

Classification spectrale de graphes

THOMAS SOUBIRAN

CERAPS (UMR 8026 CNRS - Université de Lille)

Froagnet

Toulouse, 28 mai 2019

- ▶ **objet de la communication** : analyse **spectrale** de graphes
 - ▶ plus particulièrement, **le laplacien du graphe**
 - ▶ avec une présentation de différentes interprétations
optimisation de la coupe du graphe, marches aléatoires, . . .
 - ▶ entre autres possibilités
blockmodel stochastique, analyse des correspondances, . . .
 - ▶ et en lien avec d'autres applications de l'analyse spectrale à des graphes
 - ▶ avec une application aux flux entre **commune de résidence** et **commune du lieu de travail**
issus du recensement de populations
- ▶ travail **en cours**
- ▶ de façon concomitante, aperçu de l'utilité de **l'algèbre linéaire** pour travailler avec des (grands) graphes
pour stocker, manipuler, chercher, analyser, . . .

Présentation des données

Le recensement général de population

- ▶ les volumes des trajets inter-communaux sont issus **du recensement de la population**
- ▶ bon an, mal an, le recensement s'est déroulé en France **tous les cinq ans** de 1801 jusqu'aux années cinquante
- ▶ l'intervalle inter-censitaire a ensuite progressivement **augmenté**
- ▶ jusqu'à atteindre **neuf ans** en 1999
- ▶ l'INSEE a ensuite procédé à une **« rénovation »** radicale du RGP
 - et ce, à *l'invitation* des pouvoirs publics
- ▶ qui a été effective **partir de 2004**

Les enquêtes annuelles de recensement de la population

- ▶ enquête tournante **par sondage** réalisée annuellement sur une période de six ans
- ▶ durant laquelle seule **une fraction** des ménages (logements ?) est interrogée
- ▶ en effet, chaque année :
 - ▶ seule une fraction des communes de moins de 10 000 hab.
 - ▶ seule une fraction des ménages des communes de plus de 10 000 hab.
 - ▶ sont interrogées
- ▶ ce changement a suscité de **nombreuses interrogations** dès sa mise en œuvre et continue d'en susciter, particulièrement de la part d'élus locaux
- ▶ les flux ne sont donc pas **comptabilisés** mais bien **inférés**

Note : pour plus de détails, voire notamment le n° spécial d'*Économie et statistiques* de 2016 sur le recensement rénové (n° 483-484-485 – 2016)

Les trajets entre communes




FIGURE 1 – Relations binaires entre les communes ($a_{ij} > 0$), tri par cantons

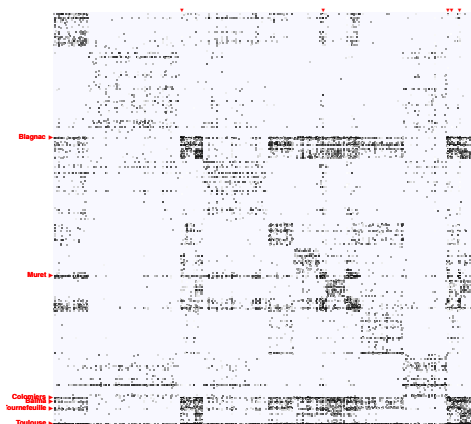


FIGURE 2 – Flux entre les communes de la Haute-Garonne, tri par cantons

La structure sous-jacente du graphe

- ▶ les deux graphes permettent de faire ressortir la structure **territoriale** des flux
- ▶ autre **topologie** : la géographie
- ▶ référence qui permet **d'évaluer** les analyses
 - avec d'autres critères que les seuls mesures statistiques
- ▶ utile pour **des tests**
- ▶ avant application à **un autre graphe : les signatures** à un site **de pétitionnement en ligne**

- ▶ site de pétitionnement lancé **fin 2006**
- ▶ extraction de la base SQL servant de *backend* au site en **février 2015**
- ▶ la base renseigne

- ▶ plus de **15 000 pétitions**

en fait, plutôt 12 4000, le nombre variant en fonction de la table considérée. . .

- ▶ près de **3,8 millions** de signatures

- ▶ la base **renseigne aussi** (avec un nombre de données manquantes variables) :

- ▶ hash des adresses électroniques utilisées pour valider les signatures

ces hashes pouvant correspondre à plusieurs personnes utilisant l'adresse

- ▶ prénom du signataire
- ▶ horodatage de la signature et de sa validation
- ▶ la commune de résidence du signataire
- ▶ . . .

Les co-signatures aux pétitions




FIGURE 3 – Relations binaires entre les pétitions ($n_{ij} > 0$), tri par date de création des pétitions

L'effet de plate-forme

- ▶ le graphe permet de faire ressortir la structure avant tout **temporelle** qui relie les pétitions

- ▶ en effet 21 % signatures multiples ont lieu **dans l'heure** suivant la précédente signature

tendance sans doute renforcée par la mise en avant sur le site des pétitions les plus signées du moment

- ▶ une large partie des liens entre les pétitions (et donc les signataires) provient très probablement de **la navigation sur le site**

la signature de pétitions en ligne conduit donc à la signature de pétitions que les personnes n'auraient peut-être jamais signées autrement

- ▶ à ce titre, il semble de plus que les comportements changent avec **la pratique du site**

plus le nombre de signatures augmente, plus le temps entre deux signatures se réduit

- ▶ illustration de **la dualité** des graphes biparti
- ▶ qui, combiné à **l'éparpillement des signatures**
- ▶ et complique l'analyse du graphe

Les flux entre communes




FIGURE 4 – Nuage de points des flux sortant et entrants

- ▶ le graphe des flux est **orienté** : flux entrants et flux sortants
- ▶ les flux ont été **symétrisés** ($a_{ij}^{sym} = a_{ij} + a_{ji}$)

Note : il existe des variantes pour graphe orienté de l'analyse spectrale cf. infra)

- ▶ de plus,
 - ▶ les analyses portent sur **la métropole**
 - ▶ **les arrondissements** de Paris, Lyon et Marseille n'ont pas été agrégés

Graphes et algèbre linéaire

Analyse spectrale de graphe

- ▶ avec les moindres carrés, **la décomposition en valeurs propres** est la cheville ouvrière de l'analyse de données
 - et ce, tant d'un point de vue théorique que pratique
- ▶ l'analyse de graphes ne fait **pas exception**
- ▶ il existe **une relation privilégiée** entre analyse de graphe et analyse spectrale
 - ▶ les valeurs propres **encodent** en effet différentes propriétés des graphes
 - ▶ notamment liées à **la conductivité** du graphe

Décomposition en valeurs propres

- ▶ pour une matrice $\mathbf{A}$
- ▶ $\lambda \in \mathbb{C}$ est **une valeur propre** de $\mathbf{A}$
- ▶ s'il existe un vecteur $\mathbf{x} \in \mathbb{C}$ qui satisfait la relation

$$\lambda \mathbf{x} = \mathbf{A} \mathbf{x} \quad (1)$$

où $\mathbf{x}$ est **un vecteur propre**

- ▶ si $\mathbf{A}$ est **symétrique** ($\mathbf{A} \in \mathbb{R}^{n \times n}$) :
 - ▶ les vecteurs propres sont réels
 - ▶ ils sont orthogonaux ($\mathbf{x}_1 \perp \mathbf{x}_2$)
 - ▶ si $\mathbf{A}$ est définie semi-positive ($\mathbf{x}^\top \mathbf{A} \mathbf{x} \geq 0$), les valeurs propres sont aussi réelles
- ▶ pour les matrices **non symétriques**, cf. décomposition en valeurs singulières

Décomposition en valeurs propres

- ▶ de plus, les valeurs propres sont **ordonnées** : $\lambda_1 \leq \dots \leq \lambda_n$

plusieurs valeurs propres peuvent être égales (multiplicité)

- ▶ et, entre autres choses,

$$\text{trace}(\mathbf{A}) = \sum_i^n a_{ii} = \sum_i^n \lambda_i \quad (2)$$

- ▶ **caractérisation variationnelle** des valeurs propres :

$$\lambda_1 = \min_{\mathbf{x} \neq 0} \frac{\mathbf{x}^\top \mathbf{A} \mathbf{x}}{\mathbf{x}^\top \mathbf{x}} \quad (3)$$

$$\lambda_2 = \min_{\substack{\mathbf{x} \neq 0 \\ \mathbf{x}^\top \mathbf{x}_1 > 0}} \frac{\mathbf{x}^\top \mathbf{A} \mathbf{x}}{\mathbf{x}^\top \mathbf{x}} \quad (4)$$

$$\dots \quad (5)$$

- ▶ **centralité des valeurs propres** : cf. infra p.33
- ▶ **centralité de Katz** :

$$x_i = \alpha \sum_j^n a_{ij} x_{ij} + \beta \quad (6)$$

$$\mathbf{x} = \alpha \mathbf{A}^\top \mathbf{x} + \beta \mathbf{1} \quad (7)$$

- ▶ **PageRank** : cf. infra p.36
- ▶ **le laplacien du graphe** : cf. infra p.37

- ▶ l'application de l'algèbre linéaire aux graphes **ne se limite toutefois pas à l'analyse spectrale**
- ▶ et ce, d'un point de vue **théorique**
 - étude des propriétés de certaines catégories de graphes
- ▶ mais aussi **pratique** comme le stockage et la manipulation de graphes
- ▶ ou encore l'implémentation **de primitives** comme des algorithmes de recherche
 - Exemple :** le parcours en largeur (BFS)
- ▶ en effet, un graphe peut être représenté par **une matrice d'adjacence**

La matrice d'adjacence

- ▶ la matrice d'adjacence est **une matrice carrée** de dimension $(|V|, |V|)$:

$$\mathbf{A} = \begin{pmatrix} a_{1,1} & \dots & a_{1,j} & \dots & a_{1,J} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ a_{1,i} & \dots & a_{i,j} & \dots & a_{i,J} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ a_{I,1} & \dots & a_{I,j} & \dots & a_{I,J} \end{pmatrix}$$

- ▶ $a_{i,j}$ manifestent **les liens** entre les sommets du graphe
- ▶ elles peuvent être **binaires ou valuées**
- ▶ la matrice peut être **symétrique ou asymétrique**

- ▶ les matrices d'adjacences sont généralement **éparse**

seule une fraction de $a_{ij} > 0$

- ▶ et ça, d'autant plus que **le nombre de sommets** (dimensions de la matrice) croît

pour le graphes des flux inter-communiaux : $\frac{\#a_{ij} | a_{ij} > 0}{|V|^2} = \frac{908279}{1254363889} \simeq 7e^{-4}$

- ▶ dans ce cas de figure, le graphe peut être représenté au moyen **d'une matrice éparse**
- ▶ pour lesquels différentes **implémentations** efficaces existent

- ▶ comme SuiteSparse qui est accessible dans R via la paquet Matrix
- ▶ qui propose un large éventail de structures de données

éparses symétriques, éparses asymétriques, diagonales, structurées, denses, . . .

- ▶ et de méthodes pour les opérations sur ces matrices

y compris de types différents

La création du graphe des flux

- création **d'un dictionnaire des communes**

- en le triant sur le code commune
- ce dictionnaire renseigne les sommets du graphe et donc les lignes (resp. les colonnes) de la matrice

- assignation des indices pour obtenir **le triplet** (i, j, n_{ij})

Départ	Destination	n	i	j	n
L'Abergement-Clémenciat	Bourg-en-Bresse	35	1	49	35
L'Abergement-Clémenciat	Châtillon-sur-Chalaronne	55	1	86	55
L'Abergement-Clémenciat	Feillens	5	1	146	5
...	...	...	...	...	...

avec la fonction `match()`

- suppression **des boucles** et des trajets vers **des destinations à l'étranger** (frontaliers)

La création du graphe (suite)

- création de **la matrice épars**

```
1      A ← sparseMatrix(  
2          i = i  
3          , j = j  
4          , x = n  
5          , dims = c(nrc, nrc)  
6          , dimnames = list(communes0$CODGEO, communes0$CODGEO)  
7      )
```

- tout ça en un plus de **~ 1 seconde...**

Note :

- SuiteSparse utilise une version compressée et ne stocke pas les paires i, j
- mais seulement les i
- les indices des colonnes peuvent être retrouvés en utilisant un vecteur p de dimension $|J|$ qui stocke le nombre d'éléments de la colonne

Exemples d'opérations

- ▶ changer l'ordre des colonnes pour **trier en fonction du cantons** :

```
1 A[perm , perm]
```

avec perm l'indice des sommets triés par cantons

- ▶ sous-ensemble pour extraire **le super-composant**

```
1 cmpn ← graph.components(A)
2 idx ← cmpn==1
3 A ← A[idx , idx]
```

- ▶ la fonction `graph.components()` permet **d'attribuer chaque sommet à son composant** (sous-graphe connecté) cf. infra p.29
- ▶ cette opération est nécessaire pour l'analyse spectrale **du laplacien du graphe**

► **degré :**

- sortant : $\sum_j^n a_{ij}$ rowSums(A)
- rentrant : $\sum_i^n a_{ij}$ colSums(A)

- **symétrisation** $(\mathbf{A} + \mathbf{A}^\top)$ $\mathbf{A} + \mathbf{t}(\mathbf{A})$
- **nombre de chemins** entre sommets

- calcul **du nombre de chemins** entre sommets pour les trajets de longueur k

- pour un trajet de longueur 1 (**mes amis**), le nombre de chemins entre v_i et v_j est donné par les entrées de $\mathbf{A}$
- pour un trajet de longueur 2 (**amis de mes amis**), le nombre de chemins est donné par $\sum_k^N a_{ik} a_{kj}$, soit

$$\mathbf{A}\mathbf{A} = \mathbf{A}^2 \quad (8)$$

- pour un trajet de longueur 3 (**amis des amis de mes amis**), le nombre de chemins est donnée par $\sum_k^N \sum_l^N a_{ik} a_{kl} a_{lj}$, soit

$$\mathbf{A}\mathbf{A}\mathbf{A} = \mathbf{A}^3 \quad (9)$$

- plus généralement (amis des amis des amis. . . de mes amis),

$$\mathbf{A}^k = \mathbf{A}\mathbf{A}\mathbf{A} \dots \mathbf{A} \quad (10)$$

- la diagonale de $\mathbf{A}^k$ donne le nombre de fois où un chemins partant de v_i repasse par v_i

les amis de mes amis sont-ils mes amis ? – cf. triangles p.31

- Matrix : $\mathbf{A}^k$

cf. infra p.31 pour une autre approche utilisant les valeurs propres

- ▶ l'objet ainsi crée **s'intègre parfaitement** dans R
- ▶ pour réaliser **d'autres opérations**
- ▶ mais aussi pour la **sérialisation**
- ▶ **plus généralement,**
 - ▶ pas besoin de convertir un objet représentant le graphe en matrice pour certaines opérations
 - ▶ organisation des données en mémoire (localité)
 - ▶ parallélisation
 - la parallélisation pour les matrices éparses reste toutefois un domaine de recherche actif (graphes hyper-épars)

- ▶ différentes opérations sur le graphe peuvent donc être **facilement réalisées** avec les fonctions|méthodes proposées par un paquet comme Matrix
- ▶ l'intérêt de la représentation d'un graphe par une matrice éparses va cependant **au de-là** du stockage et la réalisation d'opérations élémentaires sur le graphe
- ▶ car
 - ▶ différents algorithmes conçus pour des graphes peuvent être **exprimés** dans le langage de l'algèbre linéaire
 - ▶ certains calculs peuvent aussi être réalisés **en reformulant** le problème du point de vue de l'algèbre linéaire

Composants du graphes

- ▶ `graph.components()` est basé sur une variante de **l'algorithme BFS**
- ▶ comme le graphe est représenté par une matrice éparsée, l'implémentation de l'algorithme peut être **vectorisée**
 - ▶ sans utiliser '['
 - ▶ mais en accédant directement aux slots de la structure de données (`A@i`, `A@p`)
 - ▶ et en utilisant `~` l'arithmétique des pointeurs
 - ▶ pour des raisons d'efficacité
- ▶ il peut aussi être exprimé dans **le langage de l'algèbre linéaire**
- ▶ et implémenté avec les opérations fournies par le package `Matrix`
- ▶ la version vectorisée est toutefois **un peu plus rapide**
 - effet du dispatch des classes S4 ?

Plus courts chemins

- ▶ l'algorithme BFS peut être exprimé de façon concise dans **le langage de l'algèbre linéaire**
- ▶ **Exemple** : calcul du plus court chemin :

```
1 sp.bfgs ← function(G, src=1){  
2   n      ← nrow(G)  
3   d      ← integer(n)  
4   d[src] ← 1  
5   u      ← d  
6   for (i in 1:n){  
7     u ← ( G %*% u ) & (d==0)  
8     idx ← as.vector(u!=0)  
9     if( all(idx==F)) break  
10    d[idx] ← i+1  
11  }  
12  d  
13 }
```

- ▶ le remplacement de **d** par une matrice permet de faire la recherche **sur tous les sommets**
- ▶ **limite** : SuiteSparse n'est pas parallélisée

- ▶ la décomposition en valeur propre peut servir à compter le nombre de chemins
- ▶ en effet,

$$\mathbf{A}^n \mathbf{X} = \lambda^n \mathbf{X}$$

- ▶ les valeurs propres peuvent donc aussi servir à calculer le nombre de triangles :

- ▶ nombre total de triangles

$$\begin{aligned}\Delta(\mathbf{A}) &= \frac{1}{6} \text{trace}(\mathbf{A}^3) \\ &= \frac{1}{6} \sum_i^n \lambda_i^3\end{aligned}$$

- ▶ nombre de triangles auxquels le sommet v_i participe

$$\Delta(\mathbf{A})_{v_i} = \frac{\sum_j^n \lambda_j^3 x_{ij}^2}{2}$$

- ▶ **autres exemples :**

- ▶ algorithme de Brandes pour la centralité d'intermédiarité
- ▶ algèbre tropical (produit min-max)
 - algorithme de Prim
- ▶ graphes de Kronecker
- ▶ ...

- ▶ l'utilité de l'application de l'algèbre linéaire aux graphes a conduit à **une normalisation** : graphBLAS

par analogie à BLAS

- ▶ **plusieurs implémentations** sont en cours de développement
 - dont une basée sur SuiteSparse

- centralité des valeurs propres :

$\lambda \mathbf{x} = \mathbf{A} \mathbf{x}$ (décomposition en valeur propre de $\mathbf{A}$)

$$\mathbf{x} = \lambda^{-1} \mathbf{A} \mathbf{x}$$

$$x_i = \frac{1}{\lambda} \sum_{j, j \neq i} a_{i,j} x_j$$

- la centralité d'un sommet x_i est donc proportionnelle **à la centralité de ses voisins immédiats**

autrement dit, les sommets les plus centraux sont ceux comptant le plus de voisins centraux eux aussi

- mais aussi **du nombre de ses voisins**
- cas particulier **de marche aléatoire** (*random walk*) sur un graphes

Marches aléatoires sur un graphe

- ▶ différentes mesures de centralité sont liées à la notion **de marche aléatoire sur un graphe**
- ▶ l'idée est de faire ressortir les sommets **les plus visités** si on parcourt le graphe **de façon aléatoire** mais pas nécessairement de façon uniforme
- ▶ les probabilités d'atteindre un sommet v_i sont données par **la matrice de transition**

- ▶ graphe non-dirigé

$$\mathbf{W} = \mathbf{D}^{-1} \mathbf{A} \text{ soit } p_{ij} = \frac{a_{ij}}{d_{v_i}} \quad (11)$$

- ▶ graphe dirigé

$$\mathbf{A} \mathbf{D}_{ex}^{-1} \text{ sortant} \quad (12)$$

$$\mathbf{D}_{in}^{-1} \mathbf{A} \text{ rentrant} \quad (13)$$

Marches aléatoires sur un graphe

- ▶ la probabilité d'atteindre la sommet v_i à **la k étape**

$$\mathbf{p}^{(k+1)} = \sum_i w_{ij} p_i(k) = \mathbf{W}_{\text{ex}} \mathbf{p}^{(k)} = \mathbf{W}_{\text{ex}}^{(k)} \mathbf{p}^{(1)} \quad (14)$$

- ▶ sous certaines conditions, la marche aléatoire **converge vers la distribution** :

$$\lim_{k \rightarrow \infty} \mathbf{W}_{\text{ex}} \mathbf{p}^{(ks)} = \pi \quad (15)$$

- ▶ π est donc **un vecteur propre** (correspondant à une valeur propre de 1)

car π satisfait la relation $\pi = \mathbf{W}\pi$

- ▶ **Problème** : certains sommets peuvent mener **nulle part**

- ▶ on a donc une division par 0 dans la matrice de transition

- ▶ **Exemple** : une page sans liens sortants

- ▶ **Solution** : la téléportation
- ▶ qui consiste à ajouter **une petite probabilité uniforme** d'accéder à n'importe quelle page

$$\pi = \alpha \frac{1}{n} \mathbf{1} \mathbf{1}^\top + (1 - \alpha) \mathbf{W}_{ex} \pi \quad (16)$$

- ▶ en calculant **le premier vecteur propre** de (16)
- ▶ on obtient alors le fameux **vecteur PageRank**
- ▶ **Note** : pour les matrices de grande taille, on peut calculer directement le vecteur en reformulant (16)

Le laplacien du graphe

- ▶ dans les deux cas précédents, on calcule **le premier vecteur propre** de la matrice d'adjacence du graphe (**ou d'une transformation**)
- ▶ c'est aussi le cas pour **le laplacien du graphe**

cf. ACP

- ▶ mais sans forcément **se limiter au premier vecteur**

où plutôt le deuxième (vecteur de Fiedler)

Le laplacien du graphe

- ▶ le laplacien a pour **forme** :

$$\mathbf{L} = \mathbf{D} - \mathbf{A} \text{ avec } l_{ij} = \begin{cases} d_{v_i} & \text{si } i = j \\ -a_{ij} & \text{si } i \neq j \end{cases} \quad (17)$$

où $\mathbf{D}$ est une matrice avec les degrés d_i des sommets v_i dans la diagonale

- ▶ **variante normalisée** :

$$\mathbf{L}_{\text{norm}} = \mathbf{D}^{-\frac{1}{2}} \mathbf{L} \mathbf{D}^{-\frac{1}{2}} = \mathbf{I} - \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} \quad (18)$$

avec

$$l_{ij} = \begin{cases} 1 & \text{si } i = j \\ -\frac{a_{ij}}{\sqrt{d_{v_i}} \sqrt{d_{v_j}}} & \text{si } i \neq j \end{cases}$$

- forme quadratique du laplacien :

$$\mathbf{x}^\top \mathbf{L} \mathbf{x} = \frac{1}{2} \sum_{i,j}^n a_{ij} (f_i - f_j)^2$$
$$\geq 0$$

Exemple : graphe régulier

$$\mathbf{x}^\top \mathbf{L} \mathbf{x} = (x_1 x_2) \begin{pmatrix} 1 & -1 \\ -1 & 1 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = (x_1 - x_2)^2$$

Note : dans ce cas, $\mathbf{x} = \left(\frac{1}{\sqrt{2}} \quad -\frac{1}{\sqrt{2}}\right)^\top$ est un vecteur propre de $\mathbf{L}$ et a 2 pour valeur propre

De plus, $[\mathbf{L}\mathbf{x}]_i = d_{v_i} * (x_i - \text{la moyenne des } x \text{ des voisins de } i)$

- forme quadratique du laplacien normalisé :

$$\mathbf{x}^\top \mathbf{L}_{\text{norm}} \mathbf{x} = \frac{1}{2} \sum_{i,j}^n a_{ij} \left(\frac{f_i}{\sqrt{d_{v_i}}} - \frac{f_j}{\sqrt{d_{v_j}}} \right)^2$$
$$\geq 0$$

Le laplacien du graphe

De plus,

- ▶ $\mathbf{L}$ et $\mathbf{L}_{\text{norm}}$ sont des matrices **définies positives** si $a_{ij} \geq 0$
- ▶ la plus petite valeur propre de $\mathbf{L}$ **vaut 0** et elle a $\mathbf{x} = \mathbf{1}$ **pour vecteur propre**
pour $\mathbf{L}_{\text{norm}}$, $\mathbf{x} = \mathbf{D}^{1/2}\mathbf{1}$
- ▶ $\mathbf{L}$ et $\mathbf{L}_{\text{norm}}$ ont **n valeurs propres** réelles et non négatives :
 $0 = \lambda_1 < \lambda_2, \dots, \lambda_n$
- ▶ les valeurs propres sont comprises entre **0 et 2**
- ▶ la multiplicité du zéro donne le nombre **le nombre de composants**

- ▶ l'analyse du laplacien peut être vu comme **un problème de découpage de graphe**
- ▶ on souhaite **répartir les sommets dans K partitions** $A_1, \dots, A_k, \dots, A_K$ homogènes de façon à ce que

- ▶ les arêtes entre groupes ont un poids faible
- ▶ les arêtes à l'intérieur des groupes ont un poids forts

cf. variance intra-extra

- ▶ **la coupe** (*cut*) du graphe a pour expression

$$cut(A_i, \bar{A}_i) = \sum_{v_i \in A_i, v_j \in \bar{A}_i} a_{ij}$$

- ▶ deux critères d'homogénéité :

- ▶ *Ratio cut* :

$$RCut(A_1, \dots, A_K) = \frac{1}{2} \sum_{k=1}^K \frac{cut(A_i, \bar{A}_i)}{|A_i|} \quad (19)$$

- ▶ *Normalized cut* :

$$Ncut(A_1, \dots, A_K) = \sum_{k=1}^K \frac{cut(A_i, \bar{A}_i)}{vol(A_i)} \quad (20)$$

$$\text{avec } vol(A_i) = \sum_{v_i \in A_i} d_i$$

- ▶ le laplacien et le laplacien normalisé sont respectivement **la solution de (19) et (20)**

Marche aléatoire sur le graphe

- ▶ marche aléatoire sur le graphe :

$$\mathbf{W} = \mathbf{A}\mathbf{D}^{-1} \quad (21)$$

- ▶ le laplacien normalisé **est lié** à une marche aléatoire sur le graphe par

$$\mathbf{L}_{rw} = \mathbf{D}^{-1/2}\mathbf{W}\mathbf{D}^{1/2} \quad (22)$$

$$= \mathbf{D}^{-1/2}\mathbf{A}\mathbf{D}^{-1/2} \quad (23)$$

$$= \mathbf{I} - \mathbf{L}_{\text{norm}} \quad (24)$$

- ▶ $\mathbf{L}_{rw}$ et $\mathbf{L}_{rw}$ ont (presque) **les mêmes valeurs propres** $\lambda_i^{rw} = 1 - \lambda_i^{norm}$

toutefois, on a $1 = \lambda_1^{rw} > \dots > \lambda_n^{rw}$

- ▶ et leurs vecteurs propres **sont identiques**

Classification spectrale de graphe

En pratique, **la classification spectrale** consiste à :

1. transformer la matrice d'adjacence **A**
avec (18), (18) ou (24)
2. calculer les k plus grandes|petites valeurs propres et vecteurs correspondants **X**
3. réaliser une classification sur les **X**
comme *k-means*

Application






FIGURE 5 – 200 premières valeurs propres de L_{rw}

Premier vecteur propre




2 - 3



2

3 - 4



3


- ▶ comme souvent, la classification spectrale fonctionne bien sur des partitions **clairement séparées**
- ▶ ce qui n'est pas forcément le cas en pratique
 - ce qui se manifeste par l'hétérogénéité des degrés des sommets
- ▶ alternative **pour tempérer** l'effet de l'hétérogénéité, **le laplacien régularisé** :

$$\mathbf{L}_\tau = \mathbf{D}_\tau^{-1/2} \mathbf{W} \mathbf{D}_\tau^{1/2} \quad (25)$$


avec $\mathbf{D}_\tau = \mathbf{D} + \tau \mathbf{I}$

- ▶ τ peut prendre **différentes valeurs**

$\tau = \bar{d}_v$ marche bien en théorie et en pratique



4 - 5



Conclusion

- ▶ **l'analyse spectrale** du laplacien du graphe est une méthode performante pour dégager **des sous-ensembles cohésifs**
- ▶ mais elle est notamment sensible à **l'hétérogénéité de la distribution** des degrés des sommets
- ▶ la régularisation permet toutefois **d'en tempérer les effets**
- ▶ plus généralement, l'algèbre linéaire offre **de nombreuses possibilités** pour :
 - ▶ le stockage
 - ▶ la manipulation
 - ▶ l'analyse
- ▶ **de grands graphes**

Merci pour votre attention

Bibliographie

- CONTAMIN, Jean-Gabriel, Thomas LÉONARD et Thomas SOUBIRAN (2017), « Les transformations des comportements politiques au prisme de l'e-pétitionnement. Potentialités et limites d'un dispositif d'étude pluridisciplinaire ». *Réseaux*, 204, 4, p. 97–131.
- KEPNER, Jeremy et John GILBERT, eds. (2011), *Graph Algorithms in the Language of Linear Algebra*. SIAM. 375 p.
- LUXBURG, Ulrike von (2007), « A tutorial on spectral clustering ». *Statistics and Computing*, 17, p. 395–416.
- QIN, Tai et Karl ROHE (2013), « Regularized Spectral Clustering under the Degree-Corrected Stochastic Blockmodel ». *arXiv e-prints*. arXiv :1309.4111.