^{-1}$ para cada $G \in \mathcal{G}_{N_v, N_e}$, donde $N = |V^{(2)}| = \binom{N_v}{2}$
- La variante más común es conocida como modelo de **Erdős-Renyi**(-Gilbert) y la notaremos como $ER(n, p)$ (también se usa $G_{n, p}$)
 - ⇒ Grafo no dirigido con $N_v = n$ nodos (igual que antes)
 - ⇒ La arista (u, v) existe con probabilidad p independiente del resto

Grafos Aleatorios Clásicos

- Se le asigna la misma probabilidad a todos los grafos (no-dirigidos) de cierto orden y tamaño
 - Se especifica la colección \mathcal{G}_{N_v, N_e} como aquellos grafos $G(V, E)$ con $|V| = N_v$, $|E| = N_e$
 - $P(G) = \binom{N}{N_e}^{-1}$ para cada $G \in \mathcal{G}_{N_v, N_e}$, donde $N = |V^{(2)}| = \binom{N_v}{2}$
- La variante más común es conocida como modelo de **Erdős-Renyi**(-Gilbert) y la notaremos como $ER(n, p)$ (también se usa $G_{n, p}$)
 - ⇒ Grafo no dirigido con $N_v = n$ nodos (igual que antes)
 - ⇒ La arista (u, v) existe con probabilidad p independiente del resto
- **Simulación**: sortear $N = \binom{N_v}{2} \approx N_v^2/2$ i.i.d. $\text{Ber}(p)$ VAs
 - Claramente ineficiente cuando $p \sim N_v^{-1} \Rightarrow$ grafo esparso, la mayoría de las veces vamos a sacar un 0
 - Mejor sortear $\text{Geo}(p)$ i.i.d. para ver qué aristas generar (corre en tiempo $O(N_v + N_e)$)

Propiedades de $ER(n, p)$

- $ER(n, p)$ es un modelo ampliamente estudiado, y se conocen expresiones para varios indicadores. **Algunas propiedades interesantes:**

Propiedades de $ER(n, p)$

- $ER(n, p)$ es un modelo ampliamente estudiado, y se conocen expresiones para varios indicadores. **Algunas propiedades interesantes:**

P1) **Distribución de grados** ¿Cuánto vale $P(D_i = d) = P(d)$, la probabilidad de que el nodo i tenga d vecinos?

Propiedades de $ER(n, p)$

- $ER(n, p)$ es un modelo ampliamente estudiado, y se conocen expresiones para varios indicadores. **Algunas propiedades interesantes:**

P1) **Distribución de grados** ¿Cuánto vale $P(D_i = d) = P(d)$, la probabilidad de que el nodo i tenga d vecinos?

$$\left. \begin{array}{l} D_i = \sum_{\substack{j=1, \dots, n \\ j \neq i}} A_{i,j} \\ (A_{i,j})_{j \neq i} \sim \text{Ber}(p) \text{ i.i.d.} \end{array} \right\} \Rightarrow D_i \sim \text{Bin}(n-1, p)$$

Propiedades de $ER(n, p)$


- $ER(n, p)$ es un modelo ampliamente estudiado, y se conocen expresiones para varios indicadores. **Algunas propiedades interesantes:**

P1) **Distribución de grados** ¿Cuánto vale $P(D_i = d) = P(d)$, la probabilidad de que el nodo i tenga d vecinos?

$$\left. \begin{array}{l} D_i = \sum_{\substack{j=1, \dots, n \\ j \neq i}} A_{i,j} \\ (A_{i,j})_{j \neq i} \sim \text{Ber}(p) \text{ i.i.d.} \end{array} \right\} \Rightarrow D_i \sim \text{Bin}(n-1, p) \xrightarrow{\text{Hoeffding}} P(D_i - p(n-1) \geq t) \leq e^{-\frac{2t^2}{n-1}}$$

$\Rightarrow P(d)$ está concentrado alrededor de $p(n-1)$ con colas exponenciales

Ejemplo Histograma de grados de un $ER(n, p)$ con $n = 10,000$ y $p = 20/10,000$



Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**


- Si $np > 1$, $ER(n, p)$ tiene una componente gigante de tamaño $O(n)$ w.h.p.
- Si $np < 1$, $ER(n, p)$ tienen componentes de tamaño $O(\log n)$ w.h.p.

Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- Si $np > 1$, $ER(n, p)$ tiene una componente gigante de tamaño $O(n)$ w.h.p.
- Si $np < 1$, $ER(n, p)$ tienen componentes de tamaño $O(\log n)$ w.h.p.

Ejemplo $ER(n, p)$ para $n = 200$ a medida que cambia p




Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- Si $np > 1$, $ER(n, p)$ tiene una componente gigante de tamaño $O(n)$ w.h.p.
- Si $np < 1$, $ER(n, p)$ tienen componentes de tamaño $O(\log n)$ w.h.p.

Ejemplo $ER(n, p)$ para $n = 200$ a medida que cambia p




Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- Si $np > 1$, $ER(n, p)$ tiene una componente gigante de tamaño $O(n)$ w.h.p.
- Si $np < 1$, $ER(n, p)$ tienen componentes de tamaño $O(\log n)$ w.h.p.

Ejemplo $ER(n, p)$ para $n = 200$ a medida que cambia p




Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- Si $np > 1$, $ER(n, p)$ tiene una componente gigante de tamaño $O(n)$ w.h.p.
- Si $np < 1$, $ER(n, p)$ tienen componentes de tamaño $O(\log n)$ w.h.p.

Ejemplo $ER(n, p)$ para $n = 200$ a medida que cambia p




Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- Si $np > 1$, $ER(n, p)$ tiene una componente gigante de tamaño $O(n)$ w.h.p.
- Si $np < 1$, $ER(n, p)$ tienen componentes de tamaño $O(\log n)$ w.h.p.

Ejemplo $ER(n, p)$ para $n = 200$ a medida que cambia p




Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- Si $np > 1$, $ER(n, p)$ tiene una componente gigante de tamaño $O(n)$ w.h.p.
- Si $np < 1$, $ER(n, p)$ tienen componentes de tamaño $O(\log n)$ w.h.p.

Ejemplo $ER(n, p)$ para $n = 200$ a medida que cambia p




Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- Si $np > 1$, $ER(n, p)$ tiene una componente gigante de tamaño $O(n)$ w.h.p.
- Si $np < 1$, $ER(n, p)$ tienen componentes de tamaño $O(\log n)$ w.h.p.

Ejemplo $ER(n, p)$ para $n = 200$ a medida que cambia p




Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- Si $np > 1$, $ER(n, p)$ tiene una componente gigante de tamaño $O(n)$ w.h.p.
- Si $np < 1$, $ER(n, p)$ tienen componentes de tamaño $O(\log n)$ w.h.p.

Ejemplo $ER(n, p)$ para $n = 200$ a medida que cambia p




Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- Si $np > 1$, $ER(n, p)$ tiene una componente gigante de tamaño $O(n)$ w.h.p.
- Si $np < 1$, $ER(n, p)$ tienen componentes de tamaño $O(\log n)$ w.h.p.

Ejemplo $ER(n, p)$ para $n = 200$ a medida que cambia p




Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- Si $np > 1$, $ER(n, p)$ tiene una componente gigante de tamaño $O(n)$ w.h.p.
- Si $np < 1$, $ER(n, p)$ tienen componentes de tamaño $O(\log n)$ w.h.p.

Ejemplo $ER(n, p)$ para $n = 200$ a medida que cambia p




Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- Si $np > 1$, $ER(n, p)$ tiene una componente gigante de tamaño $O(n)$ w.h.p.
- Si $np < 1$, $ER(n, p)$ tienen componentes de tamaño $O(\log n)$ w.h.p.

Ejemplo $ER(n, p)$ para $n = 200$ a medida que cambia p




Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- Si $np > 1$, $ER(n, p)$ tiene una componente gigante de tamaño $O(n)$ w.h.p.
- Si $np < 1$, $ER(n, p)$ tienen componentes de tamaño $O(\log n)$ w.h.p.

Ejemplo $ER(n, p)$ para $n = 200$ a medida que cambia p



Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- ¿Cómo podemos demostrarlo?
- Definamos un **proceso de exploración** en el grafo que recorra la componente conexa arrancando de algún nodo al azar y veamos con qué tamaño termina

Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- ¿Cómo podemos demostrarlo?
- Definamos un **proceso de exploración** en el grafo que recorra la componente conexa arrancando de algún nodo al azar y veamos con qué tamaño termina
- Nodos en uno de tres estados: **activo** (\mathcal{A}_t), **inactivo** (\mathcal{I}_t) o **explorado** (\mathcal{E}_t)

Propiedades de $ER(n, p)$

P2) Transición de fase en la aparición de una componente gigante

- ¿Cómo podemos demostrarlo?
- Definamos un **proceso de exploración** en el grafo que recorra la componente conexa arrancando de algún nodo al azar y veamos con qué tamaño termina
- Nodos en uno de tres estados: **activo** (\mathcal{A}_t), **inactivo** (\mathcal{I}_t) o **explorado** (\mathcal{E}_t)

$G = (V, E) \sim ER(n, p)$, $V = 1, \dots, n$ % Genero un grafo ER

$\mathcal{A}_0 = \{1\}$, $\mathcal{I}_0 = \{2, \dots, n\}$, $\mathcal{E}_0 = \emptyset$ % Inicialización: un activo cualquiera

while $\mathcal{A}_t \neq \emptyset$ **do**

 Esperar tiempo exponencial de media 1

 Elegir $v \in \mathcal{A}_t$ % Explorar algún nodo activo

foreach $w \in \mathcal{I}_t \cap \mathcal{N}(v)$ **do**

 | $\mathcal{A}_t \leftarrow \mathcal{A}_t \cup \{w\}$ % Agrego vecinos inactivos de v

end

$\mathcal{E}_t \leftarrow \mathcal{E}_t \cup \{v\}$ % Paso v a los explorados

$\mathcal{A}_t \leftarrow \mathcal{A}_t \setminus \{v\}$

end

return $|\mathcal{E}_t|$

Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- Nos interesa $|\mathcal{E}_t| = E_t$. Junto con $|\mathcal{A}_t| = A_t$ forman una **cadena de Markov en tiempo continuo**:

Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- Nos interesa $|\mathcal{E}_t| = E_t$. Junto con $|\mathcal{A}_t| = A_t$ forman una **cadena de Markov en tiempo continuo**:
 - El vector (E_t, A_t) permanece en cada estado durante un tiempo exponencial
 - En los momentos que hay cambio:

$$(E_{t+}, A_{t+}) = (\underbrace{E_t + 1}_{\text{Un explorado más (v)}}, \underbrace{A_t + X_t - 1}_{\text{Los vecinos inactivos de v ahora son activos (y v ahora es explorado)}})$$

Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- Nos interesa $|\mathcal{E}_t| = E_t$. Junto con $|\mathcal{A}_t| = A_t$ forman una **cadena de Markov en tiempo continuo**:
 - El vector (E_t, A_t) permanece en cada estado durante un tiempo exponencial
 - En los momentos que hay cambio:

$$(E_{t+}, A_{t+}) = (\underbrace{E_t + 1}_{\text{Un explorado más } (v)}, \underbrace{A_t + X_t - 1}_{\text{Los vecinos inactivos de } v \text{ ahora son activos (y } v \text{ ahora es explorado)}})$$

$$X_t \sim \text{Bin}(|\mathcal{I}_t|, p) = \text{Bin}(n - A_t - E_t, p)$$

Propiedades de ER(n, p)

P2) Transición de fase en la **aparición de una componente gigante**

- Nos interesa $|\mathcal{E}_t| = E_t$. Junto con $|\mathcal{A}_t| = A_t$ forman una **cadena de Markov en tiempo continuo**:
 - El vector (E_t, A_t) permanece en cada estado durante un tiempo exponencial
 - En los momentos que hay cambio:

$$(E_{t+}, A_{t+}) = (\underbrace{E_t + 1}_{\text{Un explorado más } (v)}, \underbrace{A_t + X_t - 1}_{\text{Los vecinos inactivos de } v \text{ ahora son activos (y } v \text{ ahora es explorado)}})$$

$$X_t \sim \text{Bin}(|\mathcal{I}_t|, p) = \text{Bin}(n - A_t - E_t, p)$$

- ¿Cuánto vale E_t cuando A_t se hace cero (**a medida que $n \rightarrow \infty$**)?

Propiedades de ER(n, p)

P2) Transición de fase en la aparición de una componente gigante


- Nos interesa $|\mathcal{E}_t| = E_t$. Junto con $|\mathcal{A}_t| = A_t$ forman una cadena de Markov en tiempo continuo:

- El vector (E_t, A_t) permanece en cada estado durante un tiempo exponencial
- En los momentos que hay cambio:

$$(E_{t+}, A_{t+}) = (\underbrace{E_t + 1}_{\text{Un explorado más (} v \text{)}}, \underbrace{A_t + X_t - 1}_{\text{Los vecinos inactivos de } v \text{ ahora son activos (y } v \text{ ahora es explorado)}})$$

$$X_t \sim \text{Bin}(|\mathcal{I}_t|, p) = \text{Bin}(n - A_t - E_t, p)$$

- ¿Cuánto vale E_t cuando A_t se hace cero (a medida que $n \rightarrow \infty$)? Ej: $p = 2/n$



Propiedades de ER(n, p)

P2) Transición de fase en la **aparición de una componente gigante**


- Nos interesa $|\mathcal{E}_t| = E_t$. Junto con $|\mathcal{A}_t| = A_t$ forman una **cadena de Markov en tiempo continuo**:

- El vector (E_t, A_t) permanece en cada estado durante un tiempo exponencial
- En los momentos que hay cambio:

$$(E_{t+}, A_{t+}) = (\underbrace{E_t + 1}_{\text{Un explorado más (} v \text{)}}, \underbrace{A_t + X_t - 1}_{\text{Los vecinos inactivos de } v \text{ ahora son activos (y } v \text{ ahora es explorado)}})$$

$$X_t \sim \text{Bin}(|\mathcal{I}_t|, p) = \text{Bin}(n - A_t - E_t, p)$$

- ¿Cuánto vale E_t cuando A_t se hace cero (a medida que $n \rightarrow \infty$)? Ej: $p = 2/n$



Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**


- Nos interesa $|\mathcal{E}_t| = E_t$. Junto con $|\mathcal{A}_t| = A_t$ forman una **cadena de Markov en tiempo continuo**:

- El vector (E_t, A_t) permanece en cada estado durante un tiempo exponencial
- En los momentos que hay cambio:

$$(E_{t+}, A_{t+}) = (\underbrace{E_t + 1}_{\text{Un explorado más (v)}}, \underbrace{A_t + X_t - 1}_{\text{Los vecinos inactivos de v ahora son activos (y v ahora es explorado)}})$$

$$X_t \sim \text{Bin}(|\mathcal{I}_t|, p) = \text{Bin}(n - A_t - E_t, p)$$

- ¿Cuánto vale E_t cuando A_t se hace cero (**a medida que $n \rightarrow \infty$**)? Ej: $p = 2/n$



Propiedades de $ER(n, p)$


P2) Transición de fase en la **aparición de una componente gigante**

- Nos interesa $|\mathcal{E}_t| = E_t$. Junto con $|\mathcal{A}_t| = A_t$ forman una **cadena de Markov en tiempo continuo**:
 - El vector (E_t, A_t) permanece en cada estado durante un tiempo exponencial
 - En los momentos que hay cambio:

$$(E_{t+}, A_{t+}) = (\underbrace{E_t + 1}_{\text{Un explorado más (v)}}, \underbrace{A_t + X_t - 1}_{\text{Los vecinos inactivos de v ahora son activos (y v ahora es explorado)}})$$

$$X_t \sim \text{Bin}(|\mathcal{I}_t|, p) = \text{Bin}(n - A_t - E_t, p)$$

- ¿Cuánto vale E_t cuando A_t se hace cero (**a medida que $n \rightarrow \infty$**)? Ej: $p = 2/n$



Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- Los procesos escalado $\frac{E_{\tau n}}{n} = e_{\tau}$ y $\frac{A_{\tau n}}{n} = a_{\tau}$ parecen tener un comportamiento determinístico con $n \rightarrow \infty$: **límite fluido**

Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- Los procesos escalado $\frac{E_{\tau n}}{n} = e_{\tau}$ y $\frac{A_{\tau n}}{n} = a_{\tau}$ parecen tener un comportamiento determinístico con $n \rightarrow \infty$: **límite fluido**
 - Una cadena de Markov admite la siguiente descomposición:

$$Y(t) = Y(0) + \int_0^t Q(Y(s))ds + M(t)$$

con $Q(l) = \sum_m (l - m)q(l, m) = \sum_m (l - m)p_{l,m}\lambda_l$ el **drift** del proceso (el cambio promedio del proceso en l) y $M(t)$ una **martingala** (ruido)

Propiedades de ER(n, p)

P2) Transición de fase en la **aparición de una componente gigante**

- Los procesos escalado $\frac{E_{\tau n}}{n} = e_{\tau}$ y $\frac{A_{\tau n}}{n} = a_{\tau}$ parecen tener un comportamiento determinístico con $n \rightarrow \infty$: **límite fluido**
 - Una cadena de Markov admite la siguiente descomposición:

$$Y(t) = Y(0) + \int_0^t Q(Y(s))ds + M(t)$$

con $Q(l) = \sum_m (l - m)q(l, m) = \sum_m (l - m)p_{l,m}\lambda_l$ el **drift** del proceso (el cambio promedio del proceso en l) y $M(t)$ una **martingala** (ruido)

- Para este caso en particular resulta

$$E_t = 0 + \int_0^t 1ds + M_E(t)$$

$$A_t = 1 + \int_0^t (p(n - A_s - E_s) - 1) ds + M_A(t)$$

Propiedades de ER(n, p)

P2) Transición de fase en la **aparición de una componente gigante**

- Re-escalando, usando $p = c/n$ (cantidad de vecinos promedio $\approx c$)...

$$e_\tau = \frac{E_{\tau n}}{n} = 0 + \frac{1}{n} \int_0^{\tau n} 1 ds + \frac{M_E(\tau n)}{n}$$
$$a_\tau = \frac{A_{\tau n}}{n} = \frac{1}{n} + \frac{1}{n} \int_0^{\tau n} \left(\frac{c}{n} (n - A_s - E_s) - 1 \right) ds + \frac{M_A(\tau n)}{n}$$

Propiedades de ER(n, p)

P2) Transición de fase en la **aparición de una componente gigante**

- Re-escalando, usando $p = c/n$ (cantidad de vecinos promedio $\approx c$)...

$$e_\tau = \frac{E_{\tau n}}{n} = 0 + \frac{1}{n} \int_0^{\tau n} 1 ds + \frac{M_E(\tau n)}{n}$$
$$a_\tau = \frac{A_{\tau n}}{n} = \frac{1}{n} + \frac{1}{n} \int_0^{\tau n} \left(\frac{c}{n} (n - A_s - E_s) - 1 \right) ds + \frac{M_A(\tau n)}{n}$$

... y suponiendo que las martinagalas re-escaladas van a cero en n

$$e_\tau = \tau$$
$$\frac{da_\tau}{d\tau} = \frac{1}{n} \left(\frac{c}{n} (n - A_{\tau n} - E_{\tau n}) - 1 \right) n$$
$$a_0 = 0$$

Propiedades de ER(n, p)

P2) Transición de fase en la **aparición de una componente gigante**

- Re-escalando, usando $p = c/n$ (cantidad de vecinos promedio $\approx c$)...

$$e_\tau = \frac{E_{\tau n}}{n} = 0 + \frac{1}{n} \int_0^{\tau n} 1 ds + \frac{M_E(\tau n)}{n}$$
$$a_\tau = \frac{A_{\tau n}}{n} = \frac{1}{n} + \frac{1}{n} \int_0^{\tau n} \left(\frac{c}{n} (n - A_s - E_s) - 1 \right) ds + \frac{M_A(\tau n)}{n}$$

... y suponiendo que las martinagalas re-escaladas van a cero en n

$$e_\tau = \tau$$
$$\frac{da_\tau}{d\tau} = \frac{1}{n} \left(\frac{c}{n} (n - A_{\tau n} - E_{\tau n}) - 1 \right) n = c(1 - a_\tau - e_\tau) - 1$$
$$a_0 = 0$$

... que tiene solución analítica!

Propiedades de $ER(n, p)$


P2) Transición de fase en la **aparición de una componente gigante**

- Finalmente, en el límite $n \rightarrow \infty$

$$e_\tau = \tau$$

$$a_\tau = 1 - \tau - e^{-c\tau}$$

Ejemplo: $p = 2/n$



Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- Finalmente, en el límite $n \rightarrow \infty$

$$e_\tau = \tau$$

$$a_\tau = 1 - \tau - e^{-c\tau}$$

\Rightarrow Habrá una componente gigante $\Leftrightarrow c > 1$ y su tamaño (proporcional a n) será la solución positiva de $1 - \tau = e^{-c\tau}$

Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- Finalmente, en el límite $n \rightarrow \infty$

$$e_\tau = \tau$$

$$a_\tau = 1 - \tau - e^{-c\tau}$$

\Rightarrow Habrá una componente gigante $\Leftrightarrow c > 1$ y su tamaño (proporcional a n) será la solución positiva de $1 - \tau = e^{-c\tau}$

- Ver Remco van der Hofstad, “Random Graphs and Complex Networks. Volume One.” Cambridge Series in Statistical and Probabilistic Mathematics (2017) para más formalidad

Propiedades de $ER(n, p)$

P2) Transición de fase en la **aparición de una componente gigante**

- Finalmente, en el límite $n \rightarrow \infty$

$$e_\tau = \tau$$

$$a_\tau = 1 - \tau - e^{-c\tau}$$

\Rightarrow Habrá una componente gigante $\Leftrightarrow c > 1$ y su tamaño (proporcional a n) será la solución positiva de $1 - \tau = e^{-c\tau}$

- Ver Remco van der Hofstad, “Random Graphs and Complex Networks. Volume One.” Cambridge Series in Statistical and Probabilistic Mathematics (2017) para más formalidad

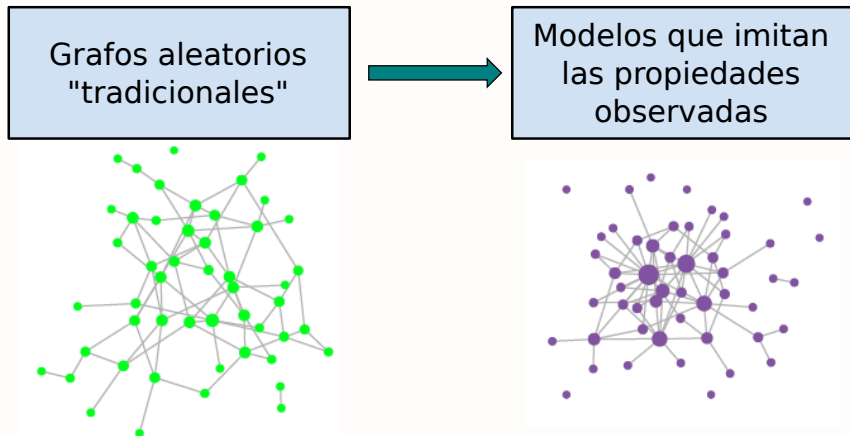
P3) **Clustering coefficient pequeño** de orden $O(n^{-1})$ y **diámetro corto** de orden $O(\log n)$ w.h.p.

Modelos de Grafos Aleatorios

- 1 Introducción
- 2 Grafos Aleatorios
- 3 Configuration models**
- 4 Network-growth models
- 5 Modelos Small-world
- 6 Exponential random graph models

Modelos para redes reales

- Quizá la innovación más importante en los modelos modernos de grafos



Generalizando los grafos aleatorios

■ Receta para generalizar el modelo de Erdős-Renyi

⇒ Especificar \mathcal{G} conteniendo los grafos de orden N_v , pero que además posean cierta característica

⇒ Asignamos probabilidad uniforme para todos los grafos $G \in \mathcal{G}$

Generalizando los grafos aleatorios

- Receta para generalizar el modelo de Erdős-Renyi
 - ⇒ Especificar \mathcal{G} conteniendo los grafos de orden N_v , pero que además posean cierta característica
 - ⇒ Asignamos probabilidad uniforme para todos los grafos $G \in \mathcal{G}$
- ¿Con qué dato contamos sobre nuestra red?
 - Lo único que sabemos es la **cantidad media de vecinos c**
 - ⇒ $ER(n, c/n)$ parece una buena elección

Generalizando los grafos aleatorios

■ Receta para generalizar el modelo de Erdős-Renyi

⇒ Especificar \mathcal{G} conteniendo los grafos de orden N_v , pero que además posean cierta característica


⇒ Asignamos probabilidad uniforme para todos los grafos $G \in \mathcal{G}$

■ ¿Con qué dato contamos sobre nuestra red?

- Lo único que sabemos es la **cantidad media de vecinos c**

⇒ $ER(n, c/n)$ parece una buena elección

- ¿Y si sabemos la **secuencia o la distribución de grados**? ¿Siguen pareciendo?



Generalizando los grafos aleatorios

■ Receta para generalizar el modelo de Erdős-Renyi

⇒ Especificar \mathcal{G} conteniendo los grafos de orden N_v , pero que además posean cierta característica



⇒ Asignamos probabilidad uniforme para todos los grafos $G \in \mathcal{G}$

■ ¿Con qué dato contamos sobre nuestra red?

- Lo único que sabemos es la **cantidad media de vecinos c**

⇒ $ER(n, c/n)$ parece una buena elección

- ¿Y si sabemos la **secuencia o la distribución de grados**? ¿Sigue pareciendo?



Conectividad
entre
Autonomous
Systems
(ASs)

Generalizando los grafos aleatorios

■ Receta para generalizar el modelo de Erdős-Renyi

⇒ Especificar \mathcal{G} conteniendo los grafos de orden N_v , pero que además posean cierta característica



⇒ Asignamos probabilidad uniforme para todos los grafos $G \in \mathcal{G}$

■ ¿Con qué dato contamos sobre nuestra red?

- Lo único que sabemos es la **cantidad media de vecinos c**

⇒ $ER(n, c/n)$ parece una buena elección

- ¿Y si sabemos la **secuencia o la distribución de grados**? ¿Siguen pareciendo?



Actores que
comparten
películas en
IMdB

Generalizando los grafos aleatorios

■ Receta para generalizar el modelo de Erdős-Renyi

⇒ Especificar \mathcal{G} conteniendo los grafos de orden N_v , pero que además posean cierta característica



⇒ Asignamos probabilidad uniforme para todos los grafos $G \in \mathcal{G}$

■ ¿Con qué dato contamos sobre nuestra red?

- Lo único que sabemos es la **cantidad media de vecinos c**

⇒ $ER(n, c/n)$ parece una buena elección

- ¿Y si sabemos la **secuencia o la distribución de grados**? ¿Siguen pareciendo?



Conectividad
entre amigos
en Facebook

Generalizando los grafos aleatorios

■ Receta para generalizar el modelo de Erdős-Renyi

⇒ Especificar \mathcal{G} conteniendo los grafos de orden N_v , pero que además posean cierta característica




⇒ Asignamos probabilidad uniforme para todos los grafos $G \in \mathcal{G}$

■ ¿Con qué dato contamos sobre nuestra red?

- Lo único que sabemos es la **cantidad media de vecinos c**

⇒ $ER(n, c/n)$ parece una buena elección

- ¿Y si sabemos la **secuencia o la distribución de grados**? ¿Siguiendo pareciendo?



La WWW
según dos
datasets

Generalizando los grafos aleatorios


- **Configuration model:** secuencia de grados dada $\mathbf{d} = \{d_1, \dots, d_{N_v}\}$
 - El tamaño también queda dado bajo este modelo: $N_e = \sum_i d_i/2 = \bar{d}N_v/2 \Rightarrow \mathcal{G} \subset \mathcal{G}_{N_v, N_e}$
 - O sea, que es equivalente a especificar el modelo mediante una distribución condicional en \mathcal{G}_{N_v, N_e}

Generalizando los grafos aleatorios

- **Configuration model:** secuencia de grados dada $\mathbf{d} = \{d_1, \dots, d_{N_v}\}$
 - El tamaño también queda dado bajo este modelo: $N_e = \sum_i d_i/2 = \bar{d}N_v/2 \Rightarrow \mathcal{G} \subset \mathcal{G}_{N_v, N_e}$
 - O sea, que es equivalente a especificar el modelo mediante una distribución condicional en \mathcal{G}_{N_v, N_e}
- Modelos tipo configuration son útiles como ‘nulos’
 - Ej: comparar grafo observado G con $G' \in \mathcal{G}$ con power-law $P(d)$
- También son útiles para imponer restricciones de conectividad
 - Ej: La mayoría de los grafos no tienen nodos aislados


Simulando Configuration Models $CM_n(\mathbf{d})$

- **Matching algorithm.** Ejemplo: $\mathbf{d} = \{1, 2, 2, 2, 3\}$




Simulando Configuration Models $CM_n(\mathbf{d})$

- **Matching algorithm.** Ejemplo: $\mathbf{d} = \{1, 2, 2, 2, 3\}$



- **Switching algorithm.**



Simulando Configuration Models

- Muchas veces me interesa generar grafos con cierta distribución de grados $P(d)$
- Puedo sortear la secuencia $\mathbf{d} = \{d_1, d_2, \dots, N_v\}$ iid de $P(d)$

Simulando Configuration Models

- Muchas veces me interesa generar grafos con cierta distribución de grados $P(d)$
- Puedo sortear la secuencia $\mathbf{d} = \{d_1, d_2, \dots, N_v\}$ iid de $P(d)$
 - ¿Cualquier secuencia es válida?
 - ⇒ Al menos necesito que $\sum_i d_i$ sea par. ¿Qué más?

Simulando Configuration Models

- Muchas veces me interesa generar grafos con cierta distribución de grados $P(d)$
- Puedo sortear la secuencia $\mathbf{d} = \{d_1, d_2, \dots, N_v\}$ iid de $P(d)$
 - ¿Cualquier secuencia es válida?
 - ⇒ Al menos necesito que $\sum_i d_i$ sea par. ¿Qué más?
 - ⇒ Ejemplo: ¿ $\mathbf{d} = \{5, 3, 1, 1, 1, 1\}$ puede generar un grafo simple?

Simulando Configuration Models

- Muchas veces me interesa generar grafos con cierta distribución de grados $P(d)$
- Puedo sortear la secuencia $\mathbf{d} = \{d_1, d_2, \dots, N_v\}$ iid de $P(d)$
 - ¿Cualquier secuencia es válida?
 - ⇒ Al menos necesito que $\sum_i d_i$ sea par. ¿Qué más?
 - ⇒ Ejemplo: ¿ $\mathbf{d} = \{5, 3, 1, 1, 1, 1\}$ puede generar un grafo simple?
 - **Teorema de Erdős-Gallai** Condición necesaria y suficiente para que la secuencia sea gráfica: ser par y además

$$\underbrace{\sum_{i=1}^k d_i}_{\text{Semi-aristas de los primeros } k \text{ nodos}} \leq \underbrace{k(k-1)}_{\substack{2 \times \text{máximo número de} \\ \text{aristas entre } k \text{ nodos} \\ \text{(los } k \text{ interconectados)}}} + \underbrace{\sum_{i=k+1}^{N_v} \min(d_i, k)}_{\substack{\text{Máximo número de aristas} \\ \text{desde los nodos } i > k \\ \text{(los } k \text{ conectados hacia afuera)}}} \quad \forall 1 \leq k \leq N_v$$

con $d_1 \leq d_2 \leq \dots \leq d_{N_v}$

Simulando Configuration Models

- Muchas veces me interesa generar grafos con cierta distribución de grados $P(d)$
- Puedo sortear la secuencia $\mathbf{d} = \{d_1, d_2, \dots, N_v\}$ iid de $P(d)$
 - ¿Cualquier secuencia es válida?
 - ⇒ Al menos necesito que $\sum_i d_i$ sea par. ¿Qué más?
 - ⇒ Ejemplo: ¿ $\mathbf{d} = \{5, 3, 1, 1, 1, 1\}$ puede generar un grafo simple?
 - **Teorema de Erdős-Gallai** Condición necesaria y suficiente para que la secuencia sea gráfica: ser par y además

$$\underbrace{\sum_{i=1}^k d_i}_{\text{Semi-aristas de los primeros } k \text{ nodos}} \leq \underbrace{k(k-1)}_{\substack{2 \times \text{máximo número de} \\ \text{aristas entre } k \text{ nodos} \\ \text{(los } k \text{ interconectados)}}} + \underbrace{\sum_{i=k+1}^{N_v} \min(d_i, k)}_{\substack{\text{Máximo número de aristas} \\ \text{desde los nodos } i > k \\ \text{(los } k \text{ conectados hacia afuera)}}} \quad \forall 1 \leq k \leq N_v$$

con $d_1 \leq d_2 \leq \dots \leq d_{N_v}$

- Por suerte, no hace falta chequear esta condición para el algoritmo de matching

Simulando Configuration Models

- **Problema** Incluso si la secuencia $\mathbf{d} = \{d_1, d_2, \dots, d_{N_v}\}$ es gráfica, el algoritmo de matching puede generar **multi-aristas** y **loops**
 - ⇒ Borrémoslos del grafo resultante y llamemos a esta nueva secuencia $\mathbf{d}^{(er)}$ ⇒ típicamente $\mathbf{d} \neq \mathbf{d}^{(er)}$

Simulando Configuration Models

- **Problema** Incluso si la secuencia $\mathbf{d} = \{d_1, d_2, \dots, d_{N_v}\}$ es gráfica, el algoritmo de matching puede generar **multi-aristas** y **loops**

⇒ Borrémoslos del grafo resultante y llamemos a esta nueva secuencia $\mathbf{d}^{(er)}$ ⇒ típicamente $\mathbf{d} \neq \mathbf{d}^{(er)}$

- Por suerte, si $P(d)$ tiene media finita y $P(D \geq 1) = 1$ entonces

$$P \left(\sum_{d=1}^{N_v} |P^{(er)}(d) - P(d)| > \epsilon \right) \rightarrow 0$$

Simulando Configuration Models

- **Problema** Incluso si la secuencia $\mathbf{d} = \{d_1, d_2, \dots, d_{N_v}\}$ es gráfica, el algoritmo de matching puede generar **multi-aristas** y **loops**

⇒ Borrémoslos del grafo resultante y llamemos a esta nueva secuencia $\mathbf{d}^{(er)}$ ⇒ típicamente $\mathbf{d} \neq \mathbf{d}^{(er)}$

- Por suerte, si $P(d)$ tiene media finita y $P(D \geq 1) = 1$ entonces

$$P \left(\sum_{d=1}^{N_v} |P^{(er)}(d) - P(d)| > \epsilon \right) \rightarrow 0$$

- **Otro problema** ¿Pero $\text{CM}_n(\mathbf{d})$ genera al azar uniforme entre todos los que tiene secuencia de grados \mathbf{d} ?

Simulando Configuration Models

- **Problema** Incluso si la secuencia $\mathbf{d} = \{d_1, d_2, \dots, d_{N_v}\}$ es gráfica, el algoritmo de matching puede generar **multi-aristas** y **loops**

⇒ Borrémoslos del grafo resultante y llamemos a esta nueva secuencia $\mathbf{d}^{(er)}$ ⇒ típicamente $\mathbf{d} \neq \mathbf{d}^{(er)}$

- Por suerte, si $P(d)$ tiene media finita y $P(D \geq 1) = 1$ entonces

$$P\left(\sum_{d=1}^{N_v} |P^{(er)}(d) - P(d)| > \epsilon\right) \rightarrow 0$$

- **Otro problema** ¿Pero $\text{CM}_n(\mathbf{d})$ genera al azar uniforme entre todos los que tiene secuencia de grados \mathbf{d} ?

✓ Condicionado al evento $\{\text{CM}_n(\mathbf{d}) \text{ es un grafo simple}\}$

⇒ si además además $\text{Var}(D) < \infty$ entonces la probabilidad de obtener un grafo simple bajo $\text{CM}_n(\mathbf{d})$ converge en N_v a

$$e^{-\nu/2 - \nu^2/4} \text{ con } \nu = \mathbb{E}\{D(D-1)\}/\mathbb{E}\{D\}$$

Simulando Configuration Models

■ ¿Para qué sirve lo anterior?

- Quiero estudiar una propiedad de los grafos uniformes con secuencia de grados \mathbf{d} ($\text{UG}_n(\mathbf{d})$) del estilo

$$\lim_{n \rightarrow \infty} P(\text{UG}_n(\mathbf{d}) \in \mathcal{E}_n) \rightarrow 1$$

- Puedo hacer el siguiente razonamiento, y estudiar si $P(\text{CM}_n(\mathbf{d}) \in \mathcal{E}_n^c) \rightarrow 0$ (que es mucho más fácil)

$$\begin{aligned} P(\text{UG}_n(\mathbf{d}) \in \mathcal{E}_n^c) &= P(\text{CM}_n(\mathbf{d}) \in \mathcal{E}_n^c | \text{CM}_n(\mathbf{d}) \text{ simple}) \\ &= \frac{P(\text{CM}_n(\mathbf{d}) \in \mathcal{E}_n^c, \text{CM}_n(\mathbf{d}) \text{ simple})}{P(\text{CM}_n(\mathbf{d}) \text{ simple})} \\ &\leq \frac{P(\text{CM}_n(\mathbf{d}) \in \mathcal{E}_n^c)}{P(\text{CM}_n(\mathbf{d}) \text{ simple})} \rightarrow 0 \end{aligned}$$

Algunos Resultados de $CM_n(\mathbf{d})$

P1) Transición de fase en la **aparición de una componente gigante**

- Se puede hacer un análisis con ecuaciones diferenciales como hicimos para $ER(n, c/n)$
 - Hay que considerar el proceso dado por $A_t(j)$ (nodos activos de grado j), E_t (nodos explorados, lo que me interesa contar) y U_t (semi-aristas sin juntar)
- Componente gigante de tamaño $O(n)$ como en $ER(n, c/n)$
- Condición: $\nu = \mathbb{E}\{D(D-1)\}/\mathbb{E}\{D\} > 1$ (caso $ER(n, c/n)$ equivale a $c(1+c) > 2c$)

Algunos Resultados de $CM_n(\mathbf{d})$



P1) Transición de fase en la **aparición de una componente gigante**

- Se puede hacer un análisis con ecuaciones diferenciales como hicimos para $ER(n, c/n)$
 - Hay que considerar el proceso dado por $A_t(j)$ (nodos activos de grado j), E_t (nodos explorados, lo que me interesa contar) y U_t (semi-aristas sin juntar)
- Componente gigante de tamaño $O(n)$ como en $ER(n, c/n)$
- Condición: $\nu = \mathbb{E}\{D(D-1)\}/\mathbb{E}\{D\} > 1$ (caso $ER(n, c/n)$ equivale a $c(1+c) > 2c$)
 - **Intuitivamente**: necesito que el grado (menos uno) de un vecino del nodo sea mayor a 1

Algunos Resultados de $CM_n(\mathbf{d})$

P1) Transición de fase en la **aparición de una componente gigante**

- Se puede hacer un análisis con ecuaciones diferenciales como hicimos para $ER(n, c/n)$
 - Hay que considerar el proceso dado por $A_t(j)$ (nodos activos de grado j), E_t (nodos explorados, lo que me interesa contar) y U_t (semi-aristas sin juntar)
- Componente gigante de tamaño $O(n)$ como en $ER(n, c/n)$
- Condición: $\nu = \mathbb{E}\{D(D-1)\}/\mathbb{E}\{D\} > 1$ (caso $ER(n, c/n)$ equivale a $c(1+c) > 2c$)
 - **Intuitivamente:** necesito que el grado (menos uno) de un vecino del nodo sea mayor a 1




$$P(\text{grado del vecino} = j) = \frac{\sum_i d_i \mathbb{I}_{d_i=j}}{\sum_i d_i}$$

Algunos Resultados de $CM_n(\mathbf{d})$

P1) Transición de fase en la aparición de una componente gigante

- Se puede hacer un análisis con ecuaciones diferenciales como hicimos para $ER(n, c/n)$
 - Hay que considerar el proceso dado por $A_t(j)$ (nodos activos de grado j), E_t (nodos explorados, lo que me interesa contar) y U_t (semi-aristas sin juntar)
- Componente gigante de tamaño $O(n)$ como en $ER(n, c/n)$
- Condición: $\nu = \mathbb{E}\{D(D-1)\}/\mathbb{E}\{D\} > 1$ (caso $ER(n, c/n)$ equivale a $c(1+c) > 2c$)
 - **Intuitivamente:** necesito que el grado (menos uno) de un vecino del nodo sea mayor a 1




$$\begin{aligned} P(\text{grado del vecino} = j) &= \frac{\sum_i d_i \mathbb{I}_{d_i=j}}{\sum_i d_i} = \\ &= \frac{j \sum_i \mathbb{I}_{d_i=j}}{\sum_i d_i} = \frac{j n_j}{\sum_i i n_i} = \frac{j p_j}{\sum_i i p_i} \end{aligned}$$

Algunos Resultados de $CM_n(\mathbf{d})$

P1) Transición de fase en la aparición de una componente gigante

- Se puede hacer un análisis con ecuaciones diferenciales como hicimos para $ER(n, c/n)$
 - Hay que considerar el proceso dado por $A_t(j)$ (nodos activos de grado j), E_t (nodos explorados, lo que me interesa contar) y U_t (semi-aristas sin juntar)
- Componente gigante de tamaño $O(n)$ como en $ER(n, c/n)$
- Condición: $\nu = \mathbb{E}\{D(D-1)\}/\mathbb{E}\{D\} > 1$ (caso $ER(n, c/n)$ equivale a $c(1+c) > 2c$)
 - **Intuitivamente:** necesito que el grado (menos uno) de un vecino del nodo sea mayor a 1



$$\begin{aligned} P(\text{grado del vecino} = j) &= \frac{\sum_i d_i \mathbb{I}_{d_i=j}}{\sum_i d_i} = \\ &= \frac{j \sum_i \mathbb{I}_{d_i=j}}{\sum_i d_i} = \frac{j n_j}{\sum_i i n_i} = \frac{j p_j}{\sum_i i p_i} \\ \mathbb{E}\{\text{grado del vecino} - 1\} &= \sum_j (j-1) \frac{j p_j}{\sum_i i p_i} = \\ &= \frac{\mathbb{E}\{D(D-1)\}}{\mathbb{E}\{D\}} \end{aligned}$$

Algunos Resultados de $CM_n(\mathbf{d})$

P2) El clustering coefficient también se va a 0 como en $ER(n, c/n)$

Algunos Resultados de $CM_n(\mathbf{d})$

P2) El clustering coefficient también se va a 0 como en $ER(n, c/n)$

P3) Distancias típicas dependen de $P(d)$

- Si $Var(D) < \infty \Rightarrow$ distancias típicas de orden $O(\log_\nu n)$
- Caso particular de una power-law $P(d) \sim Cd^{-\alpha}$ con $\alpha \in (2, 3)$ (i.e. media finita y varianza infinita) \Rightarrow distancias típicas de orden $O(\log \log(n))$

Algunos Resultados de $CM_n(\mathbf{d})$

P2) El clustering coefficient también se va a 0 como en $ER(n, c/n)$

P3) Distancias típicas dependen de $P(d)$

- Si $Var(D) < \infty \Rightarrow$ distancias típicas de orden $O(\log_v n)$
- Caso particular de una power-law $P(d) \sim Cd^{-\alpha}$ con $\alpha \in (2, 3)$ (i.e. media finita y varianza infinita) \Rightarrow distancias típicas de orden $O(\log \log(n))$

P4) Se puede calcular cotas sobre el independence number de estos grafos analizando procesos de exploración mediante límites fluidos.

- Brightwell, Graham, Svante Janson, and Malwina Luczak. “The greedy independent set in a random graph with given degrees.” *Random Structures & Algorithms* 51, no. 4 (2017): 565-586.
- Bermolen, Paola, Matthieu Jonckheere, and Pascal Moyal. “The jamming constant of uniform random graphs.” *Stochastic Processes and their Applications* 127, no. 7 (2017): 2138-2178.

Aplicación 1: Indicadores Estadísticamente Significativos

- Consideremos un grafo G^{obs} que se obtuvo de una observación
- **Q:** Es el indicador estructural $\eta(G^{obs})$ **estadísticamente significativo**, i.e., inusual?
⇒ Para evaluar si es significativo se necesita un marco de referencia: un modelo nulo

Aplicación 1: Indicadores Estadísticamente Significativos

- Consideremos un grafo G^{obs} que se obtuvo de una observación
- **Q:** Es el indicador estructural $\eta(G^{obs})$ **estadísticamente significativo**, i.e., inusual?
 - ⇒ Para evaluar si es significativo se necesita un marco de referencia: un modelo nulo
 - ⇒ Es habitual usar grafos aleatorios como marco de referencia

Aplicación 1: Indicadores Estadísticamente Significativos

- Consideremos un grafo G^{obs} que se obtuvo de una observación
- **Q:** Es el indicador estructural $\eta(G^{obs})$ **estadísticamente significativo**, i.e., inusual?
 - ⇒ Para evaluar si es significativo se necesita un marco de referencia: un modelo nulo
 - ⇒ Es habitual usar grafos aleatorios como marco de referencia
- Definamos una colección \mathcal{G} , y comparemos $\eta(G^{obs})$ con los valores $\{\eta(G) : G \in \mathcal{G}\}$
 - ⇒ Más formalmente, construyamos una distribución de referencia

$$P_{\eta, \mathcal{G}}(t) = \frac{|\{G \in \mathcal{G} : \eta(G) \leq t\}|}{|\mathcal{G}|}$$

- Si $\eta(G^{obs})$ es suficientemente improbable bajo $P_{\eta, \mathcal{G}}(t)$
 - ⇒ Evidencia contra la hipótesis nula H_0 : G^{obs} es una muestra uniforme de \mathcal{G}

Ejemplo: club de karate de Zachary

- El club de karate de Zachary tiene coeficiente de clustering $cl(G^{obs}) = 0,2257$
⇒ Usemos grafos aleatorios para verificar si este es un valor inusual

Ejemplo: club de karate de Zachary

- El club de karate de Zachary tiene coeficiente de clustering $cl(G^{obs}) = 0,2257$
⇒ Usemos grafos aleatorios para verificar si este es un valor inusual
- Construimos dos referencias
 - 1) Conjunto \mathcal{G}_1 de grafos aleatorios con el mismo $N_v = 34$ y $N_e = 78$ (i.e. $ER(N_v, N_e)$)
 - 2) Agregar la restricción que los grafos en \mathcal{G}_2 tengan la misma secuencia de grados que G^{obs} (i.e. $CM_{N_v}(\mathbf{d})$)


Ejemplo: club de karate de Zachary

- El club de karate de Zachary tiene coeficiente de clustering $cl(G^{obs}) = 0,2257$
 - ⇒ Usemos grafos aleatorios para verificar si este es un valor inusual
- Construimos dos referencias
 - 1) Conjunto \mathcal{G}_1 de grafos aleatorios con el mismo $N_v = 34$ y $N_e = 78$ (i.e. $ER(N_v, N_e)$)
 - 2) Agregar la restricción que los grafos en \mathcal{G}_2 tengan la misma secuencia de grados que G^{obs} (i.e. $CM_{N_v}(\mathbf{d})$)
- $|\mathcal{G}_1| \approx 8,4 \times 10^{96}$ y $|\mathcal{G}_2|$ mucho más pequeño, pero igual enorme
 - ⇒ Hallar todos los grafos \mathcal{G}_1 o \mathcal{G}_2 para obtener las distribuciones $P_{\eta, \mathcal{G}_1}(t)$ o $P_{\eta, \mathcal{G}_2}(t)$ es imposible
- Alternativa: usa simulaciones para aproximar las distribuciones
 - ⇒ Generamos 10.000 muestras uniformes G de \mathcal{G}_1 y \mathcal{G}_2
 - ⇒ Calculamos $\eta(G) = cl(G)$ para cada muestra y graficamos los histogramas


Ejemplo: club de karate de Zachary (cont.)

- Gráfica de histogramas para aproximar la distribución

Mismo orden y tamaño



Misma secuencia de grados




- El valor $cl(G^{obs}) = 0,2257$ es muy poco probable para ambos modelos
Ej: solo 3 de las 10.000 muestras de \mathcal{G}_1 tenía $cl(G) > 0,2257$
- La evidencia nos hace concluir que G^{obs} no fue obtenida de una muestra uniforme en \mathcal{G}_1 o \mathcal{G}_2

Aplicación 2: Detectar motifs en grafos

- Otra aplicación de grafos aleatorios es la detección de **network motifs**
 - ⇒ Hallar las estructuras de las que se construye el grafo


Aplicación 2: Detectar motifs en grafos

- Otra aplicación de grafos aleatorios es la detección de **network motifs**
⇒ Hallar las estructuras de las que se construye el grafo
- **Def:** Network motifs son sub-grafos pequeños que ocurren mucho más frecuentemente en el grafo observado que en un grafo aleatorio comparable
- **Ej:** Hay $L_3 = 13$ grafos dirigidos (y conexos) distintos con $k = 3$ vértices



Aplicación 2: Detectar motifs en grafos


- Otra aplicación de grafos aleatorios es la detección de **network motifs**
 - ⇒ Hallar las estructuras de las que se construye el grafo
- **Def:** Network motifs son sub-grafos pequeños que ocurren mucho más frecuentemente en el grafo observado que en un grafo aleatorio comparable
- **Ej:** Hay $L_3 = 13$ grafos dirigidos (y conexos) distintos con $k = 3$ vértices



- Sea N_i^k el número de sub-grafos de k vértices del tipo i en G , $i = 1, \dots, L_k$
 - ⇒ Cada valor N_i^k puede compararse con referencia $P_{N_i, G}$
 - ⇒ Si N_i^k es extremo ⇒ sub-grafo es network motif

Ejemplo: red de blogs sobre SIDA

- Red de blogs sobre SIDA G^{obs} con $N_v = 146$ bloggers y $N_e = 183$ enlaces
⇒ Se buscan motifs con $k = 3$ and 4 vertices



- Se simulan 10.000 grafos dirigidos usando el algoritmo de switching
⇒ Se respetó la secuencia de grados de entrada y salida de G^{obs} , así como las aristas mutuas
⇒ Se estimaron distribuciones de referencia $P_{N_i, \mathcal{G}}(t)$

■ Ej: dos bloggers con una arista mutua y una ‘autoridad’ en común

Desafíos para detectar motifs

- Los motifs generalmente se intersectan con copias de sí mismos
 - ⇒ Un requisito extra puede ser que sean subgrafos **frecuentes** pero también **disjuntos**

Desafíos para detectar motifs

- Los motifs generalmente se intersectan con copias de sí mismos
 - ⇒ Un requisito extra puede ser que sean subgrafos **frecuentes** pero también **disjuntos**
- A medida que el grafo crece, los **desafíos computacionales** son cada vez mayores
 - ⇒ Por ejemplo, el número de potenciales motifs L_k crece muy rápidamente con k
Ej: Subgrafos dirigidos $L_3 = 13$, $L_4 = 199$, $L_5 = 9364$

Desafíos para detectar motifs

- Los motifs generalmente se intersectan con copias de sí mismos
 - ⇒ Un requisito extra puede ser que sean subgrafos **frecuentes** pero también **disjuntos**
- A medida que el grafo crece, los **desafíos computacionales** son cada vez mayores
 - ⇒ Por ejemplo, el número de potenciales motifs L_k crece muy rápidamente con k
Ej: Subgrafos dirigidos $L_3 = 13$, $L_4 = 199$, $L_5 = 9364$
- Una estrategia posible es **muestrear el grafo**

Modelos de Grafos Aleatorios

- 1 Introducción
- 2 Grafos Aleatorios
- 3 Configuration models
- 4 Network-growth models**
- 5 Modelos Small-world
- 6 Exponential random graph models

Redes Dinámicas

- Un buen modelo estadístico debería ser [Robbins-Morris'07]
 - ✓ Estimable a partir de y razonablemente representativo de los datos observados
 - ✓ Plausible teóricamente sobre los efectos que pueden haber producido la red
 - ✓ Capaz de discriminar entre los distintos efectos que mejor explican los datos

Redes Dinámicas

- Un buen modelo estadístico debería ser [Robbins-Morris'07]
 - ✓ Estimable a partir de y razonablemente representativo de los datos observados
 - ✓ Plausible teóricamente sobre los efectos que pueden haber producido la red
 - ✓ Capaz de discriminar entre los distintos efectos que mejor explican los datos
- El modelo $CM_n(\mathbf{d})$ puede generar grafos tomando en cuenta la distribución de grados, incluso varios casos de **power-law**
 - ¿Pero qué mecanismo lleva a esta configuración?
 - Modelos como el Preferential Attachment dan una explicación sencilla pero que brinda intuición

Redes Dinámicas

- Muchas redes **crecen** o al menos **evolucionan en el tiempo**

Ej: Web, citas científicas, Twitter, genoma ...

- Posible encare para modelos que imitan el crecimiento de un grafo

- Especificar mecanismos simples para la dinámica del grafo
- Estudiar las características estructurales que emergen a medida que el tiempo $t \rightarrow \infty$

- Q: Estas propiedades son las que se observan en grafos del mundo real?

Redes Dinámicas

- Muchas redes **crecen** o al menos **evolucionan en el tiempo**
Ej: Web, citas científicas, Twitter, genoma ...
- Posible **encare para modelos que imitan el crecimiento de un grafo**
 - Especificar mecanismos simples para la dinámica del grafo
 - Estudiar las características estructurales que emergen a medida que el tiempo $t \rightarrow \infty$
- **Q:** Estas propiedades son las que se observan en grafos del mundo real?
- Los dos métodos de este tipo más populares por lejos son
 - ⇒ Preferential attachment models
 - ⇒ Copying models
- **Mecanismos que pueden explicar popularidad y duplicación de genes respectivamente**

Preferential attachment model

- Modelo simple para la creación de, por ejemplo, enlaces entre páginas web
 - Los vértices se crean de a uno, y los notamos $1, \dots, N_v$

Preferential attachment model

- Modelo simple para la creación de, por ejemplo, enlaces entre páginas web
 - Los vértices se crean de a uno, y los notamos $1, \dots, N_v$
 - Cuando el nodo j es creado tiene un único enlace hacia i , $1 \leq i < j$

Preferential attachment model

- Modelo simple para la creación de, por ejemplo, enlaces entre páginas web
 - Los vértices se crean de a uno, y los notamos $1, \dots, N_v$
 - Cuando el nodo j es creado tiene un único enlace hacia i , $1 \leq i < j$
 - La creación del enlace (j, i) es aleatorio:
 - Con probabilidad p , j se conecta con i elegido uniforme al azar
 - Con probabilidad $1 - p$, j se conecta con i con probabilidad $\propto d_i^{in}$

Preferential attachment model

- Modelo simple para la creación de, por ejemplo, enlaces entre páginas web
 - Los vértices se crean de a uno, y los notamos $1, \dots, N_v$
 - Cuando el nodo j es creado tiene un único enlace hacia i , $1 \leq i < j$
 - La creación del enlace (j, i) es aleatorio:
 - Con probabilidad p , j se conecta con i elegido uniforme al azar
 - Con probabilidad $1 - p$, j se conecta con i con probabilidad $\propto d_i^{in}$
- El grafo resultante es dirigido, donde cada vértice tiene $d_v^{out} = 1$

Preferential attachment model

- Modelo simple para la creación de, por ejemplo, enlaces entre páginas web
 - Los vértices se crean de a uno, y los notamos $1, \dots, N_v$
 - Cuando el nodo j es creado tiene un único enlace hacia i , $1 \leq i < j$
 - La creación del enlace (j, i) es aleatorio:
 - Con probabilidad p , j se conecta con i elegido uniforme al azar
 - Con probabilidad $1 - p$, j se conecta con i con probabilidad $\propto d_i^{in}$
- El grafo resultante es dirigido, donde cada vértice tiene $d_v^{out} = 1$
- El modelo **preferential attachment** lleva a una dinámica de “rico se vuelve más rico”
 - ⇒ Los enlaces se forman preferentemente hacia los nodos que (actualmente) son los más populares
 - ⇒ La probabilidad de que el nodo i aumente su popularidad \propto a la popularidad actual del nodo i

Preferential attachment resulta en power laws

Teorema

El preferential attachment model resulta en una distribución de grados del tipo power-law con exponente $\alpha = 1 + \frac{1}{1-p}$, i.e.,

$$P(d^{in} = d) \propto d^{-(1 + \frac{1}{1-p})}$$

Preferential attachment resulta en power laws

Teorema

El preferential attachment model resulta en una distribución de grados del tipo power-law con exponente $\alpha = 1 + \frac{1}{1-p}$, i.e.,

$$P(d^{in} = d) \propto d^{-(1 + \frac{1}{1-p})}$$

- **La clave:** “ j se conecta con i con probabilidad $\propto d_i^{in}$ ” es básicamente **copiar**, i.e., “ j elige una arista uniforme al azar y copia su destino”, i.e., “copiar la decisión de otro nodo elegido uniforme al azar”
- **Importante:** Copiar las decisiones de otros vs. decisiones totalmente independientes en $ER(n, p)$ o $CM_n(\mathbf{d})$

Preferential attachment resulta en power laws

Teorema

El preferential attachment model resulta en una distribución de grados del tipo power-law con exponente $\alpha = 1 + \frac{1}{1-p}$, i.e.,

$$P(d^{in} = d) \propto d^{-(1 + \frac{1}{1-p})}$$

- **La clave:** “ j se conecta con i con probabilidad $\propto d_i^{in}$ ” es básicamente **copiar**, i.e., “ j elige una arista uniforme al azar y copia su destino”, i.e., “copiar la decisión de otro nodo elegido uniforme al azar”
- **Importante:** Copiar las decisiones de otros vs. decisiones totalmente independientes en $ER(n, p)$ o $CM_n(\mathbf{d})$
- A medida que $p \rightarrow 0 \Rightarrow$ La copia se vuelve más frecuente \Rightarrow Menor $\alpha \rightarrow 2$
 - **Intuitivamente:** mucho más probable encontrarse con páginas web extremadamente populares (colas más pesadas en la distribución de grados)

Aproximación Continua usando Límites Fluidos

- Grado entrante $d_i^{in}(t)$ del nodo i en tiempo $t \geq i$ es una **cadena de Markov**:
 - 1) **Condición inicial**: $d_i^{in}(i) = 0$ dado que el nodo i se crea en tiempo $t = i$
 - 2) **Dinámica**: $d_i^{in}(t)$ aumenta en uno con probabilidad (cf. hay t aristas creadas en tiempo t)

$$P((t+1, i) \in E) = p \times \frac{1}{t} + (1-p) \times \frac{d_i^{in}(t)}{t}$$

Aproximación Continua usando Límites Fluidos

- Grado entrante $d_i^{in}(t)$ del nodo i en tiempo $t \geq i$ es una **cadena de Markov**:
 - 1) **Condición inicial**: $d_i^{in}(i) = 0$ dado que el nodo i se crea en tiempo $t = i$
 - 2) **Dinámica**: $d_i^{in}(t)$ aumenta en uno con probabilidad (cf. hay t aristas creadas en tiempo t)

$$P((t+1, i) \in E) = p \times \frac{1}{t} + (1-p) \times \frac{d_i^{in}(t)}{t}$$

- Hagamos una aproximación por límite fluido como ya hicimos con $ER(n, c/n)$
 - Tiempo continuo $t \in [0, N_v]$
 - Los grados ahora son continuos e indexados por i : $x_i^{in}(t) : [i, N_v] \mapsto \mathbb{R}_+$

Aproximación Continua usando Límites Fluidos

■ Grado entrante $d_i^{in}(t)$ del nodo i en tiempo $t \geq i$ es una **cadena de Markov**:

- 1) **Condición inicial**: $d_i^{in}(i) = 0$ dado que el nodo i se crea en tiempo $t = i$
- 2) **Dinámica**: $d_i^{in}(t)$ aumenta en uno con probabilidad (cf. hay t aristas creadas en tiempo t)

$$P((t+1, i) \in E) = p \times \frac{1}{t} + (1-p) \times \frac{d_i^{in}(t)}{t}$$

■ Hagamos una aproximación por límite fluido como ya hicimos con ER($n, c/n$)

- Tiempo continuo $t \in [0, N_v]$
- Los grados ahora son continuos e indexados por i : $x_i^{in}(t) : [i, N_v] \mapsto \mathbb{R}_+$

■ Como siempre crece en uno, el **drift** resulta en la siguiente ecuación diferencial:

$$\frac{dx_i^{in}(t)}{dt} = \frac{p}{t} + \frac{(1-p)x_i^{in}(t)}{t}, \quad x_i^{in}(i) = 0$$

Resolviendo la ecuación diferencial

- La ecuación diferencial es (con $q = 1 - p$)

$$\frac{dx_i^{in}(t)}{dt} = \frac{p + qx_i^{in}(t)}{t}$$

Resolviendo la ecuación diferencial

- La ecuación diferencial es (con $q = 1 - p$)

$$\frac{dx_i^{in}(t)}{dt} = \frac{p + qx_i^{in}(t)}{t}$$

- Divido ambos lados por $p + qx_i^{in}(t)$ e integro en t

$$\int \frac{1}{p + qx_i^{in}} \frac{dx_i^{in}}{dt} dt = \int \frac{1}{t} dt$$

Resolviendo la ecuación diferencial

- La ecuación diferencial es (con $q = 1 - p$)

$$\frac{dx_i^{in}(t)}{dt} = \frac{p + qx_i^{in}(t)}{t}$$

- Divido ambos lados por $p + qx_i^{in}(t)$ e integro en t

$$\int \frac{1}{p + qx_i^{in}} \frac{dx_i^{in}}{dt} dt = \int \frac{1}{t} dt$$

- Resolviendo las integrales resulta (c es una constante)

$$\ln(p + qx_i^{in}) = q \ln(t) + c$$

Resolviendo la ecuación diferencial (cont.)

- Tomando exponentes y usando $K = e^c$ se obtiene

$$\ln(p + qx_i^{in}(t)) = q \ln(t) + c \Rightarrow x_i^{in}(t) = \frac{1}{q} (Kt^q - p)$$

Resolviendo la ecuación diferencial (cont.)

- Tomando exponentes y usando $K = e^c$ se obtiene

$$\ln(p + qx_i^{in}(t)) = q \ln(t) + c \Rightarrow x_i^{in}(t) = \frac{1}{q} (Kt^q - p)$$

- Para determinar la constante K usamos la condición inicial

$$0 = x_i^{in}(i) = \frac{1}{q} (Ki^q - p) \Rightarrow K = \frac{p}{i^q}$$

Resolviendo la ecuación diferencial (cont.)

- Tomando exponentes y usando $K = e^c$ se obtiene

$$\ln(p + qx_i^{in}(t)) = q \ln(t) + c \Rightarrow x_i^{in}(t) = \frac{1}{q} (Kt^q - p)$$

- Para determinar la constante K usamos la condición inicial

$$0 = x_i^{in}(i) = \frac{1}{q} (Ki^q - p) \Rightarrow K = \frac{p}{i^q}$$

- Y finalmente el límite fluido de $d_i^{in}(t)$ resulta

$$x_i^{in}(t) = \frac{1}{q} \left(\frac{p}{i^q} \times t^q - p \right) = \frac{p}{q} \left[\left(\frac{t}{i} \right)^q - 1 \right]$$

¿Y la distribución de grados?

■ **Q:** En tiempo t qué fracción $\bar{F}(d)$ de los nodos tiene grado $\geq d$?

En términos del límite fluido: ¿Qué fracción de las funciones cumple $x_i^{in}(t) \geq d$ en tiempo t ?

$$x_i^{in}(t) = \frac{p}{q} \left[\left(\frac{t}{i} \right)^q - 1 \right] \geq d$$

¿Y la distribución de grados?

- **Q:** En tiempo t qué fracción $\bar{F}(d)$ de los nodos tiene grado $\geq d$?

En términos del límite fluido: ¿Qué fracción de las funciones cumple $x_i^{in}(t) \geq d$ en tiempo t ?

$$x_i^{in}(t) = \frac{p}{q} \left[\left(\frac{t}{i} \right)^q - 1 \right] \geq d$$

- Se puede re-escribir en términos de i como

$$i \leq t \left[\left(\frac{q}{p} \right) d + 1 \right]^{-1/q}$$

¿Y la distribución de grados?

- **Q:** En tiempo t qué fracción $\bar{F}(d)$ de los nodos tiene grado $\geq d$?

En términos del límite fluido: ¿Qué fracción de las funciones cumple $x_i^{in}(t) \geq d$ en tiempo t ?

$$x_i^{in}(t) = \frac{p}{q} \left[\left(\frac{t}{i} \right)^q - 1 \right] \geq d$$

- Se puede re-escribir en términos de i como

$$i \leq t \left[\left(\frac{q}{p} \right) d + 1 \right]^{-1/q}$$

- En tiempo t hay exactamente t nodos en el grafo, así que la fracción es

$$\bar{F}(d) = \left[\left(\frac{q}{p} \right) d + 1 \right]^{-1/q} = 1 - F(d)$$

¿Y la distribución de grados?

- La distribución de grados está dada por la PDF $P(d)$
- Recordemos que la PDF, la CDF y la CCDF tienen la siguiente relación

$$p(x) = \frac{dF(x)}{dx} = -\frac{d\bar{F}(x)}{dx}$$

¿Y la distribución de grados?

- La distribución de grados está dada por la PDF $P(d)$
- Recordemos que la PDF, la CDF y la CCDF tienen la siguiente relación

$$p(x) = \frac{dF(x)}{dx} = -\frac{d\bar{F}(x)}{dx}$$

- Tomando la derivada de $\bar{F}(d) = \left[\left(\frac{q}{p}\right) d + 1\right]^{-1/q}$ resulta

$$P(d) = \frac{1}{p} \left[\left(\frac{q}{p}\right) d + 1\right]^{-\left(1+\frac{1}{q}\right)}$$

⇒ “Mostramos” que $P(d) \propto d^{-(1+1/q)}$, una distribución tipo power law con exponente $\alpha = 1 + \frac{1}{1-p}$

Modelo de Barabási-Albert

- El modelo de **Barabási-Albert (BA)** es para grafos no-dirigidos
- El grafo inicial $G_{BA}(0)$ tiene $N_v(0)$ vértices y $N_e(0)$ aristas ($t = 0$)

Modelo de Barabási-Albert

- El modelo de **Barabási-Albert (BA)** es para grafos no-dirigidos
- El grafo inicial $G_{BA}(0)$ tiene $N_v(0)$ vértices y $N_e(0)$ aristas ($t = 0$)
- Para $t = 1, 2, \dots$ el grafo actual $G_{BA}(t - 1)$ “crece” a $G_{BA}(t)$:
 - Se agrega un vertice u de grado $d_u(t) = m \geq 1$
 - Las m aristas nuevas son incidentes a m vértices diferentes en $G_{BA}(t - 1)$
 - El nuevo vertice u se conecta a $v \in V(t - 1)$ con probabilidad

$$P((u, v) \in E(t)) = \frac{d_v(t - 1)}{\sum_{v'} d_{v'}(t - 1)}$$

- El nuevo vértice prefiere nodos con grado más alto
- A. Barabási and R. Albert, “Emergence of scaling in random networks,” *Science*, vol. 286, pp. 509-512, 1999

Linearized Chord Diagram

- El modelo de BA tiene varios problemas formales (y no tanto):
 - No se especifica el grafo inicial
 - El número de aristas medio es 1 y no m
 - Se sortea un grupo de m vértices, pero no se dan las marginales de cada nodo
- El **Linearized chord diagram (LCD)** model (y otros) elimina estas ambigüedades

Linearized Chord Diagram

- El modelo de BA tiene varios problemas formales (y no tanto):
 - No se especifica el grafo inicial
 - El número de aristas medio es 1 y no m
 - Se sortea un grupo de m vértices, pero no se dan las marginales de cada nodo
- El **Linearized chord diagram (LCD)** model (y otros) elimina estas ambigüedades
- Para $m = 1$, se comienza con $G_{LCD}(0)$: un único nodo con un self-loop

Linearized Chord Diagram

- El modelo de BA tiene varios problemas formales (y no tanto):
 - No se especifica el grafo inicial
 - El número de aristas medio es 1 y no m
 - Se sortea un grupo de m vértices, pero no se dan las marginales de cada nodo
- El **Linearized chord diagram (LCD)** model (y otros) elimina estas ambigüedades
- Para $m = 1$, se comienza con $G_{LCD}(0)$: un único nodo con un self-loop
- Para $t = 1, 2, \dots$ el grafo $G_{LCD}(t-1)$ “crece” a $G_{LCD}(t)$:
 - Se agrega un vértice v_t con una arista hacia $v_s \in V(t)$
 - El vértice destino v_s , $1 \leq s \leq t$ se elige con probabilidad

$$P(s = j) = \begin{cases} \frac{d_{v_j}(t-1)}{2t-1}, & \text{si } 1 \leq j \leq t-1, \\ \frac{1}{2t-1}, & \text{si } j = t \end{cases}$$

Linearized Chord Diagram

- El modelo de BA tiene varios problemas formales (y no tanto):
 - No se especifica el grafo inicial
 - El número de aristas medio es 1 y no m
 - Se sortea un grupo de m vértices, pero no se dan las marginales de cada nodo
- El **Linearized chord diagram (LCD)** model (y otros) elimina estas ambigüedades
- Para $m = 1$, se comienza con $G_{LCD}(0)$: un único nodo con un self-loop
- Para $t = 1, 2, \dots$ el grafo $G_{LCD}(t-1)$ “crece” a $G_{LCD}(t)$:
 - Se agrega un vértice v_t con una arista hacia $v_s \in V(t)$
 - El vértice destino v_s , $1 \leq s \leq t$ se elige con probabilidad

$$P(s = j) = \begin{cases} \frac{d_{v_j}(t-1)}{2t-1}, & \text{si } 1 \leq j \leq t-1, \\ \frac{1}{2t-1}, & \text{si } j = t \end{cases}$$

- Para $m > 1$ simplemente se repite lo anterior m veces en cada t
 - Los m vértices creados se “colapsan” en un único vértice, manteniendo las aristas
- A. Bollobás et al, “The degree sequence of a scale-free random graph process,”
Random Struct. and Alg., vol. 18, pp. 279-290, 2001

Algunas propiedades del modelo PA

- P1) Cuando $t \rightarrow \infty$, $G_{LCD}(t)$ tiene distribución de grados tipo **power-law** con $\alpha = 3$
- \Rightarrow Se genera $\alpha = 3 + \delta/m > 2$ agregando un bias $\delta > -m$ a las probabilidades
 - \Rightarrow Ver Remco van der Hofstad, “Random Graphs and Complex Networks. Volume One.” Cambridge Series in Statistical and Probabilistic Mathematics (2017)

Algunas propiedades del modelo PA

- P1) Cuando $t \rightarrow \infty$, $G_{LCD}(t)$ tiene distribución de grados tipo **power-law** con $\alpha = 3$
- \Rightarrow Se genera $\alpha = 3 + \delta/m > 2$ agregando un bias $\delta > -m$ a las probabilidades
 - \Rightarrow Ver Remco van der Hofstad, “Random Graphs and Complex Networks. Volume One.” Cambridge Series in Statistical and Probabilistic Mathematics (2017)
- P2) El grafo $G_{LCD}(t)$ es **conexo w.h.p.**

Algunas propiedades del modelo PA

- P1) Cuando $t \rightarrow \infty$, $G_{LCD}(t)$ tiene distribución de grados tipo **power-law** con $\alpha = 3$
⇒ Se genera $\alpha = 3 + \delta/m > 2$ agregando un bias $\delta > -m$ a las probabilidades
⇒ Ver Remco van der Hofstad, “Random Graphs and Complex Networks. Volume One.” Cambridge Series in Statistical and Probabilistic Mathematics (2017)
- P2) El grafo $G_{LCD}(t)$ es **conexo w.h.p.**
- P3) **Diámetro pequeño**

$$\text{diam}(G_{LCD}(t)) = \begin{cases} O(\log N_v(t)), & m = 1 \\ O\left(\frac{\log N_v(t)}{\log \log N_v(t)}\right), & m > 1 \end{cases}$$

Algunas propiedades del modelo PA

- P1) Cuando $t \rightarrow \infty$, $G_{LCD}(t)$ tiene distribución de grados tipo **power-law** con $\alpha = 3$
 \Rightarrow Se genera $\alpha = 3 + \delta/m > 2$ agregando un bias $\delta > -m$ a las probabilidades
 \Rightarrow Ver Remco van der Hofstad, "Random Graphs and Complex Networks. Volume One." Cambridge Series in Statistical and Probabilistic Mathematics (2017)
- P2) El grafo $G_{LCD}(t)$ es **conexo w.h.p.**
- P3) **Diámetro pequeño**

$$\text{diam}(G_{LCD}(t)) = \begin{cases} O(\log N_v(t)), & m = 1 \\ O\left(\frac{\log N_v(t)}{\log \log N_v(t)}\right), & m > 1 \end{cases}$$

- P4) **Clustering pequeño**, pues para $m > 1$

$$\mathbb{E}[\text{cl}(G_{LCD}(t))] \approx \frac{m-1}{8} \frac{(\log N_v(t))^2}{N_v(t)}$$

\Rightarrow Apenas mejor que el $O(N_v^{-1})$ de los grafos aleatorios clásicos

Modelos de copia

- La **copia** es otro mecanismo de interés

Ej: la duplicación de genes para re-usar información en la evolución de organismos

- Ya vimos que **copiar lleva distribuciones tipo power law**

- Preferential Attachment genera $\alpha > 2$, pero muchas redes biológicas tienen $1 < \alpha < 2$
- Copiar **varias** decisiones de otro nodo puede generar esos exponentes

Modelos de copia

- La **copia** es otro mecanismo de interés

Ej: la duplicación de genes para re-usar información en la evolución de organismos

- Ya vimos que **copiar lleva distribuciones tipo power law**

- Preferential Attachment genera $\alpha > 2$, pero muchas redes biológicas tienen $1 < \alpha < 2$
- Copiar **varias** decisiones de otro nodo puede generar esos exponentes

- Inicializo con el grafo $G_C(0)$ ($t = 0$)

Modelos de copia

- La **copia** es otro mecanismo de interés

Ej: la duplicación de genes para re-usar información en la evolución de organismos

- Ya vimos que **copiar lleva distribuciones tipo power law**

- Preferential Attachment genera $\alpha > 2$, pero muchas redes biológicas tienen $1 < \alpha < 2$
- Copiar **varias** decisiones de otro nodo puede generar esos exponentes

- Inicializo con el grafo $G_C(0)$ ($t = 0$)

- Para $t = 1, 2, \dots$ el grafo actual $G_C(t - 1)$ “crece” a $G_C(t)$:

- Agregar un vértice nuevo u
- Elegir otro vértice $v \in V(t - 1)$ aleatorio uniforme (i.e. con proba $\frac{1}{N_v(t-1)}$)
- Unir el nuevo vértice u con los vecinos de v independiente con probabilidad p


Modelos de copia

- La **copia** es otro mecanismo de interés
 - Ej: la duplicación de genes para re-usar información en la evolución de organismos
- Ya vimos que **copiar lleva distribuciones tipo power law**
 - Preferential Attachment genera $\alpha > 2$, pero muchas redes biológicas tienen $1 < \alpha < 2$
 - Copiar **varias** decisiones de otro nodo puede generar esos exponentes
- Inicializo con el grafo $G_C(0)$ ($t = 0$)
- Para $t = 1, 2, \dots$ el grafo actual $G_C(t - 1)$ “crece” a $G_C(t)$:
 - Agregar un vértice nuevo u
 - Elegir otro vértice $v \in V(t - 1)$ aleatorio uniforme (i.e. con proba $\frac{1}{N_v(t-1)}$)
 - Unir el nuevo vértice u con los vecinos de v independiente con probabilidad p
- El caso $p = 1$ lleva a **copiar totalmente** las aristas de un nodo pre-existente
- F. Chung et al, “Duplication models for biological networks,” *Journal of Computational Biology*, vol. 10, pp. 677-687, 2003

Distribución de grados asintótica

- La distribución de grados tiende a una power law w.h.p. [Chung et al'03]
⇒ El exponente α en la curva es la solución de la ecuación

$$p(\alpha - 1) = 1 - p^{\alpha-1}$$



- Duplicación total ($p = 1$) no genera power-law; aunque sí lo hace si
⇒ se copia parcialmente una fracción $q \in (0, 1)$ de veces

Modelos de Grafos Aleatorios

- 1 Introducción
- 2 Grafos Aleatorios
- 3 Configuration models
- 4 Network-growth models
- 5 Modelos Small-world**
- 6 Exponential random graph models

¿Un mundo pequeño?

- **Seis grados de separación** se volvió popular a partir de una obra de teatro [Guare'90]
 - ⇒ Caminos cortos entre nosotros y cualquiera en el mundo
 - ⇒ El término es relativamente nuevo, no así el concepto

¿Un mundo pequeño?

- **Seis grados de separación** se volvió popular a partir de una obra de teatro [Guare'90]
 - ⇒ Caminos cortos entre nosotros y cualquiera en el mundo
 - ⇒ El término es relativamente nuevo, no así el concepto
- El escritor húngaro Frigyes Karinthy lo describe en uno de sus cuentos de 1929
 - ⇒ El mundo moderno se está 'achicando' debido al aumento en la conectividad humana
 - ⇒ **Apuesta** que puede encontrar a cualquier persona usando no más de 5 individuos, siendo uno de ellos un conocido suyo, y todos usando su red contactos personales

¿Un mundo pequeño?

- **Seis grados de separación** se volvió popular a partir de una obra de teatro [Guare'90]
 - ⇒ Caminos cortos entre nosotros y cualquiera en el mundo
 - ⇒ El término es relativamente nuevo, no así el concepto
- El escritor húngaro Frigyes Karinthy lo describe en uno de sus cuentos de 1929
 - ⇒ El mundo moderno se está 'achicando' debido al aumento en la conectividad humana
 - ⇒ **Apuesta** que puede encontrar a cualquier persona usando no más de 5 individuos, siendo uno de ellos un conocido suyo, y todos usando su red contactos personales
- Primer tratamiento matemático en [Kochen-Pool'50]
 - ⇒ Modela formalmente los mecanismos de las redes sociales
 - ⇒ **Pero la cuestión de los 'grados de separación' quedó sin responder**

¿Un mundo pequeño?


- **Seis grados de separación** se volvió popular a partir de una obra de teatro [Guare'90]
 - ⇒ Caminos cortos entre nosotros y cualquiera en el mundo
 - ⇒ El término es relativamente nuevo, no así el concepto
- El escritor húngaro Frigyes Karinthy lo describe en uno de sus cuentos de 1929
 - ⇒ El mundo moderno se está 'achicando' debido al aumento en la conectividad humana
 - ⇒ **Apuesta** que puede encontrar a cualquier persona usando no más de 5 individuos, siendo uno de ellos un conocido suyo, y todos usando su red contactos personales
- Primer tratamiento matemático en [Kochen-Pool'50]
 - ⇒ Modela formalmente los mecanismos de las redes sociales
 - ⇒ **Pero la cuestión de los 'grados de separación' quedó sin responder**
 - ⇒ Este trabajo a su vez inspira el famoso experimento en [Milgram'67]
- Mucha más info e historia en Schnettler, Sebastian. "A structured overview of 50 years of small-world research." Social networks 31, no. 3 (2009).

Experimento de Milgram

- **Q1:** ¿Cuál es la distancia típica entre dos personas?
 - ⇒ La idea es medirlo en la red social (global) de amistades
 - ⇒ Dado que no puedo obtener la red completa, es necesario estimar las distancias

Experimento de Milgram

- **Q1:** ¿Cuál es la distancia típica entre dos personas?
 - ⇒ La idea es medirlo en la red social (global) de amistades
 - ⇒ Dado que no puedo obtener la red completa, es necesario estimar las distancias
- La (muy ingeniosa) solución de S. Milgram en su famoso experimento de 1967
 - Se enviaron 296 cartas a personas en Wichita, Kansas y Omaha, Nebraska
 - Las cartas indicaban una (única) persona de **contacto** en Boston, Massachusetts
 - Las instrucciones eran hacer llegar la carta al contacto siguiendo las siguientes **reglas**



Experimento de Milgram


- **Q1:** ¿Cuál es la distancia típica entre dos personas?
 - ⇒ La idea es medirlo en la red social (global) de amistades
 - ⇒ Dado que no puedo obtener la red completa, es necesario estimar las distancias
- La (muy ingeniosa) solución de S. Milgram en su famoso experimento de 1967
 - Se enviaron 296 cartas a personas en Wichita, Kansas y Omaha, Nebraska
 - Las cartas indicaban una (única) persona de **contacto** en Boston, Massachusetts
 - Las instrucciones eran hacer llegar la carta al contacto siguiendo las siguientes **reglas**

- **Amigo:** alguien que tratamos por nombre de pila

Regla 1: Si el contacto es un amigo, enviarlo al amigo; sino


Regla 2: Re-enviarlo al amigo que más probablemente sea amigo del contacto

- **Q2:** ¿Cuántas llegaron? ¿Cuánto demoraron?



Resultados del experimento de Milgram



- 64 de las 296 cartas llegaron al destino, con un largo promedio de $\bar{\ell} = 6,2$
⇒ Esto a su vez inspiró la obra de Guare
- **Conclusión:** caminos cortos conectan dos personas cualesquiera



- S. Milgram, "The small-world problem," *Psychology Today*, vol. 2, pp. 60-67, 1967


¿Qué pasa acá?

- Milgram muestra que los caminos cortos existen y en abundancia
- Q: ¿Es la teoría del mundo pequeño razonable? Por supuesto si asumimos:
 - Tenemos 100 amigos, cada cual con **otros** 100 amigos, ...
 - Después de 5 grados tenemos 10^{10} personas > doble de la población de la Tierra




¿Qué pasa acá?

- Milgram muestra que los caminos cortos existen y en abundancia
- Q: ¿Es la teoría del mundo pequeño razonable? Por supuesto si asumimos:
 - Tenemos 100 amigos, cada cual con **otros** 100 amigos, ...
 - Después de 5 grados tenemos 10^{10} personas > doble de la población de la Tierra




- No parece un modelo razonable para una red social, que típicamente es:
 - ⇒ Homofilia [Lazarzfeld'54]
 - ⇒ Abundantes triángulos cerrados [Rapoport'53]
- Q: ¿Una red **muy estructurada localmente** y **globalmente pequeña**? ¿Cómo?

Estructura y aleatoriedad como extremos




High clustering and diameter




Low clustering and diameter

- **Lattice regular uni-dimensional** G_r de N_v vértices
 - Cada vértice está conectado a sus $2r$ vecinos más cercanos (r a cada lado)

Estructura y aleatoriedad como extremos



High clustering and diameter



Low clustering and diameter


■ Lattice regular uni-dimensional G_r de N_v vértices

- Cada vértice está conectado a sus $2r$ vecinos más cercanos (r a cada lado)


Tanta estructura resulta en clustering alto, pero también en un diámetro alto

$$\text{cl}(G_r) = \frac{3r - 3}{4r - 2} \text{ y } \text{diam}(G_r) = \frac{N_v}{2r}$$

Estructura y aleatoriedad como extremos



High clustering and diameter



Low clustering and diameter

- **Lattice regular uni-dimensional** G_r de N_v vértices

- Cada vértice está conectado a sus $2r$ vecinos más cercanos (r a cada lado)

Tanta estructura resulta en clustering alto, pero también en un diámetro alto

$$\text{cl}(G_r) = \frac{3r - 3}{4r - 2} \text{ y } \text{diam}(G_r) = \frac{N_v}{2r}$$


- El otro extremo es un grafo aleatorio $\text{ER}(N_v, p)$ con $p = O(N_v^{-1})$

Ya vimos que esta aleatoriedad genera un diámetro pequeño, pero un bajo clustering

$$\text{cl}(G_{N_v, p}) = O(N_v^{-1}) \text{ y } \text{diam}(G_{N_v, p}) = O(\log N_v)$$

El modelo Watts-Strogatz


- **Small-world model:** mezcla estructura con una pizca de aleatoriedad
 - 1: Inicializamos con un lattice regular que tenga el clustering buscado
 - 2: La aleatoriedad se genera introduciendo atajos en el grafo
 - ⇒ Cada arista se re-conecta aleatoriamente con probabilidad (pequeña) p



- La reconexión interpola entre los extremos **regular** y **puramente aleatorio**

Resultados numéricos

- Simulación del modelo Watts-Strogatz con $N_v = 1,000$ y $r = 6$
 - Probabilidad de reconexión p variando de 0 (lattice G_r) a 1 ($ER(N_v, 2r/N_v)$)
 - $cl(G)$ y $diam(G)$ normalizados respecto al valor máximo ($p = 0$)



- Intervalo importante de $p \in [10^{-3}, 10^{-1}]$ resulta en $diam(G)$ pequeño y $cl(G)$ grande

El modelo Watts-Strogatz

■ Propiedades estructurales del modelo de Watts-Strogatz

P1: Para N_v grande el clustering coefficient resulta

$$cl(G) \approx \frac{3r-3}{4r-2}(1-p^3) = cl(G_r)(1-p^3)$$

P2: La distribución de grados se concentra alrededor de su media $2r$

El modelo Watts-Strogatz

- Propiedades estructurales del modelo de Watts-Strogatz

P1: Para N_v grande el clustring coefficient resulta

$$\text{cl}(G) \approx \frac{3r-3}{4r-2}(1-p^3) = \text{cl}(G_r)(1-p^3)$$

P2: La distribución de grados se concentra alrededor de su media $2r$

- Los modelos y propiedades tipo small-world son importantes en varias disciplinas
- Particularmente en “comunicación” en el sentido amplio
 - ⇒ Dispersión de rumores, chismes, noticias (falsas)
 - ⇒ Dispersión de enfermedades y epidemias
 - ⇒ Búsqueda de información en redes

Modelos de Grafos Aleatorios

- 1 Introducción
- 2 Grafos Aleatorios
- 3 Configuration models
- 4 Network-growth models
- 5 Modelos Small-world
- 6 Exponential random graph models**

Exponential random graph models

- Un buen modelo estadístico debería ser [Robbins-Morris'07]
 - ✓ Estimable a partir de y razonablemente representativo de los datos observados
 - ✓ Plausible teóricamente sobre los efectos que pueden haber producido la red
 - ✓ Capaz de discriminar entre los distintos efectos que mejor explican los datos

Exponential random graph models

- Un buen modelo estadístico debería ser [Robbins-Morris'07]
 - ✓ Estimable a partir de y razonablemente representativo de los datos observados
 - ✓ Plausible teóricamente sobre los efectos que pueden haber producido la red
 - ✓ Capaz de discriminar entre los distintos efectos que mejor explican los datos
- Los modelos del tipo **Exponential random graph models (ERGMs)** (también conocidos como **p^* models**) se diseñaron específicamente con estos criterios en mente
- G. Robbins et al., “An introduction to exponential random graph (p^*) models for social networks,” *Social Networks*, vol. 29, pp. 173-191, 2007

Distribuciones exponenciales

- **Def:** Un vector aleatorio discreto $\mathbf{Z} \in \mathcal{Z}$ pertenece a la familia de las **exponenciales** si

$$P_{\theta}(\mathbf{Z} = \mathbf{z}) = \exp \left\{ \boldsymbol{\theta}^{\top} \mathbf{g}(\mathbf{z}) - \psi(\boldsymbol{\theta}) \right\}$$

- $\boldsymbol{\theta} \in \mathbb{R}^p$ es un vector de parámetros y $\mathbf{g} : \mathcal{Z} \mapsto \mathbb{R}^p$ es una función
- $\psi(\boldsymbol{\theta})$ es simplemente para normalizar, mateniendo $\sum_{\mathbf{z} \in \mathcal{Z}} P_{\theta}(\mathbf{z}) = 1$
- **Ej:** Bernoulli, binomial, Poisson, geométrica

Distribuciones exponenciales

- **Def:** Un vector aleatorio discreto $\mathbf{Z} \in \mathcal{Z}$ pertenece a la familia de las **exponenciales** si

$$P_{\theta}(\mathbf{Z} = \mathbf{z}) = \exp \left\{ \boldsymbol{\theta}^{\top} \mathbf{g}(\mathbf{z}) - \psi(\boldsymbol{\theta}) \right\}$$

- $\boldsymbol{\theta} \in \mathbb{R}^p$ es un vector de parámetros y $\mathbf{g} : \mathcal{Z} \mapsto \mathbb{R}^p$ es una función
 - $\psi(\boldsymbol{\theta})$ es simplemente para normalizar, manteniendo $\sum_{\mathbf{z} \in \mathcal{Z}} P_{\theta}(\mathbf{z}) = 1$
 - **Ej:** Bernoulli, binomial, Poisson, geométrica
- Las distribuciones continuas tienen una forma similar
Ej: gaussiana, Pareto, chi-cuadrado
- Estas distribuciones comparten propiedades algebraicas y geométricas útiles
 \Rightarrow Las hace matemáticamente conveniente para inferencia y simulación

Exponential random graph model

- Sea $G(V, E)$ un **grafo aleatorio no-dirigido**, con $Y_{ij} := \mathbb{I}\{(i, j) \in E\}$
 - La matriz $\mathbf{Y} = [Y_{ij}]$ es la de adyacencia (aleatoria), $\mathbf{y} = [y_{ij}]$ una realización

Exponential random graph model

- Sea $G(V, E)$ un **grafo aleatorio no-dirigido**, con $Y_{ij} := \mathbb{I}\{(i, j) \in E\}$
 - La matriz $\mathbf{Y} = [Y_{ij}]$ es la de adyacencia (aleatoria), $\mathbf{y} = [y_{ij}]$ una realización
- Un ERGM especifica una forma exponencial para la distribución de \mathbf{Y} , i.e.,

$$P_{\theta}(\mathbf{Y} = \mathbf{y}) = \left(\frac{1}{\kappa(\boldsymbol{\theta})} \right) \exp \left\{ \sum_H \theta_H g_H(\mathbf{y}) \right\}, \quad \text{donde}$$

- (i) cada H es una **configuración**: un conjunto posible de aristas en G ;
- (ii) $g_H(\mathbf{y})$ es el **estadístico de red** correspondiente a la configuración H

$$g_H(\mathbf{y}) = \prod_{y_{ij} \in H} y_{ij} = \mathbb{I}\{H \text{ está en } \mathbf{y}\}$$

- (iii) $\theta_H \neq 0$ solo si las aristas de H son **condicionalmente dependientes**; y
- (iv) $\kappa(\boldsymbol{\theta})$ es una constante normalizadora que mantiene $\sum_{\mathbf{y}} P_{\theta}(\mathbf{y}) = 1$

Discusión

- Los vértices del grafo N_v y su orden están fijos y dados, sólo las aristas son aleatorias
⇒ Asumimos aristas no-dirigidas y sin pesos. Extensiones posibles

Discusión

- Los vértices del grafo N_v y su orden están fijos y dados, sólo las aristas son aleatorias
⇒ Asumimos aristas no-dirigidas y sin pesos. Extensiones posibles
- ERGMs describen el grafo aleatorio a partir de patrones locales
 - Estas configuraciones son las características estructurales de interés
 - Ej: ¿Hay efectos de reciprocidad? Agregar arcos mutuos en las configuraciones
 - Ej: ¿Hay efectos de transitividad? Agreguemos triángulos

Discusión

- Los vértices del grafo N_v y su orden están fijos y dados, sólo las aristas son aleatorias
⇒ Asumimos aristas no-dirigidas y sin pesos. Extensiones posibles
- ERGMs describen el grafo aleatorio a partir de patrones locales
 - Estas configuraciones son las características estructurales de interés
 - Ej: ¿Hay efectos de reciprocidad? Agregar arcos mutuos en las configuraciones
 - Ej: ¿Hay efectos de transitividad? Agreguemos triángulos
- La (in)dependencia es condicional en todas las otras variables (aristas) en G
⇒ Se controla las configuraciones relevantes (i.e., $\theta_H \neq 0$) para el modelo
- Ciertas dependencias implican modelos particulares

¿Cómo construir un modelo?

- Al usar un ERGM para una red los pasos son básicamente los siguientes
 - ⇒ Cuidado: hay varias decisiones explícitas que tienen un fuerte impacto
 - Paso 1:** Cada arista (relación) es una variable aleatoria
 - Paso 2:** Se propone una hipótesis de dependencia
 - Paso 3:** La hipótesis de dependencia implica una forma particular para el modelo
 - Paso 4:** El modelo se simplifica, e.g., a través de la homogeneización
 - Paso 5:** Estimar e interpretar los resultados

Ejemplo: grafos aleatorios de Bernoulli

- Hipótesis: cada arista está presente independientemente de todas las demás (e.g., $ER(n, p)$)
⇒ La hipótesis más simple (e irrealista) de dependencia

Ejemplo: grafos aleatorios de Bernoulli

- Hipótesis: cada arista está presente independientemente de todas las demás (e.g., $ER(n, p)$)
⇒ La hipótesis más simple (e irrealista) de dependencia
- Para cada (i, j) , suponemos Y_{ij} independiente de Y_{uv} , para todo $(u, v) \neq (i, j)$
⇒ $\theta_H = 0$ para todo H que involucre dos o más aristas
- Sólo la configuración de arista, i.e., $g_H(\mathbf{y}) = y_{ij}$, es relevante, y el ERGM resulta

$$P_{\theta}(\mathbf{Y} = \mathbf{y}) = \left(\frac{1}{\kappa(\boldsymbol{\theta})} \right) \exp \left\{ \sum_{i,j} \theta_{ij} y_{ij} \right\}$$

Ejemplo: grafos aleatorios de Bernoulli

- Hipótesis: cada arista está presente independientemente de todas las demás (e.g., $ER(n, p)$)
⇒ La hipótesis más simple (e irrealista) de dependencia
- Para cada (i, j) , suponemos Y_{ij} independiente de Y_{uv} , para todo $(u, v) \neq (i, j)$
⇒ $\theta_H = 0$ para todo H que involucre dos o más aristas
- Sólo la configuración de arista, i.e., $g_H(\mathbf{y}) = y_{ij}$, es relevante, y el ERGM resulta

$$P_{\theta}(\mathbf{Y} = \mathbf{y}) = \left(\frac{1}{\kappa(\boldsymbol{\theta})} \right) \exp \left\{ \sum_{i,j} \theta_{ij} y_{ij} \right\}$$

⇒ Cada arista existe de forma independiente con probabilidad $\propto e^{\theta_{ij}}$ y no existe con probabilidad $\propto 1$

$$\Rightarrow p_{ij} = \frac{\exp(\theta_{ij})}{1 + \exp(\theta_{ij})}$$

Restricción de los parámetros: homogeneidad

- Demasiado parámetros hacen la estimación a partir de un único \mathbf{y} imposible
⇒ En este caso, tenemos N_v^2 parámetros $\{\theta_{ij}\}$. ¡Reducción?

Restricción de los parámetros: homogeneidad

- Demasiado parámetros hacen la estimación a partir de un único \mathbf{y} imposible
⇒ En este caso, tenemos N_v^2 parámetros $\{\theta_{ij}\}$. ¡Reducción?
- **Homogeneidad** en G , i.e., $\theta_{ij} = \theta$ para todo (i, j) resulta en

$$P_{\theta}(\mathbf{Y} = \mathbf{y}) = \left(\frac{1}{\kappa(\boldsymbol{\theta})} \right) \exp \{ \theta L(\mathbf{y}) \}$$

- El estadístico suficiente en este caso es el número de aristas observadas $L(\mathbf{y}) = \sum_{i,j} y_{ij}$
- Este ejemplo de ERGM resulta en un $ER(n, p)$, con $p = \frac{\exp \theta}{1 + \exp \theta}$

Restricción de los parámetros: homogeneidad

- Demasiado parámetros hacen la estimación a partir de un único \mathbf{y} imposible

⇒ En este caso, tenemos N_v^2 parámetros $\{\theta_{ij}\}$. ¡Reducción?

- **Homogeneidad** en G , i.e., $\theta_{ij} = \theta$ para todo (i, j) resulta en

$$P_{\theta}(\mathbf{Y} = \mathbf{y}) = \left(\frac{1}{\kappa(\boldsymbol{\theta})} \right) \exp \{ \theta L(\mathbf{y}) \}$$

- El estadístico suficiente en este caso es el número de aristas observadas $L(\mathbf{y}) = \sum_{i,j} y_{ij}$
- Este ejemplo de ERGM resulta en un $ER(n, p)$, con $p = \frac{\exp \theta}{1 + \exp \theta}$

- **Otro ejemplo:** sabemos a priori que hay dos tipos de nodos y cuáles son

⇒ Podemos imponer homogeneidad en las aristas intra e inter-conjuntos, i.e.,

$$P_{\theta}(\mathbf{Y} = \mathbf{y}) = \left(\frac{1}{\kappa(\boldsymbol{\theta})} \right) \exp \{ \theta_1 L_1(\mathbf{y}) + \theta_{12} L_{12}(\mathbf{y}) + \theta_2 L_2(\mathbf{y}) \}$$

Más ejemplos: Markov random graphs

- **Dependencia tipo Markov** para grafos [Frank-Strauss'86]
 - Asumimos que dos aristas son dependientes si comparten un vértice
 - La existencia de la arista (Y_{ij}) depende de todas las otras aristas que involucren i o j
 - **Intuición:** Los amigos de dos personas nos dicen mucho sobre si son amigos o no

Más ejemplos: Markov random graphs

■ Dependencia tipo Markov para grafos [Frank-Strauss'86]


- Asumimos que dos aristas son dependientes si comparten un vértice
- La existencia de la arista (Y_{ij}) depende de todas las otras aristas que involucren i o j
- **Intuición:** Los amigos de dos personas nos dicen mucho sobre si son amigos o no

Teorema

Suponiendo homogeneidad, G es un Markov random graph sii

$$P_{\theta}(\mathbf{Y} = \mathbf{y}) = \left(\frac{1}{\kappa(\theta)} \right) \exp \left\{ \sum_{k=1}^{N_v-1} \theta_k S_k(\mathbf{y}) + \theta_{\tau} T(\mathbf{y}) \right\}, \text{ donde}$$

$S_k(\mathbf{y})$ es el número de k -estrellas, y $T(\mathbf{y})$ el número de triángulos



Estadísticos Alternativos

- Incluir términos para k alto es claramente un desafío
 - ⇒ Solución típica: efectos de las estrellas grandes se omiten, e.g., $\theta_k = 0$, $k \geq 4$
 - ⇒ Pero esto resulta en modelos que ajustan pobremente los datos. ¿Qué hacemos?

Estadísticos Alternativos

- Incluir términos para k alto es claramente un desafío
 - ⇒ Solución típica: efectos de las estrellas grandes se omiten, e.g., $\theta_k = 0$, $k \geq 4$
 - ⇒ Pero esto resulta en modelos que ajustan pobremente los datos. ¿Qué hacemos?
- **Idea:** Tomemos una forma paramétrica para $\theta_k \propto (-1)^k \lambda^{2-k}$ [Snijders et al'06]
 - Combinamos $S_k(\mathbf{y})$, $k \geq 2$ en un único estadístico denominado **alternating k -star**, i.e.,

$$\text{AKS}_\lambda(\mathbf{y}) = \sum_{k=2}^{N_v-1} (-1)^k \frac{S_k(\mathbf{y})}{\lambda^{k-2}}, \quad \lambda > 1$$

Estadísticos Alternativos

- Incluir términos para k alto es claramente un desafío
 - ⇒ Solución típica: efectos de las estrellas grandes se omiten, e.g., $\theta_k = 0$, $k \geq 4$
 - ⇒ Pero esto resulta en modelos que ajustan pobremente los datos. ¿Qué hacemos?
- **Idea:** Tomemos una forma paramétrica para $\theta_k \propto (-1)^k \lambda^{2-k}$ [Snijders et al'06]
 - Combinamos $S_k(\mathbf{y})$, $k \geq 2$ en un único estadístico denominado **alternating k -star**, i.e.,

$$\text{AKS}_\lambda(\mathbf{y}) = \sum_{k=2}^{N_v-1} (-1)^k \frac{S_k(\mathbf{y})}{\lambda^{k-2}}, \quad \lambda > 1$$

- Se puede probar que $\text{AKS}_\lambda(\mathbf{y}) \propto$ la **media exponencial de grados**

$$\text{GWD}_\gamma(\mathbf{y}) = \sum_{d=0}^{N_v-1} e^{-\gamma d} N_d(\mathbf{y}), \quad \gamma > 0$$

⇒ $N_d(\mathbf{y})$ es el número de vértices de grado d

Incorporando atributos de los vértices

- Es relativamente sencillo incorporar atributos de los vértices a los ERGMs

Ej: género, jerarquía en la organización, función dentro del sistema

Incorporando atributos de los vértices

- Es relativamente sencillo incorporar atributos de los vértices a los ERGMs


Ej: género, jerarquía en la organización, función dentro del sistema

- Tomamos una realización \mathbf{x} de un vector aleatorio $\mathbf{X} \in \mathbb{R}^{N_v}$ definido en V
- Especificamos una familia exponencial para la **distribución condicional**

$$P_{\theta}(\mathbf{Y} = \mathbf{y} \mid \mathbf{X} = \mathbf{x})$$

⇒ Se incluyen estadísticas adicionales $g(\cdot)$ sobre \mathbf{y} y \mathbf{x}

- Ej: configuraciones para Markov, con atributos binarios



Estimación de los parámetros del ERGM

- MLE para el vector $\boldsymbol{\theta}$ en un ERGM es

$$\hat{\boldsymbol{\theta}} = \arg \max_{\boldsymbol{\theta}} \left\{ \boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y}) - \psi(\boldsymbol{\theta}) \right\}, \quad \text{donde } \psi(\boldsymbol{\theta}) := \log \kappa(\boldsymbol{\theta})$$

Estimación de los parámetros del ERGM

- MLE para el vector $\boldsymbol{\theta}$ en un ERGM es

$$\hat{\boldsymbol{\theta}} = \arg \max_{\boldsymbol{\theta}} \left\{ \boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y}) - \psi(\boldsymbol{\theta}) \right\}, \quad \text{donde } \psi(\boldsymbol{\theta}) := \log \kappa(\boldsymbol{\theta})$$

- Pero $\psi(\boldsymbol{\theta})$ implica la suma de $2^{\binom{N_v}{2}}$ posibles valores de \mathbf{y} para cada posible $\boldsymbol{\theta}$
 \Rightarrow Se necesitan métodos numéricos para aproximarlos

Estimación de los parámetros del ERGM

- MLE para el vector $\boldsymbol{\theta}$ en un ERGM es

$$\hat{\boldsymbol{\theta}} = \arg \max_{\boldsymbol{\theta}} \left\{ \boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y}) - \psi(\boldsymbol{\theta}) \right\}, \quad \text{donde } \psi(\boldsymbol{\theta}) := \log \kappa(\boldsymbol{\theta})$$

- Pero $\psi(\boldsymbol{\theta})$ implica la suma de $2^{\binom{N_v}{2}}$ posibles valores de \mathbf{y} para cada posible $\boldsymbol{\theta}$
 \Rightarrow Se necesitan métodos numéricos para aproximarlos

- **Idea:** para valores fijos $\boldsymbol{\theta}_0$, maximizar log-likelihood ratio

$$r(\boldsymbol{\theta}, \boldsymbol{\theta}_0) = \ell(\boldsymbol{\theta}) - \ell(\boldsymbol{\theta}_0) = (\boldsymbol{\theta} - \boldsymbol{\theta}_0)^\top \mathbf{g}(\mathbf{y}) - [\psi(\boldsymbol{\theta}) - \psi(\boldsymbol{\theta}_0)]$$

- **Identidad clave:** (ver transparencias al final)

$$\exp \{ \psi(\boldsymbol{\theta}) - \psi(\boldsymbol{\theta}_0) \} = \mathbb{E}_{\boldsymbol{\theta}_0} \left[\exp \{ (\boldsymbol{\theta} - \boldsymbol{\theta}_0)^\top \mathbf{g}(\mathbf{Y}) \} \right]$$

Markov chain Monte Carlo MLE

- En limpio: para valores fijos θ_0 , maximizar log-likelihood ratio

$$r(\theta, \theta_0) = (\theta - \theta_0)^\top \mathbf{g}(\mathbf{y}) - \log (\mathbb{E}_{\theta_0} [\exp \{(\theta - \theta_0)^\top \mathbf{g}(\mathbf{Y})\}])$$

Markov chain Monte Carlo MLE

- **En limpio:** para valores fijos $\boldsymbol{\theta}_0$, maximizar **log-likelihood ratio**

$$r(\boldsymbol{\theta}, \boldsymbol{\theta}_0) = (\boldsymbol{\theta} - \boldsymbol{\theta}_0)^\top \mathbf{g}(\mathbf{y}) - \log(\mathbb{E}_{\boldsymbol{\theta}_0}[\exp\{(\boldsymbol{\theta} - \boldsymbol{\theta}_0)^\top \mathbf{g}(\mathbf{Y})\}])$$

- **Markov chain Monte Carlo MLE para buscar $\boldsymbol{\theta}$**

Paso 1: obtener muestras $\mathbf{y}_1, \dots, \mathbf{y}_n$ del ERGM usando $\boldsymbol{\theta}_0$

Paso 2: aproximar $\mathbb{E}_{\boldsymbol{\theta}_0}[\cdot]$ a través de la media de los $\exp\{(\boldsymbol{\theta} - \boldsymbol{\theta}_0)^\top \mathbf{g}(\mathbf{y}_k)\}$

Paso 3: aproximar $\psi(\boldsymbol{\theta}) - \psi(\boldsymbol{\theta}_0)$ mediante el logaritmo de lo anterior

Paso 4: evaluar el log-likelihood ratio $r(\boldsymbol{\theta}, \boldsymbol{\theta}_0)$ aproximado

Estimación de los parámetros del ERGM revisited

- MLE para el vector $\boldsymbol{\theta}$ en un ERGM es

$$\hat{\boldsymbol{\theta}} = \arg \max_{\boldsymbol{\theta}} \left\{ \boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y}) - \psi(\boldsymbol{\theta}) \right\}, \quad \text{donde } \psi(\boldsymbol{\theta}) := \log \kappa(\boldsymbol{\theta})$$

Estimación de los parámetros del ERGM revisited

- MLE para el vector $\boldsymbol{\theta}$ en un ERGM es

$$\hat{\boldsymbol{\theta}} = \arg \max_{\boldsymbol{\theta}} \left\{ \boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y}) - \psi(\boldsymbol{\theta}) \right\}, \quad \text{donde } \psi(\boldsymbol{\theta}) := \log \kappa(\boldsymbol{\theta})$$

- Derivando e igualando a cero

$$\mathbf{g}(\mathbf{y}) = \nabla \psi(\boldsymbol{\theta})|_{\boldsymbol{\theta}=\hat{\boldsymbol{\theta}}}$$

- ¿Cambiamos una expresión horrible por su derivada?

Estimación de los parámetros del ERGM revisited

- MLE para el vector $\boldsymbol{\theta}$ en un ERGM es

$$\hat{\boldsymbol{\theta}} = \arg \max_{\boldsymbol{\theta}} \left\{ \boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y}) - \psi(\boldsymbol{\theta}) \right\}, \quad \text{donde } \psi(\boldsymbol{\theta}) := \log \kappa(\boldsymbol{\theta})$$

- Derivando e igualando a cero

$$\mathbf{g}(\mathbf{y}) = \nabla \psi(\boldsymbol{\theta})|_{\boldsymbol{\theta}=\hat{\boldsymbol{\theta}}}$$

- ¿Cambiamos una expresión horrible por su derivada?

- Usando que $\mathbb{E}_{\boldsymbol{\theta}}[\mathbf{g}(\mathbf{Y})] = \nabla \psi(\boldsymbol{\theta})$ (ver slides al final), el MLE es la solución de

$$\mathbb{E}_{\hat{\boldsymbol{\theta}}}[\mathbf{g}(\mathbf{Y})] = \mathbf{g}(\mathbf{y})$$

que puede resolverse usando el método clásico de Robbins y Monro

Evaluación de un modelo

- **Mejor ajuste** elegido de una cierta clase de modelos . . .

Evaluación de un modelo

- **Mejor ajuste** elegido de una cierta clase de modelos . . . pero puede ser un **mal ajuste** a los datos si la **clase de modelos no es suficientemente rica**

Evaluación de un modelo

- **Mejor ajuste** elegido de una cierta clase de modelos . . . pero puede ser un **mal ajuste** a los datos si la **clase de modelos no es suficientemente rica**

- ¿Cómo evaluamos un modelo (ERGM)?

Paso 1: simulamos muchas realizaciones de grafos aleatorios bajo el modelo ajustado

Paso 2: comparamos características de alto nivel con el G^{obs}

Ej: distribución de grados, centralidad, diámetro

- Si hay diferencias significativas con G^{obs} , concluimos

⇒ El modelo es incapaz de expresar los datos

⇒ **Lamentablemente no se han desarrollado indicadores de bondad de ajuste (goodness-of-fit)**

Evaluación de un modelo

- **Mejor ajuste** elegido de una cierta clase de modelos . . . pero puede ser un **mal ajuste** a los datos si la **clase de modelos no es suficientemente rica**

- ¿Cómo evaluamos un modelo (ERGM)?

Paso 1: simulamos muchas realizaciones de grafos aleatorios bajo el modelo ajustado

Paso 2: comparamos características de alto nivel con el G^{obs}

Ej: distribución de grados, centralidad, diámetro

- Si hay diferencias significativas con G^{obs} , concluimos

⇒ El modelo es incapaz de expresar los datos


⇒ **Lamentablemente no se han desarrollado indicadores de bondad de ajuste (goodness-of-fit)**

- **Importante:** especificar el modelo para los ERGMs es difícil (y muy importante)

⇒ Si bien ERGM tiene limitaciones matemáticas importantes, ilustra varios aspectos importantes de modelado estadístico

Ejemplo: red de colaboración de abogados

- Grafo G^{obs} de relaciones laborales entre abogados [Lazega'01]
 - Los nodos son $N_v = 36$ “partners”, y las aristas indican si trabajaron juntos



- Además, se incluye varios atributos de cada nodo:
 - Antigüedad (la etiqueta indica el orden en el ranking)
 - Ubicación de la oficina (triángulo, cuadrado o pentágono)
 - Tipo de práctica, i.e., litigación (rojo) o corporativa (cían)
 - Género (sólo tres partners son femeninas, etiquetadas con 27, 29 y 34)
- **Objetivo:** estudiar la cooperación entre actores sociales en una organización

Modelo para la red de colaboración de abogados

- Evaluación del efecto de la red: usemos $S_1(\mathbf{y}) = N_e$ y el alternating k -triangles

$$\text{AKT}_\lambda(\mathbf{y}) = 3T_1(\mathbf{y}) + \sum_{k=2}^{N_v-2} (-1)^{k+1} \frac{T_k(\mathbf{y})}{\lambda^{k-1}}$$

⇒ similar al TKS, pero $T_k(\mathbf{y})$ cuenta cuántas veces k triángulos comparten una base

Modelo para la red de colaboración de abogados

- Evaluación del **efecto de la red**: usemos $S_1(\mathbf{y}) = N_e$ y el alternating k -triangles

$$\text{AKT}_\lambda(\mathbf{y}) = 3T_1(\mathbf{y}) + \sum_{k=2}^{N_v-2} (-1)^{k+1} \frac{T_k(\mathbf{y})}{\lambda^{k-1}}$$

⇒ similar al TKS, pero $T_k(\mathbf{y})$ cuenta cuántas veces k triángulos comparten una base

- Testear los siguientes **efectos exógenos**:

$$h^{(1)}(\mathbf{x}_i, \mathbf{x}_j) = \text{antigüedad}_i + \text{antigüedad}_j, \quad h^{(2)}(\mathbf{x}_i, \mathbf{x}_j) = \text{práctica}_i + \text{práctica}_j$$

$$h^{(3)}(\mathbf{x}_i, \mathbf{x}_j) = \mathbb{I} \{ \text{práctica}_i = \text{práctica}_j \}, \quad h^{(4)}(\mathbf{x}_i, \mathbf{x}_j) = \mathbb{I} \{ \text{género}_i = \text{género}_j \}$$

$$h^{(5)}(\mathbf{x}_i, \mathbf{x}_j) = \mathbb{I} \{ \text{oficina}_i = \text{oficina}_j \}, \quad \mathbf{h}(\mathbf{x}_i, \mathbf{x}_j) := [h^{(1)}(\mathbf{x}_i, \mathbf{x}_j), \dots, h^{(5)}(\mathbf{x}_i, \mathbf{x}_j)]^T$$

Modelo para la red de colaboración de abogados

- Evaluación del efecto de la red: usemos $S_1(\mathbf{y}) = N_e$ y el alternating k -triangles

$$\text{AKT}_\lambda(\mathbf{y}) = 3T_1(\mathbf{y}) + \sum_{k=2}^{N_v-2} (-1)^{k+1} \frac{T_k(\mathbf{y})}{\lambda^{k-1}}$$

⇒ similar al TKS, pero $T_k(\mathbf{y})$ cuenta cuántas veces k triángulos comparten una base

- Testear los siguientes efectos exógenos:

$$h^{(1)}(\mathbf{x}_i, \mathbf{x}_j) = \text{antigüedad}_i + \text{antigüedad}_j, \quad h^{(2)}(\mathbf{x}_i, \mathbf{x}_j) = \text{práctica}_i + \text{práctica}_j$$

$$h^{(3)}(\mathbf{x}_i, \mathbf{x}_j) = \mathbb{I}\{\text{práctica}_i = \text{práctica}_j\}, \quad h^{(4)}(\mathbf{x}_i, \mathbf{x}_j) = \mathbb{I}\{\text{género}_i = \text{género}_j\}$$

$$h^{(5)}(\mathbf{x}_i, \mathbf{x}_j) = \mathbb{I}\{\text{oficina}_i = \text{oficina}_j\}, \quad \mathbf{h}(\mathbf{x}_i, \mathbf{x}_j) := [h^{(1)}(\mathbf{x}_i, \mathbf{x}_j), \dots, h^{(5)}(\mathbf{x}_i, \mathbf{x}_j)]^T$$

- ERGM resultante

$$\mathbb{P}_{\theta, \beta}(\mathbf{Y} = \mathbf{y} | \mathbf{X} = \mathbf{x}) = \frac{1}{\kappa(\theta, \beta)} \exp \left\{ \theta_1 S_1(\mathbf{y}) + \theta_2 \text{AKT}_\lambda(\mathbf{y}) + \beta^T \mathbf{g}(\mathbf{y}, \mathbf{x}) \right\}$$

$$\mathbf{g}(\mathbf{y}, \mathbf{x}) = \sum_{i,j} y_{ij} \mathbf{h}(\mathbf{x}_i, \mathbf{x}_j)$$

Resultado del ajuste

- Resultados del ajuste usando el método de MCMC MLE

Parameter	Estimate	'Standard Error'
Density (θ_1)	-6.2073	0.5697
Alternating k -triangles (θ_2)	0.5909	0.0882
Seniority Main Effect (β_1)	0.0245	0.0064
Practice Main Effect (β_2)	0.3945	0.1103
Same Practice (β_3)	0.7721	0.1973
Same Gender (β_4)	0.7302	0.2495
Same Office (β_5)	1.1614	0.1952

⇒ Errores estándar obtenidos de manera **heurística**

- Se pueden identificar varios factores que incrementan la probabilidad de cooperación

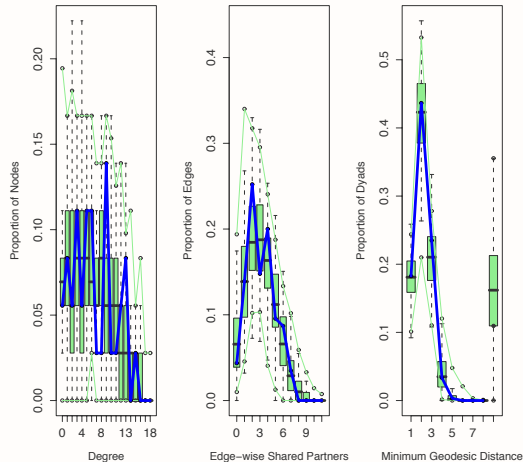
Ej: misma práctica, género y lugar de la oficina duplican las chances

- Gran evidencia de transitividad dado que $\hat{\theta}_2 \gg \text{se}(\hat{\theta}_2)$

⇒ **Homofilia ya está tomada en cuenta, por lo que hay algo que no tuvimos en cuenta que explica esto**

“Goodness-of-fit”

- Evaluemos el modelo respecto a G^{obs}
 - Tomemos muestras del ERGM ajustado
- Comparamos la distribución de
 - Grados
 - Número de vecinos en común
 - Distancia
- Las gráficas muestran un buen ajuste



Anexo 1: Propiedad clave

- Recordemos que $\exp \psi(\boldsymbol{\theta}) = \sum_{\mathbf{y}} \exp \{ \boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y}) \}$ para escribir

$$\exp \{ \psi(\boldsymbol{\theta}) - \psi(\boldsymbol{\theta}_0) \} = \frac{\sum_{\mathbf{y}} \exp \{ \boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y}) \}}{\exp \psi(\boldsymbol{\theta}_0)}$$

Anexo 1: Propiedad clave

- Recordemos que $\exp \psi(\boldsymbol{\theta}) = \sum_{\mathbf{y}} \exp \{ \boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y}) \}$ para escribir

$$\exp \{ \psi(\boldsymbol{\theta}) - \psi(\boldsymbol{\theta}_0) \} = \frac{\sum_{\mathbf{y}} \exp \{ \boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y}) \}}{\exp \psi(\boldsymbol{\theta}_0)}$$

- Multiplicando y dividiendo entre $\exp \{ \boldsymbol{\theta}_0^\top \mathbf{g}(\mathbf{y}) \} > 0$ resulta en

$$\begin{aligned} \exp \{ \psi(\boldsymbol{\theta}) - \psi(\boldsymbol{\theta}_0) \} &= \sum_{\mathbf{y}} \exp \{ (\boldsymbol{\theta} - \boldsymbol{\theta}_0)^\top \mathbf{g}(\mathbf{y}) \} \times \frac{\exp \{ \boldsymbol{\theta}_0^\top \mathbf{g}(\mathbf{y}) \}}{\exp \psi(\boldsymbol{\theta}_0)} \\ &= \sum_{\mathbf{y}} \exp \{ (\boldsymbol{\theta} - \boldsymbol{\theta}_0)^\top \mathbf{g}(\mathbf{y}) \} P_{\boldsymbol{\theta}_0}(\mathbf{Y} = \mathbf{y}) \\ &= \mathbb{E}_{\boldsymbol{\theta}_0} [\exp \{ (\boldsymbol{\theta} - \boldsymbol{\theta}_0)^\top \mathbf{g}(\mathbf{Y}) \}] \end{aligned}$$

- Se usó que $\exp \{ \boldsymbol{\theta}_0^\top \mathbf{g}(\mathbf{y}) - \psi(\boldsymbol{\theta}_0) \}$ es la densidad de las exponenciales $P_{\boldsymbol{\theta}_0}(\mathbf{Y} = \mathbf{y})$

Anexo 2: prueba de $\mathbb{E}[g(\mathbf{Y})] = \nabla\psi(\theta)$

- La densidad de \mathbf{Y} es $P_{\theta}(\mathbf{Y} = \mathbf{y}) = \exp\{\boldsymbol{\theta}^{\top} \mathbf{g}(\mathbf{y}) - \psi(\theta)\}$, por lo que

$$\begin{aligned}\mathbb{E}_{\theta}[g(\mathbf{Y})] &= \sum_{\mathbf{y}} g(\mathbf{y})P_{\theta}(\mathbf{Y} = \mathbf{y}) \\ &= \sum_{\mathbf{y}} g(\mathbf{y}) \exp\{\boldsymbol{\theta}^{\top} \mathbf{g}(\mathbf{y}) - \psi(\theta)\}\end{aligned}$$

Anexo 2: prueba de $\mathbb{E}[g(\mathbf{Y})] = \nabla\psi(\theta)$

- La densidad de \mathbf{Y} es $P_\theta(\mathbf{Y} = \mathbf{y}) = \exp\{\boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y}) - \psi(\theta)\}$, por lo que

$$\begin{aligned}\mathbb{E}_\theta[g(\mathbf{Y})] &= \sum_{\mathbf{y}} g(\mathbf{y})P_\theta(\mathbf{Y} = \mathbf{y}) \\ &= \sum_{\mathbf{y}} g(\mathbf{y}) \exp\{\boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y}) - \psi(\theta)\}\end{aligned}$$

- Recordemos que $\psi(\boldsymbol{\theta}) = \log \sum_{\mathbf{y}} \exp\{\boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y})\}$ y usando la regla de la cadena

$$\begin{aligned}\nabla\psi(\boldsymbol{\theta}) &= \frac{\sum_{\mathbf{y}} g(\mathbf{y}) \exp\{\boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y})\}}{\sum_{\mathbf{y}} \exp\{\boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y})\}} = \frac{\sum_{\mathbf{y}} g(\mathbf{y}) \exp\{\boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y})\}}{\exp\psi(\theta)} \\ &= \sum_{\mathbf{y}} g(\mathbf{y}) \exp\{\boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y}) - \psi(\theta)\}\end{aligned}$$

Anexo 2: prueba de $\mathbb{E}[g(\mathbf{Y})] = \nabla\psi(\theta)$

- La densidad de \mathbf{Y} es $P_\theta(\mathbf{Y} = \mathbf{y}) = \exp\{\boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y}) - \psi(\theta)\}$, por lo que

$$\begin{aligned}\mathbb{E}_\theta[g(\mathbf{Y})] &= \sum_{\mathbf{y}} g(\mathbf{y})P_\theta(\mathbf{Y} = \mathbf{y}) \\ &= \sum_{\mathbf{y}} g(\mathbf{y}) \exp\{\boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y}) - \psi(\theta)\}\end{aligned}$$

- Recordemos que $\psi(\boldsymbol{\theta}) = \log \sum_{\mathbf{y}} \exp\{\boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y})\}$ y usando la regla de la cadena

$$\begin{aligned}\nabla\psi(\boldsymbol{\theta}) &= \frac{\sum_{\mathbf{y}} g(\mathbf{y}) \exp\{\boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y})\}}{\sum_{\mathbf{y}} \exp\{\boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y})\}} = \frac{\sum_{\mathbf{y}} g(\mathbf{y}) \exp\{\boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y})\}}{\exp\psi(\theta)} \\ &= \sum_{\mathbf{y}} g(\mathbf{y}) \exp\{\boldsymbol{\theta}^\top \mathbf{g}(\mathbf{y}) - \psi(\theta)\}\end{aligned}$$

- La sumas en rojo y azul son iguales $\Rightarrow \mathbb{E}_\theta[g(\mathbf{Y})] = \nabla\psi(\boldsymbol{\theta})$