



FACULTAD DE
INGENIERÍA



UNIVERSIDAD
DE LA REPÚBLICA
URUGUAY

Aprendizaje Automático para Datos en Grafos

Graph representation learning

Marcelo Fiori

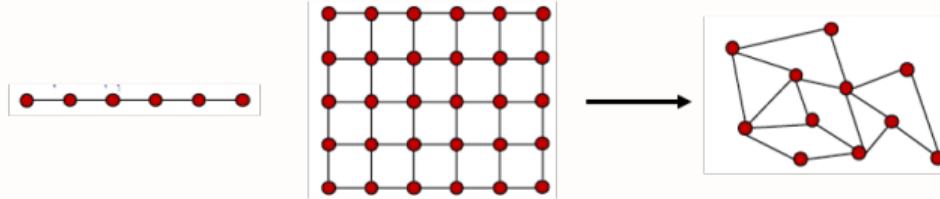
Muy basado en transparencias de Gonzalo Mateos

mfiori@fing.edu.uy
<http://www.fing.edu.uy/~mfiori/>

10 de noviembre, 2022

Aprendizaje automático en grafos: Motivación

- Modelos muy exitosos para representación (y) aprendizaje en **datos estructurados**
 - Secuencias (e.g., texto, audio, videos) via **recurrent neural networks (RNNs)**
 - Clasificación de imágenes via **convolutional neural networks (CNNs)**



- Pero los datos no siempre son regulares \Rightarrow Estructuras relacionales complejas
 - **Grafos** en redes sociales, química computacional, biología, ...
- **Desafíos:** aplicar modelos diseñados para datos regulares, en grafos
 - La estructura de los grafos puede ser arbitraria y variar en diferentes escenarios
 - Las convoluciones no generalizan a dominios irregulares

M. Bronstein et al, "Geometric deep learning: Going beyond Euclidean data," *IEEE Signal Processing Magazine*, vol. 34, 2017

¿De qué vamos a hablar?

Graph representation learning (GRL)

- Aprender vectores en baja dimensión (embeddings) para datos en grafos
- Tipos de aprendizaje:
 - **Supervisado**: aprender representaciones para clasificación de nodos o grafos
 - **No-supervisado**: aprender representaciones que preserven estructura de grafos
- Dominio subyacente:
 - **Transductivo**: estructura del grafo fija (e.g., una red social muy grande)
 - **Inductivo**: los grafos de entrada pueden variar (e.g., multiples moléculas)
- Información en los nodos:
 - **Featureless**: no tenemos información adicional (i.e., graph signals)
 - **With features**: los nodos tienen atributos o características

Roadmap

- 1 The network embedding problem
- 2 Una taxonomía de modelos de graph embedding
- 3 Unsupervised graph embedding
- 4 Applications

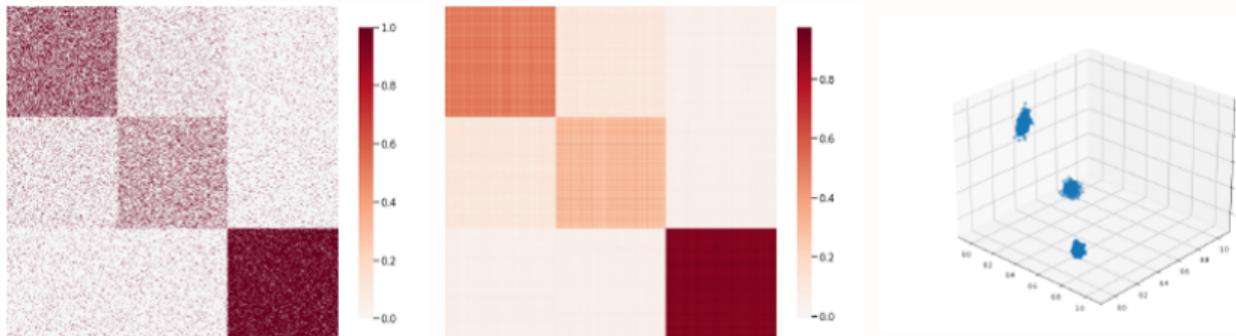
Embeddings de grafos

- Aprender un mapa de un grafo discreto a un dominio continuo
- Dado $G(\mathcal{V}, \mathcal{E})$ con matriz de adyacencia (con pesos) $\mathbf{W} \in \mathbb{R}^{N_v \times N_v}$
- **Objetivo:** aprender una representación en vectores d -dimensionales $\{\mathbf{z}_i\}_{i \in \mathcal{V}}$
 - ⇒ Criterio es preservar propiedades locales y globales del grafo
- Salida es una matriz de embeddings de nodos $\mathbf{Z} = [\mathbf{z}_1, \dots, \mathbf{z}_{N_v}]^\top \in \mathbb{R}^{N_v \times d}$
 - ⇒ Elegir $d \ll N_v$ para escalabilidad
 - ⇒ Hay reducción de dimensionalidad
- Es posible extender esto a un **embedding del grafo entero** via $\mathbf{z} \in \mathbb{R}^d$

Adjacency spectral embedding (revisitado)

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

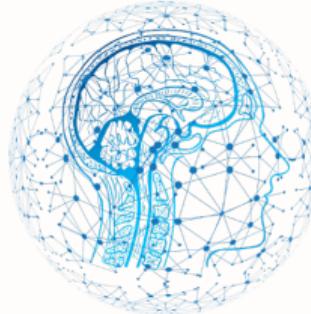
$$\boldsymbol{\alpha} = \begin{bmatrix} 1/3 \\ 1/3 \\ 1/3 \end{bmatrix}, \quad \boldsymbol{\Pi} = \begin{bmatrix} 0,5 & 0,1 & 0,05 \\ 0,1 & 0,3 & 0,05 \\ 0,05 & 0,05 & 0,9 \end{bmatrix}$$



- Adyacencia muestrada (izq.), $\mathbf{Z}\mathbf{Z}^\top$ (centro), filas de \mathbf{Z} (der.)
- Embeddings para poder usar métodos geométricos de análisis

El rol de las señales en grafos

- Señales en grafos (a.k.a. atributos en nodos o **características**) $\mathbf{X} \in \mathbb{R}^{N_v \times F}$



- Ex: Edad, género (redes sociales), señales fMRI, ratings de productos
- Los embeddings captura información **estructural** y **semántica** del grafo

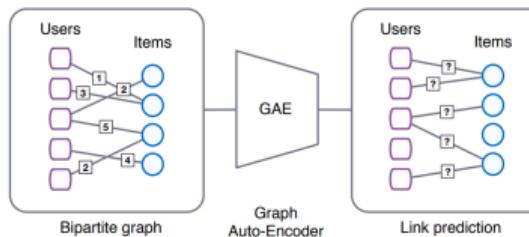
$$\{\mathbf{W}, \mathbf{X}\} \mapsto \mathbf{Z}$$

- Sin \mathbf{X} , el embedding $\{\mathbf{W}\} \mapsto \mathbf{Z}$ se dice **featureless**
⇒ El mapeo **solo** preserva información **estructural**

Embeddings transductivos e inductivos

Transductive network embedding

- Embedding de nodos de un grafo fijo (en general grande)
 - Ex: Recomendación de productos o amigos via predicción de enlaces
 - Ex: Clasificación de nodos en aprendizaje semi-supervisado



- Dados nuevos nodos, hay que actualizar o re-entrenar el modelo

Inductive network embedding

- Aprender mapas a representaciones que generalizan a grafos no vistos
 - Ex: Embedding de grafos de cerebros para clasificación de sujetos
 - Ex: Embedding de grafos dinámicos para clustering temporal
- Típicamente se necesitan señales **X** para hacer embedding inductivo

Embeddings supervisados y no-supervisados

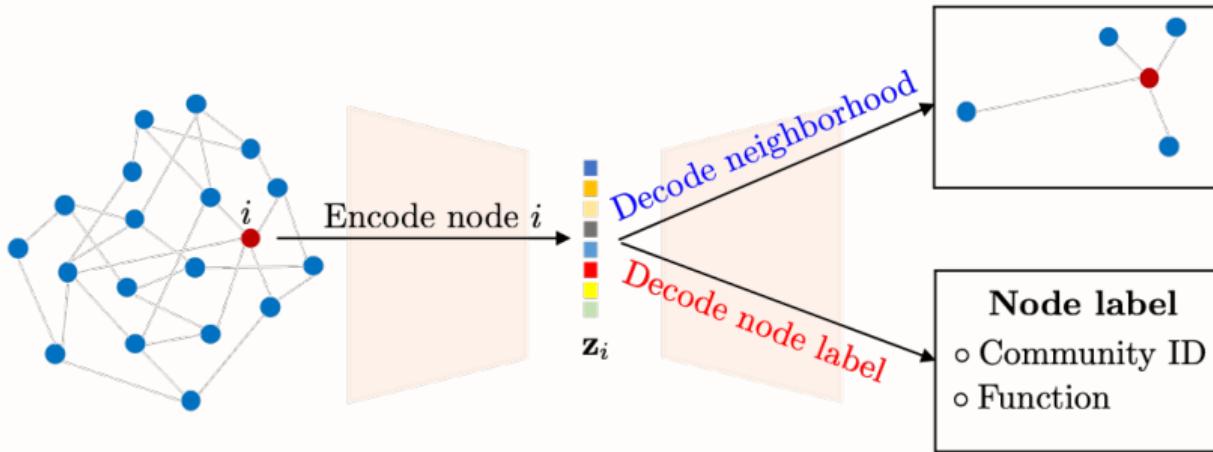
Unsupervised network embedding

- Solamente tenemos la topología del grafo \mathbf{W} (y eventualmente \mathbf{X})
 - Preservar estructuras del grafo optimizando una función de pérdida/reconstrucción
 - Decodificar los embedding \mathbf{Z} para aproximar bien \mathbf{W}
- Ex: compresión, visualización, clustering, predicción de enlaces

Supervised network embedding

- Además de \mathbf{W} (y \mathbf{X}), tenemos disponibles etiquetas de nodos o grafos \mathbf{y}^S
 - Optimizar embeddings para tareas aguas abajo
 - Combina reconstrucción y función de pérdida de la tarea específica
- Ex: clasificación de nodos, clasificación de grafos

Una perspectiva encoder-decoder



W. L. Hamilton et al, "Representation learning on graphs: Methods and applications," *IEEE Data Engineering Bulletin*, 2018

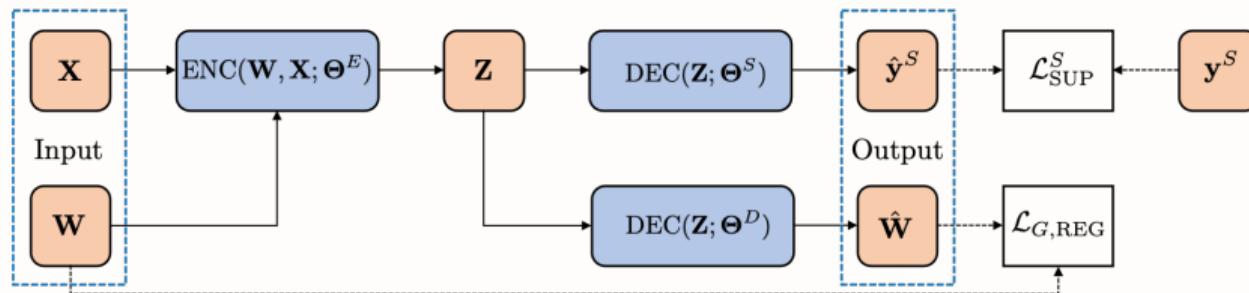
Roadmap

- 1 The network embedding problem
- 2 Una taxonomía de modelos de graph embedding
- 3 Unsupervised graph embedding
- 4 Applications

Un modelo abarcativo para graph embedding

■ Graph Encoder Decoder Model (GraphEDM)

- ⇒ Marco unificador para revisar y comparar métodos de GRL
- ⇒ **Biblioteca open-source** con métodos y aplicaciones



I. Chami et al, “Machine learning on graphs: A model and comprehensive taxonomy,” *arXiv:2005.03675 [cs.LG]*, 2020

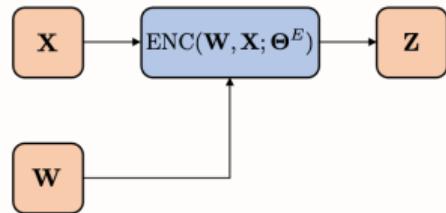
■ Q: ¿Cuáles son los componentes constitutivos del modelo?

<https://github.com/google/gcnn-survey-paper>

Input

- Grafo no dirigido $G(\mathcal{V}, \mathcal{E})$, con $|\mathcal{V}| = N_v$ y $|\mathcal{E}| = N_e$
⇒ Matriz de adyacencia (con pesos) $\mathbf{W} \in \mathbb{R}^{N_v \times N_v}$
- Opcionalmente señales en el grafo (características de nodos) $\mathbf{X} \in \mathbb{R}^{N_v \times F}$
- Para aprendizaje (semi)-supervisado, también necesitamos etiquetas de:
 - **Nodos (N)**, para clasificación de nodos y clustering
 - **Aristas (E)**, para predicción de enlaces o clasificación de relaciones
 - **Grafos (G)**, para clustering y clasificación de grafos
- Las etiquetas de supervisión las denotamos \mathbf{y}^S , donde $S \in \{N, E, G\}$

Encoder



■ Graph encoder network

$$\text{ENC}_{\Theta^E} : \mathbb{R}^{N_v \times N_v} \times \mathbb{R}^{N_v \times F} \mapsto \mathbb{R}^{N_v \times d}$$

⇒ Parámetros entrenables Θ^E

■ Combina la estructura del grafo con señales para producir un embedding

$$\mathbf{Z} = \text{ENC}(\mathbf{W}, \mathbf{X}; \Theta^E)$$

⇒ Captura diferentes propiedades del grafo en base al tipo de supervisión

Decoder (I)



■ Graph decoder network

$$\text{DEC}_{\Theta^D} : \mathbb{R}^{N_v \times d} \mapsto \mathbb{R}^{N_v \times N_v}$$

⇒ Parámetros entrenables Θ^D

■ Usa \mathbf{Z} para producir scores de (di)similitud \hat{W}_{ij} para cada $\{i, j\} \in \mathcal{V}^{(2)}$

$$\hat{\mathbf{W}} = \text{DEC}(\mathbf{Z}; \Theta^D)$$

⇒ Reconstrucción no supervisada del grafo

⇒ Aproxima \mathbf{W} , o más en general una matriz de (di)similitud $s(\mathbf{W})$

Decoder (II)



■ Classification network

$$\text{DEC}_{\Theta^S} : \mathbb{R}^{N_v \times d} \mapsto \mathbb{R}^{N_v \times |\mathcal{Y}|}$$

⇒ Parámetros entrenables Θ^S , espacio de etiquetas \mathcal{Y}

■ Usa **Z** para producir distribuciones de etiquetas para cada nodo

$$\hat{\mathbf{y}}^S = \text{DEC}(\mathbf{Z}; \Theta^S)$$

⇒ Aprendizaje (semi)-supervisado para clasificación de nodos/grafos

Output

- Matriz de similitud reconstruida $\hat{\mathbf{W}} \in \mathbb{R}^{N_v \times N_v}$
 - ⇒ Usado para entrenar algoritmos de embedding no supervisados
- Para aprendizaje (semi)-supervisado, las salidas son las etiquetas que se predicen $\hat{\mathbf{y}}^S$
 - El espacio de salida de etiquetas varía dependiendo del tipo de supervisión
- Node-level: $\hat{\mathbf{y}}^N \in \mathcal{Y}^{N_v}$ or $\hat{\mathbf{Y}}^N \in [0, 1]^{N_v \times |\mathcal{Y}|}$
 - ⇒ Cuando $|\mathcal{Y}| = d$, se puede usar activación softmax en las filas de \mathbf{Z}
- Edge-level: $\hat{\mathbf{Y}}^E \in \mathcal{Y}^{N_v \times N_v}$, where typically $\mathcal{Y} = \{0, 1\}^{\#\text{relation types}}$
 - ⇒ Cuando $\#\text{relation types} = 1$ (i.e., predicción de enlaces), salida $\hat{\mathbf{W}}$
- Graph-level: $\hat{y}^G \in \mathcal{Y}$
 - ⇒ Usando \mathbf{W} , convertir \mathbf{Z} a \hat{y}^G via graph pooling

Funciones de pérdida

■ Supervised loss

⇒ $\mathcal{L}_{\text{SUP}}^S$ compara las etiquetas que se predicen $\hat{\mathbf{y}}^S$ al ground truth \mathbf{y}^S

Ex: clasificación semi-supervisada de nodos ($S = N$, $\mathcal{V} = \mathcal{V}_{obs} \cup \mathcal{V}_{miss}$)

$$\mathcal{L}_{\text{SUP}}^N(\mathbf{y}^N, \hat{\mathbf{y}}^N; \Theta) = \sum_{i \in \mathcal{V}_{obs}} \ell(y_i^N, \hat{y}_i^N; \Theta)$$

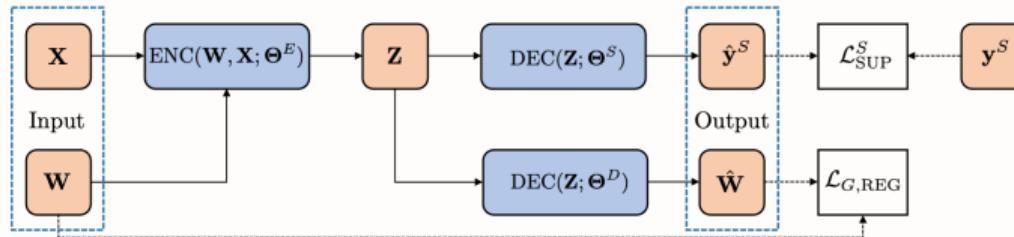
■ Graph regularization loss

⇒ $\mathcal{L}_{G,\text{REG}}$ compara $\hat{\mathbf{W}}$ con matriz de (di)similitud objetivo $s(\mathbf{W})$

$$\mathcal{L}_{G,\text{REG}}(\mathbf{W}, \hat{\mathbf{W}}; \Theta) = d_1(s(\mathbf{W}), \hat{\mathbf{W}})$$

- $d_1(\cdot, \cdot)$: función distancia o de disimilitud
- Aprovechr G via $s(\mathbf{W})$ para regularizar los parámetros del modelo Θ

Función objetivo



■ Weight regularization loss

⇒ \mathcal{L}_{REG} regulariza los parámetros entrenables Θ para reducir overfitting

$$\mathcal{L}_{\text{REG}}(\Theta) = \sum_{\theta \in \Theta} \|\theta\|_2^2$$

■ Función objetivo GraphEDM total

$$\mathcal{L}(\Theta) = \alpha \mathcal{L}_{\text{SUP}}^S(\mathbf{y}^S, \hat{\mathbf{y}}^S; \Theta) + \beta \mathcal{L}_{G,\text{REG}}(\mathbf{W}, \hat{\mathbf{W}}; \Theta) + \mathcal{L}_{\text{REG}}(\Theta)$$

⇒ Entrenamiento supervisado ($\alpha \neq 0$) o no supervisado ($\alpha = 0$)

■ Q: ¿Aprendizaje supervisado end-to-end o en dos etapas?

Taxonomía de graph embedding

- Categorizamos los métodos de GRL en base al encoder y la función de pérdida
- Shallow embedding methods $\mathbf{Z} = \text{ENC}(\boldsymbol{\Theta}^E) = \boldsymbol{\Theta}^E$
 - Un simple embedding lookup
- Graph auto-encoding methods $\mathbf{Z} = \text{ENC}(\mathbf{W}; \boldsymbol{\Theta}^E)$
 - Transductivos como los shallow embeddings, no hay señal \mathbf{X} , así que funciona para grafo fijo G
- Graph regularization methods $\mathbf{Z} = \text{ENC}(\mathbf{X}; \boldsymbol{\Theta}^E)$
 - Usamos \mathbf{W} via $\mathcal{L}_{G,\text{REG}}$ para regularizar los embeddings
- Neighborhood aggregation methods $\mathbf{Z} = \text{ENC}(\mathbf{W}, \mathbf{X}; \boldsymbol{\Theta}^E)$
 - Usamos \mathbf{W} para propagar información entre nodos y aprender \mathbf{Z}

Roadmap

- 1 The network embedding problem
- 2 Una taxonomía de modelos de graph embedding
- 3 Unsupervised graph embedding
- 4 Applications

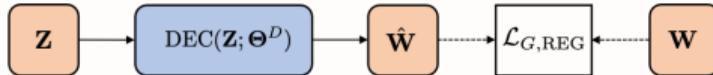
Unsupervised graph embedding

- **Objetivo:** Aprender embeddings de nodos que preserven estructura del grafo
- Optimizamos para reconstruir cierta matriz de (di)similitud entre nodos $s(\mathbf{W})$

$$\mathcal{L}(\Theta) = \alpha \cancel{\mathcal{L}_{\text{SUP}}^S(\mathbf{y}^S, \hat{\mathbf{y}}^S; \Theta)} + \beta \mathcal{L}_{G,\text{REG}}(\mathbf{W}, \hat{\mathbf{W}}; \Theta) + \mathcal{L}_{\text{REG}}(\Theta)$$

- La salida del decoder es $\hat{\mathbf{W}}$, con $\hat{W}_{ij} = d_2(\mathbf{z}_i, \mathbf{z}_j)$
 - Regularización $\mathcal{L}_{G,\text{REG}} = d_1(s(\mathbf{W}), \hat{\mathbf{W}})$
 - Optimizamos sobre conjunto de entrenamiento $\{i, j\} \in \mathcal{V}_{obs}^{(2)}$, usando SGD o métodos espectrales
- La matriz de similitud objetivo $s(\mathbf{W})$ puede tomar varias formas
 - Ex: Reconstruir proximidad de primer orden via $[s(\mathbf{W})]_{ij} = W_{ij}$
 - Ex: Proximidad de alto orden $[s(\mathbf{W})]_{ij} = |\mathcal{N}_i \cap \mathcal{N}_j|$, Jaccard, Adamic-Adar
 - Ex: Prob. $[s(\mathbf{W})]_{ij} = P(v_j | v_i)$ que $i, j \in \mathcal{V}$ co-ocurran en paseos al azar (random walks)

Shallow embeddings



■ Shallow embedding methods

$$\mathbf{Z} = \text{ENC}(\boldsymbol{\Theta}^E) = \boldsymbol{\Theta}^E \in \mathbb{R}^{N_v \times d}$$

⇒ Un simple embedding lookup, se optimiza directamente \mathbf{Z}

■ Dos clases, en base al tipo de decoder $\hat{\mathbf{W}} = \text{DEC}(\mathbf{Z}; \boldsymbol{\Theta}^D)$

- **Métodos basados en distancia:** $\hat{W}_{ij} = d_2(\mathbf{z}_i, \mathbf{z}_j)$
- **Métodos basados en productos externos:** $\hat{\mathbf{W}} = \mathbf{Z}\mathbf{Z}^\top \Rightarrow \hat{W}_{ij} = \mathbf{z}_i^\top \mathbf{z}_j$

■ Inspirados en reducción de dimensionalidad via low-rank matrix factorization

⇒ Enfoques más recientes se basan en random walks (analogías con NLP)

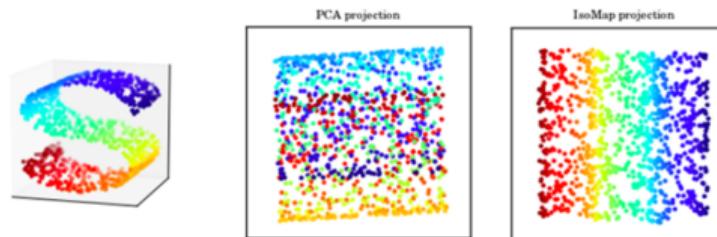
Métodos basados en distancia

- **Idea:** que los embeddings preserven **distancias** en G [codificadas en $s(\mathbf{W})$]

$$\mathcal{L}_{G,\text{REG}}(\mathbf{W}, \hat{\mathbf{W}}; \Theta) = d_1(s(\mathbf{W}), \hat{\mathbf{W}}) = \sum_{i,j \in \mathcal{V}_{obs}^{(2)}} ([s(\mathbf{W})]_{ij} - \hat{W}_{ij})^2$$

\Rightarrow Euclidean distance decoder: $\hat{W}_{ij} = d_2(\mathbf{z}_i, \mathbf{z}_j) = \|\mathbf{z}_i - \mathbf{z}_j\|_2$

- **Multi-dimensional scaling (MDS)** preserva conectividad **local**
 - Seteamos $[s(\mathbf{W})]_{ij} = 1$ (o W_{ij}) si $W_{ij} > 0$ y 0 si no
- **IsoMAP** preserva distancias geodésicas **globales** en la variedad
 - Seteamos e.g., $[s(\mathbf{W})]_{ij} = d_G(i, j)$, distancia del camino más corto entre $i, j \in \mathcal{V}$



Laplacian eigenmaps

- Captura información de G via propiedades espectrales de $\mathbf{L} = \mathbf{D} - \mathbf{W}$
 - ⇒ Esquema no lineal de reducción de dimensionalidad que preserva propiedades locales

$$\min_{\mathbf{Z} \in \mathbb{R}^{N_v \times d}} \text{trace}(\mathbf{Z}^\top \mathbf{L} \mathbf{Z}), \quad \text{s. to } \mathbf{Z}^\top \mathbf{D} \mathbf{Z} = \mathbf{I}$$

- Se puede escribir de forma equivalente como un término de regularización

$$\mathcal{L}_{G,\text{REG}}(\mathbf{W}, \hat{\mathbf{W}}; \Theta) = d_1(s(\mathbf{W}), \hat{\mathbf{W}}) = \sum_{i,j \in \mathcal{V}_{obs}^{(2)}} W_{ij} \hat{W}_{ij}^2$$

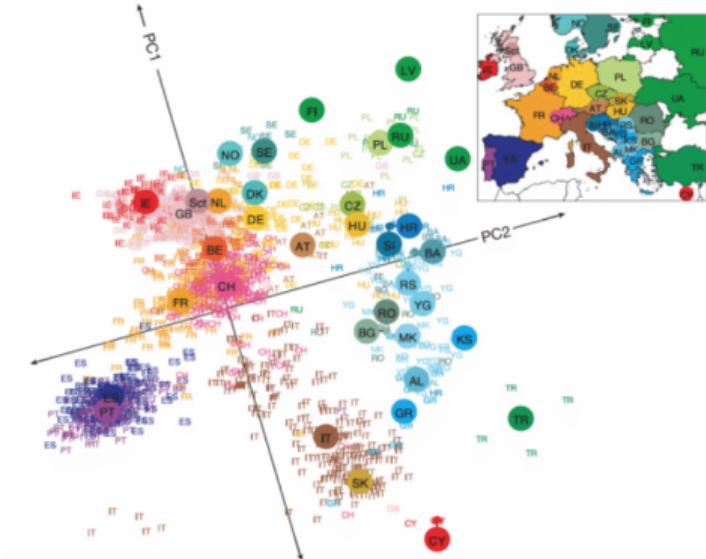
⇒ Euclidean distance decoder: $\hat{W}_{ij} = d_2(\mathbf{z}_i, \mathbf{z}_j) = \|\mathbf{z}_i - \mathbf{z}_j\|_2$

⇒ Embeddings estarán cerca en \mathbb{R}^d si i, j están bien conectados en G

M. Belkin and P. Niyogi, "Laplacian eigenmaps for dimensionality reduction and data representation," *Neural Computation*, 2003.

Gene cartography

- Ex: Spectral embedding de matriz de ‘gene similarity’ ($d = 2$)
⇒ Consistente con el origen de los individuos en Europa



J. Novembre, “Genes mirror geography within Europe,” *Nature*, 2008

Non-Euclidean embedding spaces

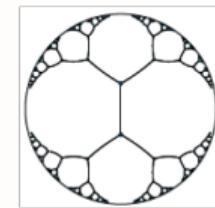
- **Idea:** embedding de grafos con estructura jerárquica en espacio hiperbólico

$$\mathcal{L}_{G,\text{REG}}(\mathbf{W}, \hat{\mathbf{W}}; \Theta) = d_1(s(\mathbf{W}), \hat{\mathbf{W}}) = - \sum_{i,j \in \mathcal{V}_{obs}^{(2)}} W_{ij} \log \frac{e^{-\hat{W}_{ij}}}{\sum_{k | \mathbf{W}_{ik} = 0} e^{-\hat{W}_{ik}}}$$

⇒ Poincaré distance decoder:

$$\hat{W}_{ij} = d_2(\mathbf{z}_i, \mathbf{z}_j) = \text{arcosh} \left(1 + 2 \frac{\|\mathbf{z}_i - \mathbf{z}_j\|_2^2}{(1 - \|\mathbf{z}_i\|_2^2)(1 - \|\mathbf{z}_j\|_2^2)} \right)$$

- Captura similitud y jerarquía
- Se usan herramientas de optimización en variedades



M. Nickel and D. Kiela, "Poincaré embeddings for learning hierarchical representations," *NeurIPS*, 2017

Matrix factorization methods

- **Idea:** aprender representaciones de bajo rango de la matriz de similitud $s(\mathbf{W})$

$$\mathcal{L}_{G,\text{REG}}(\mathbf{W}, \hat{\mathbf{W}}; \Theta) = d_1(s(\mathbf{W}), \hat{\mathbf{W}}) = \|s(\mathbf{W}) - \hat{\mathbf{W}}\|_F^2$$

⇒ Decodificador de producto externo: $\hat{\mathbf{W}} = \text{DEC}(\mathbf{Z}; \Theta^D) = \mathbf{Z}\mathbf{Z}^\top$

⇒ Implica una **aproximación** via producto interno $[s(\mathbf{W})]_{ij} \approx \mathbf{z}_i^\top \mathbf{z}_j$

- **Graph factorization (GF)** preserva similitud de primer orden en G
 - Seteamos $[s(\mathbf{W})]_{ij} = W_{ij}$ y evaluamos $\mathcal{L}_{G,\text{REG}}(\mathbf{W}, \hat{\mathbf{W}}; \Theta)$ en $(i, j) \in \mathcal{E}$
- **GraRep** preserva similitud de orden mayor en G
 - Seteamos e.g., $[s(\mathbf{W})]_{ij} = [\mathbf{W}^k]_{ij}$, $k \geq 2$, cantidad de caminos de largo k
- **HOPE** preserva medidas de similitud general en G (dirigido)
 - Jaccard, Adamic-Adar y scores relacionados usando vecinos
- Muy relacionado al **adjacency spectral embedding (ASE)** para RDPGs

De textos a grafos

- Utilizar herramientas de modelado y aprendizaje de características en NLP
 - Ex: Red neuronal *skip-gram* para word2vec embeddings
 - De texto (secuencias de palabras) a grafos (secuencias de nodos)
- Idea: \mathbf{z}_i similares a nodos que tiendan a co-ocurrir en random walks sobre G
- Mirar oraciones en NLP como random walks sobre el vocabulario
 - Generar random walks cortos sobre G para samplear secuencias de nodos
 - Aprender distribuciones posicionales de nodos como con palabras [Perozzi et al'14]
- Prob. $P(j | i)$ de visitar j en un random walk de largo T desde i
⇒ Medida de similitud (asimétrica) $[s(\mathbf{W})]_{ij}$ a decodificar desde \mathbf{Z}

Random walk approaches

- Pares de entrenamiento $\{i, j\} \in \mathcal{V}_{obs}^{(2)}$ sampleados de random walks cortos
 - Para cada $i \in \mathcal{V}$, N se sortean pares $\{i, j_1\}, \dots, \{i, j_N\}$ de $P(j | i)$
 - Largo de cada paseo es $T \in \{2, \dots, 10\}$
- Término de regularización del grafo: cross-entropy loss

$$\mathcal{L}_{G,\text{REG}}(\mathbf{W}, \hat{\mathbf{W}}; \Theta) = - \sum_{i,j \in \mathcal{V}_{obs}^{(2)}} \log \hat{W}_{ij}$$

⇒ Composición de un softmax y un decodificador de producto externo

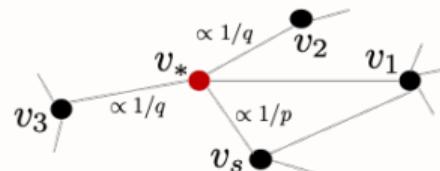
$$\hat{W}_{ij} = \frac{e^{\mathbf{z}_i^\top \mathbf{z}_j}}{\sum_{k \in \mathcal{V}} e^{\mathbf{z}_i^\top \mathbf{z}_k}}$$

⇒ Implica una aproximación $\hat{W}_{ij} \approx [s(\mathbf{W})]_{ij} = P(j | i)$

- Evaluar el denominador del softmax es desafiante (complejidad $\mathcal{O}(N_v)$)

DeepWalk y node2vec

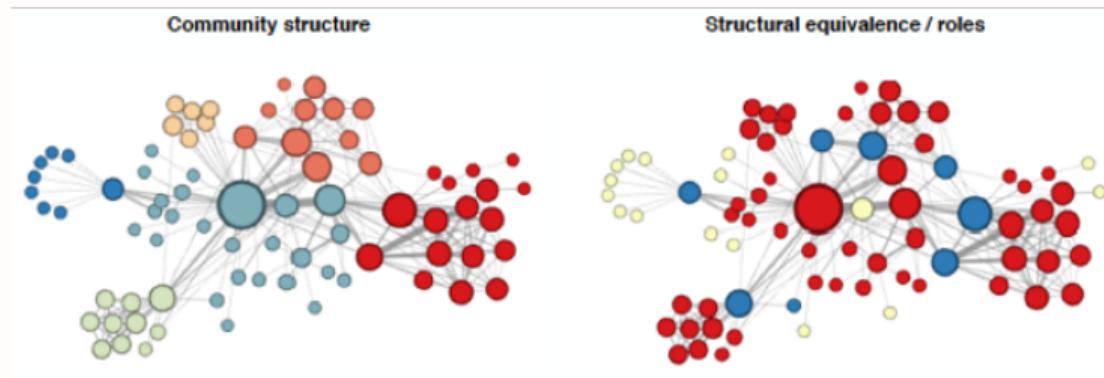
- DeepWalk sortea random walks de forma uniforme (equiprobable en los vecinos)
 - Matriz de probabilidad de transición $\mathbf{P} = \mathbf{D}^{-1}\mathbf{W}$
 - Usan *softmax jerárquico* para calcular $\sum_{k \in \mathcal{V}} e^{\mathbf{z}_i^\top \mathbf{z}_k}$ usando árboles binarios
- Node2Vec usa una definición flexible de random walks (sesgados)
 - Interpolá suavemente entre paseos del tipo BFS (Breadth First Search) o DFS (Depth First Search)
 - Efectivo para capturar roles estructurales o estructuras de comunidades
 - Aproxima $\sum_{k \in \mathcal{V}^*} e^{\mathbf{z}_i^\top \mathbf{z}_k}$ muestreando \mathcal{V}^*



- Hyperparámetros p (de retorno) y q (in-out). Después de hacer $v_s \rightarrow v_*$
 - (i) Controla la probabilidad de revisitar nodos ($v_* \rightarrow v_s$); o
 - (ii) Quedarse cerca del nodo predecesor ($v_* \rightarrow v_1$); o
 - (iii) Moverse “más lejos” ($v_* \rightarrow \{v_2, v_3\}$)

Random walks sesgados

- Ex: grafo de interacción entre personajes de la novela ‘Les Miserables’



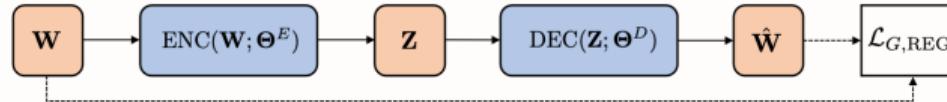
- node2vec interpola entre capturar estructuras **globales** y **locales**
 - El coloreo de la izquierda recupera membresía a comunidades (**global**)
 - El coloreo de la derecha indica roles que juega entre vecinos (**local**)

A. Grover and J. Leskovec, “node2vec: Scalable feature learning for networks,” *KDD*, 2016

Limitaciones

- Shallow embeddings: el encoder es muy sencillo
 ⇒ Optimiza directamente un único embedding \mathbf{z}_i para cada nodo $i \in \mathcal{V}$
- No se comparten parámetros entre nodos en el encoder
 - Estadísticamente ineficiente, compartir parámetros actúa como un regularizador
 - Computacionalmente ineficiente, el número de parámetros es $\mathcal{O}(N_v)$
- No permite aprovechar señales
 - Perdemos atributos potencialmente muy informativos respecto a la posición y rol en G
- Inherentemente transductivos
 - Problema para grafos grandes o dinámicos
 - No generalizan a otros grafos más allá de G (usado en training)

Autoencoders



- Autoencoders

$$\mathbf{Z} = \text{ENC}(\mathbf{W}; \Theta^E)$$

⇒ Incorporamos \mathbf{W} en el encoder

- Usamos una **red neuronal profunda** en encoder y decoder

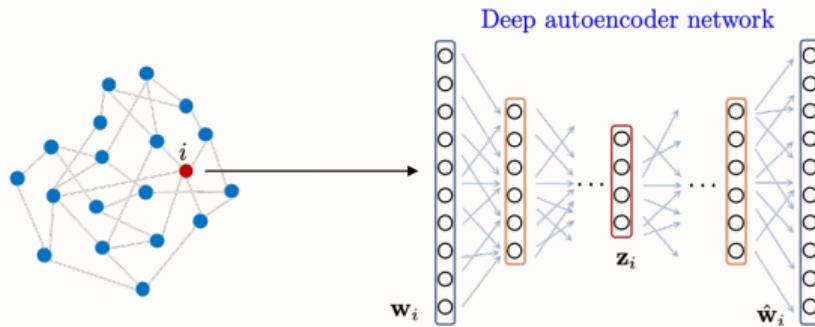
⇒ Habilidad para modelar no linealidades

⇒ Lleva a representaciones más complejas

- Se entrena el modelo end-to-end minimizando una función de pérdida

Métodos de neighborhood autoencoder

- Sea $\mathbf{w}_i \in \mathbb{R}^{N_v}$ la i -ésima columna de \mathbf{W}
⇒ Captura la información de vecinos de $i \in \mathcal{V}$



- Objetivo del autoencoder: reconstruir \mathbf{w}_i a partir del embedding \mathbf{z}_i aprendido

Structural deep network embedding

- Structural deep network embedding (SDNE) minimiza

$$\mathcal{L}_{G,\text{REG}}(\mathbf{W}, \hat{\mathbf{W}}; \Theta) = \sum_i \|\mathbf{w}_i - \hat{\mathbf{w}}_i\|_2^2 + \gamma \sum_{i,j} W_{ij} \|\mathbf{z}_i - \mathbf{z}_j\|_2^2$$

⇒ Incorpora el costo de Laplacian eigenmaps

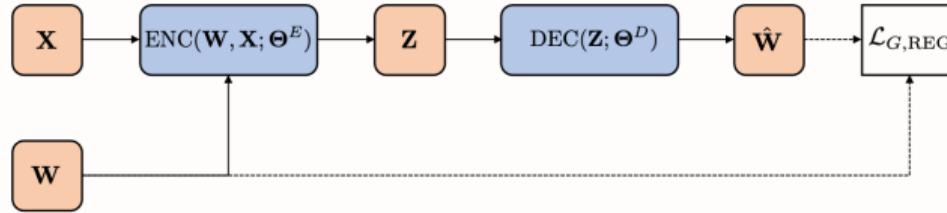
- Usa deep autoencoders por nodo (parámetros compartidos)

$$\mathbf{z}_i = \text{ENC}(\mathbf{w}_i; \Theta^E), \quad \hat{\mathbf{w}}_i = \text{DEC}(\mathbf{z}_i; \Theta^D)$$

- Vía \mathbf{w}_i , se regulariza el encoder con la topología de G
- Desventaja: la dimensión de entrada está fija a N_v , costoso para grafos G grandes

D. Wang et al, "Structural deep network embedding," KDD, 2016

Graph neural networks



■ Graph Neural Networks

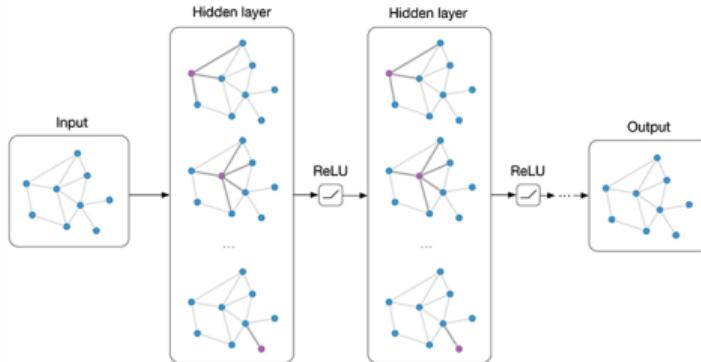
$$\mathbf{Z} = \text{ENC}(\mathbf{W}, \mathbf{X}; \Theta^E)$$

⇒ Usa **señales en el grafo \mathbf{X}** y topología \mathbf{W} en el encoder

■ Genera embedding \mathbf{z}_i por agregación de señales en \mathcal{N}_i

- **Convolucional:** implementación local y distribuida
- **Eficiencia:** dimensión de parámetros independiente de N_v
- **Regularización:** a través de los parámetros compartidos
- **Inductivos:** genera embeddings para nodos no vistos en entrenamiento

Convolutional graph autoencoders



- Graph autoencoders (GAE) usa una GCN encoder para aprender embeddings

$$\mathbf{Z} = \text{GCN}(\mathbf{W}, \mathbf{X}; \boldsymbol{\Theta}^E)$$

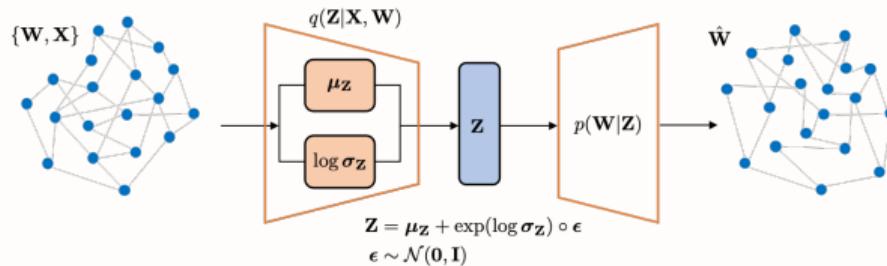
- Sigmoid cross entropy loss entre \mathbf{W} y la salida del decoder $\hat{\mathbf{W}}$

$$\mathcal{L}_{G,\text{REG}}(\mathbf{W}, \hat{\mathbf{W}}; \boldsymbol{\Theta}) = - \sum_{i,j \in \mathcal{V}_{obs}^{(2)}} (1 - W_{ij}) \log(1 - \sigma(\hat{W}_{ij})) + W_{ij} \log \sigma(\hat{W}_{ij})$$

⇒ Decoder de producto externo: $\hat{\mathbf{W}} = \text{DEC}(\mathbf{Z}; \boldsymbol{\Theta}^D) = \mathbf{Z}\mathbf{Z}^\top$

⇒ Modelo no probabilístico, adecuado para grafos sin pesos

Variational graph autoencoders



- **Objetivo:** entrenar un decoder probabilístico para generar grafos realistas

$$\hat{\mathbf{W}} \sim p(\mathbf{W} | \mathbf{Z})$$

dadas variables latentes de un encoder probabilístico $\mathbf{Z} \sim q(\mathbf{Z} | \mathbf{X}, \mathbf{W})$

- Minimiza error de reconstrucción dados grafos y señales de entrenamiento
- Post entrenamiento, podemos tirar el encoder y generar grafos $\hat{\mathbf{W}} \sim p(\mathbf{W} | \mathbf{Z})$
 - Dadas variables latentes $\mathbf{Z} \sim p(\mathbf{Z})$ muestreadas de una distribución a priori

T. N. Kipf and M. Welling, "Variational graph auto encoders," *arXiv:1611.07308 [stat.ML]*, 2016

Encoder y decoder probabilístico

- **Encoder:** modelo simple de inferencia parametrizado por GCNs

$$q(\mathbf{Z} \mid \mathbf{X}, \mathbf{W}) = \prod_{i \in \mathcal{V}} q(\mathbf{z}_i \mid \mathbf{X}, \mathbf{W}), \text{ with } q(\mathbf{z}_i \mid \mathbf{X}, \mathbf{W}) = \mathcal{N}(\mathbf{z}_i; \boldsymbol{\mu}_i, \text{diag}(\boldsymbol{\sigma}_i^2))$$

- Dos GCNs separadas para generar media y varianza

$$\boldsymbol{\mu}_{\mathbf{Z}} = \text{GCN}_{\boldsymbol{\mu}}(\mathbf{W}, \mathbf{X}), \quad \log \boldsymbol{\sigma}_{\mathbf{Z}} = \text{GCN}_{\boldsymbol{\sigma}}(\mathbf{W}, \mathbf{X})$$

- Dados $\boldsymbol{\mu}_{\mathbf{Z}}$ y $\log \boldsymbol{\sigma}_{\mathbf{Z}}$, podemos muestrear embeddings latentes via

$$\mathbf{Z} = \boldsymbol{\mu}_{\mathbf{Z}} + \exp(\log \boldsymbol{\sigma}_{\mathbf{Z}}) \circ \boldsymbol{\epsilon}, \quad \boldsymbol{\epsilon} \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$$

(reparametrization trick)

- **Decoder:** modelo generativo basado en productos externos

$$p(\mathbf{W} \mid \mathbf{Z}) = \prod_{i,j \in \mathcal{V}^{(2)}} p(W_{ij} \mid \mathbf{z}_i, \mathbf{z}_j), \text{ with } p(W_{ij} = 1 \mid \mathbf{z}_i, \mathbf{z}_j) = \sigma(\mathbf{z}_i^\top \mathbf{z}_j)$$

- $\sigma(\cdot)$ es la función sigmoide logística

Prior: embeddings latentes de nodos asumidos $\mathbf{z}_i \stackrel{\text{i.i.d.}}{\sim} \mathcal{N}(\mathbf{0}, \mathbf{I})$

Entrenando VGAE

■ Maximizar el evidence likelihood lower bound (ELBO)

$$\mathcal{L}(\Theta) = \sum_i \mathbb{E}_{q(\mathbf{Z}|\mathbf{X}_i, \mathbf{W}_i)} [\log p(\mathbf{W}_i | \mathbf{Z})] - \text{KL}(q(\mathbf{Z} | \mathbf{X}_i, \mathbf{W}_i), p(\mathbf{Z}))$$

- $\text{KL}(\cdot, \cdot)$ es la Kullback-Leibler divergence
- Los parámetros a entrenar Θ son los filtros de la GCN \mathbf{H}_k
- Requiere un conjunto de grafos de entrenamiento $\{\mathbf{W}_1, \mathbf{X}_1\}, \dots, \{\mathbf{W}_P, \mathbf{X}_P\}$

■ Generar una distribución sobre \mathbf{Z} que satisfaga dos objetivos (contrapuestos)

- Los \mathbf{Z} muestreados sean suficientemente ricos para que el decoder reconstruya \mathbf{W}
- Que la distribución $q(\mathbf{Z} | \mathbf{X}, \mathbf{W})$ esté lo más cerca posible del prior $p(\mathbf{Z})$

■ Objetivo (b) es crítico para generar nuevos grafos después de entrenar

⇒ Muestrear $\mathbf{Z} \sim p(\mathbf{Z}) \rightarrow$ Decodificar $\hat{\mathbf{W}} \sim p(\mathbf{W}_i | \mathbf{Z})$

VGAE en acción

- Ex: Cora dataset con $N_v = 2708$ papers y $N_e = 5429$ citas
 - Señales de grafos: presencia/ausencia de 1433 palabras de un diccionario



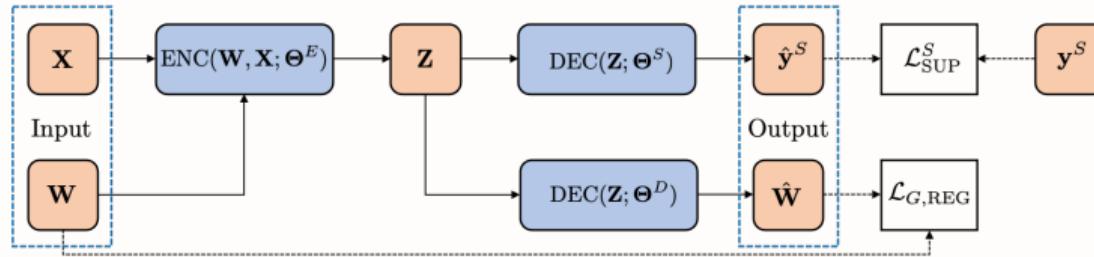
- Espacio latente aprendido con VGAE
 - ⇒ Colores indican la etiqueta (disciplina, no usada en entrenamiento)

Roadmap

- 1 The network embedding problem
- 2 Una taxonomía de modelos de graph embedding
- 3 Unsupervised graph embedding
- 4 Applications

Applications

- GRL has been successfully applied in a wide range of domains
 - Unsupervised learning to preserve graph structure
 - Supervised learning for prediction or classification



- Ex: brain network analysis for patient-control study
 - (Un)supervised GRL for graph reconstruction and classification
- Ex: social network analysis for temporal graph clustering
 - Unsupervised setting to learn graph-level representation

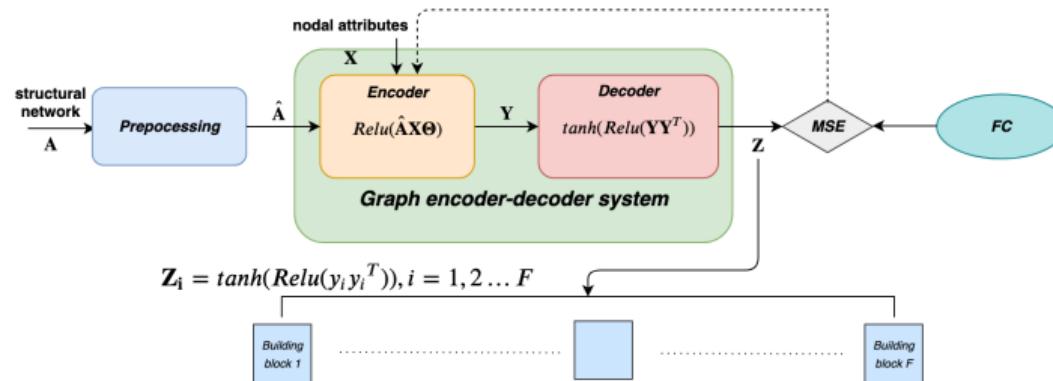
Networks of the brain

- **Challenge:** understand human brain function and structure
 - Neuroimaging advances ⇒ Data increase in volume and complexity
 - Graph-centric analysis and methods of network science [Sporns'10]
- Brain networks can reflect two connectivity patterns
 - **Structural connectivity (SC).** How is the brain wired?
⇒ Anatomical tracts connecting brain regions (DTI)
 - **Functional connectivity (FC).** How the brain functions?
⇒ Correlation between neural signals in different regions (fMRI)
- **Key problem:** deciphering the relationship between SC and FC
 - Simulations of nonlinear cortical activity models [Honey et al'09]
 - Diffusion-based parametric inverse problem [Abdelnour et al'14]
 - Network deconvolution [Li-Mateos'19]
- **Goal:** pursue SC-to-FC mapping as a regression problem
 - ⇒ Reconstruct FC network from SC network

Problem statement

Study the generation of FC patterns from SC graphs

- **Goal:** learn the mapping from brain SC networks to FC networks
- **Approach:** reconstruct FC networks from the given SC networks
- **Model:** GCN-based encoder-decoder system



- **Analysis:** investigate latent variables within the system

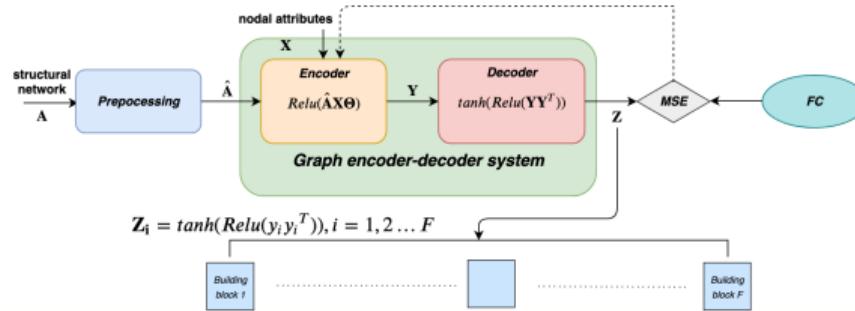
Model architecture: encoder

- Input SC network $\mathbf{A} \in \mathbb{R}^{N \times N}$, N regions from brain atlas
 - ⇒ Edge weights represent SC between brain regions
 - ⇒ Preprocessing: $\hat{\mathbf{A}} := \tilde{\mathbf{D}}^{-1/2} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-1/2}$, $\tilde{\mathbf{A}} = \mathbf{I} + \mathbf{A}$
- Learn vertex representations (i.e., embeddings) that capture
 - (i) **Nodal attributes**, e.g. intrinsic properties of brain regions
 - (ii) **Graph topology information**, e.g. regional connection strengths
- A single-layer GCN used for encoder to learn node embeddings

$$\mathbf{Y} = \text{ReLU}(\hat{\mathbf{A}}\mathbf{X}\Theta) \in \mathbb{R}^{N \times F}$$

- $\mathbf{X} \in \mathbb{R}^{N \times T}$: input signal matrix
- $\Theta \in \mathbb{R}^{T \times F}$: learnable GCN filter coefficients
- $\text{ReLU}(x) = \max(0, x)$ activation for training the network

Model architecture: decoder

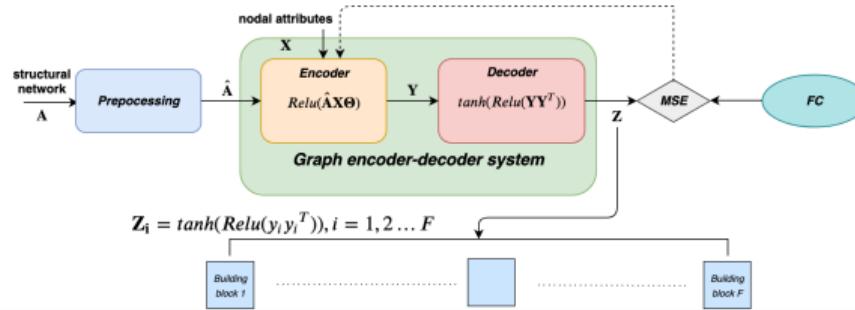


- Node embeddings $\mathbf{Y} \in \mathbb{R}^{N \times F}$ go through the outer-product decoder

$$\mathbf{Z} = \tanh(\text{ReLU}(\mathbf{Y}\mathbf{Y}^T)) \in \mathbb{R}^{N \times N}$$

- Weights in empirical FC networks restricted to $[0,1]$
 - Ensure the output of the decoder in the same range
 - Choose **tanh** and **ReLU** over sigmoid
- Loss function: MSE between \mathbf{Z} and empirical FC

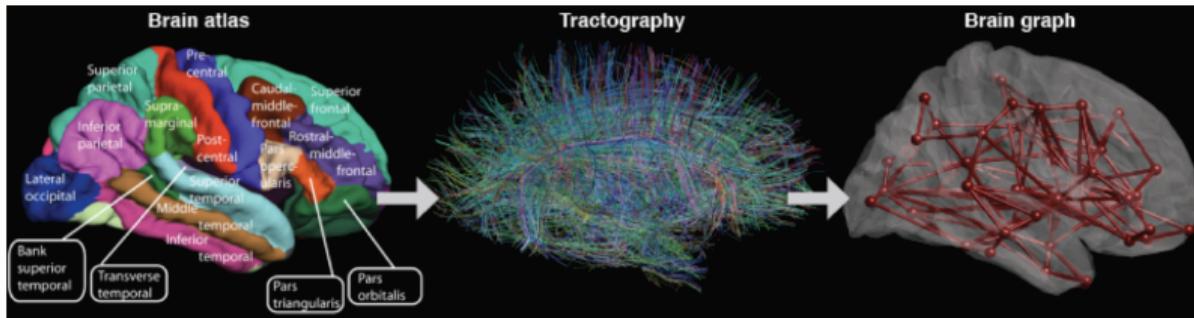
Model architecture: latent variables



- YY^T : rank- F approximation of FC graph before activation
 - Extract and analyze each of the rank-1 components $y_i y_i^T$
$$Z_i = \tanh(\text{ReLU}(y_i y_i^T)), \quad i = 1, \dots, F$$
- Z_i \Leftrightarrow outputs of individual filters in graph convolutional layer
⇒ View as **building blocks** of FC network
- Reveal details about generation of FC patterns from SC networks

Numerical tests: data

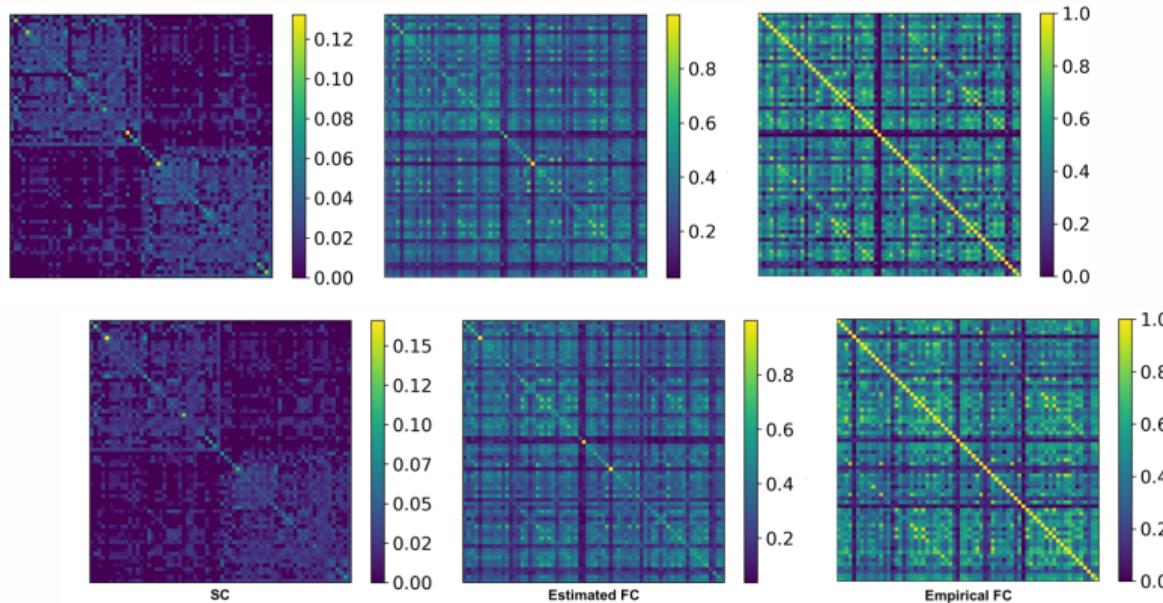
- $P = 1058$ healthy subjects from Human Connectome Project (HCP)
- Preprocessed SC network \mathbf{A} from diffusion MRI
 - ⇒ Fiber counts between $N = 68$ cortical surface regions



- Preprocessed FC network from functional MRI
 - ⇒ Blood oxygen-level dependent (BOLD) signals
 - ⇒ Estimated FC \Leftrightarrow Pearson correlation between BOLD signals
- One-hot encoding as the signal on each graph node ($\mathbf{X} = \mathbf{I}_N$)

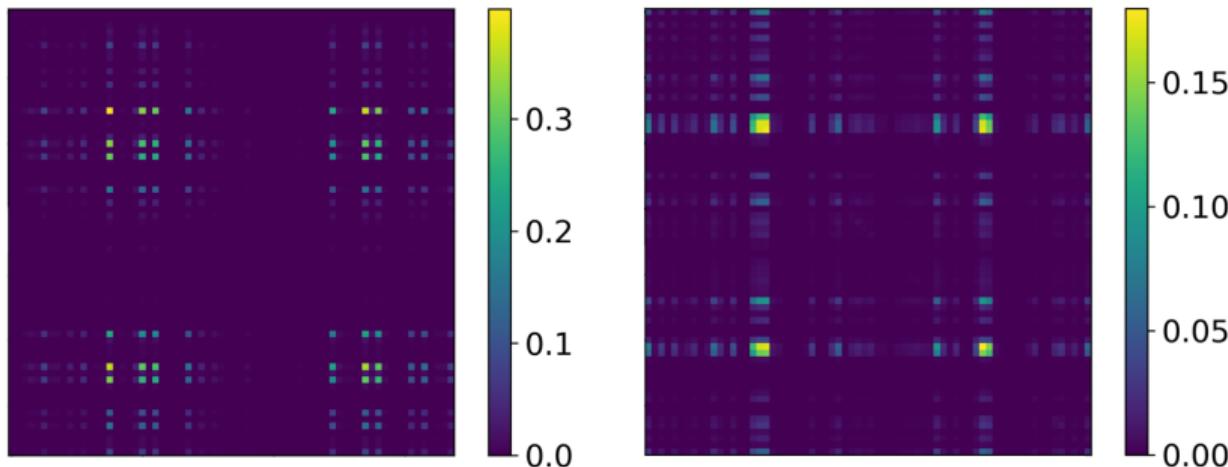
Numerical tests: FC reconstruction performance

- MSE between reconstructed and empirical FC networks
 - Average test reconstruction error = 0.0304 with std = 0.0011
 - Capture **population patterns** of SC-FC relationship



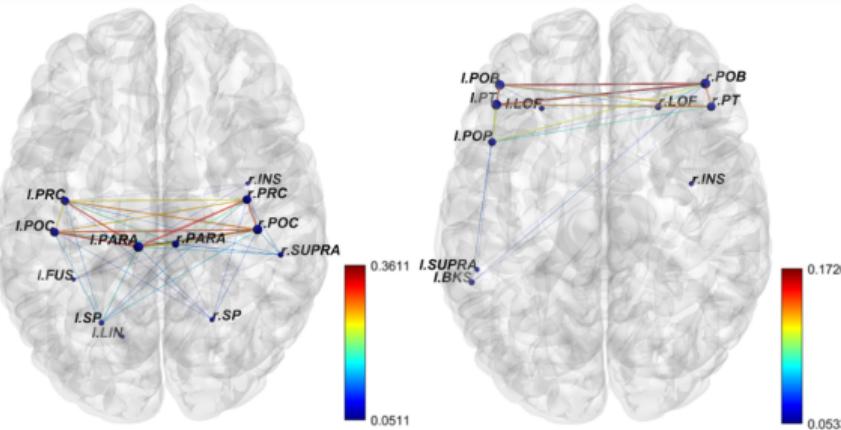
Numerical tests: component graphs

- Investigate the latent variables learnt during model training
 - Output of each graph filter in the graph convolution layer
 - Building blocks Z_i that generate reconstructed FC graph



- Subgraphs may reveal key insights about SC-to-FC mapping

Numerical tests: component graphs

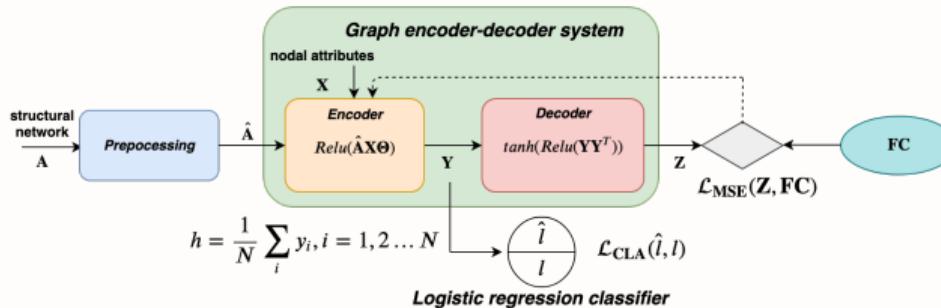


- Left: subnetwork of regions in frontal and parietal lobe
 - *Precentral (PRC)*, *Paracentral (PARA)*, motor/sensory functions
 - *Postcentral (POC)*, *Superior Parietal (SP)*, spatial/somatosensory
- Right: subnetwork of regions in Inferior Frontal Gyrus
 - *Parsopercularis (POP)*, *Parsorbitalis (POB)*, *Parstriangularis (PT)*
 - Critically involved in complex brain functions [Greenlee et al'07]

Supervised GRL for brain network classification

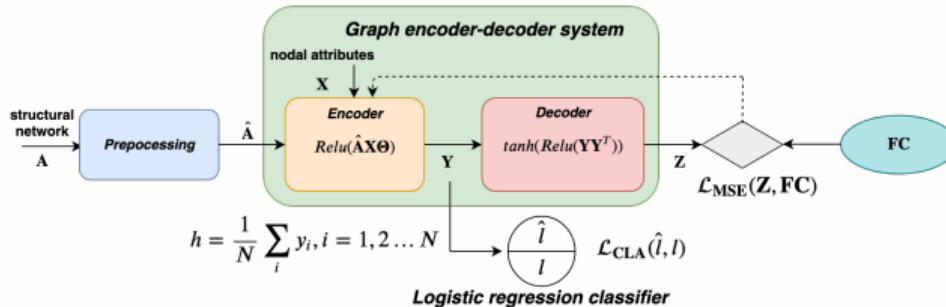
Model the relationship between brain structural and functional network

- **Goal:** summarize SC-FC relationship by simultaneously learning
 - Node embeddings to reconstruct FC from the given SC networks
 - Graph embeddings for graph classification
- **Model:** supervised graph encoder-decoder system



- **Analysis:** investigate group-wise difference within reconstructed FCs

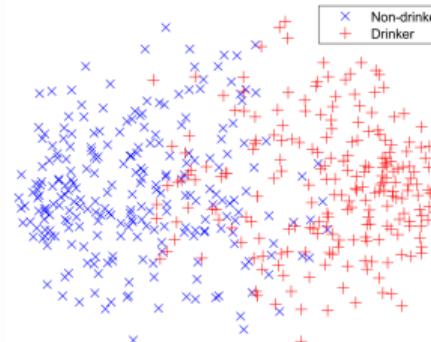
Model architecture: classifier



- Apply row-wise average-pooling on the encoder output Y
 - ⇒ Vector summarizing SC-FC relationship, i.e., graph embedding
- Construct logistic regression classifier to predict subject labels
 - Sigmoid cross-entropy loss between predicted and empirical labels
- Loss function: $\mathcal{L} = \mathcal{L}_{\text{MSE}}(Z, \text{FC}) + \lambda \times \mathcal{L}_{\text{CLA}}(\hat{l}, l)$

Numerical tests: results

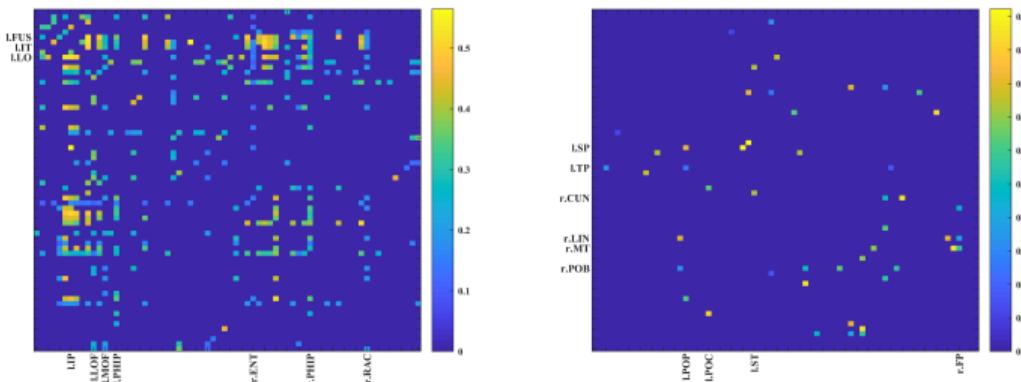
- $P = 466$ subjects from Human Connectome Project (HCP)
 - Two classes: 245 non-drinkers, 221 heavy drinkers
- MSE between reconstructed and empirical FC networks
 - Average test reconstruction error = 0.034174 with std = 0.00208
 - Captured population patterns of SC-FC relationship
- Classification accuracy: $67.4 \pm 2\%$
 - Captured discriminative patterns within each group



- Reduced dimensional graph embeddings exhibit cluster structure

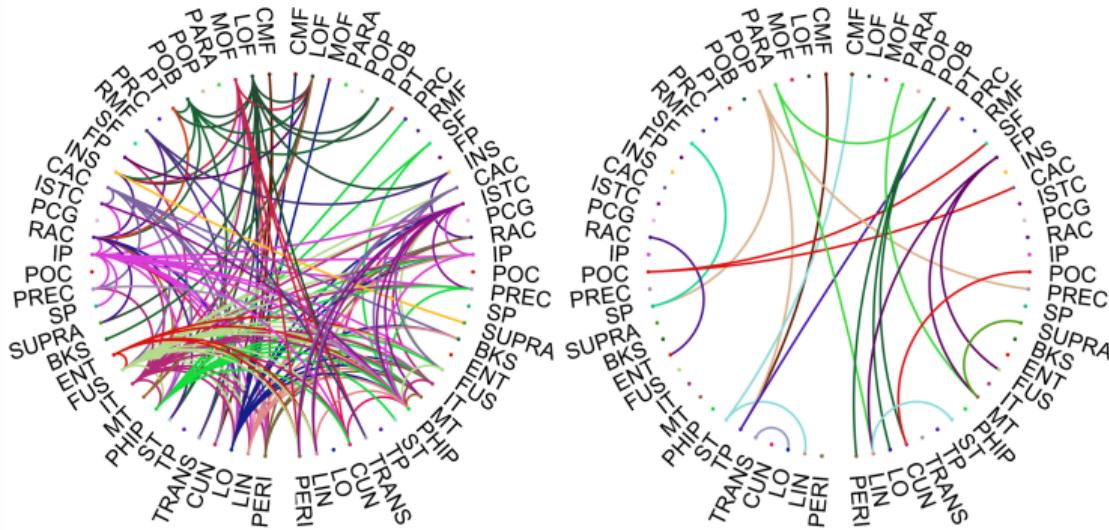
Numerical tests: reconstructed FC

- Investigate group-wise difference within reconstructed FCs
 - Captured difference between subjects in latent representations
- Test for significant group-wise difference in functional connections
 - Edge-wise T-tests ($p < 0,05$) with FDR correction



- Connections **weaker** (left) & **stronger** (right) in drinkers

Numerical tests: class differences



- Left: subnetwork of connections weaker in drinkers
 - *Entorhinal, Parahippocampus, limbic system impaired in drinkers*
 - Overall decrease in connection strengths in drinkers
- Right: subnetwork of connections stronger in drinkers
 - Involve regions in multiple cortices ⇒ neural compensation
 - Additional connections compensate for alcohol damages

Dynamic social network clustering

- **Goal:** Reveal temporal stages of the evolution of dynamic graphs
 - ⇒ Cast as a problem of **clustering** graph sequences
- **Approach:** Unsupervised **distance-based graph-level** RL
- **Model:** Siamese GRL network + K-means clustering
 - Learn **graph-level** embedding in unsupervised manner
 - ⇒ Preserve network structure and **distances between graphs**
 - Cluster learned graph embeddings via K-means algorithm
 - ⇒ Each cluster represents one temporal stage
- Siamese encoder better for input graphs with divergent structures

Grafos de fútbol

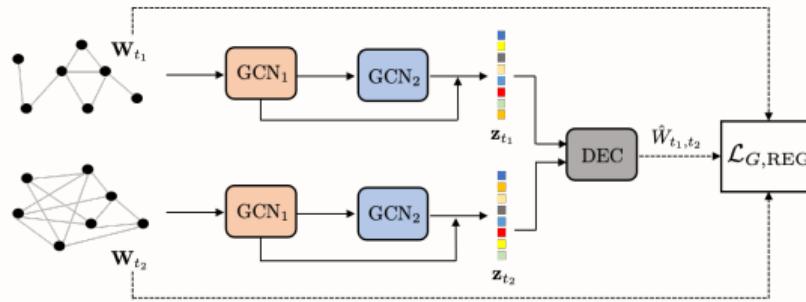
- $T = 145$ grafos de fútbol desde 1872 a 2016
 - Nodos: $N_v = 238$ selecciones nacionales jugando partidos oficiales
 - Aristas: $W_{ij}(t)$ es la cantidad de partidos entre $\{i, j\}$ en el año t
 - Los datos incluyen 39,052 partidos en 145 años



- Esperamos encontrar diferentes etapas en la historia de este deporte

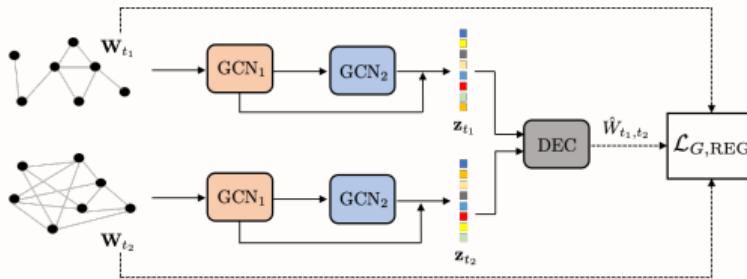
Arquitectura del modelo: encoder

- Input: $\binom{145}{2} = 10440$ pares $\{\mathbf{W}_{t_1}, \mathbf{W}_{t_2}\}$ de grafos



- **Modelo:** Siamese encoder network with two GRL pipelines
 - Two-layer GCN with parameters shared across pipelines
- **Output:** embeddings de grafos $\{\mathbf{z}_{t_1}, \mathbf{z}_{t_2}\}$ para cada grafo de entrada
 - Concatenate node embeddings learned at each layer
 - Average graph pooling from node embeddings

Model architecture: decoder



- Idea: los embeddings preservan **distancias** entre pares de grafos

$$\mathcal{L}_{G, REG}(\{\mathbf{W}_t\}, \hat{\mathbf{W}}; \Theta) = \sum_{t_1, t_2} ([s(\{\mathbf{W}_t\})]_{t_1, t_2} - \hat{W}_{t_1, t_2})^2$$

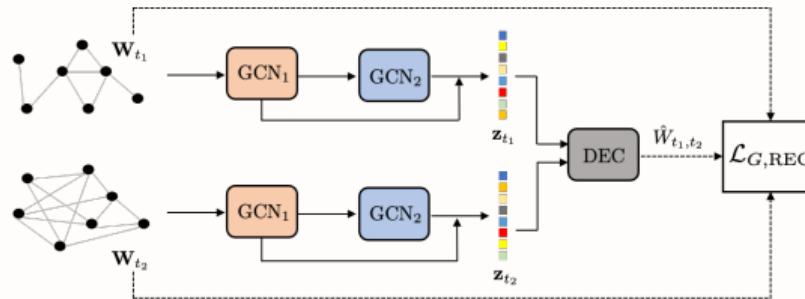
⇒ Euclidean distance decoder: $\hat{W}_{t_1, t_2} = \|\mathbf{z}_{t_1} - \mathbf{z}_{t_2}\|_2$

- Prescribed distances between input graphs encoded in

$$[s(\{\mathbf{W}_t\})]_{t_1, t_2} = d_G(\mathbf{W}_{t_1}, \mathbf{W}_{t_2})$$

⇒ Like MDS and IsoMAP but at **graph-(not node-)level**

Model architecture: graph distance



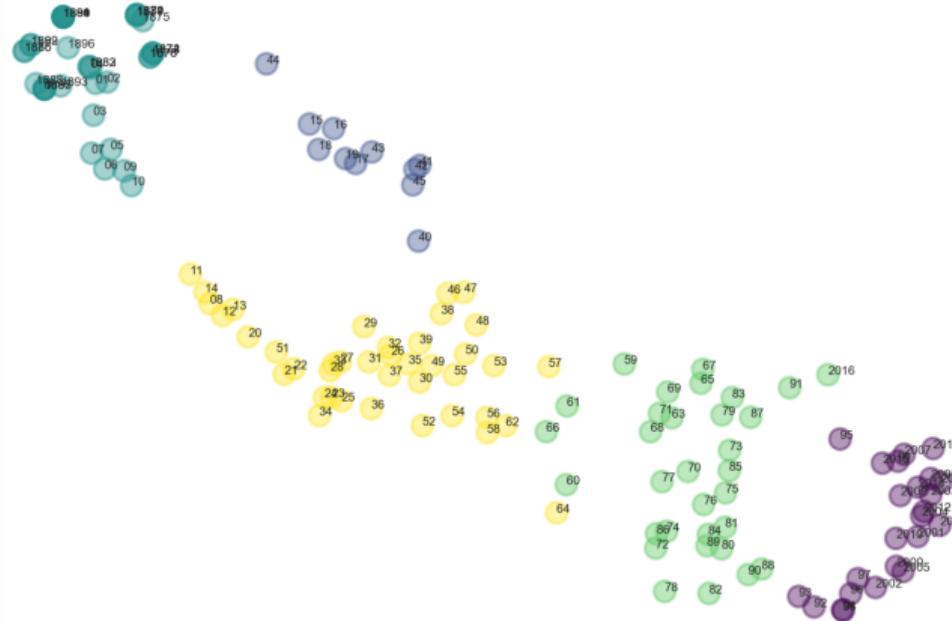
- User defined graph distance $d_G(\mathbf{W}_{t_1}, \mathbf{W}_{t_1})$
- Ex: **Spectrum distance**
 - Distance between spectrum (eigenvalues) of both Laplacian matrices
- Ex: **Vertex-edge-overlap (VEO)**
 - Measure structural similarity between graphs

$$\text{VEO}(\mathbf{W}_{t_1}, \mathbf{W}_{t_2}) = 2 \times \frac{|\mathcal{E}_{t_1} \cap \mathcal{E}_{t_2}| + |\mathcal{V}_{t_1} \cap \mathcal{V}_{t_2}|}{|\mathcal{E}_{t_1}| + |\mathcal{E}_{t_2}| + |\mathcal{V}_{t_1}| + |\mathcal{V}_{t_2}|}$$

- Distance computed as one minus normalized VEO

Graph clustering results

- K-means clustering applied to learned graph embeddings in \mathbb{R}^{48}
 \Rightarrow Number of clusters $K = 5$ chosen by elbow rule



Cluster 1: early 20th century



- Mostly regions around UK and the River Plate

Cluster 2: World Wars



- Decreased activity in Europe and sustained growth in South America

Cluster 3: Post-World War II recovery



- Noticeable bridging between Europe and America

Cluster 4: Modern development



- Modern expansion of football with Africa and Asia involved

Cluster 5: Current landscape



- Global nature of the game is patently apparent

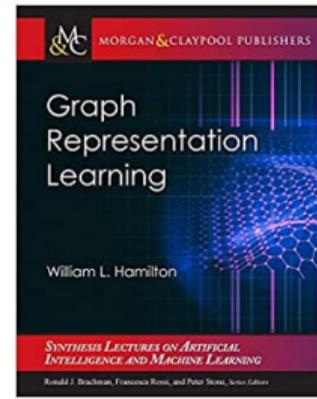
Open research directions

- GRL is a very active area of research. Many **open questions** remain:
 - Scalability, interpretability, fairness, theoretical guarantees
 - Robust and unified evaluation protocols and benchmarks
 - Modeling of directed, dynamic and multi-layer graphs
 - Beyond pairwise decoders: decoding higher-order motifs
 - Expressivity via non-Euclidean embeddings?

arXiv:2005.03794v1 [cs.LG] 7 May 2020



arXiv:2005.03843 [cs.LG] 10 Apr 2020



Glossary

- Convolutional neural network
- Graph representation learning
- Node and graph embedding
- (Un)supervised learning
- Transductive and inductive
- Link prediction
- Encoder-decoder model
- Learnable parameters
- (Dis)similarity scores
- Graph pooling
- Graph regularization loss
- End-to-end learning
- Shallow embedding
- Graph autoencoders
- Neighborhood aggregation
- Higher-order proximity
- Matrix factorization
- Random walks
- Laplacian eigenmaps
- Hyperbolic geometry
- Variational autoencoders
- Brain network analysis
- Graph convolutional network