

Sur la normalisation de la matrice Laplacienne en partitionnement spectral

Julien Ah-Pine
(julien.ah-pine@univ-lyon2.fr)

Université Lyon 2
Laboratoire ERIC

Lyon, le 28 juin 2017
SFC 2017

- 1 Partitionnement spectral (spectral clustering)
- 2 Normalisation d'ordre $t > 0$ de la matrice Laplacienne
- 3 Expériences
- 4 Conclusion et travaux futurs

Rappel du Sommaire

- 1 Partitionnement spectral (spectral clustering)
- 2 Normalisation d'ordre $t > 0$ de la matrice Laplacienne
- 3 Expériences
- 4 Conclusion et travaux futurs

Partitionnement spectral (PS) en quelques mots

- Méthodes de clustering développées depuis les années 2000.
- Prise en compte de la **géométrie intrinsèque** des données (espaces courbés/variétés).
- Les notions de **graphes de similarités et de voisinage** et de **matrice laplacienne** sont importantes.
- Méthodologie : **décomposition spectrale** de la matrice Laplacienne, plongement des données dans un **espace euclidien**, et utilisation des **k-means** pour le partitionnement.
- Liens avec les problèmes et méthodes de partitionnement de graphe.
- Article d'introduction de référence : [Von Luxburg, 2007].

Graphe de similarités

- La modélisation employée est celle de **graphe non-orienté pondéré**.
- Soit $G = (\mathbb{V}, \mathbb{E})$ un graphe non-orienté, sans boucle.
- $\mathbb{V} = \{v_1, \dots, v_n\}$ est l'ensemble des sommets : objets à classifier.
- \mathbb{E} est l'ensemble des arêtes : paires d'objets qui sont **similaires**.
- Les arêtes sont pondérées et si $(v_i, v_j) \in \mathbb{E}$, alors $l(v_i, v_j) > 0$ est la **valuation de la similarité**.
- G est représenté par une **matrice d'adjacence pondérée** notée $\mathbf{W} = (w_{ij})_{i,j=1,\dots,n}$, définie comme suit :

$$w_{ij} = \begin{cases} l(v_i, v_j) & \text{si } (v_i, v_j) \in \mathbb{E} \\ 0 & \text{sinon} \end{cases}$$

Graphe de voisinage

- L'ensemble des arêtes \mathbb{E} encode des **relations de voisinage**.
- Plusieurs façons de construire \mathbb{E} (et donc \mathbf{W}) :
 - ▶ **Graphe écrêté selon un seuil $\theta \geq 0$:**

$$(v_i, v_j) \in \mathbb{E} \Leftrightarrow l(v_i, v_j) \geq \theta$$

- ▶ **Graphe des k -plus proches voisins :**

$$(v_i, v_j) \in \mathbb{E} \Leftrightarrow (v_i \in \text{NN}_k(v_j) \vee v_j \in \text{NN}_k(v_i))$$

où $\text{NN}_k(v_i)$ est l'ensemble des k plus proches voisins de v_i .

Matrice laplacienne et sa normalisation classique

- Notons $\mathbf{D} = (d_{ij})_{i,j=1,\dots,n}$ la **matrice des degrés** et définie par :

$$d_{ij} = \begin{cases} d_i & \text{si } i = j \\ 0 & \text{sinon} \end{cases}$$

où $d_i = \sum_{j=1}^n w_{ij}$, $\forall i = 1, \dots, n$.

- La **matrice Laplacienne** de G notée \mathbf{L} est définie comme suit :

$$\mathbf{L} = \mathbf{D} - \mathbf{W}$$

- La **normalisation par division symétrique** de \mathbf{L} notée \mathbf{L}_{sym} est donnée par :

$$\begin{aligned} \mathbf{L}_{sym} &= \mathbf{D}^{-1/2} \mathbf{L} \mathbf{D}^{-1/2} \\ &= \mathbf{I} - \mathbf{D}^{-1/2} \mathbf{W} \mathbf{D}^{-1/2} \end{aligned}$$

où \mathbf{I} est la matrice identité d'ordre n .

Propriétés de la matrice laplacienne normalisée

Propriété.

Soit \mathbf{L}_{sym} la matrice laplacienne **normalisée** d'un graphe G :

- Pour tout vecteur $\mathbf{f} \in \mathbb{R}^n$:

$$\mathbf{f}^\top \mathbf{L}_{sym} \mathbf{f} = \frac{1}{2} \sum_{i,j=1}^n w_{ij} \left(\frac{f_i}{\sqrt{d_i}} - \frac{f_j}{\sqrt{d_j}} \right)^2$$


- \mathbf{L}_{sym} est symétrique et sdp et possède n valeurs propres réelles, non-négatives :

$$0 = \lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_n$$

- L'ordre de multiplicité k de la **valeur propre 0** est le nombre de composantes connexes de G notées C_1, \dots, C_k . Le sous-espace propre associé à la valeur propre 0 est engendré par les vecteurs $\mathbf{D}^{1/2} \mathbf{1}_{C_1}, \dots, \mathbf{D}^{1/2} \mathbf{1}_{C_k}$ où $\mathbf{1}_{C_l}$ est le vecteur indicateur de C_l .

Illustration

- $\mathbb{V} = \{v_1, v_2, v_3, v_4, v_5\}$
- $\mathbb{E} = \left\{ \underbrace{(v_1, v_2)}_2, \underbrace{(v_2, v_3)}_3, \underbrace{(v_4, v_5)}_2 \right\}$



$$\rightarrow \mathbf{W} = \begin{pmatrix} 0 & 2 & 0 & 0 & 0 \\ 2 & 0 & 3 & 0 & 0 \\ 0 & 3 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 2 \\ 0 & 0 & 0 & 2 & 0 \end{pmatrix}$$

$$\rightarrow \mathbf{D} = \begin{pmatrix} 2 & 0 & 0 & 0 & 0 \\ 0 & 5 & 0 & 0 & 0 \\ 0 & 0 & 3 & 0 & 0 \\ 0 & 0 & 0 & 2 & 0 \\ 0 & 0 & 0 & 0 & 2 \end{pmatrix}$$

$$\rightarrow \mathbf{L} = \begin{pmatrix} 2 & -2 & 0 & 0 & 0 \\ -2 & 5 & -3 & 0 & 0 \\ 0 & -3 & 3 & 0 & 0 \\ 0 & 0 & 0 & 2 & -2 \\ 0 & 0 & 0 & -2 & 2 \end{pmatrix}$$

$$\rightarrow \mathbf{L}_{\text{sym}} = \begin{pmatrix} 1 & -.63 & 0 & 0 & 0 \\ -.63 & 1 & -.77 & 0 & 0 \\ 0 & -.77 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & -1 \\ 0 & 0 & 0 & -1 & 1 \end{pmatrix}$$

\rightarrow Spectre de \mathbf{L}_{sym} : $\{2, 2, 1, 0, 0\}$

$$\rightarrow \underbrace{\mathbf{D}^{1/2} \mathbf{1}_{C_1}}_{v_0^1} = \begin{pmatrix} 1.41 \\ 2.24 \\ 1.73 \\ 0 \\ 0 \end{pmatrix} \text{ et } \underbrace{\mathbf{D}^{1/2} \mathbf{1}_{C_2}}_{v_0^2} = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 1.41 \\ 1.41 \end{pmatrix}.$$

Pseudo-code des méthodes de partitionnement spectral

- 1 **Input** : l (similarité), méthode de voisinage, k (nb de classes)
 - 2 Construire le graphe de voisinage \mathbf{W} selon la méthode choisie
 - 3 Construire la matrice laplacienne normalisée \mathbf{L}_{sym}
 - 4 Calculer $\mathbf{f}^1, \dots, \mathbf{f}^k$, les k premiers vecteurs propres de \mathbf{L}_{sym}
 - 5 Construire $\mathbf{F} = (\mathbf{f}^1 \ \dots \ \mathbf{f}^k) \in \mathbb{R}^{n \times k}$
 - 6 Normer les vecteurs lignes de \mathbf{F}
 - 7 Utiliser les k -means pour partitionner les n lignes de \mathbf{F}
 - 8 **Ouput** : Partition en k classes
- Remarque : on peut utiliser \mathbf{L} à la place de \mathbf{L}_{sym} mais la dernière a de meilleures propriétés de convergence asymptotique que la première [Von Luxburg et al., 2008].

Rappel du Sommaire

- 1 Partitionnement spectral (spectral clustering)
- 2 Normalisation d'ordre $t > 0$ de la matrice Laplacienne**
- 3 Expériences
- 4 Conclusion et travaux futurs

Normalisation par division symétrique et produit de Hadamard

- **Proposition** : extension de la normalisation par division symétrique.
- Reprenons \mathbf{L}_{sym} ainsi que sa forme quadratique associée :

$$\mathbf{L}_{sym} = \mathbf{I} - \mathbf{D}^{-1/2} \mathbf{W} \mathbf{D}^{-1/2} \Rightarrow \mathbf{f}^T \mathbf{L}_{sym} \mathbf{f} = \sum_{i=1}^n f_i^2 - \sum_{i,j=1}^n \frac{w_{ij}}{\sqrt{d_i d_j}} f_i f_j$$

- Reformulation de \mathbf{L}_{sym} en utilisant le **produit de Hadamard (ou de Schur)** noté \circ (produit terme à terme entre deux matrices).
- En prenant $\mathbf{N} = (n_{ij})_{i,j=1,\dots,n}$ de terme général :

$$n_{ij} = \frac{1}{\sqrt{d_i d_j}}$$

- On montre facilement que :

$$\boxed{\mathbf{L}_{sym} = \mathbf{L} \circ \mathbf{N}}$$

Normalisation d'ordre t

- Etant donné le vecteur de degrés $\mathbf{d} = (d_1, \dots, d_n)$, on introduit la famille paramétrique de matrices $\mathbf{N}^t = (n_{ij}^t)_{i,j=1,\dots,n}$ de terme général :

$$n_{ij}^t = \frac{1}{\left(\frac{1}{2}(d_i^t + d_j^t)\right)^{\frac{1}{t}}}$$

où le paramètre t est un réel strictement positif.

Définition.

La famille de matrice Laplacienne normalisée d'ordre t , notée \mathbf{L}_{sym}^t , est définie pour tout $t > 0$ par :

$$\begin{aligned} \mathbf{L}_{sym}^t &= \mathbf{L} \circ \mathbf{N}^t \\ &= \mathbf{I} - \mathbf{W} \circ \mathbf{N}^t \end{aligned}$$

Normalisation d'ordre t (suite)

- Posons :

$$\mathcal{M}^t(d_i, d_j) = \left(\frac{1}{2}(d_i^t + d_j^t) \right)^{\frac{1}{t}}$$

- On a :

$$n_{ij}^t = \frac{1}{\mathcal{M}^t(d_i, d_j)}, \forall i, j = 1, \dots, n$$

- \mathcal{M}^t est la **moyenne généralisée (puissance) d'ordre** $t > 0$ avec les propriétés remarquables suivantes :
 - ▶ Moyenne géométrique : $\lim_{t \rightarrow 0} \mathcal{M}^t(d_i, d_j) = \sqrt{d_i d_j}$,
 - ▶ Moyenne arithmétique : $\mathcal{M}^1(d_i, d_j) = \frac{1}{2}(d_i + d_j)$,
 - ▶ Maximum : $\lim_{t \rightarrow \infty} \mathcal{M}^t(d_i, d_j) = \max(d_i, d_j)$.

- Clairement on a :

$$\lim_{t \rightarrow 0} \underbrace{\mathbf{L} \circ \mathbf{N}^t}_{\mathbf{L}_{sym}^t} = \mathbf{L}_{sym}$$

Interprétations

- Forme quadratique associée à \mathbf{L}_{sym}^t , $\forall \mathbf{f} \in \mathbb{R}^n$:

$$\mathbf{f}^\top \mathbf{L}_{sym}^t \mathbf{f} = \sum_{i=1}^n f_i^2 - \sum_{i,j=1}^n \frac{w_{ij}}{\left(\frac{1}{2}(d_i^t + d_j^t)\right)^{\frac{1}{t}}} f_i f_j$$

- Pour minimiser $\mathbf{f}^\top \mathbf{L}_{sym}^t \mathbf{f}$, il faut que $f_i f_j > 0$:

- ▶ “ $f_i f_j > 0$ si w_{ij} grand”.
- ▶ “ $f_i f_j > 0$ si $\left(\frac{1}{2}(d_i^t + d_j^t)\right)^{\frac{1}{t}}$ petit”.

- Propriété : $\forall t > 0$,
$$\begin{cases} \sqrt{d_i d_j} \leq \left(\frac{1}{2}(d_i^t + d_j^t)\right)^{\frac{1}{t}} \\ \sqrt{d_i d_j} = \left(\frac{1}{2}(d_i^t + d_j^t)\right)^{\frac{1}{t}} \text{ ssi } d_i = d_j \end{cases}$$

- ▶ “ $t > 0$ **pénalise** davantage la différence entre d_i et d_j que $t \rightarrow 0$ ”.
- ▶ v_i et v_j ont une forte probabilité d’être dans la même classe ($f_i f_j > 0$) si leur **similarité** est **forte ET** si leurs **dégrés** sont **similaires**.

Propriété de métricité

Propriété.

Pour tout $t > 0$, \mathbf{L}_{sym}^t est semi-définie positive.

Démonstration.

\mathbf{L} est sdp. On montre que \mathbf{N}^t est sdp pour tout $t > 0$ [Bhatia, 2006].
Ainsi, $\mathbf{L} \circ \mathbf{N}^t$ est sdp comme conséquence du théorème de Schur. □

- Ce résultat permet de garantir le plongement des objets dans un espace Euclidien par décomposition spectrale de \mathbf{L}_{sym}^t , $t > 0$.
- En pratique, on peut donc utiliser le pseudo-code précédent avec cette nouvelle famille de matrice Laplacienne normalisée.

Rappel du Sommaire

- 1 Partitionnement spectral (spectral clustering)
- 2 Normalisation d'ordre $t > 0$ de la matrice Laplacienne
- 3 Expériences**
- 4 Conclusion et travaux futurs

Protocol expérimental

- Tests sur 5 jeux de données accessibles en ligne.
- Tests de 5 normalisations : $t \rightarrow 0$ (référence) contre $t = 1, 2, 5, 10$.
- Critère de qualité externe : indice de Rand corrigé (ARI).
- Pour chaque cas, 10 exécutions de k -means, puis test de significativité de Wilcoxon-Mann-Withney des mesures ARI entre $t \rightarrow 0$ et $t > 0$.
- Tous les résultats présentés (moyennes des ARI) sont statistiquement différents du résultat de référence.

Résultats




FIGURE – Résultats sur 5 jeux de données et 5 normalisation différentes.

Rappel du Sommaire

- 1 Partitionnement spectral (spectral clustering)
- 2 Normalisation d'ordre $t > 0$ de la matrice Laplacienne
- 3 Expériences
- 4 Conclusion et travaux futurs

Conclusion et travaux futurs

- Contributions :
 - ▶ Généralisation de la normalisation par division symétrique.
 - ▶ “Proof of concept” sur quelques jeux de données.
- Travaux futurs :
 - ▶ Comment fixer le paramètre t ?
(coefficient de clustering, ...),
 - ▶ Un paramètre t_{ij} pour chaque paire (v_i, v_j) ?
(coefficient de clustering local, ...),
 - ▶ Partitionnement de graphes avec propriété sur les degrés.
(réseaux invariants d'échelle, ...).

Merci de votre attention !
Des questions ? :-)



Bhatia, R. (2006).

Infinately divisible matrices.

[The American Mathematical Monthly](#), 113(3) :221–235.



Von Luxburg, U. (2007).

A tutorial on spectral clustering.

[Statistics and computing](#), 17(4) :395–416.



Von Luxburg, U., Belkin, M., and Bousquet, O. (2008).

Consistency of spectral clustering.

[The Annals of Statistics](#), pages 555–586.