



FACULTAD DE
INGENIERÍA



UNIVERSIDAD
DE LA REPÚBLICA
URUGUAY

Aprendizaje Automático para Datos en Grafos

Modelos de Grafos Aleatorios - Parte II

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 Modelos de Variables Latentes

2 Random dot product graphs

Modelos de Variables Latentes

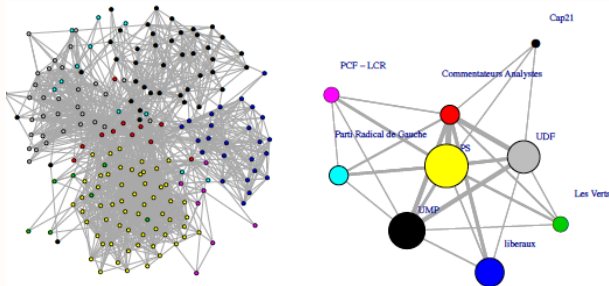
- **Variables Latentes** ampliamente usado para modelar datos con observaciones parciales
Ex: Hidden Markov Models, análisis factorial
- Esta idea se aplica en análisis estadístico de redes en (básicamente) dos variantes:
 - **Modelos de clases latentes:** la pertenencia a cierta clase (no observada) es la que marca la tendencia a conectarse
 - **Modelos de vectores latentes:** las conexiones son más probables en función de que tan “cerca” estén los nodos en cierto espacio latente
- Si bien en redes existen muchas variantes, nos enfocaremos en
 - ⇒ **Stochastic block models (SBMs)**
 - ⇒ Una variante general y no-paramétrica denominada **grafones**

Ejemplo 1: Blogs políticos franceses

■ Red de blogs políticos franceses de Octubre 2006 [Kolaczyk'17]

⇒ Es un grafo con $N_v = 192$ blogs conectados por $N_e = 1431$ aristas

⇒ Cada color indica la afiliación a cierto partido político




■ Visualmente está claro que hay una mezcla de sub-grafos densamente conectados

⇒ Diferentes tasas de conexión entre blogs dependiendo del partido

⇒ Erdős-Rényi con p fijo no puede capturar esta estructura

Ejemplo 2: Actores que comparten películas

- **Red de colaboración de actores según IMDb** entre 2017 y 2021 (ver EVA)
 - ⇒ Es un grafo con $N_v = 21617$ actores conectados por $N_e = 73702$ aristas
 - ⇒ Cada color indica comunidad estimada con la modularidad



- Diferentes tasas de conexión entre actores dependiendo de dónde trabajan: Hollywood, independientes, Bollywood, Nollywood, etc.
- Un **configuration model** tampoco puede capturar esta estructura

Stochastic block models

- Los **stochastic block models** son explícitos en esta noción
 - ⇒ Grupos, módulos o comunidades $\mathcal{C}_1, \dots, \mathcal{C}_Q$
 - ⇒ Tasas de conexión π_{qr} de vértices inter/intra grupos

Stochastic block models

- Los **stochastic block models** son explícitos en esta noción
 - ⇒ Grupos, módulos o comunidades $\mathcal{C}_1, \dots, \mathcal{C}_Q$
 - ⇒ Tasas de conexión π_{qr} de vértices inter/intra grupos

Modelo generativo para un grafo no-dirigido $G(\mathcal{V}, \mathcal{E})$

- Cada vértice $i \in \mathcal{V}$ pertenece de manera independiente a \mathcal{C}_q con probabilidad α_q

$$\boldsymbol{\alpha} = [\alpha_1, \dots, \alpha_Q]^\top, \quad \mathbf{1}^\top \boldsymbol{\alpha} = 1$$

- Para cada par de vértices $i, j \in \mathcal{V}$, con $i \in \mathcal{C}_q$ y $j \in \mathcal{C}_r \Rightarrow (i, j) \in \mathcal{E}$ con proba π_{qr}

P. W. Holland et al., "Stochastic block-models: First steps," *Social Networks*, vol. 5, pp. 109-137, 1983

Especificación del modelo y flexibilidad

- En otras palabras, con $Z_{iq} = \mathbb{I}\{i \in \mathcal{C}_q\}$ y $\mathbf{Z}_i = [Z_{i1}, \dots, Z_{iQ}]^\top$

$$\mathbf{Z}_i \stackrel{\text{i.i.d.}}{\sim} \text{Multinomial}(1, \boldsymbol{\alpha}),$$

$$A_{ij} \mid \mathbf{Z}_i = \mathbf{z}_i, \mathbf{Z}_j = \mathbf{z}_j \sim \text{Bernoulli}(\pi_{\mathbf{z}_i, \mathbf{z}_j})$$

para $1 \leq i, j \leq N_v$, donde $A_{ij} = A_{ji}$ y $A_{ii} \equiv 0$

- **Parámetros:** Q proporciones de grupos (α_q) y $Q(Q+1)/2$ probas de conexión (π_{qr})

Especificación del modelo y flexibilidad

- En otras palabras, con $Z_{iq} = \mathbb{I}\{i \in \mathcal{C}_q\}$ y $\mathbf{Z}_i = [Z_{i1}, \dots, Z_{iQ}]^\top$

$$\mathbf{Z}_i \stackrel{\text{i.i.d.}}{\sim} \text{Multinomial}(1, \boldsymbol{\alpha}),$$

$$A_{ij} \mid \mathbf{Z}_i = \mathbf{z}_i, \mathbf{Z}_j = \mathbf{z}_j \sim \text{Bernoulli}(\pi_{\mathbf{z}_i, \mathbf{z}_j})$$

para $1 \leq i, j \leq N_v$, donde $A_{ij} = A_{ji}$ y $A_{ii} \equiv 0$

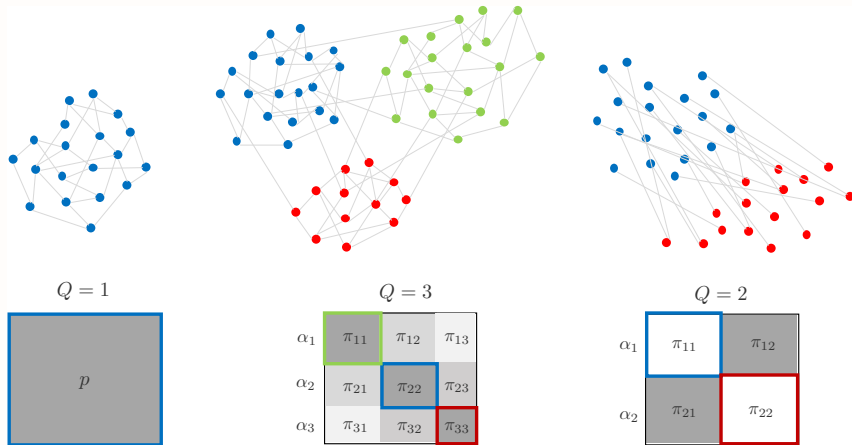
- **Parámetros:** Q proporciones de grupos (α_q) y $Q(Q+1)/2$ probas de conexión (π_{qr})
- Es una mezcla de grafos aleatorios clásicos

$$P(A_{ij} = 1) = P\left(\bigcup_{1 \leq q, r \leq Q} (i \in \mathcal{C}_q) \cap (j \in \mathcal{C}_r) \cap ((i, j) \in \mathcal{E})\right) = \sum_{1 \leq q, r \leq Q} \alpha_q \alpha_r \pi_{qr}$$

- Es más flexible para capturar la estructura de grafos observados
⇒ Hay temas de identificabilidad [Allman et al'11]

⇒ Transición de fase en la aparición de una componente gigante [Söderberg'02'03abc]

Especificación del modelo y flexibilidad (cont.)



■ Mezcla de modelos Erdős-Rényi puede ser sorprendentemente flexible

Grafones y f -random graphs

- Una **variante no-parámetrica de SBM** se puede definir así:

$$U_1, \dots, U_{N_v} \stackrel{\text{i.i.d.}}{\sim} \text{Uniform}[0, 1],$$
$$A_{ij} \mid U_i = u_i, U_j = u_j \sim \text{Bernoulli}(f(u_i, u_j))$$

para $1 \leq i, j \leq N_v$, donde $A_{ij} = A_{ji}$ y $A_{ii} \equiv 0$

- **Grafón:** función simétrica y medible $f : [0, 1]^2 \mapsto [0, 1]$
 \Rightarrow El grafo resultante G se denomina **f -random graph**

Grafones y f -random graphs

- Una **variante no-parámetrica de SBM** se puede definir así:

$$U_1, \dots, U_{N_v} \stackrel{\text{i.i.d.}}{\sim} \text{Uniform}[0, 1],$$
$$A_{ij} \mid U_i = u_i, U_j = u_j \sim \text{Bernoulli}(f(u_i, u_j))$$

para $1 \leq i, j \leq N_v$, donde $A_{ij} = A_{ji}$ y $A_{ii} \equiv 0$

- **Grafón**: función simétrica y medible $f : [0, 1]^2 \mapsto [0, 1]$
 - ⇒ El grafo resultante G se denomina **f -random graph**
- Variables aleatorias latentes U_i uniformes en $[0, 1]$ dan la posición de cada nodo
 - ⇒ El grafón $f(u_i, u_j)$ especifica la probabilidad de conexión entre i, j
- **SBM**: variables latentes \mathbf{Z}_i dan la membresía de los vértices a uno de los Q grupos
 - ⇒ La probabilidad π_{qr} define la probabilidad de conexión entre $i \in \mathcal{C}_q, j \in \mathcal{C}_r$

L. Lovász, "Large Networks and Graph Limits," *AMS Colloquium Publications*, vol. 60, 2012


Ejemplo: grafones SBM

- El modelo f -random incluye a SBM (paramétrico). ¿Cómo?

Ejemplo: grafones SBM

■ El modelo f -random incluye a SBM (paramétrico). ¿Cómo?


- (i) Partimos $[0, 1]$ en Q sub-intervalos de largo $\alpha_1, \dots, \alpha_Q$
- (ii) Tomamos el producto cartesiano para partir $[0, 1]^2$ en Q^2 bloques
- (iii) Definimos f para ser constante a tramos en los bloques: el bloque qr tiene “altura” π_{qr}



Ejemplo: grafones SBM

■ El modelo f -random incluye a SBM (paramétrico). ¿Cómo?

- (i) Partimos $[0, 1]$ en Q sub-intervalos de largo $\alpha_1, \dots, \alpha_Q$
- (ii) Tomamos el producto cartesiano para partir $[0, 1]^2$ en Q^2 bloques
- (iii) Definimos f para ser constante a tramos en los bloques: el bloque qr tiene “altura” π_{qr}



■ Se puede aproximar cualquier función medible por una constante a tramos

⇒ Podemos aproximar cualquier f -random graph (en distribución) con un SBM

⇒ Pero el número de bloques Q puede ser enorme...

Ejemplo: Generación de grafo


- Consideremos un grafo f -random con $f(x, y) = \min(x, y)$ [Lovász'12]
⇒ La gráfica de la izquierda muestra el grafón en escala de grises f
- **Q:** ¿Qué pinta tienen los grafos generados? Ejemplo con $N_v = 40$



- Gráfica del centro muestra una realización de la matriz de adyacencia \mathbf{A}
⇒ Dado sólo \mathbf{A} , es imposible reconocer el origen del grafo
- Pero ordenando los vértices según la conectividad $d_{(1)}, \dots, d_{(40)}$ aparece un patrón
⇒ Parece posible una estimación no-paramétrica del grafón

Intercambiabilidad de vértices


- **Def:** una matriz aleatoria $\mathbf{A} = [A_{ij}]_{i,j \in \mathcal{V}}$ es intercambiable en vértices si $\mathbf{A}_\sigma := [A_{\sigma(i)\sigma(j)}]_{i,j \in \mathcal{V}} \stackrel{D}{=} \mathbf{A}$ para cada permutación $\sigma : \mathcal{V} \mapsto \mathcal{V}$



- Modelos intercambiables asignan la misma probabilidad a grafos isomorfos
 \Rightarrow Estos modelos son más naturales para **grafos no etiquetados**

Intercambiabilidad de vértices

- **Def:** una matriz aleatoria $\mathbf{A} = [A_{ij}]_{i,j \in \mathcal{V}}$ es intercambiable en vértices si $\mathbf{A}_\sigma := [A_{\sigma(i)\sigma(j)}]_{i,j \in \mathcal{V}} \stackrel{D}{=} \mathbf{A}$ para cada permutación $\sigma : \mathcal{V} \mapsto \mathcal{V}$



- Modelos intercambiables asignan la misma probabilidad a grafos isomorfos
⇒ Estos modelos son más naturales para **grafos no etiquetados**
- Como en SBMs, uno puede demostrar que los **grafos f -random son intercambiables**
- Notablemente, **cada modelo intercambiable es una mezcla de grafos f -random**
⇒ El teorema de Aldous-Hoover extiende el resultado sobre secuencias de de Finetti

D. J. Aldous, "Representations for partially exchangeable arrays of random variables," *Journal of Multivariate Analysis*, vol. 11, 1981

Todo grafo f -random es intercambiable

- La distribución de un grafo f -random con N_v vértices es

$$P(\mathbf{A} = \mathbf{a}) =$$

Todo grafo f -random es intercambiable

- La distribución de un grafo f -random con N_v vértices es

$$P(\mathbf{A} = \mathbf{a}) = \int_{[0,1]^{N_v}} \prod_{1 \leq i \neq j \leq N_v} f(u_i, u_j)^{a_{ij}} (1 - f(u_i, u_j))^{1 - a_{ij}} du_1 \dots du_{N_v}$$

Todo grafo f -random es intercambiable

- La distribución de un grafo f -random con N_v vértices es

$$P(\mathbf{A} = \mathbf{a}) = \int_{[0,1]^{N_v}} \prod_{1 \leq i \neq j \leq N_v} f(u_i, u_j)^{a_{ij}} (1 - f(u_i, u_j))^{1 - a_{ij}} du_1 \dots du_{N_v}$$

- Para permutaciones arbitrarias $\sigma : \mathcal{V} \mapsto \mathcal{V}$ resulta

$$\begin{aligned} P(\mathbf{A}_\sigma = \mathbf{a}_\sigma) &= \int_{[0,1]^{N_v}} \prod_{1 \leq i \neq j \leq N_v} f(u_i, u_j)^{a_{\sigma(i)\sigma(j)}} (1 - f(u_i, u_j))^{1 - a_{\sigma(i)\sigma(j)}} du_1 \dots du_{N_v} \\ &= \int_{[0,1]^{N_v}} \prod_{1 \leq i \neq j \leq N_v} f(u_{\sigma^{-1}(i)}, u_{\sigma^{-1}(j)})^{a_{ij}} (1 - f(u_{\sigma^{-1}(i)}, u_{\sigma^{-1}(j)}))^{1 - a_{ij}} \\ &\quad \times du_{\sigma^{-1}(1)} \dots du_{\sigma^{-1}(N_v)} \\ &= \int_{[0,1]^{N_v}} \prod_{1 \leq i \neq j \leq N_v} f(u_i, u_j)^{a_{ij}} (1 - f(u_i, u_j))^{1 - a_{ij}} du_1 \dots du_{N_v} \\ &= P(\mathbf{A} = \mathbf{a}) \end{aligned}$$

Problemas de identidad

- Dos f distintas pueden producir grafos f -random con la misma distribución \Rightarrow No identificable

Ej: grafones $f(x, y)$ y $f(1 - x, 1 - y)$ resultan en el mismo modelo

$$U \stackrel{D}{=} 1 - U \text{ para } U \sim \text{Uniform}[0, 1]$$

Ej: dos grafones $f(x, y)$ y $f(\phi(x), \phi(y))$ para un ϕ que preserve la medida, i.e.,

$$\phi : [0, 1] \mapsto [0, 1] \text{ para el cual } \phi(U) \sim \text{Uniform}[0, 1]$$

Problemas de identidad

- Dos f distintas pueden producir grafos f -random con la misma distribución \Rightarrow No identificable

Ej: grafones $f(x, y)$ y $f(1 - x, 1 - y)$ resultan en el mismo modelo

$$U \stackrel{D}{=} 1 - U \text{ para } U \sim \text{Uniform}[0, 1]$$

Ej: dos grafones $f(x, y)$ y $f(\phi(x), \phi(y))$ para un ϕ que preserve la medida, i.e.,

$$\phi : [0, 1] \mapsto [0, 1] \text{ para el cual } \phi(U) \sim \text{Uniform}[0, 1]$$

- Son necesarias ciertas restricciones en el grafón f para su modelado estadístico
- **Def:** f es **estrictamente monótono** si $\exists \phi$ tal que $\tilde{f}(x, y) = f(\phi(x), \phi(y))$ tiene una función de grados $\tilde{g}(x) = \int_{[0,1]} \tilde{f}(x, y) dy$ estrictamente creciente
 \Rightarrow Esta restricción a \tilde{f} resulta en un modelo identificable [Bickel-Chen'09]

Límite de un grafo

- Una secuencia de grafos $G_n(\mathcal{V}_n, \mathcal{E}_n)$ con una **cantidad de vértices creciente** $N_v = n$


Q: ¿Cuándo podemos decir que $\{G_n\}_{n=1}^{\infty}$ converge a un límite?

Q: ¿Qué sentido tiene esta convergencia?


Q: ¿Qué tipo de objeto es este límite?

- **Spoiler:** Si la secuencia $\{G_n\}_{n=1}^{\infty}$ converge, **el límite es un grafón f**


Ej: La secuencia $ER(n, p)$ a medida que $n \rightarrow \infty$




$n = 50$



$n = 100$



$n = 200$



Grafón $f(x, y) \equiv p$

Densidad de homomorfismo

Def: Homomorfismos h son aquellos mapeos del motif $F(\mathcal{V}', \mathcal{E}')$ (i.e. un grafo pequeño) a un grafo $G(\mathcal{V}, \mathcal{E})$ que preservan la adyacencia

$$h : \mathcal{V}' \mapsto \mathcal{V} \text{ tal que } (i, j) \in \mathcal{E}' \text{ implica } (h(i), h(j)) \in \mathcal{E}$$

- Existen $\binom{|\mathcal{V}|}{|\mathcal{V}'|}$ mapeos posibles de F a G , pero sólo $\text{hom}(F, G)$ son homomorfismos
⇒ **Def:** Densidad de homomorfismos del motif F en el grafo G es

$$t(F, G) = \frac{\text{hom}(F, G)}{\binom{|\mathcal{V}|}{|\mathcal{V}'|}}$$

Densidad de homomorfismo

Def: Homomorfismos h son aquellos mapeos del motif $F(\mathcal{V}', \mathcal{E}')$ (i.e. un grafo pequeño) a un grafo $G(\mathcal{V}, \mathcal{E})$ que preservan la adyacencia

$$h : \mathcal{V}' \mapsto \mathcal{V} \text{ tal que } (i, j) \in \mathcal{E}' \text{ implica } (h(i), h(j)) \in \mathcal{E}$$

- Existen $\binom{|\mathcal{V}|}{|\mathcal{V}'|}$ mapeos posibles de F a G , pero sólo $\text{hom}(F, G)$ son homomorfismos
⇒ **Def:** Densidad de homomorfismos del motif F en el grafo G es

$$t(F, G) = \frac{\text{hom}(F, G)}{\binom{|\mathcal{V}|}{|\mathcal{V}'|}}$$

- Medida relativa del número de formas en que F puede mapearse a G
- **Interpretación:** si se sortea uniforme aleatorio un mapeo, cuál es la probabilidad de que sea un homomorfismo?

Densidad de homomorfismo


Def: Homomorfismos h son aquellos mapeos del motif $F(\mathcal{V}', \mathcal{E}')$ (i.e. un grafo pequeño) a un grafo $G(\mathcal{V}, \mathcal{E})$ que preservan la adyacencia

$$h : \mathcal{V}' \mapsto \mathcal{V} \text{ tal que } (i, j) \in \mathcal{E}' \text{ implica } (h(i), h(j)) \in \mathcal{E}$$

- Existen $\binom{|\mathcal{V}|}{|\mathcal{V}'|}$ mapeos posibles de F a G , pero sólo $\text{hom}(F, G)$ son homomorfismos
 \Rightarrow **Def:** Densidad de homomorfismos del motif F en el grafo G es

$$t(F, G) = \frac{\text{hom}(F, G)}{\binom{|\mathcal{V}|}{|\mathcal{V}'|}}$$

- Medida relativa del número de formas en que F puede mapearse a G
- Interpretación:** si se sortea uniforme aleatorio un mapeo, cuál es la probabilidad de que sea un homomorfismo?



Densidad de homomorfismo


Def: Homomorfismos h son aquellos mapeos del motif $F(\mathcal{V}', \mathcal{E}')$ (i.e. un grafo pequeño) a un grafo $G(\mathcal{V}, \mathcal{E})$ que preservan la adyacencia

$$h : \mathcal{V}' \mapsto \mathcal{V} \text{ tal que } (i, j) \in \mathcal{E}' \text{ implica } (h(i), h(j)) \in \mathcal{E}$$

- Existen $\binom{|\mathcal{V}|}{|\mathcal{V}'|}$ mapeos posibles de F a G , pero sólo $\text{hom}(F, G)$ son homomorfismos
 \Rightarrow **Def:** Densidad de homomorfismos del motif F en el grafo G es

$$t(F, G) = \frac{\text{hom}(F, G)}{\binom{|\mathcal{V}|}{|\mathcal{V}'|}}$$

- Medida relativa del número de formas en que F puede mapearse a G
- Interpretación:** si se sortea uniforme aleatorio un mapeo, cuál es la probabilidad de que sea un homomorfismo?



Densidad de homomorfismo


Def: Homomorfismos h son aquellos mapeos del motif $F(\mathcal{V}', \mathcal{E}')$ (i.e. un grafo pequeño) a un grafo $G(\mathcal{V}, \mathcal{E})$ que preservan la adyacencia

$$h : \mathcal{V}' \mapsto \mathcal{V} \text{ tal que } (i, j) \in \mathcal{E}' \text{ implica } (h(i), h(j)) \in \mathcal{E}$$

- Existen $\binom{|\mathcal{V}|}{|\mathcal{V}'|}$ mapeos posibles de F a G , pero sólo $\text{hom}(F, G)$ son homomorfismos
 \Rightarrow **Def:** Densidad de homomorfismos del motif F en el grafo G es

$$t(F, G) = \frac{\text{hom}(F, G)}{\binom{|\mathcal{V}|}{|\mathcal{V}'|}}$$

- Medida relativa del número de formas en que F puede mapearse a G
- Interpretación:** si se sortea uniforme aleatorio un mapeo, cuál es la probabilidad de que sea un homomorfismo?



Densidad de homomorfismo


Def: Homomorfismos h son aquellos mapeos del motif $F(\mathcal{V}', \mathcal{E}')$ (i.e. un grafo pequeño) a un grafo $G(\mathcal{V}, \mathcal{E})$ que preservan la adyacencia

$$h : \mathcal{V}' \mapsto \mathcal{V} \text{ tal que } (i, j) \in \mathcal{E}' \text{ implica } (h(i), h(j)) \in \mathcal{E}$$

- Existen $\binom{|\mathcal{V}|}{|\mathcal{V}'|}$ mapeos posibles de F a G , pero sólo $\text{hom}(F, G)$ son homomorfismos
 \Rightarrow **Def:** Densidad de homomorfismos del motif F en el grafo G es

$$t(F, G) = \frac{\text{hom}(F, G)}{\binom{|\mathcal{V}|}{|\mathcal{V}'|}}$$

- Medida relativa del número de formas en que F puede mapearse a G
- Interpretación:** si se sortea uniforme aleatorio un mapeo, cuál es la probabilidad de que sea un homomorfismo?



Densidad de homomorfismo


Def: Homomorfismos h son aquellos mapeos del motif $F(\mathcal{V}', \mathcal{E}')$ (i.e. un grafo pequeño) a un grafo $G(\mathcal{V}, \mathcal{E})$ que preservan la adyacencia

$$h : \mathcal{V}' \mapsto \mathcal{V} \text{ tal que } (i, j) \in \mathcal{E}' \text{ implica } (h(i), h(j)) \in \mathcal{E}$$

- Existen $\binom{|\mathcal{V}|}{|\mathcal{V}'|}$ mapeos posibles de F a G , pero sólo $\text{hom}(F, G)$ son homomorfismos
⇒ **Def:** Densidad de homomorfismos del motif F en el grafo G es

$$t(F, G) = \frac{\text{hom}(F, G)}{\binom{|\mathcal{V}|}{|\mathcal{V}'|}}$$

- Medida relativa del número de formas en que F puede mapearse a G
- **Interpretación:** si se sortea uniforme aleatorio un mapeo, cuál es la probabilidad de que sea un homomorfismo?



Convergencia de secuencias de grafos

- **Def:** Una secuencia de grafos $\{G_n\}_{n=1}^{\infty}$ converge cuando para todo motif F , la secuencia de densidad de homomorfismos $\{t(F, G_n)\}_{n=1}^{\infty}$ converge
- Algunos aspectos importantes de la definición
 - Si la secuencia se vuelve constante, entonces converge
 - Secuencias de grafos isomórficos converge
 - La convergencia es en cantidades normalizadas, no en número de aristas, triángulos, ...
 - Los resultados son para secuencias de grafos **densos**, i.e., $|\mathcal{E}_n| = \Omega(n^2)$

Convergencia de secuencias de grafos

- **Def:** Una secuencia de grafos $\{G_n\}_{n=1}^{\infty}$ converge cuando para todo motif F , la secuencia de densidad de homomorfismos $\{t(F, G_n)\}_{n=1}^{\infty}$ converge
- Algunos aspectos importantes de la definición
 - Si la secuencia se vuelve constante, entonces converge
 - Secuencias de grafos isomórficos converge
 - La convergencia es en cantidades normalizadas, no en número de aristas, triángulos, ...
 - Los resultados son para secuencias de grafos **densos**, i.e., $|\mathcal{E}_n| = \Omega(n^2)$
- Respondimos las dos primeras preguntas. Sólo nos queda la tercera y última
 - ⇒ El límite de una secuencia de grafos no es necesariamente un grafo
 - ⇒ **Q:** ¿Qué tipo de objeto es este límite?

L. Lovász and B. Szegedy, "Limits of dense graph sequences," *Journal of Combinatorial Theory, Series B*, vol. 96, 2006

Grafón inducido


■ Todo grafo admite una representación denominada **grafón inducido**

● Consideremos un grafo $G(\mathcal{V}, \mathcal{E})$ con matriz de adyacencia \mathbf{A}


● Hagamos una partición uniforme de $[0, 1]$ en N_v sub-intervalos $\Rightarrow I_i = [\frac{i-1}{N_v}, \frac{i}{N_v})$

Def: El **grafón inducido** f_G de G es

$$f_G(x, y) = \sum_{1 \leq i, j \leq N_v} A_{ij} \mathbb{I}\{x \in I_i\} \mathbb{I}\{y \in I_j\}$$



Grafo cíclico G con $N_v = 6$ nodos



Grafón f_G inducido por el grafo G

El límite es un grafón

- **Propiedad:** La densidad de homomorfismo del motif F en el grafo G está dado por

$$t(F, G) = \int_{[0,1]^{|\mathcal{V}'|}} \prod_{(i,j) \in \mathcal{E}'} f_G(u_i, u_j) du_1 \dots du_{|\mathcal{V}'|}$$



El límite es un grafón

- **Propiedad:** La densidad de homomorfismo del motif F en el grafo G está dado por

$$t(F, G) = \int_{[0,1]^{|\mathcal{V}'|}} \prod_{(i,j) \in \mathcal{E}'} f_G(u_i, u_j) du_1 \dots du_{|\mathcal{V}'|}$$

Ej: Sea F el motif más simple: una arista

- $t(F, G)$ responde la pregunta “Cuántas aristas tiene G (dividido entre las $N_v \times N_v$ posibilidades)?”



- Podemos contar las aristas o simplemente calcular $\int_{[0,1]^2} f_G(u_1, u_2) du_1 du_2$ (el área gris en el grafón inducido)

El límite es un grafón

- Esto sigue siendo cierto en el límite. Si la secuencia $\{G_n\}_{n=1}^{\infty}$ converge, entonces

$$\lim_{n \rightarrow \infty} t(F, G_n) = \int_{[0,1]^{|\mathcal{V}'|}} \prod_{(i,j) \in \mathcal{E}'} f(u_i, u_j) du_1 \dots du_{|\mathcal{V}'|}$$

para alguna función $f : [0, 1]^2 \mapsto [0, 1]$ simétrica y medible

El límite es un grafón

- Esto sigue siendo cierto en el límite. Si la secuencia $\{G_n\}_{n=1}^{\infty}$ converge, entonces

$$\lim_{n \rightarrow \infty} t(F, G_n) = \int_{[0,1]^{|\mathcal{V}'|}} \prod_{(i,j) \in \mathcal{E}'} f(u_i, u_j) du_1 \dots du_{|\mathcal{V}'|}$$

para alguna función $f : [0, 1]^2 \mapsto [0, 1]$ simétrica y medible

- La **intuición** es la misma de antes: probabilidad de mapear el motif

Ej Sea F el motif tipo estrella de antes

$$t(F, G) = \int_{[0,1]^4} f(u_1, u_2) f(u_1, u_3) f(u_1, u_4) du_1 du_2 du_3 du_4$$

El límite es un grafón

- Esto sigue siendo cierto en el límite. Si la secuencia $\{G_n\}_{n=1}^{\infty}$ converge, entonces

$$\lim_{n \rightarrow \infty} t(F, G_n) = \int_{[0,1]^{|\mathcal{V}'|}} \prod_{(i,j) \in \mathcal{E}'} f(u_i, u_j) du_1 \dots du_{|\mathcal{V}'|}$$

para alguna función $f : [0, 1]^2 \mapsto [0, 1]$ simétrica y medible

- La **intuición** es la misma de antes: probabilidad de mapear el motif

Ej Sea F el motif tipo estrella de antes

$$t(F, G) = \int_{[0,1]^4} \underbrace{f(u_1, u_2)f(u_1, u_3)f(u_1, u_4)}_{\substack{\text{probabilidad de la estrella} \\ \text{dados } (u_1, u_2, u_3, u_4)}} du_1 du_2 du_3 du_4$$

El límite es un grafón

- Esto sigue siendo cierto en el límite. Si la secuencia $\{G_n\}_{n=1}^{\infty}$ converge, entonces

$$\lim_{n \rightarrow \infty} t(F, G_n) = \int_{[0,1]^{|\mathcal{V}'|}} \prod_{(i,j) \in \mathcal{E}'} f(u_i, u_j) du_1 \dots du_{|\mathcal{V}'|}$$

para alguna función $f : [0, 1]^2 \mapsto [0, 1]$ simétrica y medible

- La **intuición** es la misma de antes: probabilidad de mapear el motif

Ej Sea F el motif tipo estrella de antes

$$t(F, G) = \int_{[0,1]^4} \underbrace{f(u_1, u_2)f(u_1, u_3)f(u_1, u_4)}_{\substack{\text{probabilidad de la estrella} \\ \text{dados } (u_1, u_2, u_3, u_4)}} du_1 du_2 du_3 du_4$$

promediada entre los (u_1, u_2, u_3, u_4) sorteados uniformes

El límite es un grafón

- Esto sigue siendo cierto en el límite. Si la secuencia $\{G_n\}_{n=1}^{\infty}$ converge, entonces

$$\lim_{n \rightarrow \infty} t(F, G_n) = \int_{[0,1]^{|\mathcal{V}'|}} \prod_{(i,j) \in \mathcal{E}'} f(u_i, u_j) du_1 \dots du_{|\mathcal{V}'|}$$

para alguna función $f : [0, 1]^2 \mapsto [0, 1]$ simétrica y medible

- La **intuición** es la misma de antes: probabilidad de mapear el motif

Ej Sea F el motif tipo estrella de antes

$$t(F, G) = \underbrace{\int_{[0,1]^4} \underbrace{f(u_1, u_2) f(u_1, u_3) f(u_1, u_4)}_{\substack{\text{probabilidad de la estrella} \\ \text{dados } (u_1, u_2, u_3, u_4)}} du_1 du_2 du_3 du_4}_{\text{promediada entre los } (u_1, u_2, u_3, u_4) \text{ sorteados uniformes}}$$

- Identificamos el **objeto límite** – el **grafón** – con f

¿Y esto para qué sirve?

Impacto matemático

- Trae herramientas de análisis a lo que a priori es un contexto puramente combinatorio

Impacto en inferencia estadística

- Realizaciones grandes se vuelven representativas del proceso generativo
 - ⇒ Inferir el mecanismo de generación de los datos examinando una única realización

Impacto en machine learning

- Estudiar filtros de grafos y GNNs en el límite de grandes grafos
 - ⇒ **Transferabilidad** e.g., entrenando en un grafo más pequeño que donde se aplica

L. Ruiz et al, "Graphon neural networks and the transferability of graph neural networks," *NeurIPS*, 2020

Plausibilidad

- 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

Plausibilidad

- 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

Q: ¿Qué tan apropiados son modelos de variables latentes? ¿Son plausibles?

Q: ¿Podemos aproximar un grafo observado G^{obs} usando un SBM?

⇒ Una variante del lema de regularidad de Szemerédi resulta útil aquí

C. Borgs et al, "Graph limits and parameter testing," *Syposium on Theory of Computing*, 2006

Cut distance

- Discutir nociones de aproximación requiere una **distancia entre grafos**

Def: La **cut distance** entre los grafos $G(\mathcal{V}, \mathcal{E})$ y $G'(\mathcal{V}', \mathcal{E}')$ (con $|\mathcal{V}| = |\mathcal{V}'| = N_v$) es

$$d_{\square}(G, G') = \frac{1}{N_v^2} \max_{\mathcal{S}, \mathcal{T} \in \{1, \dots, N_v\}} \left| \sum_{i \in \mathcal{S}} \sum_{j \in \mathcal{T}} (A_{ij} - A'_{ij}) \right|$$

\Rightarrow Se puede demostrar que $d_{\square}(\cdot, \cdot)$ efectivamente es una métrica

- La definición y estudio de propiedades de distancias en grafos es un tema súper actual

B. Bollobás and O. Riordan, "Sparse graphs: Metrics and random models," *Random Structures & Algorithms*, vol. 39, 2011

Un resultado sobre aproximaciones

- Sea $\mathcal{P} = \{\mathcal{V}_1, \dots, \mathcal{V}_Q\}$ una partición de los vértices \mathcal{V} de G en Q clases
- Definamos un grafo completo G_P con vértices \mathcal{V} y pesos

$$w_{ij}(G_P) = \frac{1}{|\mathcal{V}_q||\mathcal{V}_r|} \sum_{u \in \mathcal{V}_q} \sum_{v \in \mathcal{V}_r} A_{uv}, \quad i \in \mathcal{V}_q, j \in \mathcal{V}_r$$

- ⇒ Básicamente la aproximación del grafo G por un SBM de Q clases
- ⇒ La probabilidad de que una arista una i, j sería $w_{ij}(G_P)$

Un resultado sobre aproximaciones

- Sea $\mathcal{P} = \{\mathcal{V}_1, \dots, \mathcal{V}_Q\}$ una partición de los vértices \mathcal{V} de G en Q clases
- Definamos un grafo completo G_P con vértices \mathcal{V} y pesos

$$w_{ij}(G_P) = \frac{1}{|\mathcal{V}_q||\mathcal{V}_r|} \sum_{u \in \mathcal{V}_q} \sum_{v \in \mathcal{V}_r} A_{uv}, \quad i \in \mathcal{V}_q, j \in \mathcal{V}_r$$

- ⇒ Básicamente la aproximación del grafo G por un SBM de Q clases
- ⇒ La probabilidad de que una arista una i, j sería $w_{ij}(G_P)$

Teorema: Para todo $\epsilon > 0$ y todo grafo $G(\mathcal{V}, \mathcal{E})$, existe una partición \mathcal{P} de \mathcal{V} en $Q \leq 2^{\frac{2}{\epsilon^2}}$ clases tal que $d_{\square}(G, G_P) \leq \epsilon$.

- Justificación de que **un SBM puede aproximar cualquier grafo**
 - ⇒ La cota superior en Q puede ser gigantesca

¿Y los grafos f -random?

- Los grafos f -random son apropiados sólo para **redes densas**

Teorema: Si un grafo G es la restricción a los vértices $\{1, \dots, N_v\}$ de un grafo aleatorio infinito intercambiable, entonces es denso o está vacío.

Intuitivamente: La proporción de aristas en $G(\mathcal{V}, \mathcal{E})$ es

$$\varphi = \int_{[0,1]^2} f(u_1, u_2) du_1 du_2$$

⇒ Si $\varphi = 0$ entonces $f = 0$ c.s. y G está vacío. Esparso, pero inútil

⇒ Si $\varphi > 0$ entonces (en media) $|\mathcal{E}| = \varphi \times \binom{N_v}{2} = \Omega(N_v^2)$

- El principal problema es la **intercambiabilidad de vértices**
 - Apropiado para grafos sin etiquetas...
 - Si tengo etiquetas, se podrían incorporar al modelo [Sweet'15]

Estimación de los parámetros de un SBM

- Los parámetros de un SBM son $\{\alpha_q\}_{q=1}^Q$ y $\{\pi_{qr}\}_{1 \leq q, r \leq Q}$
- Conceptualmente puede simplificar pensar en dos conjuntos de ‘observaciones’
 - ⇒ Clases: $\mathbf{Z} = \{\{Z_{iq}\}_{q=1}^Q\}_{i \in \mathcal{V}}$, donde $Z_{iq} = \mathbb{I}\{i \in \mathcal{C}_q\}$
 - ⇒ Enlaces: $\mathbf{A} = [A_{ij}]$, donde $A_{ij} = \mathbb{I}\{(i, j) \in \mathcal{E}\}$
- **Pero sólo observamos \mathbf{A}** (\mathbf{Z} típicamente latente). Asumamos Q conocida
 - ⇒ Interesa la **estimación de los parámetros** pero especialmente **agrupar los vértices**

Detección de comunidades basada en modelo

Supongamos que G fue generado por un SBM con Q clases. Predecir las pertenencia a clases $\mathbf{Z} = \{\{Z_{iq}\}_{q=1}^Q\}_{i \in \mathcal{V}}$, dada la observación $\mathbf{A} = \mathbf{a}$.

Estimación de Máxima Verosimilitud

- Si observáramos $\mathbf{A} = \mathbf{a}$ y $\mathbf{Z} = \mathbf{z}$, la log-likelihood sería (con $\boldsymbol{\theta} = \{\{\alpha_q\}, \{\pi_{qr}\}\}$)

$$\ell_{\boldsymbol{\theta}}(\mathbf{a}, \mathbf{z}) = \ell_{\boldsymbol{\theta}}(\mathbf{z}) + \ell_{\boldsymbol{\theta}}(\mathbf{a}|\mathbf{z})$$

$$\text{con } \ell_{\boldsymbol{\theta}}(\mathbf{z}) = \log P(\mathbf{Z} = \mathbf{z}) = \log \left(\prod_i \left(\prod_q \alpha_q^{z_{iq}} \right) \right) = \sum_i \sum_q z_{iq} \log \alpha_q$$

$$\ell_{\boldsymbol{\theta}}(\mathbf{a}|\mathbf{z}) = \frac{1}{2} \sum_{i \neq j} \sum_{q \neq r} z_{iq} z_{jr} \log \left(\pi_{qr}^{a_{ij}} (1 - \pi_{qr})^{1-a_{ij}} \right)$$

Estimación de Máxima Verosimilitud

- Pero no observamos \mathbf{Z} . Hay que trabajar con la verosimilitud de los **datos observados**

$$l_{\theta}(\mathbf{a}) = \log \left(\sum_{\mathbf{z}} \exp \{l_{\theta}(\mathbf{a}, \mathbf{z})\} \right)$$

- ¿Cuántos términos puede haber en esa sumatoria? \Rightarrow calcular $l_{\theta}(\mathbf{a})$ es inviable

Estimación de Máxima Verosimilitud

- Pero no observamos \mathbf{Z} . Hay que trabajar con la verosimilitud de los **datos observados**

$$\ell_{\theta}(\mathbf{a}) = \log \left(\sum_{\mathbf{z}} \exp \{ \ell_{\theta}(\mathbf{a}, \mathbf{z}) \} \right)$$

- ¿Cuántos términos puede haber en esa sumatoria? \Rightarrow calcular $\ell_{\theta}(\mathbf{a})$ es inviable
- Ver el modelo como una mezcla sugiere usar **Expectation Maximization** [Snijders'97]
 - \Rightarrow Alternar entre estimar $\mathbb{E} [Z_{iq} \mid \mathbf{A} = \mathbf{a}]$ y θ
 - \Rightarrow No escala más allá de $Q = 2$, $P(\mathbf{Z} \mid \mathbf{A} = \mathbf{a})$ es computacionalmente caro

Máxima verosimilitud variacional

- **Método variacional** para optimizar una cota inferior de $\ell_{\theta}(\mathbf{a})$:

$$J(R_{\mathbf{a}}; \theta) = \ell_{\theta}(\mathbf{a}) - \text{KL}(R_{\mathbf{a}}(\mathbf{Z}), P(\mathbf{Z} | \mathbf{A} = \mathbf{a}))$$

- KL es la divergencia de Kullback–Leibler
- $R_{\mathbf{a}}(\mathbf{Z})$ es una aproximación “manipulable” de $P(\mathbf{Z} | \mathbf{A} = \mathbf{a})$

- Aproximación de campo medio de la distribución condicional

$$R_{\mathbf{a}}(\mathbf{Z}) = \prod_{i=1}^{N_v} h(\mathbf{Z}_i; \tau_i)$$

- $h(\cdot; \tau_i)$: distribución multinomial con parámetro $\tau_i = [\tau_{i1}, \dots, \tau_{iQ}]^T$

J. J. Daudin et al, “A mixture model for random graphs,” *Stat. Comput.*, vol. 18, 2008

Algoritmo de maximización alternada

Proposición: Dado θ , el parámetro variacional óptimo $\{\hat{\tau}_i\} = \operatorname{argmax}_{\{\tau_i\}} J(R_{\mathbf{a}}; \{\tau_i\}, \theta)$ satisface la siguiente ecuación de punto fijo

$$\hat{\tau}_{iq} \propto \alpha_q \prod_{j \neq i} \prod_r b(A_{ij}; \pi_{qr})^{\hat{\tau}_{jr}}$$

Dados $\{\tau_i\}$, los valores de θ que maximizan $J(R_{\mathbf{a}}; \{\tau_i\}, \theta)$ son

$$\hat{\alpha}_q = \frac{1}{N_v} \sum_i \hat{\tau}_{iq}, \quad \hat{\pi}_{qr} = \sum_{i \neq j} \hat{\tau}_{iq} \hat{\tau}_{jr} A_{ij} / \sum_{i \neq j} \hat{\tau}_{iq} \hat{\tau}_{jr}$$

Algoritmo de maximización alternada

Proposición: Dado θ , el parámetro variacional óptimo $\{\hat{\tau}_i\} = \operatorname{argmax}_{\{\tau_i\}} J(R_{\mathbf{a}}; \{\tau_i\}, \theta)$ satisface la siguiente ecuación de punto fijo

$$\hat{\tau}_{iq} \propto \alpha_q \prod_{j \neq i} \prod_r b(A_{ij}; \pi_{qr})^{\hat{\tau}_{jr}}$$

Dados $\{\tau_i\}$, los valores de θ que maximizan $J(R_{\mathbf{a}}; \{\tau_i\}, \theta)$ son

$$\hat{\alpha}_q = \frac{1}{N_v} \sum_i \hat{\tau}_{iq}, \quad \hat{\pi}_{qr} = \sum_{i \neq j} \hat{\tau}_{iq} \hat{\tau}_{jr} A_{ij} / \sum_{i \neq j} \hat{\tau}_{iq} \hat{\tau}_{jr}$$

■ El algoritmo alterna entre actualizaciones de θ y $\{\tau_i\}$:

$$\theta[k+1] = \operatorname{argmax}_{\theta} J(R_{\mathbf{a}}; \{\tau_i[k]\}, \theta)$$

$$\{\tau_i[k+1]\} = \operatorname{argmax}_{\{\tau_i\}} J(R_{\mathbf{a}}; \{\tau_i\}, \theta[k+1])$$

- La secuencia de los valores de J es no-decreciente [Daudin et al'08]
- **Resultados de consistencia** para $N_v \rightarrow \infty$, Q fijo [Celisse et al'12]

¿Cuántas clases usar?





- El número de clases Q es generalmente desconocido y debe ser estimado
 - ⇒ Se pueden usar técnicas bayesianas para selección de modelos
 - ⇒ Distribución a priori $g(\boldsymbol{\theta} \mid m_Q)$ de $\boldsymbol{\theta}$ dado que el SBM m_Q tiene Q clases
- El criterio **Integrated Classification Likelihood (ICL)** resulta

$$\text{ICL}(m_Q) = \max_{\boldsymbol{\theta}} \log \ell_{\boldsymbol{\theta}, m_Q}(\mathbf{a}, \hat{\mathbf{z}}(\boldsymbol{\theta})) \\ - \frac{Q(Q+1)}{4} \log \frac{N_v(N_v-1)}{2} - \frac{Q-1}{2} \log N_v$$

donde $\ell_{\boldsymbol{\theta}, m_Q}(\mathbf{a}, \hat{\mathbf{z}}(\boldsymbol{\theta}))$ es como antes pero con m_Q explícito

Evaluando la bondad del ajuste

- Goodness-of-fit \Rightarrow mayormente computacionales y basados en visualización
- Ej: Red de blogs políticos franceses de octubre 2006 [Kolaczyk'17]
 \Rightarrow Ajuste a un SBM usando el método variacional (**mixer** en R)



- Valor óptimo $\hat{Q} = 12$, pero $Q \in [8, 12]$ parece razonable (9 partidos políticos)
 \Rightarrow Permutar la matriz de adyacencia muestra estructura (margen para agrupar)
- La distribución de grados ajusta razonablemente bien

Estimación del grafón

- **Objetivo:** estimar el grafón f de la realización observada G^{obs}
- **Regresión no-paramétrica:** estimar f dados $\{A_{ij}, U_i, U_j\}_{i,j \in \mathcal{V}}$
⇒ Desafío es que los puntos U_1, \dots, U_{N_v} son latentes

Aproximación por SBM

C. Gao et al, “Rate-optimal graphon estimation,” *Annals of Statistics*, vol. 43, 2015

Estimación por histograma (orden y suavizado)

S. H. Chan and E. M. Airoldi, “A consistent histogram estimator for exchangeable graph models,” *ICML*, 2014

Modelo como proceso Gaussiano

P. Orbanz and D. M. Roy, “Bayesian models of graphs, arrays and other exchangeable random structures,” *IEEE Trans. PAMI*, vol. 37, 2015

Extensiones de SBMs

Degree-corrected SBMs

- Comunidades con una distribución de grados “amplia”

B. Karrer B and M. E. Newman, “Stochastic blockmodels and community structure in networks,” *Physical Review E.*, vol. 83, 2011

Mixed-membership SBMs

- Los nodos pueden pertenecer a más de una clase

E. M. Airoldi, “Mixed membership stochastic blockmodels,” *J. Machine Learning Research*, vol. 9, 2008

SBMs jerárquicos

- Clustering jerárquico combinado con SBMs

A. Clauset et al, “Hierarchical structure and the prediction of missing links in networks,” *Nature*, vol. 453, 2008

Modelos de Grafos Aleatorios

1 Modelos de Variables Latentes

2 Random dot product graphs

Random dot product graphs

- Consideremos un **espacio latente** $\mathcal{X}_d \subset \mathbb{R}^d$ tal que para todo

$$\mathbf{x}, \mathbf{y} \in \mathcal{X}_d \quad \Rightarrow \quad \mathbf{x}^\top \mathbf{y} \in [0, 1]$$

\Rightarrow Distribución de producto interno $F : \mathcal{X}_d \mapsto [0, 1]$

- **Random dot product graphs** (RDPGs):

$$\mathbf{x}_1, \dots, \mathbf{x}_{N_v} \stackrel{\text{i.i.d.}}{\sim} F,$$
$$A_{ij} \mid \mathbf{x}_i, \mathbf{x}_j \sim \text{Bernoulli}(\mathbf{x}_i^\top \mathbf{x}_j)$$

para $1 \leq i, j \leq N_v$, donde $A_{ij} = A_{ji}$ y $A_{ii} \equiv 0$

- Tipo particularmente intuitivo y “tratable” de **grafos aleatorios con posiciones latentes**

\Rightarrow Posición de los vértices $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_{N_v}]^T \in \mathbb{R}^{N_v \times d}$

S. J. Young and E. R. Scheinerman, “Random dot product graph models for social networks,” WAW, 2007

Conexión a otros modelos

- RDPG incluye varios modelos clásicos de grafos aleatorios

Ej: Erdős-Renyi $ER(N_v, p)$ es un RDPG con $d = 1$ y $\mathcal{X}_d = \{\sqrt{p}\}$

Ej: SBM es un RDGP tal que F es

$$P(\mathbf{X} = \mathbf{x}_q) = \alpha_q, \quad q = 1, \dots, Q$$

con d y $\mathbf{x}_1, \dots, \mathbf{x}_Q$ tal que $\pi_{qr} = \mathbf{x}_q^\top \mathbf{x}_r$

- Esto último implica que los RDPGs son al menos tan expresivos como los SBMs

Conexión a otros modelos

- RDPG incluye varios modelos clásicos de grafos aleatorios

Ej: Erdős-Renyi $ER(N_v, p)$ es un RDPG con $d = 1$ y $\mathcal{X}_d = \{\sqrt{p}\}$

Ej: SBM es un RDGP tal que F es

$$P(\mathbf{X} = \mathbf{x}_q) = \alpha_q, \quad q = 1, \dots, Q$$

con d y $\mathbf{x}_1, \dots, \mathbf{x}_Q$ tal que $\pi_{qr} = \mathbf{x}_q^\top \mathbf{x}_r$

- Esto último implica que los RDPGs son al menos tan expresivos como los SBMs
- RDPGs son un caso especial de modelos de posiciones latentes [Hoff et al'02]

$$A_{ij} \mid \mathbf{x}_i, \mathbf{x}_j \sim \text{Bernoulli}(\kappa(\mathbf{x}_i, \mathbf{x}_j))$$

\Rightarrow RDPG aproxima cualquier $\kappa(\cdot)$ con un d suficientemente grande [Tang et al'13]

Estimación de las posiciones latentes

Q: Dado G de un RDPG ¿cuál es el “mejor” $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_{N_v}]^\top$?

■ MLE parece una buena idea, pero es impensado para N_v grandes

$$\hat{\mathbf{X}}_{ML} = \underset{\mathbf{X}}{\operatorname{argmax}} \prod_{i < j} (\mathbf{x}_i^\top \mathbf{x}_j)^{A_{ij}} (1 - \mathbf{x}_i^\top \mathbf{x}_j)^{1 - A_{ij}}$$

Estimación de las posiciones latentes

Q: Dado G de un RDPG ¿cuál es el “mejor” $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_{N_v}]^\top$?

■ MLE parece una buena idea, pero es impensado para N_v grandes

$$\hat{\mathbf{X}}_{ML} = \underset{\mathbf{X}}{\operatorname{argmax}} \prod_{i < j} (\mathbf{x}_i^\top \mathbf{x}_j)^{A_{ij}} (1 - \mathbf{x}_i^\top \mathbf{x}_j)^{1 - A_{ij}}$$

■ Sea $P_{ij} = P((i, j) \in \mathcal{E})$ y definamos la matriz $\mathbf{P} = [P_{ij}] \in [0, 1]^{N_v \times N_v}$

⇒ El modelo RDPG especifica que $\mathbf{P} = \mathbf{X}\mathbf{X}^\top$

⇒ **Clave:** La \mathbf{A} observada es una realización ruidosa de \mathbf{P} ($\mathbb{E}[\mathbf{A}] = \mathbf{P}$)

■ Sugiere aplicar **mínimos cuadrados** para hallar \mathbf{X}

$$\hat{\mathbf{X}}_{LS} = \underset{\mathbf{X}}{\operatorname{argmin}} \|\mathbf{X}\mathbf{X}^\top - \mathbf{A}\|_F^2$$

Adjacency spectral embedding

- Como \mathbf{A} es real y simétrica, podemos descomponerla como $\mathbf{A} = \mathbf{U}\mathbf{\Lambda}\mathbf{U}^\top$
 - $\mathbf{U} = [\mathbf{u}_1, \dots, \mathbf{u}_{N_v}]$ es la matriz ortogonal de vectores propios
 - $\mathbf{\Lambda} = \text{diag}(\lambda_1, \dots, \lambda_{N_v})$, con valore propios $\lambda_1 \geq \dots \geq \lambda_{N_v}$

Adjacency spectral embedding

- Como \mathbf{A} es real y simétrica, podemos descomponerla como $\mathbf{A} = \mathbf{U}\mathbf{\Lambda}\mathbf{U}^\top$
 - $\mathbf{U} = [\mathbf{u}_1, \dots, \mathbf{u}_{N_v}]$ es la matriz ortogonal de vectores propios
 - $\mathbf{\Lambda} = \text{diag}(\lambda_1, \dots, \lambda_{N_v})$, con valores propios $\lambda_1 \geq \dots \geq \lambda_{N_v}$
- Definamos $\hat{\mathbf{\Lambda}} = \text{diag}(\lambda_1^+, \dots, \lambda_d^+)$ y $\hat{\mathbf{U}} = [\mathbf{u}_1, \dots, \mathbf{u}_d]$ ($\lambda^+ := \max(0, \lambda)$)
- La mejor aproximación de rango d semi-definida positiva de \mathbf{A} es $\hat{\mathbf{U}}\hat{\mathbf{\Lambda}}\hat{\mathbf{U}}^\top$
 \Rightarrow Adjacency spectral embedding (ASE) es $\hat{\mathbf{X}}_{LS} = \hat{\mathbf{U}}\hat{\mathbf{\Lambda}}^{1/2}$ dado que

$$\mathbf{A} \approx \hat{\mathbf{U}}\hat{\mathbf{\Lambda}}\hat{\mathbf{U}}^\top = \hat{\mathbf{U}}\hat{\mathbf{\Lambda}}^{1/2}\hat{\mathbf{\Lambda}}^{1/2}\hat{\mathbf{U}}^\top = \hat{\mathbf{X}}_{LS}\hat{\mathbf{X}}_{LS}^\top$$

Adjacency spectral embedding

- Como \mathbf{A} es real y simétrica, podemos descomponerla como $\mathbf{A} = \mathbf{U}\mathbf{\Lambda}\mathbf{U}^\top$
 - $\mathbf{U} = [\mathbf{u}_1, \dots, \mathbf{u}_{N_v}]$ es la matriz ortogonal de vectores propios
 - $\mathbf{\Lambda} = \text{diag}(\lambda_1, \dots, \lambda_{N_v})$, con valores propios $\lambda_1 \geq \dots \geq \lambda_{N_v}$
- Definamos $\hat{\mathbf{\Lambda}} = \text{diag}(\lambda_1^+, \dots, \lambda_d^+)$ y $\hat{\mathbf{U}} = [\mathbf{u}_1, \dots, \mathbf{u}_d]$ ($\lambda^+ := \max(0, \lambda)$)
- La mejor aproximación de rango d semi-definida positiva de \mathbf{A} es $\hat{\mathbf{U}}\hat{\mathbf{\Lambda}}\hat{\mathbf{U}}^\top$
 \Rightarrow Adjacency spectral embedding (ASE) es $\hat{\mathbf{X}}_{LS} = \hat{\mathbf{U}}\hat{\mathbf{\Lambda}}^{1/2}$ dado que

$$\mathbf{A} \approx \hat{\mathbf{U}}\hat{\mathbf{\Lambda}}\hat{\mathbf{U}}^\top = \hat{\mathbf{U}}\hat{\mathbf{\Lambda}}^{1/2}\hat{\mathbf{\Lambda}}^{1/2}\hat{\mathbf{U}}^\top = \hat{\mathbf{X}}_{LS}\hat{\mathbf{X}}_{LS}^\top$$


Q: ¿La solución es única? Nop, dado que el producto interno es invariante a rotaciones

$$\mathbf{P} = \mathbf{X}\mathbf{W}(\mathbf{X}\mathbf{W})^\top = \mathbf{X}\mathbf{X}^\top, \quad \mathbf{W}\mathbf{W}^\top = \mathbf{I}_d$$

\Rightarrow El embedding de un RDPG es identificable modulo rotaciones

Embedding de un grafo Erdős-Renyi

- Ej: Grafo Erdős-Renyi ER(1000, 0,3) (realización de \mathbf{A} a la izquierda)






- Para $d = 1$ calculamos el ASE $\hat{\mathbf{x}}_{LS}$ y graficamos $\hat{\mathbf{x}}_{LS} \hat{\mathbf{x}}_{LS}^{\top}$ (centro)
 - ⇒ Buena aproximación de la matriz constante $\mathbf{P} = 0,3 \times \mathbf{11}^{\top}$
 - ⇒ El histograma de las entradas de $\hat{\mathbf{x}}_{LS}$ da más evidencia (derecha, $\sqrt{p} = 0,547$)
- Resultados sobre consistencia y distribuciones límites disponibles

A. Athreya et al., "Statistical inference on random dot product graphs: A survey," *J. Mach. Learn. Res.*, vol. 18, pp. 1-92, 2018

Embedding de un grafo SBM

- Ej: SBM con $N_v = 1500$, $Q = 3$ y parámetros



$$\boldsymbol{\alpha} = \begin{bmatrix} 1/3 \\ 1/3 \\ 1/3 \end{bmatrix}, \quad \boldsymbol{\Pi} = \begin{bmatrix} 0,5 & 0,1 & 0,05 \\ 0,1 & 0,3 & 0,05 \\ 0,05 & 0,05 & 0,9 \end{bmatrix}$$



- Realización de la adyacencia (izquierda), $\hat{\mathbf{X}}_{LS} \hat{\mathbf{X}}_{LS}^T$ (centro), filas de $\hat{\mathbf{X}}_{LS}$ (derecha)
- Justifica el uso de métodos geométricos (e.g. KNN o GMM del espectro)

Interpretabilidad de los embeddings

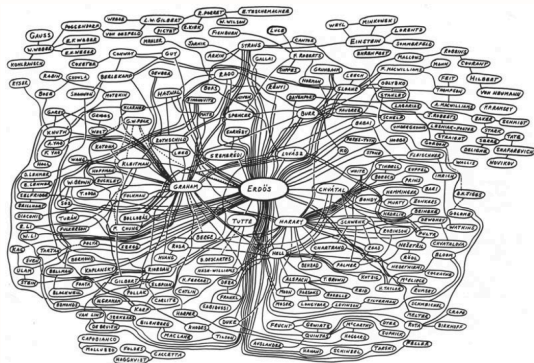
- **Ex:** Zachary's karate club con $N_v = 34$, $N_e = 78$ (izquierda)



- Embeddings (filas de $\hat{\mathbf{X}}_{LS}$) para $d = 2$ (derecha)
 - El administrador del club ($i = 0$) y el instructor ($j = 33$) son ortogonales
- La interpretabilidad es una característica muy valiosa de los RDPGs
 - ⇒ **Alineación del vector** indica afinidad entre nodos (comunidad)
 - ⇒ **Magnitud del vector** indica conectividad del nodo

Grafo de colaboración entre matemáticos

- Ej: Red de colaboración entre matemáticos centrado en Paul Erdős




- La mayoría de los matemáticos tienen un **número de Erdős** de no más de 4 o 5
⇒ Dibujo creado por R. Graham en 1979

Grafo de colaboración entre matemáticos

- Grafo de co-autoría G , $N_v = 4301$ nodos con número de Erdős ≤ 2

⇒ No hay una estructura clara de la matriz de adyacencia “cruda” \mathbf{A} (izquierda)




- La estructura de comunidades se revela al permutar la matriz (derecha)

- Se obtiene el ASE $\hat{\mathbf{X}}_{LS}$ de los matemáticos
- K-means angular** en las filas de $\hat{\mathbf{X}}_{LS}$ [Scheinerman-Tucker'10]

Relaciones internacionales

■ Ej: Red dinámica G_t de relaciones entre naciones

$\Rightarrow (i, j) \in \mathcal{E}_t$ si las naciones tuvieron un tratado de alianza en el año t



■ Ángulo entre el embedding del Reino Unido y Francia entre 1890 y 1995

- Ortogonal durante fines del siglo XIX
- Se acercan durante las guerras, y se vuelve alejar durante la ocupación nazi en la segunda guerra
- Fuertemente alineados a partir de los 70 hasta la creación de la UE

Extensiones

- Ignoramos la diagonal $[\hat{\mathbf{X}}_{LS}\hat{\mathbf{X}}_{LS}^T]_{ii} = 0$. Se puede resolver mediante algoritmos iterativos o descenso por gradiente

E. R. Scheinerman and K. Tucker, “Modeling graphs using dot product representations,” *Comput. Stat.*, vol. 25, pp. 1-16, 2010

M. Fiori et al., “Algorithmic Advances for the Adjacency Spectral Embedding,” *EUSIPCO*, 2022

- ¿ \mathbf{A} no es semi-definida positiva? Extensión conocida como **generalized RDPG**

P. Rubin-Delanchy et al, “A statistical interpretation of spectral embedding: The generalised random dot product graph,” *arXiv:1709.05506 [stat.ML]*, 2017

- Considerar el caso **con pesos y/o dirigido** es posible



B. Marenco et al., “Online Change Point Detection for Weighted and Directed Random Dot Product Graphs,” *IEEE TSIPN*, 2022

- Permite varias **aplicaciones** en testing, clustering, **change-point detection**, ...

Online change point detection: entrenamiento

- **Idea:** Usar “estimating function” [Kirsch-Tadjuidje’15]

⇒ Entrenar con m grafos “limpios” (sin cambios)




Online change point detection: Monitoreo

- Observar las matrices secuencialmente $\mathbf{A}[m+1], \mathbf{A}[m+2], \dots$

- Monitorear la suma acumulada $\mathbf{S}[m, k] = \sum_{t=m+1}^{m+k} (\hat{\mathbf{X}}\hat{\mathbf{X}}^\top - \mathbf{A}[t])$



Proposición: Para k grande y bajo la hipótesis nula de no-cambio, $\Gamma[m, k] := \|\mathbf{S}[m, k]\|^2$ tiene una distribución χ^2 generalizada.



- **Liviano:** requisito de memoria y computacional de $O(N^2)$

Monitoreo de una red inalámbrica



- Extensión del modelo para incluir grafos **con pesos y dirigidos**
- Red inalámbrica del Plan Ceibal. Medidas@hora del RSSI para $N = 6$ APs
⇒ Según el administrador de red: *AP 4 fue movido el 30 de octubre*



- Explicar el cambio a través de la interpretabilidad del ASE
- **Reproducibilidad** ⇒ Código disponible en @ https://github.com/git-artes/cpd_rdpq

Futuro

- Descenso por gradiente para hallar el ASE: **escalabilidad** y **tracking**
 - Manejo de datos faltantes, alineación mediante inicialización (M. Fiori et al. “Gradient-Based Spectral Embeddings of Random Dot Product Graphs”, arXiv preprint arXiv:2307.13818, submitted)



- Propiedades estadísticas del modelo no-paramétrico del **weighted RDPG**

$$\mathbb{E} [e^{tA_{ij}} | \mathbf{X}] = \sum_{m=0}^{\infty} \frac{t^m \mathbb{E} [A_{ij}^m]}{m!} = 1 + \sum_{m=1}^{\infty} \frac{t^m \mathbf{x}_i^\top [m] \mathbf{x}_j [m]}{m!}$$