



FACULTAD DE
INGENIERÍA



UNIVERSIDAD
DE LA REPÚBLICA
URUGUAY

Aprendizaje Automático para Datos en Grafos

Aprendiendo Grafos desde Datos

Marcelo Fiori

Muy basado en transparencias de **Gonzalo Mateos**

`m fiori@fing.edu.uy`

`http://www.fing.edu.uy/~mfiori/`

20 de octubre de 2022

Aprendiendo grafos a partir de señales suaves

- 1 Métodos estadísticos para inferencia de topología del grafo
- 2 Aprendiendo grafos a partir de observaciones de señales suaves

Formulación del problema

Motivación

- Buscamos grafos sobre el cual las señales admitan ciertas regularidades
 - Predicción por vecino más cercano (a.k.a. graph smoothing)
 - Aprendizaje semi-supervisado
- Muchos datos de redes del mundo real son suaves
 - Grafos basados en similitudes entre atributos de vértices
 - A menudo, formación de redes se basa en homofilia, proximidad en espacio latente

Formulación del problema

Motivación

- Buscamos grafos sobre el cual las señales admitan ciertas regularidades
 - Predicción por vecino más cercano (a.k.a. graph smoothing)
 - Aprendizaje semi-supervisado
- Muchos datos de redes del mundo real son suaves
 - Grafos basados en similitudes entre atributos de vértices
 - A menudo, formación de redes se basa en homofilia, proximidad en espacio latente

Planteo de problema


Dadas observaciones $\mathcal{X} := \{\mathbf{x}_p\}_{p=1}^P$, identificar un grafo G tal que las señales \mathcal{X} sean suaves en G .

- **Criterio:** Energía de Dirichlet en el grafo G con Laplaciana \mathbf{L}

$$\text{TV}(\mathbf{x}) = \mathbf{x}^\top \mathbf{L} \mathbf{x}$$

Ejemplo: Predecir funciones de proteínas


- Datos de levadura, formalmente *Saccharomyces cerevisiae*
 - **Grafo:** 134 vértices (proteínas) y 241 aristas (interacciones entre proteínas)



- **Señal:** anotación funcional **casca**s de señalización intracelular (ICSC)
 - $x_i = 1$ si proteína i anotada ICSC (**amarillo**), $x_i = 0$ si no (**azul**)

Ejemplo: Prácticas de abogados

- Relaciones laborales entre abogados [Lazega'01]
 - **Grafo:** 36 abogados, aristas indican colaboraciones



- **Señal:** varios atributos a nivel de nodo $\mathbf{x} = \{x_i\}_{i \in \mathcal{V}}$ incluyendo
 - ⇒ Tipo de práctica, i.e., litigante (red) y corporativo (cyan)
- Intuimos que abogados colaboran más con pares de su misma clase de práctica legal
 - ⇒ El conocimiento de colaboraciones es útil para predecir el tipo de práctica


Digresión II: Graph signal processing (GSP)

- Grafo G con **matriz de adyacencia** $\mathbf{A} \in \mathbb{R}^{N \times N}$

$\Rightarrow A_{ij}$ = proximidad entre i y j

- Tenemos una **señal** $\mathbf{x} \in \mathbb{R}^N$ en el grafo

$\Rightarrow x_i$ = valor de la señal en el nodo i



- **Graph Signal Processing** \rightarrow Explotar la estructura codificada en \mathbf{A} para procesar \mathbf{x}

Digresión II: Importancia de la estructura temporal de una señal


- El procesamiento de señales **se basa en explotar la estructura de la señal**

- Tiempo discreto descrito a través de un grafo cíclico

⇒ El instante de tiempo n le sigue al $n - 1$

⇒ El valor x_n está relacionado a x_{n-1}

- Formalizado bajo la noción de frecuencia



- Estructura cíclica ⇒ Transformada de Fourier ⇒ $\tilde{\mathbf{x}} = \mathbf{F}^H \mathbf{x}$ $\left(F_{kn} = \frac{e^{j2\pi kn/N}}{\sqrt{N}} \right)$

- Transformada de Fourier ⇒ **Proyección en el *eigenvector space* del ciclo**

Digresión II: Graph Fourier Transform

- Adyacencia \mathbf{A} , Laplaciana \mathbf{L} , o genéricamente **graph shift** $\mathbf{S} = \mathbf{V}\mathbf{\Lambda}\mathbf{V}^{-1}$

$\Rightarrow S_{ij} = 0$ para $i \neq j$ y $(i, j) \notin \mathcal{E}$ (captura la estructura local en G)

- La **Graph Fourier Transform (GFT)** de \mathbf{x} se define como

$$\tilde{\mathbf{x}} = \mathbf{V}^{-1}\mathbf{x}$$

- Mientras que la **GFT inversa (iGFT)** de $\tilde{\mathbf{x}}$ se define como

$$\mathbf{x} = \mathbf{V}\tilde{\mathbf{x}}$$

\Rightarrow Los vectores propios $\mathbf{V} = [\mathbf{v}_1, \dots, \mathbf{v}_N]$ son la **base frecuencial** (átomos)

Digresión II: Graph Fourier Transform

- Adyacencia \mathbf{A} , Laplaciana \mathbf{L} , o genéricamente **graph shift** $\mathbf{S} = \mathbf{V}\mathbf{\Lambda}\mathbf{V}^{-1}$

$\Rightarrow S_{ij} = 0$ para $i \neq j$ y $(i, j) \notin \mathcal{E}$ (captura la estructura local en G)

- La **Graph Fourier Transform (GFT)** de \mathbf{x} se define como

$$\tilde{\mathbf{x}} = \mathbf{V}^{-1}\mathbf{x}$$

- Mientras que la **GFT inversa (iGFT)** de $\tilde{\mathbf{x}}$ se define como

$$\mathbf{x} = \mathbf{V}\tilde{\mathbf{x}}$$

\Rightarrow Los vectores propios $\mathbf{V} = [\mathbf{v}_1, \dots, \mathbf{v}_N]$ son la **base frecuencial** (átomos)

- Estructura adicional

\Rightarrow Si \mathbf{S} es normal, entonces $\mathbf{V}^{-1} = \mathbf{V}^H$ y $\tilde{x}_k = \mathbf{v}_k^H \mathbf{x} = \langle \mathbf{v}_k, \mathbf{x} \rangle$

\Rightarrow Vale Parseval: $\|\mathbf{x}\|^2 = \|\tilde{\mathbf{x}}\|^2$

- **GFT** \Rightarrow **Proyección sobre el espacio de vectores propios de la matriz de shift \mathbf{S}**

Digresión II: Modos frecuenciales de la Laplaciana

- **Total variation** de la señal \mathbf{x} con respecto a \mathbf{L}

$$\text{TV}(\mathbf{x}) = \mathbf{x}^T \mathbf{L} \mathbf{x} = \sum_{i,j=1, j>i}^N A_{ij} (x_i - x_j)^2$$

⇒ Medida de suavidad de la señal sobre el grafo G (energía de Dirichlet)

- Para los valores propios de la Laplaciana $\mathbf{V} = [\mathbf{v}_1, \dots, \mathbf{v}_N]$ ⇒ $\text{TV}(\mathbf{v}_k) = \lambda_k$
⇒ Podemos ver a $0 = \lambda_1 < \dots \leq \lambda_N$ como frecuencias

Digresión II: Modos frecuenciales de la Laplaciana

- **Total variation** de la señal \mathbf{x} con respecto a \mathbf{L}


$$\text{TV}(\mathbf{x}) = \mathbf{x}^T \mathbf{L} \mathbf{x} = \sum_{i,j=1, j>i}^N A_{ij} (x_i - x_j)^2$$

⇒ Medida de suavidad de la señal sobre el grafo G (energía de Dirichlet)

- Para los valores propios de la Laplaciana $\mathbf{V} = [\mathbf{v}_1, \dots, \mathbf{v}_N]$ ⇒ $\text{TV}(\mathbf{v}_k) = \lambda_k$

⇒ Podemos ver a $0 = \lambda_1 < \dots \leq \lambda_N$ como frecuencias

- **Ejemplo:** grafo con $N=10$, $k=1$, $k=2$, $k=9$



Modelo de análisis factorial basado en la Laplaciana

- Consideremos un grafo desconocido G con Laplaciana $\mathbf{L} = \mathbf{V}\mathbf{\Lambda}\mathbf{V}^\top$
 - ⇒ Adoptamos la base \mathbf{V} GFT como as signal representation matrix
- Factor-analysis model para la señal observada en el grafo [Dong et al'16]

$$\mathbf{x} = \mathbf{V}\boldsymbol{\chi} + \boldsymbol{\epsilon}$$

- ⇒ Variables latentes $\boldsymbol{\chi} \sim \mathcal{N}(\mathbf{0}, \mathbf{\Lambda}^\dagger)$ (\approx coeficientes GFT)
- ⇒ Término de error isotrópico $\boldsymbol{\epsilon} \sim \mathcal{N}(\mathbf{0}, \sigma^2\mathbf{I})$
- ⇒ ¿Cuáles serán los coeficientes más grandes en $\boldsymbol{\chi}$?
- ⇒ ¿asociados a qué valores propios? ¿cómo repercute eso en \mathbf{x} ?

Modelo de análisis factorial basado en la Laplaciana

- Consideremos un grafo desconocido G con Laplaciana $\mathbf{L} = \mathbf{V}\mathbf{\Lambda}\mathbf{V}^\top$
 - ⇒ Adoptamos la base \mathbf{V} GFT como as signal representation matrix
- Factor-analysis model para la señal observada en el grafo [Dong et al'16]

$$\mathbf{x} = \mathbf{V}\boldsymbol{\chi} + \boldsymbol{\epsilon}$$

- ⇒ Variables latentes $\boldsymbol{\chi} \sim \mathcal{N}(\mathbf{0}, \mathbf{\Lambda}^\dagger)$ (\approx coeficientes GFT)
- ⇒ Término de error isotrópico $\boldsymbol{\epsilon} \sim \mathcal{N}(\mathbf{0}, \sigma^2\mathbf{I})$
- ⇒ ¿Cuáles serán los coeficientes más grandes en $\boldsymbol{\chi}$?
- ⇒ ¿asociados a qué valores propios? ¿cómo repercute eso en \mathbf{x} ?
- **Suavidad:** esto favorece señales “pasa bajo” \mathbf{x}
 - ⇒ Valores propios chicos de \mathbf{L} (baja frecuencia) → Peso alto en los factores

Inferencia como denoising via graph kernel regression

- Estimador *Maximum a posteriori* (MAP) de las variables $\boldsymbol{\chi}$

$$\hat{\boldsymbol{\chi}}_{\text{MAP}} = \arg \min_{\boldsymbol{\chi}} \{ \|\mathbf{x} - \mathbf{V}\boldsymbol{\chi}\|^2 + \alpha \boldsymbol{\chi}^\top \boldsymbol{\Lambda} \boldsymbol{\chi} \}$$

⇒ Parameterizado por \mathbf{V} y $\boldsymbol{\Lambda}$, que no conocemos

- Definamos el predictor $\mathbf{y} := \mathbf{V}\boldsymbol{\chi}$, entonces el regularizador queda:

$$\boldsymbol{\chi}^\top \boldsymbol{\Lambda} \boldsymbol{\chi} = \mathbf{y}^\top \mathbf{V} \boldsymbol{\Lambda} \mathbf{V}^\top \mathbf{y} = \mathbf{y}^\top \mathbf{L} \mathbf{y} = \text{TV}(\mathbf{y})$$

⇒ Denoiser (basado en TV Laplaciano) de \mathbf{x} , prior de suavidad en \mathbf{y}

Inferencia como denoising via graph kernel regression

- Estimador *Maximum a posteriori* (MAP) de las variables χ

$$\hat{\chi}_{\text{MAP}} = \arg \min_{\chi} \{ \|\mathbf{x} - \mathbf{V}\chi\|^2 + \alpha \chi^{\top} \mathbf{\Lambda} \chi \}$$

⇒ Parameterizado por \mathbf{V} y $\mathbf{\Lambda}$, que no conocemos

- Definamos el predictor $\mathbf{y} := \mathbf{V}\chi$, entonces el regularizador queda:

$$\chi^{\top} \mathbf{\Lambda} \chi = \mathbf{y}^{\top} \mathbf{V} \mathbf{\Lambda} \mathbf{V}^{\top} \mathbf{y} = \mathbf{y}^{\top} \mathbf{L} \mathbf{y} = \text{TV}(\mathbf{y})$$

⇒ Denoiser (basado en TV Laplaciano) de \mathbf{x} , prior de suavidad en \mathbf{y}

- **Idea:** buscar simultáneamente \mathbf{L} y la representación sin ruido (denoised) $\mathbf{y} = \mathbf{V}\chi$

$$\min_{\mathbf{L}, \mathbf{y}} \{ \|\mathbf{x} - \mathbf{y}\|^2 + \alpha \mathbf{y}^{\top} \mathbf{L} \mathbf{y} \}$$

Formulación y algoritmo

- Dadas señales $\mathcal{X} := \{\mathbf{x}_p\}_{p=1}^P$ en $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_P] \in \mathbb{R}^{N \times P}$, resolver

$$\begin{aligned} & \min_{\mathbf{L}, \mathbf{Y}} \left\{ \|\mathbf{X} - \mathbf{Y}\|_F^2 + \alpha \text{trace}(\mathbf{Y}^\top \mathbf{L} \mathbf{Y}) + \frac{\beta}{2} \|\mathbf{L}\|_F^2 \right\} \\ & \text{s. to } \text{trace}(\mathbf{L}) = N, \mathbf{L}\mathbf{1} = \mathbf{0}, L_{ij} = L_{ji} \leq 0, i \neq j \end{aligned}$$

- ⇒ Hay que fijar “la escala” ($\text{trace}(\mathbf{L}) = N$). Si no $\mathbf{L} = \mathbf{0}$ y $\mathbf{X} = \mathbf{Y}$ es solución
- ⇒ Es fácil ver que $\text{trace}(\mathbf{L}) = N$ fija la norma ℓ_1 de \mathbf{L}
- ⇒ **Función objetivo:** Ajuste a datos + suavidad + sparsity en aristas
- ⇒ No conjuntamente convexa en \mathbf{L} y \mathbf{Y} , pero **bi-convexa**

Formulación y algoritmo

- Dadas señales $\mathcal{X} := \{\mathbf{x}_p\}_{p=1}^P$ en $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_P] \in \mathbb{R}^{N \times P}$, resolver

$$\begin{aligned} & \min_{\mathbf{L}, \mathbf{Y}} \left\{ \|\mathbf{X} - \mathbf{Y}\|_F^2 + \alpha \text{trace}(\mathbf{Y}^\top \mathbf{L} \mathbf{Y}) + \frac{\beta}{2} \|\mathbf{L}\|_F^2 \right\} \\ & \text{s. to } \text{trace}(\mathbf{L}) = N, \mathbf{L}\mathbf{1} = \mathbf{0}, L_{ij} = L_{ji} \leq 0, i \neq j \end{aligned}$$

⇒ Hay que fijar “la escala” ($\text{trace}(\mathbf{L}) = N$). Si no $\mathbf{L} = \mathbf{0}$ y $\mathbf{X} = \mathbf{Y}$ es solución

⇒ Es fácil ver que $\text{trace}(\mathbf{L}) = N$ fija la norma ℓ_1 de \mathbf{L}

⇒ **Función objetivo:** Ajuste a datos + suavidad + sparsity en aristas



⇒ No conjuntamente convexa en \mathbf{L} y \mathbf{Y} , pero **bi-convexa**

- **Enfoque algorítmico:** minimización alternada (AM)
 - (S1) Fijado \mathbf{Y} : resolver para \mathbf{L} via interior-point methods, ADMM
 - (S2) Fijado \mathbf{L} , solución cerrada: filtro pasa-bajos, versión suavizada de \mathbf{X}

$$\mathbf{Y} = (\mathbf{I} + \alpha \mathbf{L})^{-1} \mathbf{X}$$

Impacto de los parámetros en esparsidad y accuracy


- Se generan muchas señales en un grafo sintético Erdős-Rényi
⇒ Se infiere el grafo para distintos valores de α and β



- Hay más aristas si **crece** β y si **decrece** α
- Si hay poco ruido, el cociente β/α determina la performance

Ejemplo: Temperatura en Suiza

- $N = 89$ estaciones meteorológicas con mediciones mensuales de temperatura (1981-2010)
⇒ Aprender un grafo G donde las **temperaturas varíen suavemente**
- La distancia geográfica puede no ser una buena idea ⇒ diferentes **alturas**



- Partición en dos usando spectral clustering en G
⇒ Clusters: rojo (**estaciones en altura**) y azul (**estaciones bajas**)

■ K-means aplicado directo a las temperaturas (derecha) falla

Signal smoothness meets edge sparsity

- Recordemos $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_P] \in \mathbb{R}^{N \times P}$, sea $\bar{\mathbf{x}}_i^\top \in \mathbb{R}^{1 \times P}$ la fila número i
 \Rightarrow Matriz de distancia Euclídea $\mathbf{Z} \in \mathbb{R}_+^{N \times N}$, donde $Z_{ij} := \|\bar{\mathbf{x}}_i - \bar{\mathbf{x}}_j\|^2$
- **Truquito:** relación entre suavidad y esparsidad [Kalofolias'16]

$$\sum_{p=1}^P \text{TV}(\mathbf{x}_p) = \text{trace}(\mathbf{X}^\top \mathbf{L} \mathbf{X}) = \frac{1}{2} \|\mathbf{A} \circ \mathbf{Z}\|_1$$

\Rightarrow Aristas \mathcal{E} esparsas cuando los datos son suaves

\Rightarrow Favorece aristas candidatas (i, j) asociadas a valores chicos de Z_{ij}

Signal smoothness meets edge sparsity

- Recordemos $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_P] \in \mathbb{R}^{N \times P}$, sea $\bar{\mathbf{x}}_i^\top \in \mathbb{R}^{1 \times P}$ la fila número i
 \Rightarrow Matriz de distancia Euclidea $\mathbf{Z} \in \mathbb{R}_+^{N \times N}$, donde $Z_{ij} := \|\bar{\mathbf{x}}_i - \bar{\mathbf{x}}_j\|^2$
- **Truquito:** relación entre suavidad y esparsidad [Kalofolias'16]

$$\sum_{p=1}^P \text{TV}(\mathbf{x}_p) = \text{trace}(\mathbf{X}^\top \mathbf{L} \mathbf{X}) = \frac{1}{2} \|\mathbf{A} \circ \mathbf{Z}\|_1$$

\Rightarrow Aristas \mathcal{E} esparsas cuando los datos son suaves

\Rightarrow Favorece aristas candidatas (i, j) asociadas a valores chicos de Z_{ij}

- Parameteriza el problema de aprender el grafo en términos de \mathbf{A} (en vez de \mathbf{L})
 \Rightarrow Ventajas porque las restricciones en \mathbf{A} quedan desacopladas

Formulación del método

- Modelo de aprendizaje de grafos propuesto [Kalofolias'16]

$$\begin{aligned} \min_{\mathbf{A}} \left\{ \|\mathbf{A} \circ \mathbf{Z}\|_1 - \alpha \mathbf{1}^\top \log(\mathbf{A}\mathbf{1}) + \frac{\beta}{2} \|\mathbf{A}\|_F^2 \right\} \\ \text{s. to } \quad \text{diag}(\mathbf{A}) = \mathbf{0}, A_{ij} = A_{ji} \geq 0, i \neq j \end{aligned}$$

⇒ Barrera logarítmica fuerza grado de nodos no nulo

⇒ Penaliza pesos grandes para controlar esparsidad

Formulación del método

- Modelo de aprendizaje de grafos propuesto [Kalofolias'16]

$$\begin{aligned} \min_{\mathbf{A}} \left\{ \|\mathbf{A} \circ \mathbf{Z}\|_1 - \alpha \mathbf{1}^\top \log(\mathbf{A}\mathbf{1}) + \frac{\beta}{2} \|\mathbf{A}\|_F^2 \right\} \\ \text{s. to } \quad \text{diag}(\mathbf{A}) = \mathbf{0}, A_{ij} = A_{ji} \geq 0, i \neq j \end{aligned}$$

⇒ Barrera logarítmica fuerza grado de nodos no nulo

⇒ Penaliza pesos grandes para controlar esparsidad



- Método primal-dual que se puede paralelizar, costo $O(N^2)$

- Laplacian-based factor analysis (Dong) revisitado. Se formula **(S1)** como

$$\begin{aligned} \min_{\mathbf{A}} \left\{ \|\mathbf{A} \circ \mathbf{Z}\|_1 - \log(\mathbb{I}\{\|\mathbf{A}\|_1 = N\}) + \frac{\beta}{2} (\|\mathbf{A}\mathbf{1}\|^2 + \|\mathbf{A}\|_F^2) \right\} \\ \text{s. to } \quad \text{diag}(\mathbf{A}) = \mathbf{0}, A_{ij} = A_{ji} \geq 0, i \neq j \end{aligned}$$

Ejemplo: aprender el grafo de dígitos de USPS

- 1001 imágenes de los 10 dígitos, altamente desbalanceados ($2,6i^2$)
⇒ 10 clases via aprender el grafo + spectral clustering
- Comparamos los métodos basados en suavidad que vimos, más el grafo k-NN



- Performance más robusta a la densidad del grafo
⇒ Posiblemente debido a no tener nodos aislados

Aprendizaje de grafos seleccionando aristas

- **Idea:** parameterizar la topología a encontrar con un **vector indicatriz de aristas**

Aprendizaje de grafos seleccionando aristas

- **Idea:** parameterizar la topología a encontrar con un **vector indicatriz de aristas**
- Tomemos el grafo completo con N nodos, que tiene $M := \binom{N}{2}$ aristas
 - ⇒ La matriz de incidencia $\mathbf{B} := [\mathbf{b}_1, \dots, \mathbf{b}_M] \in \mathbb{R}^{N \times M}$
- La Laplaciana del grafo candidato $G(\mathcal{V}, \mathcal{E})$ [Chepuri et al'17]

$$\mathbf{L}(\boldsymbol{\omega}) = \sum_{m=1}^M \omega_m \mathbf{b}_m \mathbf{b}_m^\top$$

- ⇒ **Vector binario indicatriz de aristas** $\boldsymbol{\omega} := [\omega_1, \dots, \omega_M]^\top \in \{0, 1\}^M$
- ⇒ Ofrece control explícito sobre el número de aristas $\|\boldsymbol{\omega}\|_0 = |\mathcal{E}|$

Aprendizaje de grafos seleccionando aristas

- **Idea:** parameterizar la topología a encontrar con un **vector indicatriz de aristas**
- Tomemos el grafo completo con N nodos, que tiene $M := \binom{N}{2}$ aristas
 - ⇒ La matriz de incidencia $\mathbf{B} := [\mathbf{b}_1, \dots, \mathbf{b}_M] \in \mathbb{R}^{N \times M}$
- La Laplaciana del grafo candidato $G(\mathcal{V}, \mathcal{E})$ [Chepuri et al'17]

$$\mathbf{L}(\boldsymbol{\omega}) = \sum_{m=1}^M \omega_m \mathbf{b}_m \mathbf{b}_m^\top$$

- ⇒ **Vector binario indicatriz de aristas** $\boldsymbol{\omega} := [\omega_1, \dots, \omega_M]^\top \in \{0, 1\}^M$
- ⇒ Ofrece control explícito sobre el número de aristas $\|\boldsymbol{\omega}\|_0 = |\mathcal{E}|$

Problema: Dadas observaciones $\mathcal{X} := \{\mathbf{x}_p\}_{p=1}^P$, aprender un grafo sin pesos $G(\mathcal{V}, \mathcal{E})$ tal que **señales de \mathcal{X} sean suaves** en G y $|\mathcal{E}| = K$.

Optimización booleana con restricción de cardinalidad

- La formulación natural es resolver el problema (no convexo)

$$\min_{\omega \in \{0,1\}^M} \text{trace}(\mathbf{X}^\top \mathbf{L}(\omega) \mathbf{X}), \quad \text{s. to } \|\omega\|_0 = K$$

- La solución se obtiene via un **simple procedimiento de orden de rankings**
 - Calcular scores para cada arista $c_m := \text{trace}(\mathbf{X}^\top (\mathbf{b}_m \mathbf{b}_m^\top) \mathbf{X})$
 - Poner $\omega_m = 1$ para las K aristas con menor score

Optimización booleana con restricción de cardinalidad

- La formulación natural es resolver el problema (no convexo)

$$\min_{\boldsymbol{\omega} \in \{0,1\}^M} \text{trace}(\mathbf{X}^\top \mathbf{L}(\boldsymbol{\omega}) \mathbf{X}), \quad \text{s. to } \|\boldsymbol{\omega}\|_0 = K$$

- La solución se obtiene via un **simple procedimiento de orden de rankings**

- Calcular scores para cada arista $c_m := \text{trace}(\mathbf{X}^\top (\mathbf{b}_m \mathbf{b}_m^\top) \mathbf{X})$
- Poner $\omega_m = 1$ para las K aristas con menor score

- Versión más realista con ruido aditivo (AWGN) $\mathbf{x}_p = \mathbf{y}_p + \boldsymbol{\epsilon}_p$, $p = 1, \dots, P$

$$\min_{\mathbf{Y}, \boldsymbol{\omega} \in \{0,1\}^M} \{ \|\mathbf{X} - \mathbf{Y}\|_F^2 + \alpha \text{trace}(\mathbf{Y}^\top \mathbf{L}(\boldsymbol{\omega}) \mathbf{Y}) \}, \quad \text{s. to } \|\boldsymbol{\omega}\|_0 = K$$

⇒ Se puede resolver con AM o semidefinite relaxation (SDR)

Resumen comparativo

- Propiedades del enfoque de selección de aristas
 - ✓ Controlamos directamente la esparsidad de aristas
 - ✓ Algoritmo simple en el caso sin ruido
 - ✓ No hay que imponer restricciones para obtener una Laplaciana
 - ✗ No garantiza conectividad de G
 - ✗ No podemos incluir pesos en las aristas

Resumen comparativo

- Propiedades del enfoque de selección de aristas
 - ✓ Controlamos directamente la esparsidad de aristas
 - ✓ Algoritmo simple en el caso sin ruido
 - ✓ No hay que imponer restricciones para obtener una Laplaciana
 - ✗ No garantiza conectividad de G
 - ✗ No podemos incluir pesos en las aristas
- Volviendo al framework de [Kalofolias'16], es más flexible

$$\min_{\mathbf{A}} \{ \|\mathbf{A} \circ \mathbf{Z}\|_1 + g(\mathbf{A}) \}$$

$$\text{s. to } \text{diag}(\mathbf{A}) = \mathbf{0}, A_{ij} = A_{ji} \geq 0, i \neq j$$

⇒ Engloba el factor-analysis model [Dong et al'16]

⇒ Recupera pesos de kernel gaussiano $A_{ij} := \exp\left(-\frac{\|\bar{\mathbf{x}}_i - \bar{\mathbf{x}}_j\|^2}{\sigma^2}\right)$ para

$$g(\mathbf{A}) = \sigma^2 \sum_{i,j} A_{ij} (\log(A_{ij}) - 1)$$

Case study: Clasificación

- Señales **etiquetadas** de grafos $\mathcal{X}_c := \{\mathbf{x}_p^{(c)}\}_{p=1}^{P_c}$ de C clases diferentes
 - ⇒ Las señales en cada clase tienen una estructura que las distingue
- **Asumimos:** Señales de clase c son suaves respecto a un grafo (desconocido) $G_c(\mathcal{V}, \mathcal{E}_c)$
- **Modelo de subespacios lineales múltiples**
 - ⇒ Señales generadas por unos pocos modos Laplacianos (componentes GFT)
 - ⇒ Como *subspace clustering* [Vidal'11], pero supervisado

Planteo del problema

Dadas **señales de entrenamiento** $\mathcal{X} = \bigcup_{c=1}^C \mathcal{X}_c$, aprender **grafos discriminativos** \mathbf{A}_c bajo prior de suavidad, para luego clasificar señales de test via proyecciones de GFT.

Discriminative graph learning

- Aprendizaje del grafo discriminativo c [Saboksayr et al'21]

$$\min_{\mathbf{A}_c} \left\{ \|\mathbf{A}_c \circ \mathbf{Z}_c\|_1 - \alpha \mathbf{1}^\top \log(\mathbf{A}_c \mathbf{1}) + \frac{\beta}{2} \|\mathbf{A}_c\|_F^2 - \gamma \sum_{k \neq c}^C \|\mathbf{A}_c \circ \mathbf{Z}_k\|_1 \right\}$$

s. to $\text{diag}(\mathbf{A}_c) = \mathbf{0}$, $[\mathbf{A}_c]_{ij} = [\mathbf{A}_c]_{ji} \geq 0$, $i \neq j$

⇒ Captura la topología subyacente (estructura de clase c)

⇒ Discriminabilidad para mejorar la performance de clasificación

Discriminative graph learning

- Aprendizaje del grafo discriminativo c [Saboksayr et al'21]

$$\min_{\mathbf{A}_c} \left\{ \|\mathbf{A}_c \circ \mathbf{Z}_c\|_1 - \alpha \mathbf{1}^\top \log(\mathbf{A}_c \mathbf{1}) + \frac{\beta}{2} \|\mathbf{A}_c\|_F^2 - \gamma \sum_{k \neq c}^C \|\mathbf{A}_c \circ \mathbf{Z}_k\|_1 \right\}$$

s. to $\text{diag}(\mathbf{A}_c) = \mathbf{0}$, $[\mathbf{A}_c]_{ij} = [\mathbf{A}_c]_{ji} \geq 0$, $i \neq j$

⇒ Captura la topología subyacente (estructura de clase c)

⇒ Discriminabilidad para mejorar la performance de clasificación

- **Q:** Dados grafos $\{\hat{\mathbf{A}}_c\}_{c=1}^C$, ¿cómo clasificamos una señal de test \mathbf{x} ?
- Pasamos \mathbf{x} por un banco de C filtros pasa-bajos (LPFs)

$$\tilde{\mathbf{x}}_{F,c} = \text{diag}(\tilde{\mathbf{h}}) \hat{\mathbf{V}}_c^\top \mathbf{x} \quad \Rightarrow \quad \hat{c} = \underset{c}{\text{argmax}} \{ \|\tilde{\mathbf{x}}_{F,c}\|^2 \}$$

⇒ respuesta frecuencial LPF $\tilde{\mathbf{h}}$, base aprendida GFT para la clase c $\hat{\mathbf{V}}_c$

Reconocer emociones a partir de EEG

- Aprendizaje discriminativo de grafos para reconocer emociones a partir de señales EEG
- DEAP dataset \Rightarrow 32 personas miran videos musicales (40 cada una)
 - Se les pide calificar videos: valencia, activación, like/dislike, dominancia
 - Foco en etiquetas valence: baja (1-5 rating) y alta (6-10 rating)
 - Señales adquiridas con EEG de $N = 32$ canales
- Para cada persona, se hace clasificación de valencia
 - \Rightarrow Se aprenden $C = 2$ grafos y se proyectan las señales en los 8 modos más suaves
 - \Rightarrow Se mide con leave-one (trial)-out classification accuracy
- El accuracy medio es 92,73 %

S. S. Saboksayr et al, "Online discriminative graph learning from multi-class smooth signals," *Signal Processing*, 186, 108101, 2021

