

Extraction de co-localisations sous contrainte de la structure spatiale

Rodrigue Govan¹, Nazha Selmaoui-Folcher¹,
Aristotelis Giannakos², Philippe Fournier-Viger³

{rodrigue.govan,nazha.selmaoui}@unc.nc – 4 Juillet 2023

¹ Université de la Nouvelle-Calédonie – ISEA

² Université de Picardie Jules Verne – EPROAD

³ Shenzhen University – Big Data Institute (CSSE)



INSTITUT DE SCIENCES
EXACTES ET APPLIQUÉES



Introduction

Dans le domaine de la fouille de données, l'extraction de **co-localisations** est une des méthodes permettant d'extraire des connaissances (prenant en compte la dimension spatiale des données) [HSX04 ; KH95 ; SH01].

En théorie des graphes, les sous-ensembles d'objets géographiquement proches peuvent s'obtenir par l'extraction des cliques maximales [KKK11; Yao+16; BW19; Tra+21].

En théorie des graphes, les sous-ensembles d'objets géographiquement proches peuvent s'obtenir par l'extraction des cliques maximales [KKK11; Yao+16; BW19; Tra+21].

Soit $G = (V, E)$, un graphe non orienté avec $V = \{v_1, v_2, \dots, v_n\}$ l'ensemble des sommets et $E = \{(v_i, v_j) \in V^2 \mid \forall i, j \in \{1, \dots, n\} \text{ et } i \neq j\}$. Si deux sommets v_i et v_j sont liés par une arête i.e., $(v_i, v_j) \in E$, alors on dit que v_i et v_j sont adjacents.

- Graphe complet : Un graphe est dit complet si et seulement si chaque paire de sommets du graphe est adjacent.

En théorie des graphes, les sous-ensembles d'objets géographiquement proches peuvent s'obtenir par l'extraction des cliques maximales [KKK11; Yao+16; BW19; Tra+21].

Soit $G = (V, E)$, un graphe non orienté avec $V = \{v_1, v_2, \dots, v_n\}$ l'ensemble des sommets et $E = \{(v_i, v_j) \in V^2 \mid \forall i, j \in \{1, \dots, n\} \text{ et } i \neq j\}$. Si deux sommets v_i et v_j sont liés par une arête i.e., $(v_i, v_j) \in E$, alors on dit que v_i et v_j sont adjacents.

- Graphe complet : Un graphe est dit complet si et seulement si chaque paire de sommets du graphe est adjacent.

Soit $g = (V_g, E_g)$ un sous-graphe de G tel que $V_g \subseteq V$ et $E_g \subseteq \{(v_{g,i}, v_{g,j}) \in E \mid v_{g,i} \in V_g \wedge v_{g,j} \in V_g\}$.

En théorie des graphes, les sous-ensembles d'objets géographiquement proches peuvent s'obtenir par l'extraction des cliques maximales [KKK11 ; Yao+16 ; BW19 ; Tra+21].

Soit $G = (V, E)$, un graphe non orienté avec $V = \{v_1, v_2, \dots, v_n\}$ l'ensemble des sommets et $E = \{(v_i, v_j) \in V^2 \mid \forall i, j \in \{1, \dots, n\} \text{ et } i \neq j\}$. Si deux sommets v_i et v_j sont liés par une arête i.e., $(v_i, v_j) \in E$, alors on dit que v_i et v_j sont adjacents.

- Graphe complet : Un graphe est dit complet si et seulement si chaque paire de sommets du graphe est adjacent.

Soit $g = (V_g, E_g)$ un sous-graphe de G tel que $V_g \subseteq V$ et $E_g \subseteq \{(v_{g,i}, v_{g,j}) \in E \mid v_{g,i} \in V_g \wedge v_{g,j} \in V_g\}$.

- Clique : Une clique de G est un sous-graphe $g \subseteq G$ tel que g est complet ;

En théorie des graphes, les sous-ensembles d'objets géographiquement proches peuvent s'obtenir par l'extraction des cliques maximales [KKK11 ; Yao+16 ; BW19 ; Tra+21].

Soit $G = (V, E)$, un graphe non orienté avec $V = \{v_1, v_2, \dots, v_n\}$ l'ensemble des sommets et $E = \{(v_i, v_j) \in V^2 \mid \forall i, j \in \{1, \dots, n\} \text{ et } i \neq j\}$. Si deux sommets v_i et v_j sont liés par une arête i.e., $(v_i, v_j) \in E$, alors on dit que v_i et v_j sont adjacents.

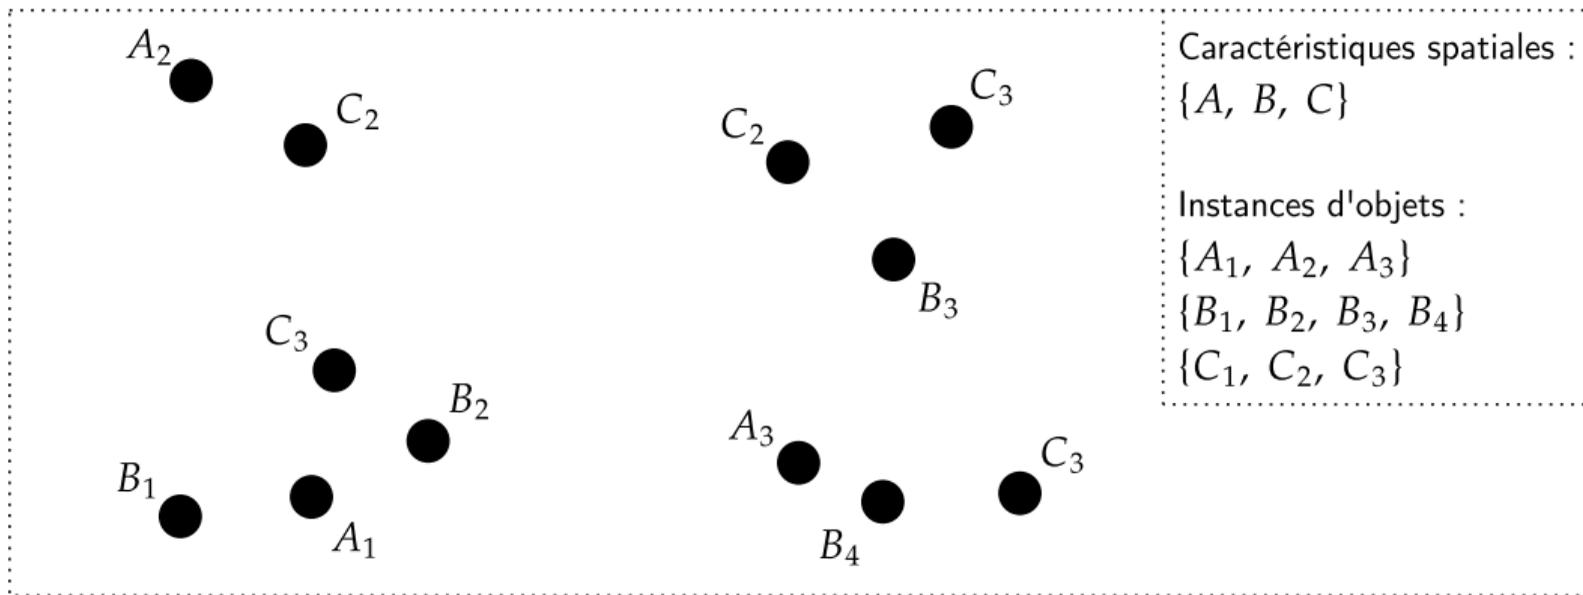
- Graphe complet : Un graphe est dit complet si et seulement si chaque paire de sommets du graphe est adjacent.

Soit $g = (V_g, E_g)$ un sous-graphe de G tel que $V_g \subseteq V$ et $E_g \subseteq \{(v_{g,i}, v_{g,j}) \in E \mid v_{g,i} \in V_g \wedge v_{g,j} \in V_g\}$.

- Clique : Une clique de G est un sous-graphe $g \subseteq G$ tel que g est complet ;
- Clique maximale : La clique g est dite maximale si et seulement s'il n'existe pas de clique g' telle que $g \subset g' \subseteq G$.

Introduction

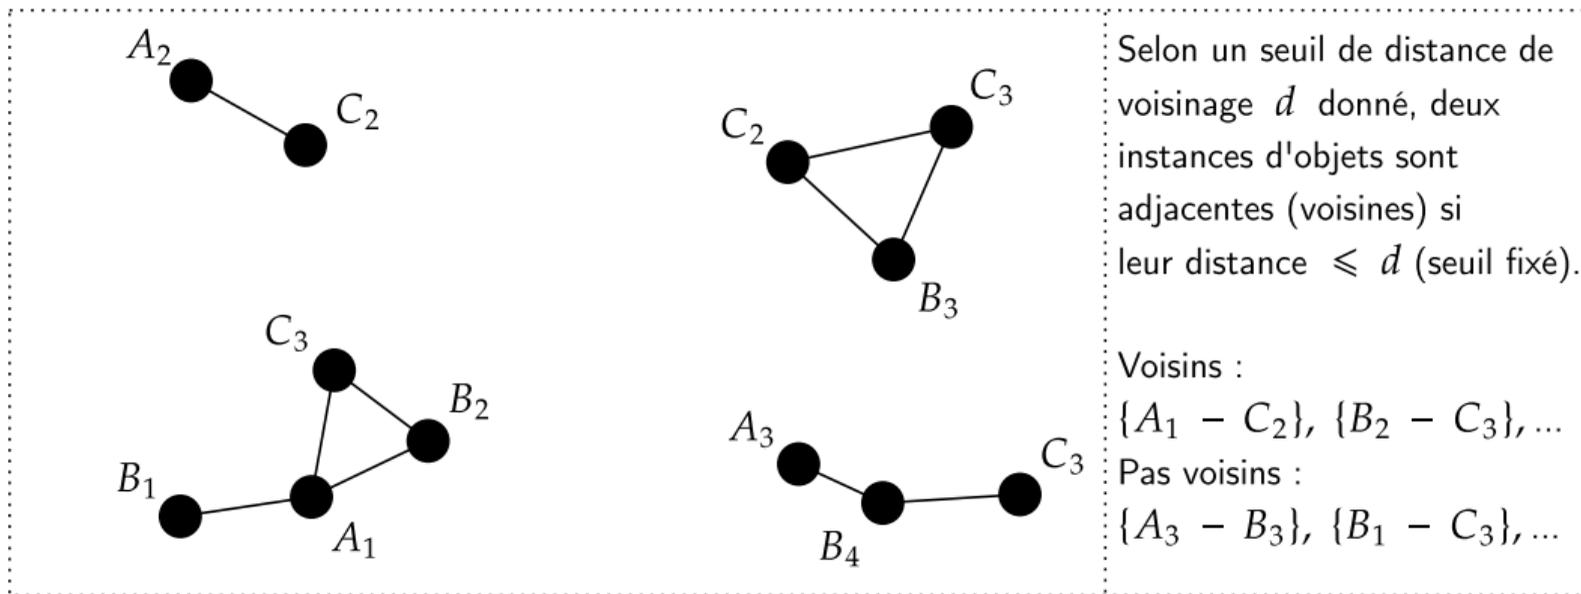
Exemple de co-localisations basées sur un ensemble de cliques de données spatialisées.



a) Données spatiales avec les caractéristiques et leurs instances.

Introduction

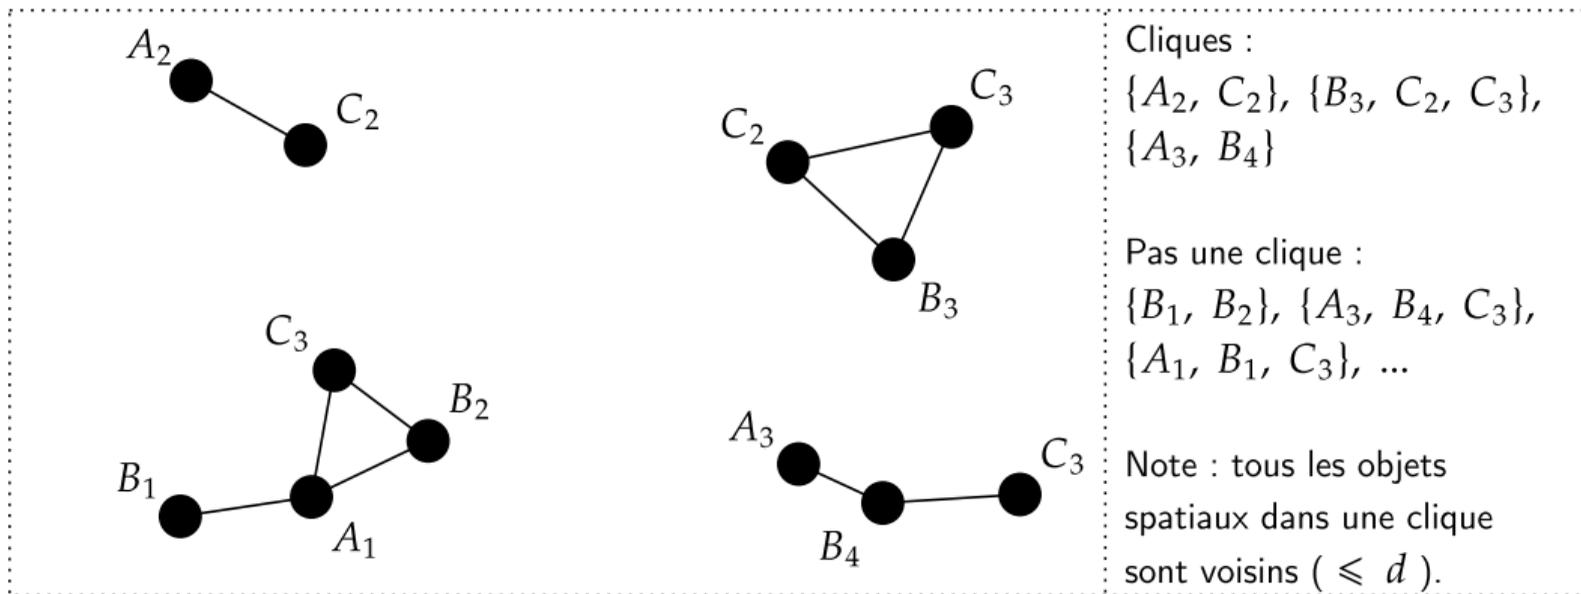
Exemple de co-localisations basées sur un ensemble de cliques de données spatialisées.



b) Représentation du graphe selon un seuil de distance d .

Introduction

Exemple de co-localisations basées sur un ensemble de cliques de données spatialisées.



c) Ensemble de cliques à partir de la représentation du graphe.

Introduction

Exemple de co-localisations basées sur un ensemble de cliques de données spatialisées.

Instances/cliques de la co-localisation $\{A, B\} : \{A_1, B_1\}, \{A_1, B_2\}, \{A_3, B_4\}$

Instances/cliques de la co-localisation $\{B, C\} : \{B_3, C_2\}, \{B_3, C_3\}, \{B_2, C_3\}, \{B_4, C_3\}$

Instances/cliques de la co-localisation $\{A, C\} : \{A_2, C_2\}, \{A_1, C_3\}$

Instances/cliques de la co-localisation $\{A, B, C\} : \{A_1, B_2, C_3\}$

d) Co-localisations à partir de l'ensemble de cliques.

Pour définir si une co-localisation est pertinente, l'indice de participation (basé sur le ratio de participation) est utilisé. L'indice de participation est aussi appelé la prévalence.

Pour définir si une co-localisation est pertinente, l'indice de participation (basé sur le ratio de participation) est utilisé. L'indice de participation est aussi appelé la prévalence.

- Ratio de participation : $Pr(f_i, \mathcal{C}) = \frac{|\{ \text{instances de } f_i \text{ participant à } \mathcal{C} \}|}{|\{ \text{instances de } f_i \}|}$
- Indice de participation : $Pi(\mathcal{C}) = \min_{f_i \in \mathcal{C}} Pr(f_i, \mathcal{C})$

Pour définir si une co-localisation est pertinente, l'indice de participation (basé sur le ratio de participation) est utilisé. L'indice de participation est aussi appelé la prévalence.

- Ratio de participation : $Pr(f_i, \mathcal{C}) = \frac{|\{ \text{instances de } f_i \text{ participant à } \mathcal{C} \}|}{|\{ \text{instances de } f_i \}|}$
- Indice de participation : $Pi(\mathcal{C}) = \min_{f_i \in \mathcal{C}} Pr(f_i, \mathcal{C})$

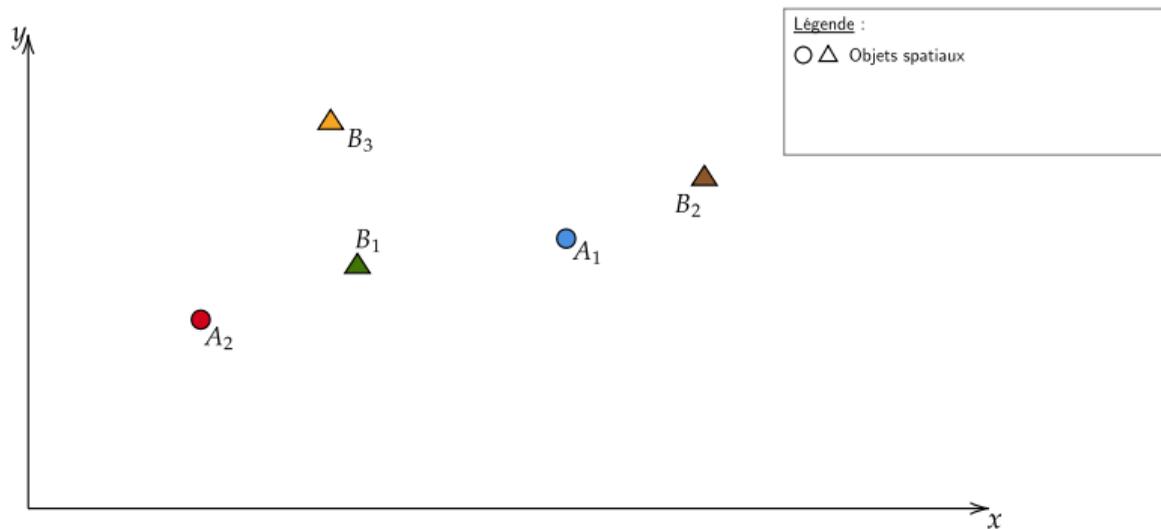
Instances/cliques de la co-localisation $\{A, B\} : \{A_1, B_1\}, \{A_1, B_2\}, \{A_3, B_4\}$

Avec A_1, A_2, A_3 comme instances de A et B_1, B_2, B_3, B_4 comme instances de B de l'exemple précédent, nous avons :

- $Pr(A, \{A, B\}) = \frac{|\{A_1, A_3\}|}{|\{A_1, A_2, A_3\}|} = \frac{2}{3}$ et $Pr(B, \{A, B\}) = \frac{|\{B_1, B_2, B_4\}|}{|\{B_1, B_2, B_3, B_4\}|} = \frac{3}{4}$
- $Pi(\{A, B\}) = \min_{f_i \in \{A, B\}} Pr(f_i, \{A, B\}) = \min(\frac{2}{3}, \frac{3}{4}) = \frac{2}{3}$

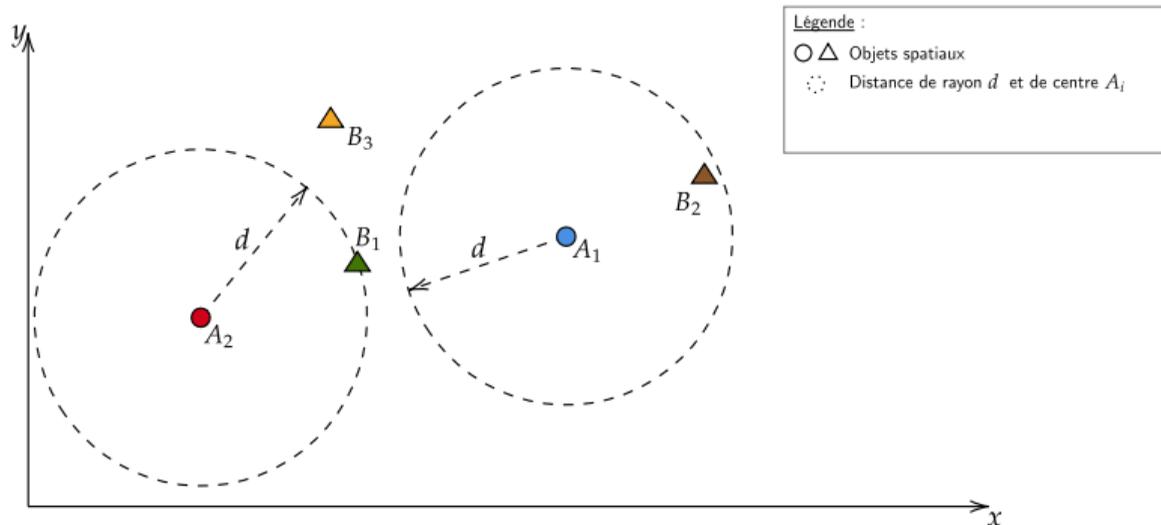
Problématique

Relation de voisinage



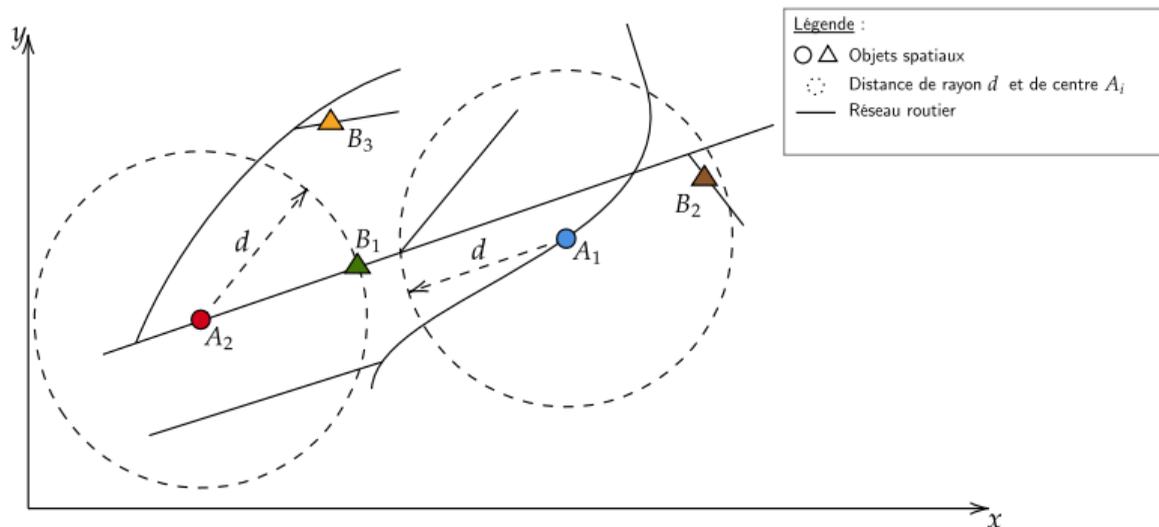
Problématique

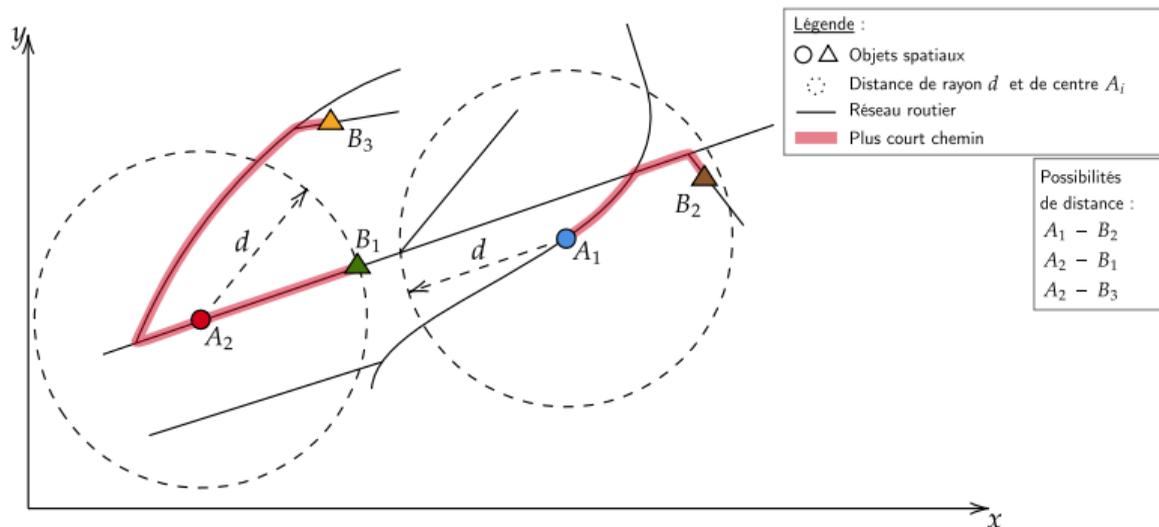
Relation de voisinage



Problématique

Relation de voisinage





Pour définir la relation de voisinage, la majorité des méthodes se basent sur une distance euclidienne [YS06 ; WBL09 ; Kim+14] ;

- La **structure spatiale** n'est pas prise en compte !
- Il faut donc considérer une autre mesure de voisinage.

Prise en compte de la contrainte

Soit \mathcal{O} un ensemble d'objets spatiaux et \mathcal{F} un ensemble de caractéristiques. On note G_S , un graphe représentant la structure spatiale tels que $G_S = (V_S, E_S)$ où V_S est l'ensemble des sommets et E_S l'ensemble des arêtes.

L'intégration de la contrainte se réalise selon les étapes suivantes :

1. Pour chaque objet $o_i \in \mathcal{O}$, nous l'associons dans la structure spatiale G_S au plus proche objet $o_S \in V_S$ (par la distance euclidienne) ;

Prise en compte de la contrainte

Soit \mathcal{O} un ensemble d'objets spatiaux et \mathcal{F} un ensemble de caractéristiques. On note G_S , un graphe représentant la structure spatiale tels que $G_S = (V_S, E_S)$ où V_S est l'ensemble des sommets et E_S l'ensemble des arêtes.

L'intégration de la contrainte se réalise selon les étapes suivantes :

1. Pour chaque objet $o_i \in \mathcal{O}$, nous l'associons dans la structure spatiale G_S au plus proche objet $o_S \in V_S$ (par la distance euclidienne) ;
2. Nous déterminons le plus court chemin pour chaque objet de V_S aux autres objets localisés dans un cercle de rayon d selon la distance euclidienne ;

Prise en compte de la contrainte

Soit \mathcal{O} un ensemble d'objets spatiaux et \mathcal{F} un ensemble de caractéristiques. On note G_S , un graphe représentant la structure spatiale tels que $G_S = (V_S, E_S)$ où V_S est l'ensemble des sommets et E_S l'ensemble des arêtes.

L'intégration de la contrainte se réalise selon les étapes suivantes :

1. Pour chaque objet $o_i \in \mathcal{O}$, nous l'associons dans la structure spatiale G_S au plus proche objet $o_S \in V_S$ (par la distance euclidienne) ;
2. Nous déterminons le plus court chemin pour chaque objet de V_S aux autres objets localisés dans un cercle de rayon d selon la distance euclidienne ;
3. Si la longueur du plus court chemin [Dij+59 ; VK11] entre deux objets de V_S est inférieure ou égale au seuil de distance d , alors ces objets sont considérés comme voisins.

Construction du graphe

Sous la contrainte de la structure spatiale, le graphe est défini tel que $G = (\mathcal{O}, E_{\mathcal{O}})$ avec :

- \mathcal{O} est l'ensemble des objets spatiaux ;
- $E_{\mathcal{O}} = \{(o_i, o_j) \mid \exists (o_{S,i}, o_{S,j}) \in E_S, D_{sp}(o_{S,i}, o_{S,j}) \leq d, \forall (i, j) \in \llbracket 1, n \rrbracket^2, i \neq j\}$.

L'extraction des cliques maximales pour obtenir les co-localisations s'effectuera à partir de ce graphe.

Paris et Chicago

Les données ont été créées en collectant des variables via les plateformes *OpenData*¹.

Variable	Attributs	# Objets
Lycées	Type	239
Cinémas	# Sièges (**)	85
(*) Vélos	Capacité (**)	996
Parcs	Type	722
(*) Métros	Ligne	326
Nombre total d'objets spatiaux : 2 968		

Description des données de Paris.

(*) : La variable concerne des stations.

(**) : Les données ont été discrétisées par quantile.

¹ opendata.paris.fr/, data.iledefrance.fr/, data.cityofchicago.org/

Données

Paris et Chicago

Description

Les données ont été créées en collectant des variables via les plateformes *OpenData*¹.

Variable	Attributs	# Objets
Lycées	Type	239
Cinémas	# Sièges (**)	85
(*) Vélos	Capacité (**)	996
Parcs	Type	722
(*) Métros	Ligne	326
Nombre total d'objets spatiaux : 2 968		

Description des données de Paris.

(*) : La variable concerne des stations.

(**) : Les données ont été discrétisées par quantile.

Variable	Attributs	# Objets
Lycées	Type	142
(*) Bus	# Lignes	5 606
(*) Tramway	# Lignes	124
<i>Fast Food</i>		877
(*) Vélos	Capacité (*)	1 402
Parcs	Type	613
Nombre total d'objets spatiaux : 8 764		

Description des données de Chicago.

¹ opendata.paris.fr/, data.iledefrance.fr/, data.cityofchicago.org/

Données

Description

Structure spatiale : réseau routier

Les réseaux routiers ont été récupérées via OSMnx [Boe17] :

- Il est possible d'obtenir le réseau accessible à pied ou en voiture ;
- Le réseau est convertible sous forme de graphe.

Données

Structure spatiale : réseau routier

Les réseaux routiers ont été récupérées via OSMnx [Boe17] :

- Il est possible d'obtenir le réseau accessible à pied ou en voiture ;
- Le réseau est convertible sous forme de graphe.

Le réseau routier de Paris se compose de 42 870 sommets 241 016 arêtes ;



Réseau routier de Paris intra-muros.

Données

Structure spatiale : réseau routier

Les réseaux routiers ont été récupérées via OSMnx [Boe17] :

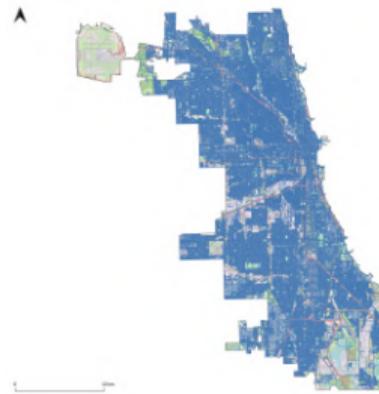
- Il est possible d'obtenir le réseau accessible à pied ou en voiture ;
- Le réseau est convertible sous forme de graphe.

Le réseau routier de Paris se compose de 42 870 sommets 241 016 arêtes ;

Le réseau routier de Chicago se compose de 184 476 sommets et 1 217 928 arêtes.



Réseau routier de Paris intra-muros.

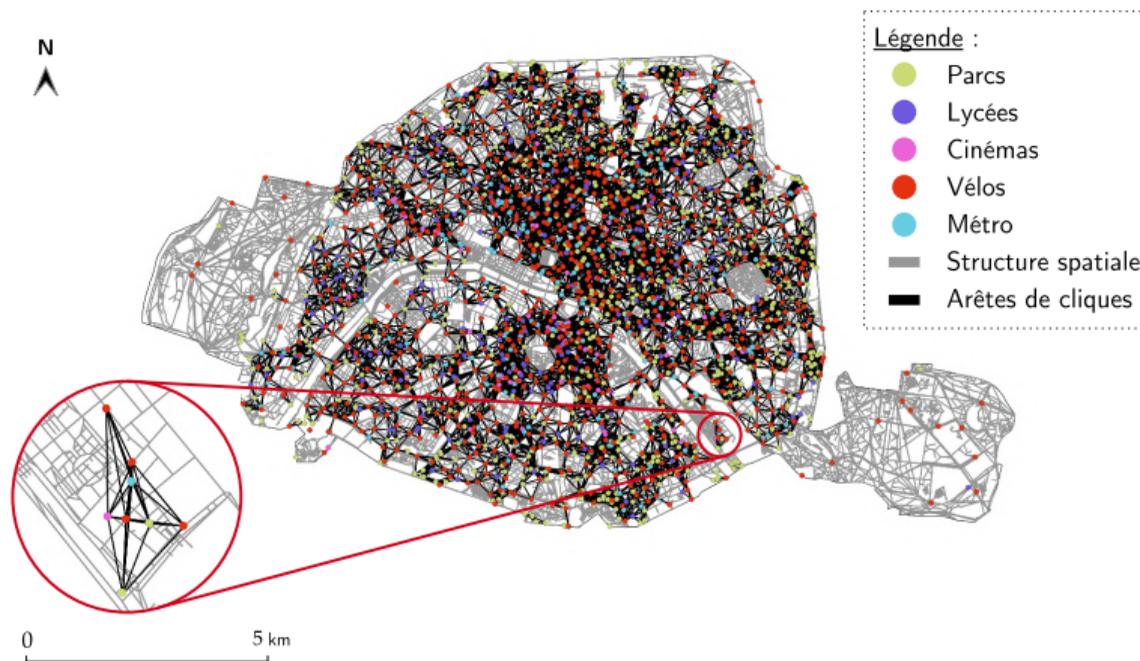


Réseau routier de Chicago.

Résultats

Distribution

Paris



Données de Paris avec les cliques maximales extraites.

Résultats

Motifs spatiaux

Paris

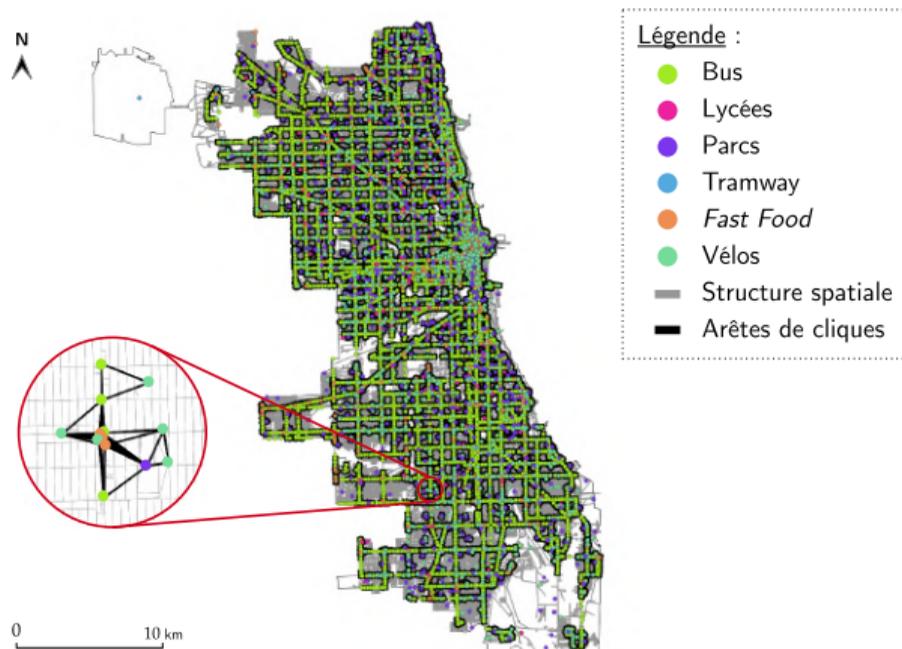
Co-localisation	Prévalence sous contrainte	Prévalence sans contrainte
{Parcs, Lycées, Vélos}	0.89	0.89
{Lycées, Vélos}	0.86	0.86
{Lycées, Cinémas, Vélos}	0.71	0.71
{Lycées, Vélos, Métros}	0.71	0.71
{Lycées, Cinémas, Vélos, Métros}	0.71	0.71
{Parcs, Lycées, Vélos, Cinémas}	0.56	0.44
{Parcs, Lycées, Cinémas, Métros}	0	0.14
...

Prévalences des co-localisations de Paris.

Résultats

Distribution

Chicago



Données de Chicago avec les cliques maximales extraites.

Co-localisation	Prévalence sous contrainte	Prévalence sans contrainte
{Bus, <i>Fast Food</i> , Lycées, Vélos}	0.58	0.5
{Bus, <i>Fast Food</i> , Lycées, Tramway, Vélos}	0.38	0.38
{Bus, <i>Fast Food</i> , Lycées}	0.33	0.17
{Bus, <i>Fast Food</i> , Lycées, Tramway}	0.3	0.3
{Bus, <i>Fast Food</i> , Lycées, Parcs}	0.17	0.17
{Bus, <i>Fast Food</i> , Lycées, Tramway, Vélos, Parcs}	0.15	0.15
...

Prévalences des co-localisations de Chicago.

Conclusion

- CSS-Miner : Une approche d'extraction de co-localisations prenant en compte la structure spatiale de la zone étudiée ;

Conclusion

- CSS-Miner : Une approche d'extraction de co-localisations prenant en compte la structure spatiale de la zone étudiée ;
- Utilisation du réseau routier comme structure spatiale et de la longueur du plus court chemin comme relation de voisinage ;

Conclusion

- CSS-Miner : Une approche d'extraction de co-localisations prenant en compte la structure spatiale de la zone étudiée ;
- Utilisation du réseau routier comme structure spatiale et de la longueur du plus court chemin comme relation de voisinage ;
- Application sur des données réelles.

Conclusion

- CSS-Miner : Une approche d'extraction de co-localisations prenant en compte la structure spatiale de la zone étudiée ;
- Utilisation du réseau routier comme structure spatiale et de la longueur du plus court chemin comme relation de voisinage ;
- Application sur des données réelles.

Perspectives

- Prendre en compte d'autres contraintes (par exemple l'altitude/pente, le parcours du chemin en voiture/vélo) ;

Conclusion

- CSS-Miner : Une approche d'extraction de co-localisations prenant en compte la structure spatiale de la zone étudiée ;
- Utilisation du réseau routier comme structure spatiale et de la longueur du plus court chemin comme relation de voisinage ;
- Application sur des données réelles.

Perspectives

- Prendre en compte d'autres contraintes (par exemple l'altitude/pente, le parcours du chemin en voiture/vélo) ;
- Intégrer la connaissance d'experts-métier [Flo+15] pour cibler/filtrer les plus pertinents motifs spatiaux ;

Conclusion

- CSS-Miner : Une approche d'extraction de co-localisations prenant en compte la structure spatiale de la zone étudiée ;
- Utilisation du réseau routier comme structure spatiale et de la longueur du plus court chemin comme relation de voisinage ;
- Application sur des données réelles.

Perspectives

- Prendre en compte d'autres contraintes (par exemple l'altitude/pente, le parcours du chemin en voiture/vélo) ;
- Intégrer la connaissance d'experts-métier [Flo+15] pour cibler/filtrer les plus pertinents motifs spatiaux ;
- Évaluer CSS-Miner sur de plus gros jeux de données.

Références

- [BW19] Xuguang BAO et Lizhen WANG. "A clique-based approach for co-location pattern mining". In : *Information Sciences* 490 (2019), p. 244-264.
- [Boe17] Geoff BOEING. "OSMnx : New methods for acquiring, constructing, analyzing, and visualizing complex street networks". In : *Computers, Environment and Urban Systems* 65 (2017), p. 126-139.
- [Dij+59] Edsger W DIJKSTRA et al. "A note on two problems in connexion with graphs". In : *Numerische mathematik* 1.1 (1959), p. 269-271.
- [Flo+15] Frédéric FLOUVAT et al. "Domain-driven co-location mining : Extraction, visualization and integration in a GIS". In : *Geoinformatica* 19 (2015), p. 147-183.
- [HSX04] Yan HUANG, Shashi SHEKHAR et Hui XIONG. "Discovering colocation patterns from spatial data sets : a general approach". In : *IEEE Transactions on Knowledge and data engineering* 16.12 (2004), p. 1472-1485.
- [Kim+14] Seung Kwan KIM et al. "A framework of spatial co-location pattern mining for ubiquitous GIS". In : *Multimedia tools and applications* 71.1 (2014), p. 199-218.
- [KH95] Krzysztof KOPERSKI et Jiawei HAN. "Discovery of spatial association rules in geographic information databases". In : *International Symposium on Spatial Databases*. Springer. 1995, p. 47-66.
- [KKK11] Seung KWAN KIM, Younghee KIM et Ungmo KIM. "Maximal cliques generating algorithm for spatial co-location pattern mining". In : *Secure and Trust Computing, Data Management and Applications : 8th FIRA International Conference, STA 2011, Loutraki, Greece, June 28-30, 2011. Proceedings 8*. Springer. 2011, p. 241-250.
- [SH01] Shashi SHEKHAR et Yan HUANG. "Discovering spatial co-location patterns : A summary of results". In : *International symposium on spatial and temporal databases*. Springer. 2001, p. 236-256.
- [Tra+21] Vanha TRAN et al. "MCHT : A maximal clique and hash table-based maximal prevalent co-location pattern mining algorithm". In : *Expert Systems with Applications* 175 (2021), p. 114830.

Références

- [VK11] Gintaras VAIRA et Olga KURASOVA. "Parallel bidirectional Dijkstra's shortest path algorithm". In : *Databases and Information Systems VI, Frontiers in Artificial Intelligence and Applications* 224 (2011), p. 422-435.
- [WBL09] Lizhen WANG, Yuzhen BAO et Zhongyu LU. "Efficient discovery of spatial co-location patterns using the iCPI-tree". In : *The Open Information Systems Journal* 3.1 (2009).
- [Yao+16] Xiaojing YAO et al. "A fast space-saving algorithm for maximal co-location pattern mining". In : *Expert Systems with Applications* 63 (2016), p. 310-323.
- [YS06] Jin Soung YOO et Shashi SHEKHAR. "A joinless approach for mining spatial colocation patterns". In : *IEEE Transactions on Knowledge and Data Engineering* 18.10 (2006), p. 1323-1337.

MERCI DE VOTRE ATTENTION

Rodrigue Govan¹, Nazha Selmaoui-Folcher¹,
Aristotelis Giannakos², Philippe Fournier-Viger³

CNIA'23 – Strasbourg (France), le 4 Juillet 2023

{rodrigue.govan,nazha.selmaoui}@unc.nc