Extraction de motifs pour la détection d'anomalies dans des graphes

Application à la fraude dans les marchés publics

Lucas Potin[1] Rosa Figueiredo[1] Vincent Labatut[1]
Christine Largeron[2]

[1]Laboratoire Informatique d'Avignon – LIA EA 4128
{prénom.nom}@univ-avignon.fr

[2]Laboratoire Hubert Curien – LabHC UMR 5516
christine.largeron@univ-st-etienne.fr

19/01/2023

Contexte applicatif : les marchés publics

Marché public

Contrat conclu à titre onéreux par un ou plusieurs acheteurs publics avec un ou plusieurs opérateurs économiques. [1]

État des lieux en France

- 169 060 marchés en 2020, pour plus de **110 milliards** d'euros.
- Données disponibles au niveau Européen via le Tenders Electronic Daily (**TED**) [2].
- Notice : informations **relationnelles** et **attributaires** :
  - Marché demandé par un ou plusieurs clients
  - Marché réalisé par un ou plusieurs fournisseurs
  - Attributs sur le marché (prix, nombre d'offres, etc.).

1. https://www.economie.gouv.fr/entreprises/definition-marche-public
2. https://ted.europa.eu/

Contexte applicatif : les marchés publics

Marché public

Contrat conclu à titre onéreux par un ou plusieurs acheteurs publics avec un ou plusieurs opérateurs économiques. [1]

État des lieux en France

- 169 060 marchés en 2020, pour plus de **110 milliards** d'euros.
- Données disponibles au niveau Européen via le Tenders Electronic Daily (**TED**) [2].
- Notice : informations **relationnelles** et **attributaires** :
  - Marché demandé par un ou plusieurs clients
  - Marché réalisé par un ou plusieurs fournisseurs
  - Attributs sur le marché (prix, nombre d'offres, etc.).

1. https://www.economie.gouv.fr/entreprises/definition-marche-public
2. https://ted.europa.eu/

Détection de marchés frauduleux

- Principale difficulté : pas de vérité terrain.
- Approche classique : passer par des **red flags** [MRM21]. Données uniquement attributaires [Nat16].
- Amélioration des liens entre les acteurs [Pot+22]. Exploitation possible via l'utilisation des graphes.
- **Notre Objectif** : proposer une méthode utilisant les relations entre les acteurs
- Peut-on utiliser l'information **relationnelle** pour identifier des marchés frauduleux en l'absence de red flags ?

Notre approche

Données

Soit une collection $\mathcal{G}$ de graphes attribués $G(V, E, \mathbf{X}, \mathbf{Y}, L)$ composés d'un ensemble de sommets V, un ensemble de liens E, une matrice d'attributs de sommets $\mathbf{X}$, une matrice d'attributs de liens $\mathbf{Y}$ et un label du graphe L qui peut être `Anormal` ou `Normal` en fonction des red flags.

Objectif

Prédire les labels inconnus pour les graphes sans label.

Idée principale

Représenter les graphes en fonction de leurs sous-graphes : **motifs**.

Motif discriminant

Certains motifs figurent principalement dans une des deux classes de graphes, tandis que d'autres sont génériques.

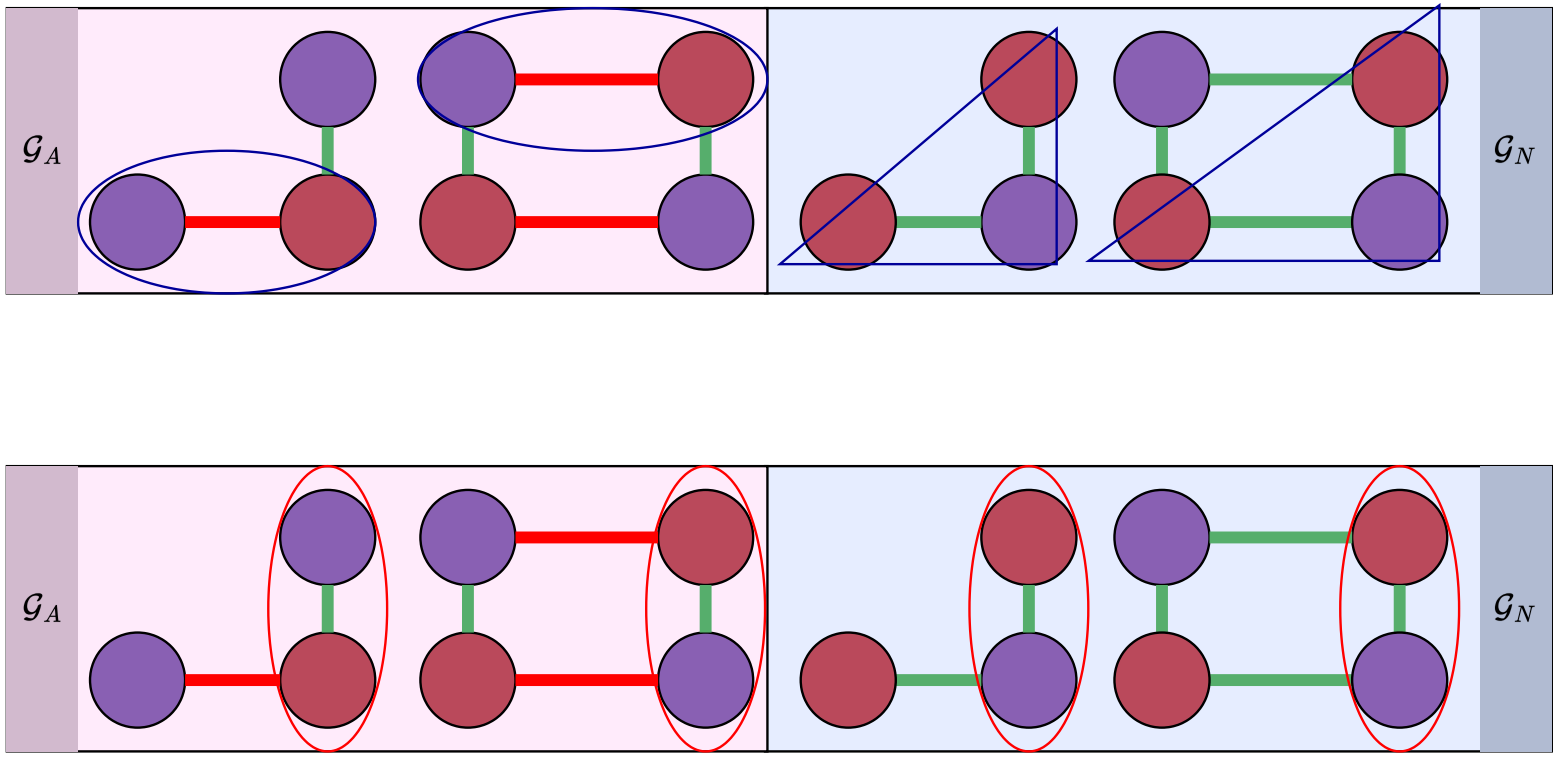

Motif discriminant

Definition (Fréquence d'un motif)

Soit $\mathcal{G}$ un ensemble de graphes attribués. La fréquence $freq(P, \mathcal{G})$ d'un motif P dans $\mathcal{G}$ est le nombre de graphes dans $\mathcal{G}$ contenant P : $freq(P, \mathcal{G}) = |\{G \in \mathcal{G} : \exists P' \subset G \text{ t.q. } P \cong P'\}|$.

Definition (Score discriminant)

Étant donné un motif P de $\mathcal{G}$, le score discriminant de P est défini par $dis(P) = |freq(P, \mathcal{G}_A) - freq(P, \mathcal{G}_N)|$.

Motif discriminant

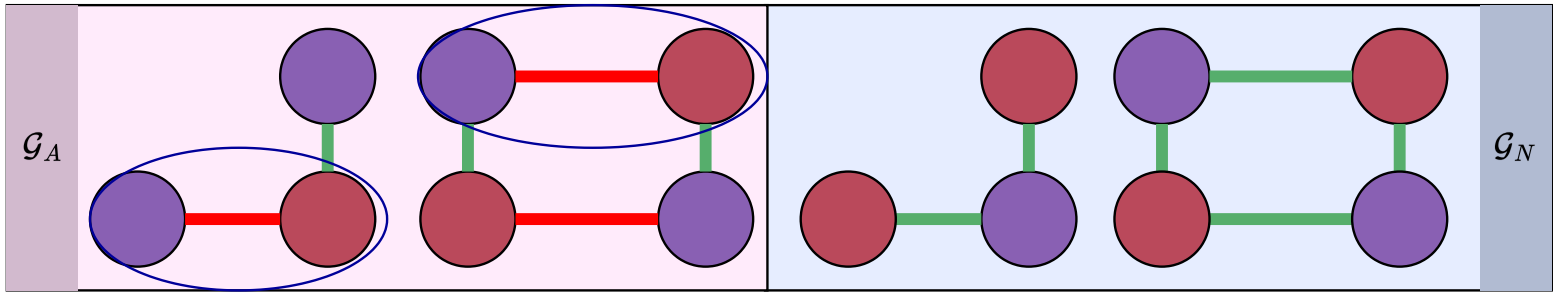

Definition (Score discriminant)

Étant donné un motif P de $\mathcal{G}$, le score discriminant de P est défini par $dis(P) = |freq(P, \mathcal{G}_A) - freq(P, \mathcal{G}_N)|$.

$$dis(P) = |2 - 0| = 2$$

Motif discriminant

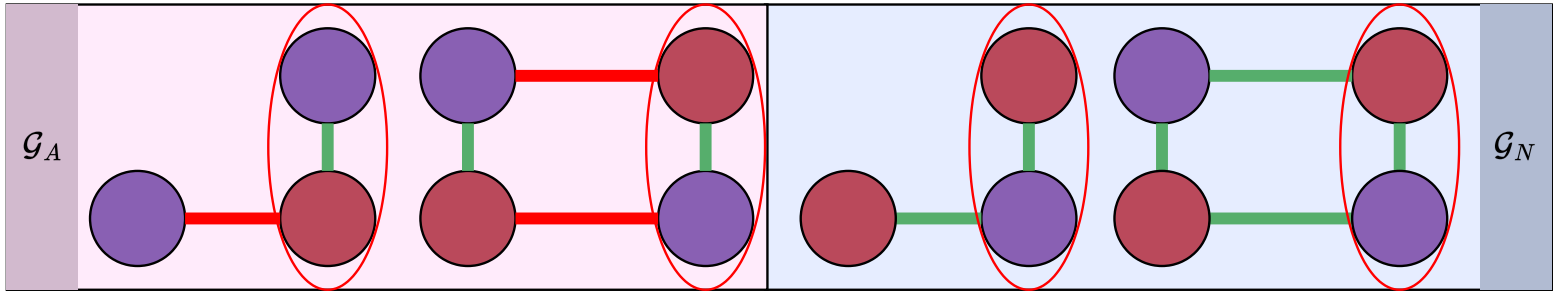

Definition (Score discriminant)

Étant donné un motif P de $\mathcal{G}$, le score discriminant de P est défini par $dis(P) = |freq(P, \mathcal{G}_A) - freq(P, \mathcal{G}_N)|$.

$$dis(P) = |2 - 2| = 0$$

Méthode PANG

- Identification d'un ensemble de motifs discriminants $\mathcal{P}_s$
- Représentation vectorielle
- Utilisation de méthodes usuelles supervisées pour classer les vecteurs obtenus.

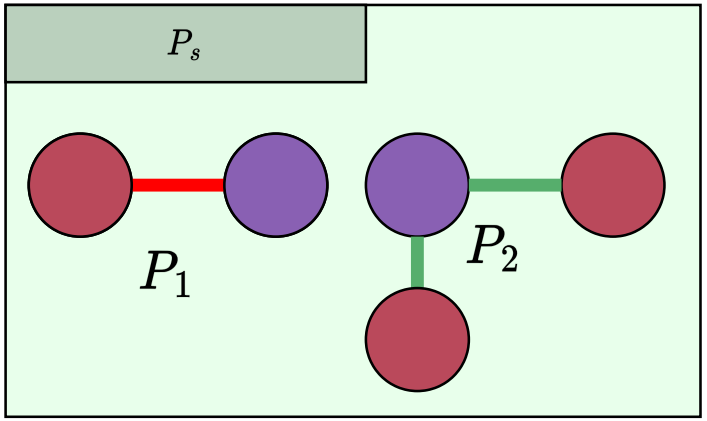

Méthode PANG

- Identification d'un ensemble de motifs discriminants $\mathcal{P}_s$
- Représentation vectorielle
- Utilisation de méthodes usuelles supervisées pour classer les vecteurs obtenus.

Représentation vectorielle

Soit G un graphe attribué et $\mathcal{P}_s = \{P_i\}$ un ensemble de s motifs discriminants choisis.
On note $\mathbf{h}$ la représentation vectorielle de G avec $h_i = 1$ si P_i est présent dans G, 0 sinon.

Méthode PANG

- Identification d'un ensemble de motifs discriminants $\mathcal{P}_s$
- Représentation vectorielle
- Utilisation de méthodes usuelles supervisées pour classer les vecteurs obtenus.

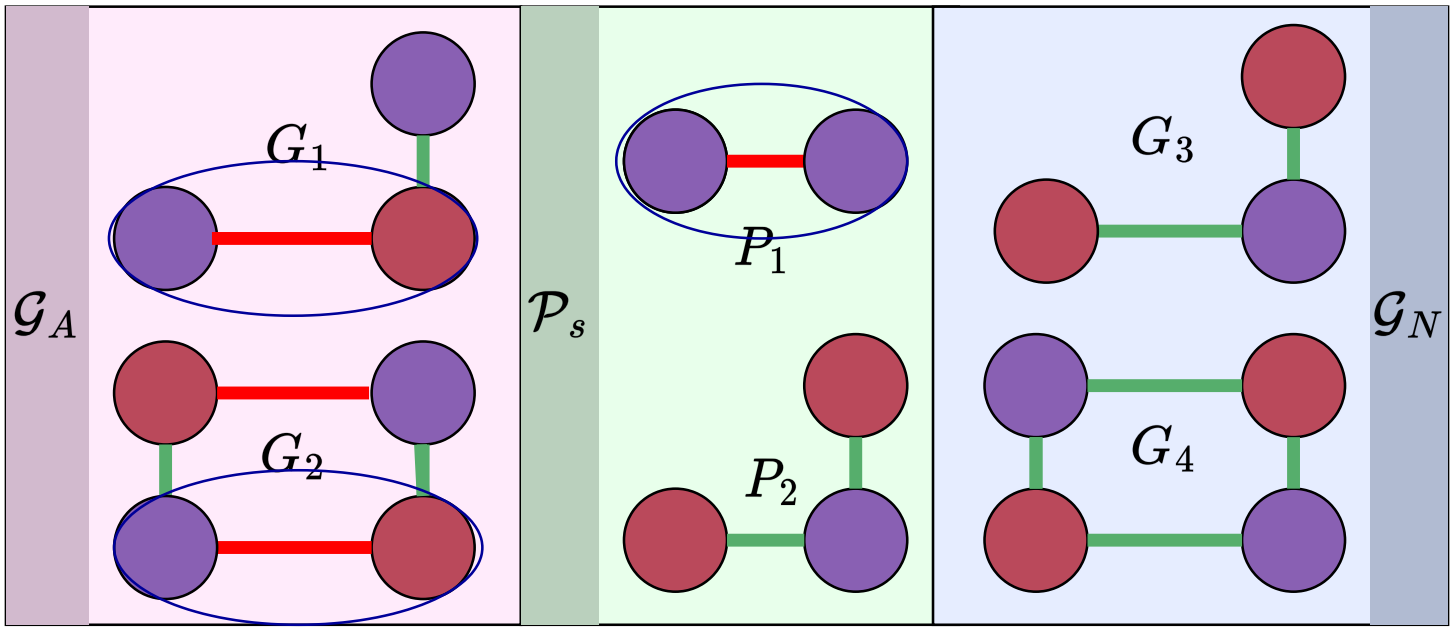

$h_1 = (1, 0)$ $h_2 = (1, 0)$ $h_3 = (0, 1)$ $h_4 = (0, 1)$

Méthode PANG

- Identification d'un ensemble de motifs discriminants $\mathcal{P}_s$
- Représentation vectorielle
- Utilisation de méthodes usuelles supervisées pour classer les vecteurs obtenus.

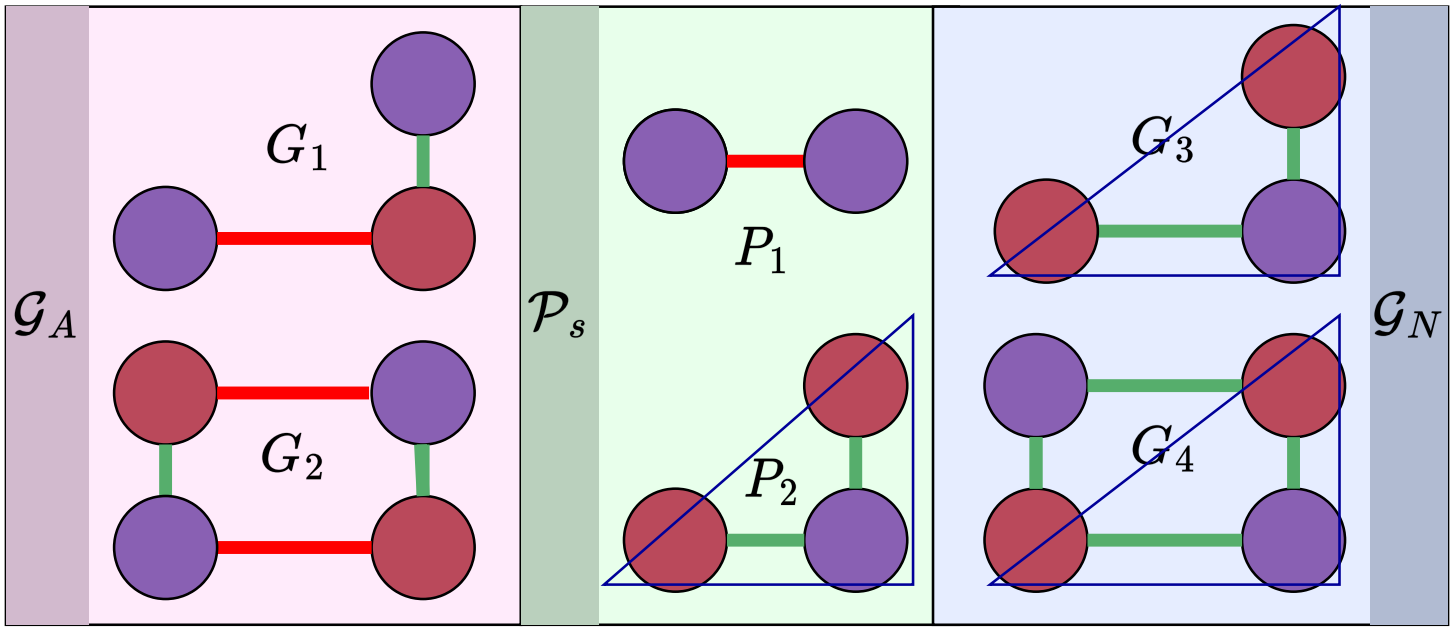

$h_1 = (1, 0)$ $h_2 = (1, 0)$ $h_3 = (0, 1)$ $h_4 = (0, 1)$

Méthode PANG

- Identification d'un ensemble de motifs discriminants $\mathcal{P}_s$
- Représentation vectorielle
- Utilisation de méthodes usuelles supervisées pour classer les vecteurs obtenus.

	h	**L**
G_1	1 0 1 1	A
G_2	1 0 0 1	A
G_3	0 1 0 0	N
G_4	0 1 0 0	N
G_5	0 1 1 0	?

Expérimentation sur le jeu des marchés publics

- Ensembles de contrats liés à des municipalités.

Label du graphe	Nombre de graphes	Nombre moyen de sommets (st)	Nombre moyen d'arêtes (st)
Anormal	330	15,76 (5,56)	17,09 (7,86)
Normal	330	12,54 (5,41)	12,59 (6,90)

- Tests de différents classifieurs (RF, SVM, k-Means).
- Utilisation de la validation croisée (5-Folds).

Résultats en termes de précision (P), rappel (R) et F-score (F)

Résultats avec Random Forest selon la valeur de s.

Nombre de motifs	Graphes anormaux P	R	F	Graphes normaux P	R	F
10	0,69	0,77	0,72	0,68	0,59	0,63
100	0,84	0,84	0,84	0,81	0,81	0,81
150	0,89	0,85	0,87	0,88	0,87	0,87
Tous	**0,94**	**0,90**	**0,92**	**0,89**	**0,93**	**0,91**
Graph2Vec	0,88	0,89	0,88	0,88	0,86	0,87

En utilisant 1% des motifs, les résultats sont équivalents à 95% de la performance totale.

Résultats

Objectif de notre approche : relier les motifs à des comportements économiques.

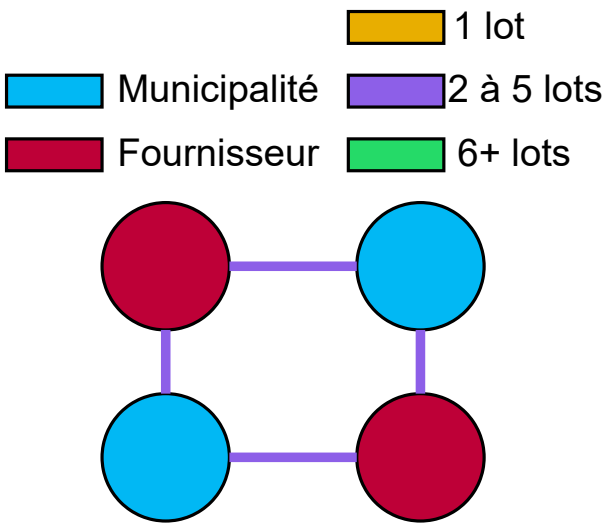

Motif lié à des secteurs sans grosse concurrence.

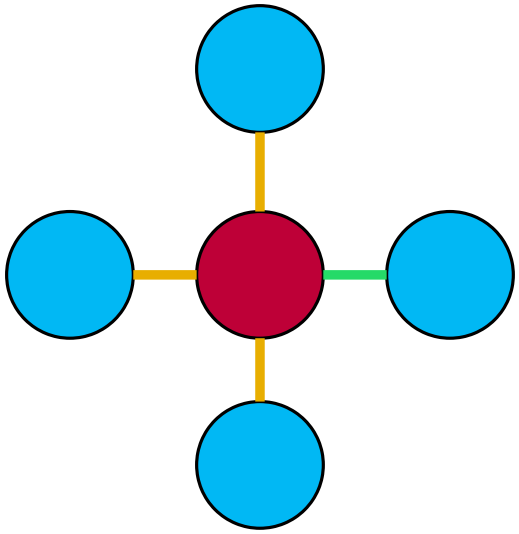

Motif pouvant être lié a du favoritisme.

Conclusion

Contributions

- PANG : Méthode générique, multi-classe et applicable à d'autres domaines.
- Construction d'un jeu de données à partir de marchés publics.
- Résultats expérimentaux confirmant une bonne identification des fraudes en l'absence des redflags.

Perspectives

- Utilisation d'autres types de plongement vectoriel des graphes.
- Définition d'autres types de red flags.
- Combinaison des informations relationnelles et attributaires.

Merci pour votre attention, avez vous des questions ?

AVIGNON UNIVERSITÉ

Bibliographie I

[MRM21] N. Modrušan, K. Rabuzin et L. Mršic. « Review of Public Procurement Fraud Detection Techniques Powered by Emerging Technologies ». In : *International Journal of Advanced Computer Science and Applications* 12.2 (2021). doi : 10.14569/ijacsa.2021.0120272.

[Nat16] National Fraud Authority. *RED FLAGS for integrity : Giving the green light to open data solutions.* Rapp. tech. Open Contracting Partnership, 2016. url : https://www.open-contracting.org/wp-content/uploads/2016/11/OCP2016-Red-flags-for-integrityshared-1.pdf.

[Pot+22] L. Potin, V. Labatut, R. Figueiredo, C. Largeron et P.-H. Morand. *FOPPA : a database of French Open Public Procurement Award notices.* Rapp. tech. Avignon Université, 2022. url : https://hal.archives-ouvertes.fr/hal-03796734 (visité le 12/10/2020).