

Partition en graphes denses pour la détection de communautés

Julien Darlay

jdarlay@bouygues.com

Nadia Brauner (G-SCOP) - Julien Moncel (LAAS)

Équipe de R&D du groupe Bouygues (12 permanents, 5 docteurs)

- Nouvelles technologies
- Optimisation

Des applications dans tous les métiers

- Media planning TF1
- Planning de personnels Bouygues Télécom
- Dimensionnement de parking Bouygues Immobilier
- Plannification de chantiers Bouygues Construction



20% de notre temps dédié à la recherche

Détection de pneumopathies interstitielles diffuses pour l'hôpital Avicenne

Id	diag	fatigue	chirurgie	douleur	antéc	âge
1	neg	0	1	0	0	76
2	neg	0	1	1	0	45
3	pos	1	0	1	1	61
4	pos	1	1	1	0	75

- Générer des “motifs” à partir d'un historique médical
 - ▶ *fatigue* \Rightarrow *positif*
 - ▶ *age* $>$ 50 \wedge *douleur* \Rightarrow *positif*
 - ▶ *chirurgie* \wedge *antecedent* \Rightarrow *negatif*
 - ▶ *douleur* \Rightarrow *negatif*
- Logical Analysis of Data [Boros et al.]

Méthode LAD

- Génération de plusieurs milliers de motifs
- Sélection d'un ensemble minimal de motifs (modèle)
- Évaluation du modèle


PARTITION DE GRAPHES POUR LE DIAGNOSTIC MÉDICAL

Méthode LAD

- Génération de plusieurs milliers de motifs
- Sélection d'un ensemble minimal de motifs (modèle)
- Évaluation du modèle

Nombreux motifs synonymes : nécessité de les regrouper

- Sommet : motif
- Arête entre deux motifs "similaires"




PARTITION DE GRAPHES POUR LE DIAGNOSTIC MÉDICAL

Méthode LAD

- Génération de plusieurs milliers de motifs
- Sélection d'un ensemble minimal de motifs (modèle)
- Évaluation du modèle

Nombreux motifs synonymes : nécessité de les regrouper

- Sommet : motif
- Arête entre deux motifs "similaires"




PARTITION DE GRAPHES POUR LE DIAGNOSTIC MÉDICAL

Méthode LAD

- Génération de plusieurs milliers de motifs
- Sélection d'un ensemble minimal de motifs (modèle)
- Évaluation du modèle

Nombreux motifs synonymes : nécessité de les regrouper

- Sommet : motif
- Arête entre deux motifs "similaires"




DÉFINITIONS

On considère

- $G = (V, E)$ un graphe simple
- Π l'ensemble des partitions de V
- $f : \Pi \rightarrow \mathbb{R}$ une fonction d'évaluation d'une partition de V

On cherche une solution du problème de partition $\max_{\mathcal{P} \in \Pi} f(\mathcal{P})$



Littérature

- coupe minimum [Newman 04]
- méthode spectrale [Biggs 93]
- Modularité [Newman, Girvan 04]
- regroupement hiérarchique [Clauset 08]

Littérature

- coupe minimum [Newman 04]
- méthode spectrale [Biggs 93]
- Modularité [Newman, Girvan 04]
- regroupement hiérarchique [Clauset 08]

Applications

- réseaux sociaux [Ugander 11]
- traitement d'images
- maillage de structures
- conception de circuits

Littérature

- coupe minimum [Newman 04]
- méthode spectrale [Biggs 93]
- Modularité [Newman, Girvan 04]
- regroupement hiérarchique [Clauset 08]

Applications

- réseaux sociaux [Ugander 11]
- traitement d'images
- maillage de structures
- conception de circuits

No free lunch theorem [Kleinberg 02]

Densité d'un graphe

La **densité** d'un graphe $G = (V, E)$ [Goldberg 84]

$$d(G) = \frac{|E|}{|V|}$$

Densité d'un graphe

La **densité** d'un graphe $G = (V, E)$ [Goldberg 84]

$$d(G) = \frac{|E|}{\binom{|V|}{2}}$$

- Un graphe dense est “presque” une clique
- Trouver un sous graphe de densité max. est polynomial [Goldberg 84]
- Lorsque la taille est fixée : NP-Difficile [Charikar 00]
- Nombreux algorithmes d'approximation [Billionnet, Roupin 2004]

La **densité** d'une partition \mathcal{P} des sommets d'un graphe G

$$d_G(\mathcal{P}) = \sum_{X \in \mathcal{P}} d(G[X])$$

Nos résultats [D., Brauner, Moncel 12]

- Trouver une partition de densité maximum est **NP-Difficile**
- Le problème ne semble pas approximable
- **Polynomial** sur les arbres

UN PROBLÈME NP-DIFFICILE

Réduction depuis k -COLORATION

- Étude du problème dans le complémentaire \overline{G}

$$d_G(\mathcal{P}) = \frac{|V|}{2} - \left\{ \frac{|\mathcal{P}|}{2} + d_{\overline{G}}(\mathcal{P}) \right\}$$

UN PROBLÈME NP-DIFFICILE

Réduction depuis k -COLORATION

- Étude du problème dans le complémentaire \overline{G}

$$\min_{\mathcal{P}} f(\mathcal{P}) = \left\{ \frac{|\mathcal{P}|}{2} + d_{\overline{G}}(\mathcal{P}) \right\}$$


UN PROBLÈME NP-DIFFICILE

Réduction depuis k -COLORATION

- Étude du problème dans le complémentaire \overline{G}

$$\min_{\mathcal{P}} f(\mathcal{P}) = \left\{ \frac{|\mathcal{P}|}{2} + d_{\overline{G}}(\mathcal{P}) \right\}$$

- Transformer \overline{G} en \overline{G}^q




UN PROBLÈME NP-DIFFICILE

Réduction depuis k -COLORATION

- Étude du problème dans le complémentaire \overline{G}

$$\min_{\mathcal{P}} f(\mathcal{P}) = \left\{ \frac{|\mathcal{P}|}{2} + d_{\overline{G}}(\mathcal{P}) \right\}$$

- Transformer \overline{G} en \overline{G}^q



- k coloration de $\overline{G} \Rightarrow k$ coloration de $\overline{G}^q \Rightarrow f(\mathcal{P}^*) \leq \frac{k}{2}$

UN PROBLÈME NP-DIFFICILE

$$\min_{\mathcal{P}} f(\mathcal{P}) = \left\{ \frac{|\mathcal{P}|}{2} + d_{\overline{G}}(\mathcal{P}) \right\}$$

- Soit \mathcal{P}^* la partition optimale de \overline{G}^q telle que $f(\mathcal{P}^*) \leq \frac{k}{2}$

UN PROBLÈME NP-DIFFICILE

$$\min_{\mathcal{P}} f(\mathcal{P}) = \left\{ \frac{|\mathcal{P}|}{2} + d_{\overline{G}}(\mathcal{P}) \right\}$$

- Soit \mathcal{P}^* la partition optimale de \overline{G}^q telle que $f(\mathcal{P}^*) \leq \frac{k}{2}$
- Soit u un sommet de \overline{G} et $u^1 \dots u^q$ les sommets de \overline{G}^q




UN PROBLÈME NP-DIFFICILE

$$\min_{\mathcal{P}} f(\mathcal{P}) = \left\{ \frac{|\mathcal{P}|}{2} + d_{\overline{G}}(\mathcal{P}) \right\}$$

- Soit \mathcal{P}^* la partition **optimale** de \overline{G}^q telle que $f(\mathcal{P}^*) \leq \frac{k}{2}$
- Soit u un sommet de \overline{G} et $u^1 \dots u^q$ les sommets de \overline{G}^q



- C_u la classe **majoritaire** de $u^1 \dots u^q$ dans \mathcal{P}^*




UN PROBLÈME NP-DIFFICILE

$$\min_{\mathcal{P}} f(\mathcal{P}) = \left\{ \frac{|\mathcal{P}|}{2} + d_{\overline{G}}(\mathcal{P}) \right\}$$

- Soit \mathcal{P}^* la partition **optimale** de \overline{G}^q telle que $f(\mathcal{P}^*) \leq \frac{k}{2}$
- Soit u un sommet de \overline{G} et $u^1 \dots u^q$ les sommets de \overline{G}^q



- C_u la classe **majoritaire** de $u^1 \dots u^q$ dans \mathcal{P}^*




- Si $q = |V|^4$ et (u, v) une arête de $\overline{G} \Rightarrow C_u \neq C_v$ (comptage)


UN PROBLÈME NP-DIFFICILE

$$\min_{\mathcal{P}} f(\mathcal{P}) = \left\{ \frac{|\mathcal{P}|}{2} + d_{\overline{G}}(\mathcal{P}) \right\}$$

- Soit \mathcal{P}^* la partition **optimale** de \overline{G}^q telle que $f(\mathcal{P}^*) \leq \frac{k}{2}$
- Soit u un sommet de \overline{G} et $u^1 \dots u^q$ les sommets de \overline{G}^q



- C_u la classe **majoritaire** de $u^1 \dots u^q$ dans \mathcal{P}^*




- Si $q = |V|^4$ et (u, v) une arête de $\overline{G} \Rightarrow C_u \neq C_v$ (comptage)
- Coloration de \overline{G} en k couleurs avec les C_u

Contexte

- $T = (V, E)$ un arbre
- Trouver une partition \mathcal{P} qui maximise $d(\mathcal{P})$

Méthode

- Structure de la solution optimale
- Algorithme de construction




LE CAS DES ARBRES

Premières observations

$T = (V, E)$ un arbre et \mathcal{P}^* une partition optimale de T

- Densité d'un arbre est $\frac{n-1}{n}$




LE CAS DES ARBRES

Premières observations

$T = (V, E)$ un arbre et \mathcal{P}^* une partition optimale de T

- Densité d'un arbre est $\frac{n-1}{n}$
- Chaque classe contient au moins deux sommets




LE CAS DES ARBRES

Premières observations

$T = (V, E)$ un arbre et \mathcal{P}^* une partition optimale de T

- Densité d'un arbre est $\frac{n-1}{n}$
- Chaque classe contient au moins deux sommets
- Le sous graphe induit par une classe est connexe




LE CAS DES ARBRES

Premières observations

$T = (V, E)$ un arbre et \mathcal{P}^* une partition optimale de T

- Densité d'un arbre est $\frac{n-1}{n}$
- Chaque classe contient au moins **deux sommets**
- Le sous graphe induit par une classe est **connexe**
- La densité d'une classe est dans $[\frac{1}{2}; 1[$



LE CAS DES ARBRES

Caractérisation des solutions optimales

Propriété

Chaque classe d'une partition optimale est une **étoile** non triviale

Propriété

Chaque classe d'une partition optimale est une **étoile** non triviale




$$d(G[X]) < 1$$

Propriété

Chaque classe d'une partition optimale est une **étoile** non triviale



$$d(G[X]) < 1$$



$$d(G[X_1]) + d(G[X_2]) \geq \frac{1}{2} + \frac{1}{2} = 1$$

LE CAS DES ARBRES

Lien avec les couplages

Propriété

Soit \mathcal{M}^* un couplage maximum et \mathcal{P}^* une partition de densité maximale
alors $|\mathcal{M}^*| = |\mathcal{P}^*|$

Démonstration

Propriété

Soit \mathcal{M}^* un couplage maximum et \mathcal{P}^* une partition de densité maximale alors $|\mathcal{M}^*| = |\mathcal{P}^*|$

Démonstration

- En prenant une arête dans chaque classe : $|\mathcal{P}^*| = |\mathcal{M}| \leq |\mathcal{M}^*|$

Propriété

Soit \mathcal{M}^* un couplage maximum et \mathcal{P}^* une partition de densité maximale alors $|\mathcal{M}^*| = |\mathcal{P}^*|$

Démonstration


- En prenant une arête dans chaque classe : $|\mathcal{P}^*| = |\mathcal{M}| \leq |\mathcal{M}^*|$
- Si $|\mathcal{M}| < |\mathcal{M}^*|$, il existe une chaîne augmentante [[Petersen 1891](#)]

Propriété

Soit \mathcal{M}^* un couplage maximum et \mathcal{P}^* une partition de densité maximale alors $|\mathcal{M}^*| = |\mathcal{P}^*|$

Démonstration

- En prenant une arête dans chaque classe : $|\mathcal{P}^*| = |\mathcal{M}| \leq |\mathcal{M}^*|$
- Si $|\mathcal{M}| < |\mathcal{M}^*|$, il existe une chaîne augmentante [[Petersen 1891](#)]




Propriété

Soit \mathcal{M}^* un couplage maximum et \mathcal{P}^* une partition de densité maximale alors $|\mathcal{M}^*| = |\mathcal{P}^*|$

Démonstration

- En prenant une arête dans chaque classe : $|\mathcal{P}^*| = |\mathcal{M}| \leq |\mathcal{M}^*|$
- Si $|\mathcal{M}| < |\mathcal{M}^*|$, il existe une chaîne augmentante [[Petersen 1891](#)]



Propriété

Soit \mathcal{T}^* un transversal minimum et \mathcal{P}^* une partition de densité maximale alors les sommets de \mathcal{T}^* sont les centres des étoiles de \mathcal{P}^*

Démonstration


- Par le théorème de [\[König 31\]](#), si \mathcal{T}^* est un transversal minimum :
 $|\mathcal{T}^*| = |\mathcal{M}^*| = |\mathcal{P}^*|$

Propriété

Soit \mathcal{T}^* un transversal minimum et \mathcal{P}^* une partition de densité maximale alors les sommets de \mathcal{T}^* sont les centres des étoiles de \mathcal{P}^*

Démonstration

- Par le théorème de [König 31], si \mathcal{T}^* est un transversal minimum :
 $|\mathcal{T}^*| = |\mathcal{M}^*| = |\mathcal{P}^*|$
- Si deux sommets de \mathcal{T}^* sont dans la même classe alors il existe une classe X sans sommet de \mathcal{T}^*




LE CAS DES ARBRES

Algorithme de partition

Programmation dynamique

- Enraciner l'arbre




LE CAS DES ARBRES

Algorithme de partition

Programmation dynamique

- Enraciner l'arbre
- Calculer la partition optimale de chaque sous-arbre




LE CAS DES ARBRES

Algorithme de partition

Programmation dynamique

- Enraciner l'arbre
- Calculer la partition optimale de chaque sous-arbre
- Calculer un **transversal** minimum




LE CAS DES ARBRES

Algorithme de partition

Programmation dynamique

- Enraciner l'arbre
- Calculer la partition optimale de chaque sous-arbre
- Calculer un **transversal** minimum
 - ① La racine n'est pas dans le transversal




LE CAS DES ARBRES

Algorithme de partition

Programmation dynamique

- Enraciner l'arbre
- Calculer la partition optimale de chaque sous-arbre
- Calculer un **transversal** minimum
 - ① La racine n'est pas dans le transversal




LE CAS DES ARBRES

Algorithme de partition

Programmation dynamique

- Enraciner l'arbre
- Calculer la partition optimale de chaque sous-arbre
- Calculer un **transversal** minimum
 - ① La racine n'est pas dans le transversal




LE CAS DES ARBRES

Algorithme de partition

Programmation dynamique

- Enraciner l'arbre
- Calculer la partition optimale de chaque sous-arbre
- Calculer un **transversal** minimum
 - ① La racine n'est pas dans le transversal




LE CAS DES ARBRES

Algorithme de partition

Programmation dynamique

- Enraciner l'arbre
- Calculer la partition optimale de chaque sous-arbre
- Calculer un **transversal** minimum
 - ① La racine n'est pas dans le transversal




LE CAS DES ARBRES

Algorithme de partition

Programmation dynamique

- Enraciner l'arbre
- Calculer la partition optimale de chaque sous-arbre
- Calculer un **transversal** minimum
 - 1 La racine n'est pas dans le transversal
 - 2 La racine est dans le transversal




LE CAS DES ARBRES

Algorithme de partition

Programmation dynamique

- Enraciner l'arbre
- Calculer la partition optimale de chaque sous-arbre
- Calculer un **transversal** minimum
 - 1 La racine n'est pas dans le transversal
 - 2 La racine est dans le transversal




LE CAS DES ARBRES

Algorithme de partition

Programmation dynamique

- Enraciner l'arbre
- Calculer la partition optimale de chaque sous-arbre
- Calculer un **transversal** minimum
 - 1 La racine n'est pas dans le transversal
 - 2 La racine est dans le transversal



LE CAS DES ARBRES

Complexité de l'algorithme

Quelques remarques

- À chaque étape
 - ▶ Calcul **dynamique** du transversal $O(d)$
 - ▶ Affectation de la racine en $O(d)$ ou $O(d \log(d))$
- Les sommets sont parcourus une seule et unique fois

Complexité en $O(n \log n)$

ÉVALUATION EMPIRIQUE DU CRITÈRE

Partition en sous-graphes denses

- NP-Difficile en général
- Polynomial sur les arbres
- Évaluation du critère sur les instances de la littérature ?

Résolution pratique

- Moteur [LocalSolver](#)
- Échanges locaux entre les classes
- *First improve* + Recuit simulé

Différentes instances

- Arbres
- Littérature

Solver de programmation mathématique basé sur la recherche locale

- Trouve de bonnes solutions en quelques minutes
- Pour des problèmes de grandes tailles
- Fortement combinatoires et non linéaires

Model & run

- Approche déclarative
- Dans un langage de modélisation innovant
- Ou via des API C++, Java, .NET


$$\max_{\mathcal{P} \in \Pi} \sum_{X \in \mathcal{P}} \frac{|E(G[X])|}{|X|}$$

```
x[1..n][1..C] <- bool();
for[i in 1..n]{
  constraint sum[j in 1..C] (x[i][j]) == 1;
}

for[c in 1..C]{
  card[c] <- max(1.0, sum[i in 1..n] (x[i][c]));
  edges[c] <- sum[i in 1..m] (x[origin[i]][c] * x[dest[i]][c]);
}

obj <- sum[c in 1..C] ((edges[c]) / (card[c]));
maximize obj;
```


EXPÉRIMENTATIONS SUR LES ARBRES



Instance	n	t	Opt	LocalSolver 3.1
zachary_tree	34	10s	6.6213	6.6213
dolphins_tree	62	10s	14.3633	14.3633
polbooks_tree	105	60s	23.8033	23.75334
football_tree	115	60s	27.3217	27.1217
netscience_tree	1589	5min	335.0197	328.0876

TABLE: Moyenne des densités trouvées sur 10 instances

EXPÉRIMENTATIONS SUR LES DONNÉES DE LA LITTÉRATURE



Instance	n	m	$ C $	$ C_Q^* $	Δ
zachary	34	78	10	4	0%
dolphins	62	159	20	5	25%
polbooks	105	254	32	5	10%
football	115	613	22	10	1%
netscience	1589	914	517	407*	16%
as-22july06	22963	48436	45*	-	-

TABLE: Solution après 5 minutes de calcul vs Modularité

CONCLUSION

Recherche locale avec LocalSolver :

- Performante sur les arbres
- Modèle quadratique : limite à 1000 sommets

Critère de partition :

- NP-difficile en général
- Tendence à créer beaucoup de classes
- Propose des solutions différentes de la modularité