Détection de communautés dans les graphes de connaissance d'activités

Marthe Désirée Olivia HABACK[1], Serge SONFACK SOUNCHIO[2], Orlane SONKENG TSAFACK[1], Halguièta TRAWINA[3], Ho Tuong Vinh[1]

[1] École internationale, Université nationale du Vietnam, Hanoï, Vietnam
[2] Robert Bosch Sp. z o. o. Jutrzenki 105, POLAND
[3] Laboratoire de Mathématique et d'Informatique; Université Joseph KI-ZERBO, Burkina Fasso

5 mai 2025

Résumé

La gestion des connaissances produites au cours des activités au sein des organisations joue un rôle important dans leur développement et leur succès. La formalisation de ces connaissances sous forme de graphe de connaissance d'activités (Activity Knowledge Graph : AKG) permet de représenter et de réutiliser ces connaissances pour résoudre des problèmes et prendre des décisions tactiques ou stratégiques. Cependant, les graphes de connaissance d'activités sont difficiles à interpréter par des cadres, car ils disposent d'une structure complexe due aux interconnexions des activités, ressources partagées. De plus, les AKGs sont spécifiques aux domaines d'activités des organisations.

Pour faciliter l'interprétation des graphes de connaissance d'activités, cette étude propose une approche basée sur la détection de communautés. Cette approche repose sur trois étapes : (1) un pré-traitement pour adapter l'AKG à l'algorithme de Louvain, (2) l'application de l'algorithme de Louvain pour la détection de communautés et (3) un post-traitement pour intégrer les communautés détectées à l'AKG.

Un cas d'étude dans le domaine de l'enseignement illustre l'applicabilité de notre approche, et les résultats démontrent la simplicité obtenue dans la compréhension des connaissances représentées par le graphique de connaissance d'activités.

Mots-clés

Graphe de connaissance, graphe de connaissance d'activité, détection de communauté, algorithme de Louvain.

Abstract

Managing the knowledge generated by organizational activities is important in their development and success. Formalizing this knowledge in the form of an Activity Knowledge Graph (AKG) enables it to be represented and reused to solve problems and make tactical or strategic decisions. However, activity knowledge graphs are difficult for managers to interpret, as they have a complex structure due to the interconnections between activities and shared resources. In addition, AKGs are specific to an organization's field of activity. This study proposes an approach based on community detection to facilitate the interpretation of activity knowledge graphs. This approach relies on three steps : (1) pre-processing to adapt the AKG to the Louvain algorithm, (2) application of the Louvain algorithm for community detection, and (3) post-processing to integrate the detected communities into the AKG. A case study in the educational domain illustrates the applicability of the approach, and the results demonstrate the simplicity achieved in understanding the knowledge represented by the activity knowledge graph.

Keywords

Knowledge graph, activity knowledge graph, community detection, Louvain alogorithm.

1 Introduction

Un graphe de connaissance est une structure permettant de représenter et d'interconnecter des informations, facilitant ainsi la représentation de la connaissance en se basant sur la logique relationnelle qui existe entre entités d'un domaine. Il constitue un outil pour les entreprises, car peut-être utilisé les connaissances de leurs activités et leur exploitation peut servir à prendre des décisions pour rester compétitives. De plus, la gestion des connaissances au sein d'une entreprise s'avère essentielle pour préserver et transmettre les savoirs accumulés, en particulier ceux des employés expérimentés proches de la retraite ou ayant eu une longue carrière au sein de l'entreprise. Une telle gestion favorise le partage d'informations, la transmission des compétences, et améliore l'efficacité organisationnelle.

Le graphe de connaissance d'activités (Activity Knowledge Graph : AKG) est une représentation de la connaissance liée aux activités d'une entreprise qui permet de conserver leur savoir-faire de l'entreprise. Cette connaissance capture le contexte des activités comme la temporalité, les règles, les objectifs, les sujets et les bénéficiaires, les outils et les lieux [11]. L'AKG d'une entreprise repose

sur l'ontologie de haut niveau (Core Activity Ontology), qui permet de créer les ontologies dans divers domaines [9].

Cependant, la forte interconnexion entre les éléments de contexte des activités et les activités elles-mêmes et la spécificité des AKG aux domaines des entreprises les rendent difficiles pour les managers appelés à prendre des décisions en entreprise sans toutefois avoir les compétences techniques du domaine de l'entreprise. En outre, l'utilisation des requêtes permet de répondre aux questions techniques, mais pas d'abstraire les connaissances pour faciliter la compréhension aux niveaux non-techniques.

Dans cette étude, nous allons proposer une approche pour la détection de communautés dans un graphe de connaissance d'activités (Activity Knowledge Graph : AKG), qui permettra de simplifier la compréhension de la connaissance des activités d'une entreprise et par conséquent améliorer la prise de décision.
Pour la suite, nous proposons d'organiser cet article en trois sections. La prochaine section (Section 2) présentera les travaux connexes relatifs à la détection de communautés, la section qui suivra (Section 3) détaillera notre méthodologie et les résultats de notre expérimentation seront illustrés à la Section 4, et nous proposerons une conclusion à la dernière section.

2 État de l'art

Dans notre travail, nous étudions les graphes de connaissances d'activités au sein des entreprises, en nous concentrant particulièrement sur le domaine éducatif. L'objectif est d'extraire de ces graphes une nouvelle forme de connaissance, simple à exploiter, qui reflète le graphe initial et apporte des informations utiles pour la prise de décision. Pour répondre à ce besoin, nous nous sommes appuyés sur plusieurs travaux récents relatifs aux graphes de connaissances et à la détection de communautés.

Une approche a proposé une structuration des grands graphes réels en communautés, basée sur une technique de clustering qui organise les données de manière hiérarchique en utilisant l'algorithme de Louvain [4]. Cependant, cette approche révèle des limitations significatives dans la gestion des communautés évolutives. En effet, malgré la combinaison de l'algorithme de Louvain avec des techniques de cartographie pour l'analyse des clusters, l'auteur n'est pas parvenu à développer une méthode efficace pour la construction et le suivi des communautés évolutives. Cette contrainte, associée aux difficultés d'utilisabilité des méthodes de détection de communauté, met en évidence les défis persistants dans l'analyse dynamique des réseaux sociaux.

D'autres efforts ont exploité les algorithmes de classification et de clustering pour les graphes de connaissances, comme le montrent [12] à travers leur approche basée sur les techniques d'apprentissage automatique pour la détection des communautés et l'analyse des relations entre entités. Les résultats montrent que ces techniques améliorent la précision des modèles d'analyse de graphiques et facilitent la prise de décision dans divers contextes organisationnels.

Dans leur étude **Organisations' Interpersonal Activity Knowledge Representation**, [11] explorent les connaissances explicites et implicites, essentielles au fonctionnement organisationnel et leurs limites. Leur approche, basée sur l'ontologie, met en évidence les défis de l'extraction de connaissances spécifiques pour une utilisation pratique, et pose les bases d'une détection de communautés pour optimiser les décisions organisationnelles.

Enfin, [7] nous introduit une approche basée sur **A motif - based probabilistic approach for community detection in complex networks**, en utilisant des algorithmes comme la descente de coordonnées de bloc. Bien que des difficultés aient été rencontrées lors de la mise en œuvre, cette approche ouvre la voie à des solutions futures utilisant des modèles génératifs.

Pour réaliser la détection de communautés, il est nécessaire de suivre un canevas bien défini, impliquant un processus structuré pour atteindre les résultats attendus. Ainsi, le choix de l'algorithme à utiliser est une étape clé dans ce processus tel que décrit par [17] et [8].

- **Méthode de Louvain** : L'algorithme de Louvain est populaire pour la détection de communautés dans les réseaux statiques. Et il peut également être adapté aux réseaux dynamiques. Il optimise la modularité du réseau en fusionnant et en divisant les communautés de manière itérative. Dans le contexte dynamique, il peut être étendu pour tenir compte des changements au fil du temps.
- **Infomap** : Cet algorithme est basé sur la théorie de l'information. Il cherche à minimiser la longueur moyenne de la description d'un parcours aléatoire sur le réseau et peut être utilisé pour détecter des communautés dynamiques en analysant les transitions entre les états du réseau.
- **LD-ABCD (Local Dissimilarities - Agent Based Cluster Discovering)** : Cet algorithme est basé sur la détection de clusters dans un graphe pondéré, ce qui correspond bien à notre contexte d'étude des interactions entre entités ou activités. Il fournit des groupes ou des clusters qui sont étroitement liés les uns aux autres en fonction de leurs interactions.
- **Clustering** : L'algorithme de Clustering est défini comme un processus automatique qui regroupe des textes non étiquetés (comme des tweets ou des descriptions de produits) en clusters ou en groupes de textes similaires. L'objectif est de détecter des motifs de similarité entre les données pour les organiser de manière sémantique [1].

Après avoir étudié plusieurs méthodes, nous avons opté pour l'algorithme de **Louvain** en raison de son efficacité dans la détection de communautés, mais également du fait qu'il permet l'optimisation de la modularité du graphe et qu'il permet de regrouper des activités similaires en communautés, ce qui facilite ainsi l'analyse et l'exploitation des graphes de connaissances.

3 Approche proposée

3.1 Notion de graphe de connaissance d'activités (AKG)

Un graphe de connaissance d'entreprise ou réseau sémantique d'entreprise, est considéré comme étant un ensemble de données, d'informations et d'objet d'une entreprise représentée sous forme de graphe structuré contenant les entités, les attributs et les relations entre ces entités et présenté sur un format compréhensible par un système [15] [6].
Un graphe de connaissance d'activités (Activity Knowledge Graph : AKG), comme illustré dans la Figure 1 est un graphe de connaissances sémantique des activités d'une entreprise et reposant sur une extension de l'ontologie de haut niveau, Core Activity Ontology (CAO) [1] [14]. Dans un AKG, des nœuds représentent les activités d'une entreprise, chacune associée à des ressources contextuelles comme la temporalité, les contraintes, les sujets, les bénéficiaires, les outils, la localisation et la motivation [13] [12].

3.2 Communauté dans l'AKG

Une communauté en général est un ensemble d'entités qui entretiennent des liens privilégiés parce qu'elles ont des affinités particulières, ou présentent des caractéristiques similaires, ou encore partagent des centres d'intérêt, ainsi que d'autres éléments [5]. Dans le sens des graphes, une communauté du point de vue structurel est un sous-ensemble de nœuds fortement connectés, c'est-à-dire qu'il existe entre eux un nombre important de connexions, davantage que celles que ces nœuds entretiennent avec les autres nœuds du même graphe [10].

Une communauté dans le cas d'un graphe de connaissance d'activités (AKG) est un ensemble d'activité fortement liée par des éléments de contexte partagés comme le temps, la motivation, les sujets (employés de la structure réalisant les activités), les bénéficiaires ou même les lieux des activités.

La détection de communautés dans un graphe sans tenir compte de la sémantique fournie par l'ontologie est simple et directe, car l'utilisation d'un algorithme ne nécessite pas des modifications de celui-ci. Néanmoins, pour les graphes sémantiques, il devient nécessaire de soit adapter les algorithmes de détection de communautés, soit d'adapter les graphes sémantiques (avec ontologie) aux algorithmes de détection de communautés. C'est cette deuxième approche que nous avons adoptée pour la détection des communautés dans les graphes de connaissances d'activités.

Pour détecter les communautés dans les graphes de connaissance d'activités, l'approche proposée repose sur trois étapes comme illustrées par la Figure 2 :

1. Pré-traitement : cette étape transforme un graphe de connaissance d'activités en un graphe plus simple dans lequel les seuls nœuds sont les activités et les relations entre les activités correspondent au fait que les deux activités ont une ressource en commun.
2. La deuxième étape est l'application de l'algorithme de Louvain pour la détection de communautés.
3. Post-traitement : cette étape permet de reconstituer le graphe de connaissance d'activités initial en tenant compte des différentes communautés identifiées à l'étape précédente.

3.2.1 Pré-traitement

L'étape de pré-traitement est celle qui permet de transformer un graphe de connaissance d'activités en un graphe simple pouvant être utilisé par l'algorithme de Louvain sans apporter des modifications particulière à l'algorithme. Cette étape allège le graphe de connaissance d'activités en convertissant la sémantique de l'ontologie du graphe à des nouvelles interactions entre les nœuds activité du graphe.

L'algorithme de transformation 1 est le suivant : toutes les activités du graphe de connaissance d'activités sont des nœuds du graphe simplifié. Par la suite, on ajoute une relation entre deux nœuds du graphe simplifié si les deux activités en question partagent un élément de contexte en commun comme la temporalité, le lieu, les ressources.

Algorithm 1 Pré-traitement

Require: Graphe de connaissance d'activités (AKG)
Ensure: AKG : G
Ensure: Graphe : $G^{'} = (V, E)$
V$\leftarrow \emptyset$, E$\leftarrow \emptyset$
for Activité :A $\in$ G **do**
  V$\leftarrow A$
end for
for Activité :A $\in$ V **do**
  for Activité :A$^{'}\in$ V **do**
    if {Nœud, A} $\in E(G)$ **and** {Nœud, A$^{'}$}$\in E(G)$ **then**
      E$\leftarrow \{A, A^{'}\}$
    end if
  end for
end for
Résult : Graphe : G$^{'}$ ▷ Graphe d'activités simplifié

Cette transformation implique évidemment une perte

1. github.com/sonfack/ActivityOntology/blob/main/core_activity_ontology.ttl

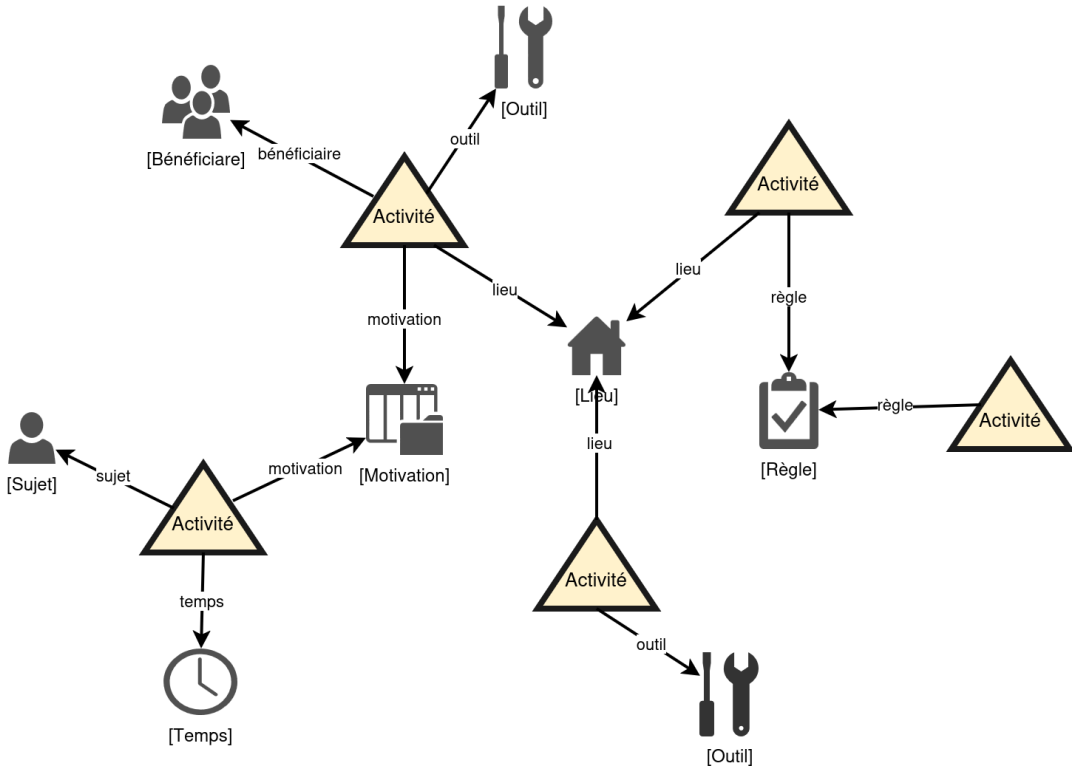

FIGURE 1 – Illustration d'un graphe de connaissance d'activité montrant les activités en triangles jaunes ainsi que les relations qui existent entre elles par l'intermédiaire des ressources ou éléments de contexte qu'elles partagent.

d'information sur le graphe résultant. Mais, elle nous permet d'avoir une sémantique claire pour la détection de communautés tout en simplifiant la structure du graphe pour l'algorithme de Louvain. En outre, l'étape du post-traitement nous permettra de remédier la perte de sémantique causée par la simplification du graphe initial.

3.2.2 Algorithme de Louvain

Pour notre travail, nous avons opté pour l'algorithme de Louvain. Cet algorithme a été sélectionné en raison de son efficacité et de sa capacité à gérer des graphes dynamiques. L'algorithme est hiérarchique et repose sur l'optimisation de la modularité, un critère mesurant la densité des liens à l'intérieur des communautés par rapport aux liens externes.

Cet algorithme optimise la modularité, qui est un indicateur qui permet de mesurer la densité des connexions à l'intérieur des communautés comparées à l'extérieur. Cet algorithme est divisé en deux phases [2, 3] :

- Phase 1
  Chaque nœud du réseau constitue initialement une communauté à lui seul : à ce stade, il y a donc autant de communautés que de nœuds. Pour chaque nœud i, on examine ses voisins directs j et on évalue le gain de modularité potentiel si le nœud i est déplacé dans la communauté de j. Le nœud i est alors transféré dans la communauté offrant le gain de modularité positif le plus élevé. Si aucun gain positif n'est obtenu, i reste dans sa communauté d'origine. Cette procédure est répétée jusqu'à ce qu'aucune amélioration supplémentaire ne soit possible.
- Phase 2
  Reconstruire le nouveau réseau dont les nœuds sont les communautés identifiées dans la phase 1 précédente. A cet effet, le poids de la relation entre deux nœuds du nouveau réseau est la somme des poids des relations entre les nœuds des communautés intervenant dans la nouvelle relation. A la fin de cette phase 2 on recommence avec la phase 1 ainsi de suite jusqu'à ce qu'on observe plus de changements et qu'on ait une modularité maximale. En effet, à chaque itération, on observera une réduction du nombre de nœuds et du temps de calcul.

Ce processus continu nous permet de créer une hiérarchie de communauté qui facilitera l'analyse des interactions entre activités [16].
La modularité Q est définie d'apres cet approche :

$$Q = \frac{1}{2m} \sum_{i,j} \left(A_{ij} - \frac{k_i k_j}{2m} \right) \delta(c_i, c_j)$$

Où :

- A_{ij} est l'élément de la matrice d'adjacence, valant 1 si les nœuds i et j sont connectés, et 0 sinon.
- k_i et k_j sont les degrés des nœuds i et j, c'est-à-dire le nombre de connexions de chaque nœud.
- m est le nombre total d'arêtes dans le graphe.

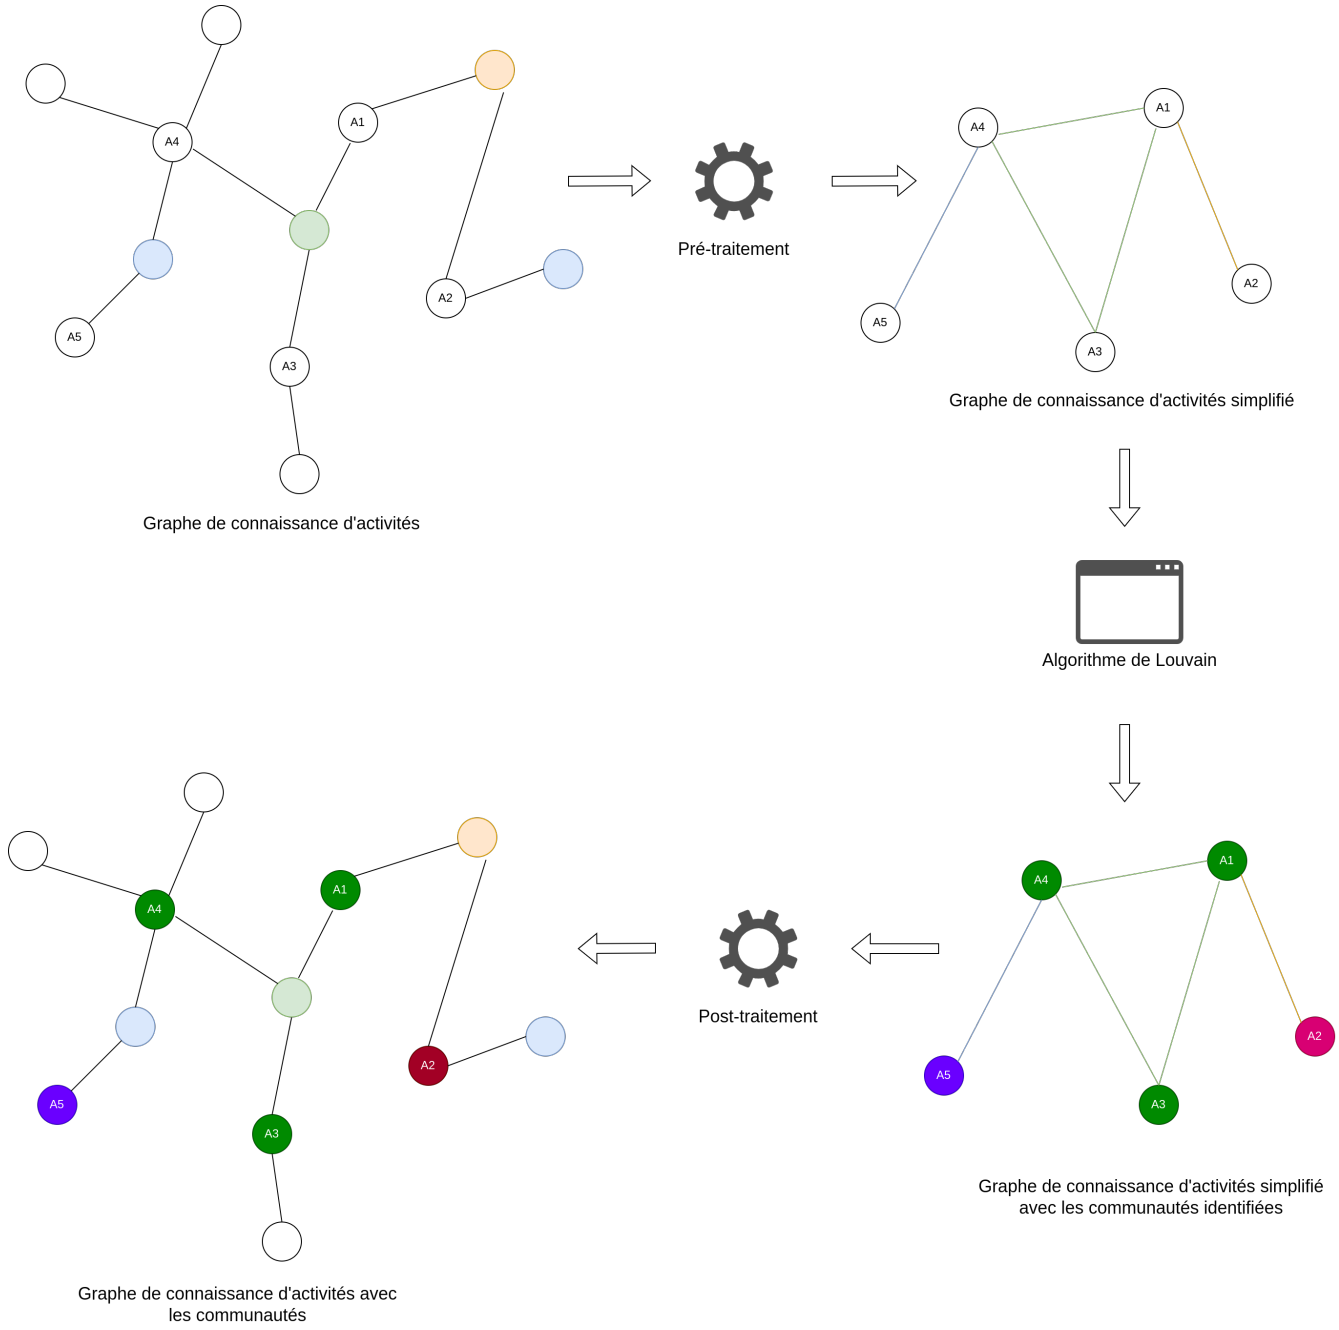

FIGURE 2 – Approche de détection de communauté pour les graphes de connaissance d'activités : 1) Pré-traitement

— $\delta(c_i, c_j)$ est la fonction delta de Kronecker, qui vaut 1 si i et j appartiennent à la même communauté, et 0 sinon.
— $\frac{k_i k_j}{2m}$ représente la probabilité attendue d'une arête entre les nœuds i et j dans un graphe aléatoire ayant les mêmes degrés.
— Initialisation : chaque nœud du graphe est initialement assigné à sa propre communauté.
— Fusion des communautés : l'algorithme parcourt chaque nœud et tente de l'assigner à la communauté de ses voisins, maximisant l'augmentation de la modularité.
— Itération : les communautés sont progressivement fusionnées jusqu'à atteindre une optimisation maximale de la modularité. Ce processus est répété de manière itérative pour créer une hiérarchie de communautés.

3.2.3 Post-traitement

Cette étape de l'approche proposée permet de transformer le graphe de connaissance d'activités simplifié avec les communautés détectées au graphe de connaissance d'activité initiale, mais en conservant les différentes communautés identifiées. Le post-traitement est aussi l'étape qui permettra de faire l'interprétation ou de comprendre le graphe de connaissance d'activités de départ

en fonction de la sémantique de l'étape de *pré-traitement*. L'algorithme 2 illustre cette étape.

Algorithm 2 Post-traitement

Require: Graphe de connaissance d'activités (AKG) simplifié avec les différentes communautés
Require: Liste des communautés
Ensure: AKG : G
Ensure: Communautés :C ▷ Liste des communautés obtenues de l'algorithme de Louvain

```
for Activité :A ∈ G do
    for c ∈ C do
        if A ∈ c then
            Mettre à A l'étiquette de sa communauté
        end if
    end for
end for
Résult : Graphe : G ▷ Graphe de connaissance d'activités avec les activités étiquetés en fonction de leur communauté
```

4 Cas d'application

4.1 Présentation de données

Les données utilisées dans l'application de l'approche proposée sont un graphe de connaissance d'activités d'enseignement construit d'une extension du core activity ontology (CAO) et contenant les activités comme les cours, les travaux dirigés, les projets et les travaux pratiques. Les instances de ces activités sont reliées aux instances faisant partie de leur contexte comme les ressources, les lieux, les motivations, les objectifs, les heures de début et de fin, les personnes, les activités.

4.2 Résultats

Le graphe de connaissance utilisé pour l'application de notre approche contient un total de 341 nœuds représentant des activités et des instances, ainsi que 505 arêtes représentant les relations entre ces entités. La figure 3 représente le graphe de connaissance d'activités de notre étude.

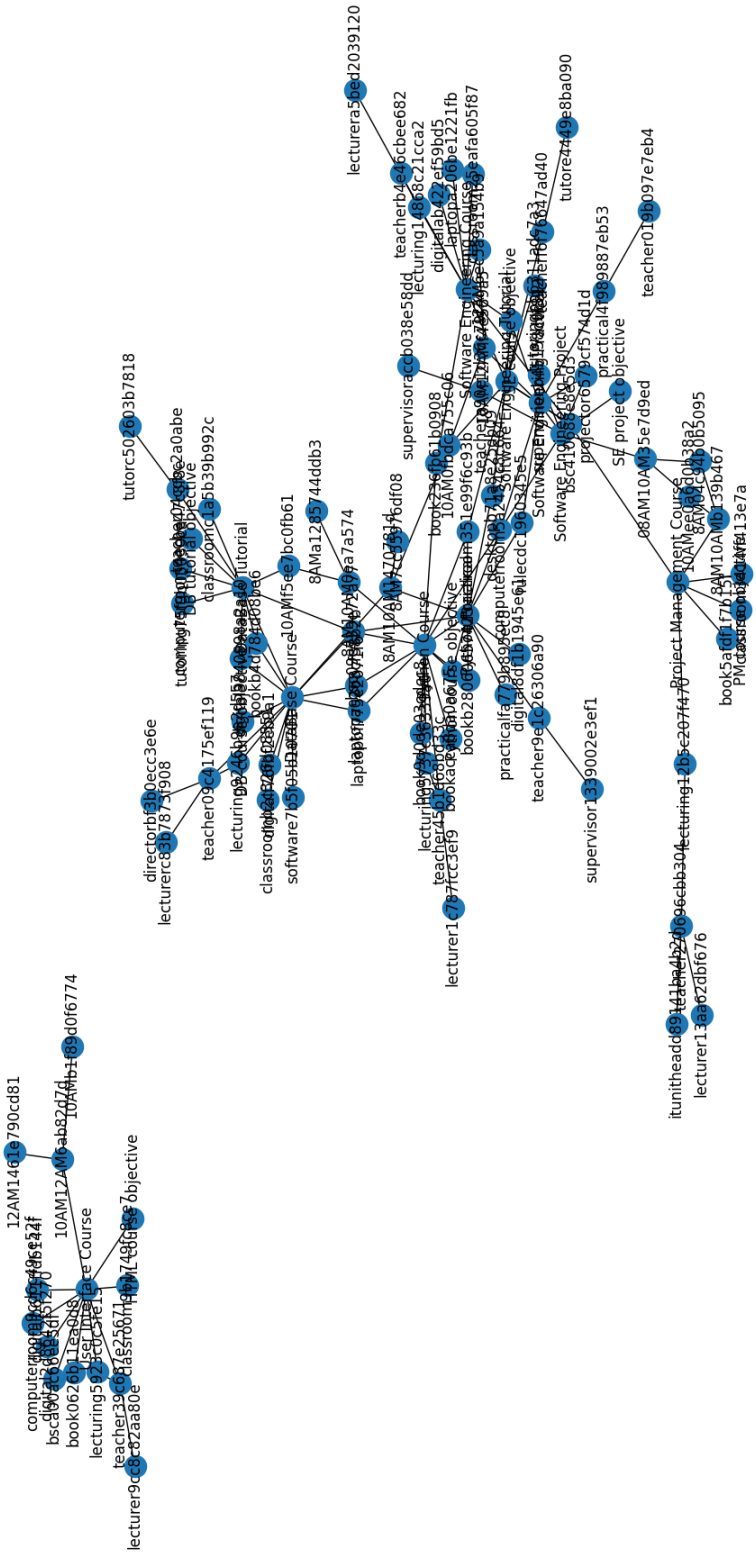

FIGURE 3 – Graphe de connaissance d'activités pivoté pour une meilleure lisibilité en colonne unique.

4.2.1 Pré-traitement

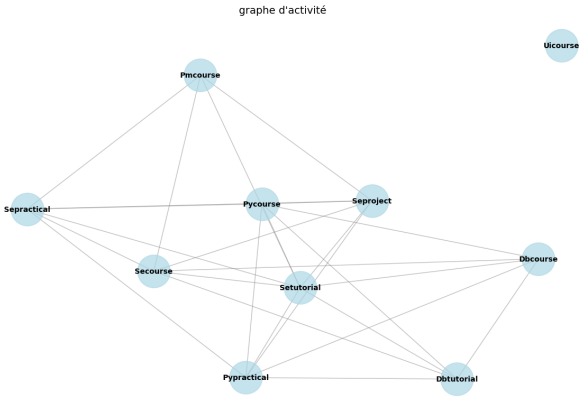

FIGURE 4 – Graphe de connaissance contenant uniquement les activités extraites du graphe de connaissances d'activités de la figure 3

Le graphe de connaissance simplifié d'activités de la figure 4 illustre les relations essentielles entre les différentes activités pédagogiques après la simplification du graphe de connaissances initial. Les dix nœuds représentent les activités principales ("Pmcourse", "Pycourse", "Setutorial", etc.), tandis que les arêtes indiquent les connexions significatives maintenues entre ces activités. La simplification conserve la structure fondamentale tout en réduisant la complexité, permettant d'identifier clairement les liens critiques entre les différentes composantes du système d'apprentissage. Cette représentation épurée facilite l'analyse des relations clé entre les activités pédagogiques et leur organisation en communautés distinctes.

4.2.2 Détection des communautés

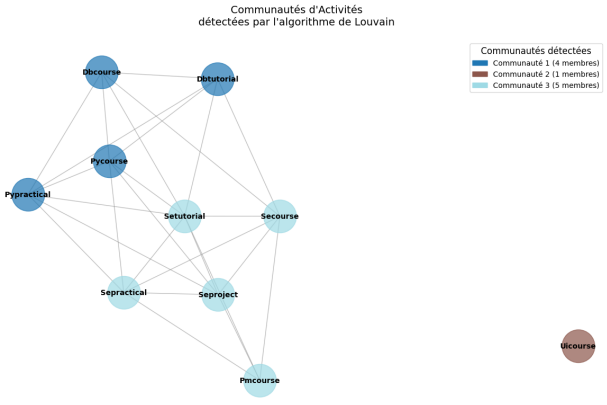

FIGURE 5 – Détection des communautés dans le graphe de connaissance d'activités simplifié de la figure 4

L'application de l'algorithme de Louvain sur le graphe de connaissance d'activités simplifié a permis d'identifier trois communautés distinctes, comme illustrées par la Figure 5. La première communauté comprend 4 membres (Dbcourse, Dbtutorial, Pypractical, Pycourse), représentant les activités liées aux bases de données et à la programmation Python. La deuxième communauté, composée d'un seul membre (Uicourse), suggère une activité indépendante d'interface utilisateur. La troisième communauté regroupe 5 membres (Pmcourse, Seproject, Sepractical, Secourse, Setutorial) centrés sur les activités de gestion de projet et de génie logiciel. Cette détection de communautés révèle une organisation naturelle des activités pédagogiques autour de domaines d'expertise spécifiques.

4.2.3 Post-traitement

La figure 6 correspond à la représentation du graphe de connaissance d'activité en tenant compte des communautés auxquelles appartient chaque activité. Elle permet aussi de voir les ressources partagées entre les activités de la même ou de communautés différentes.

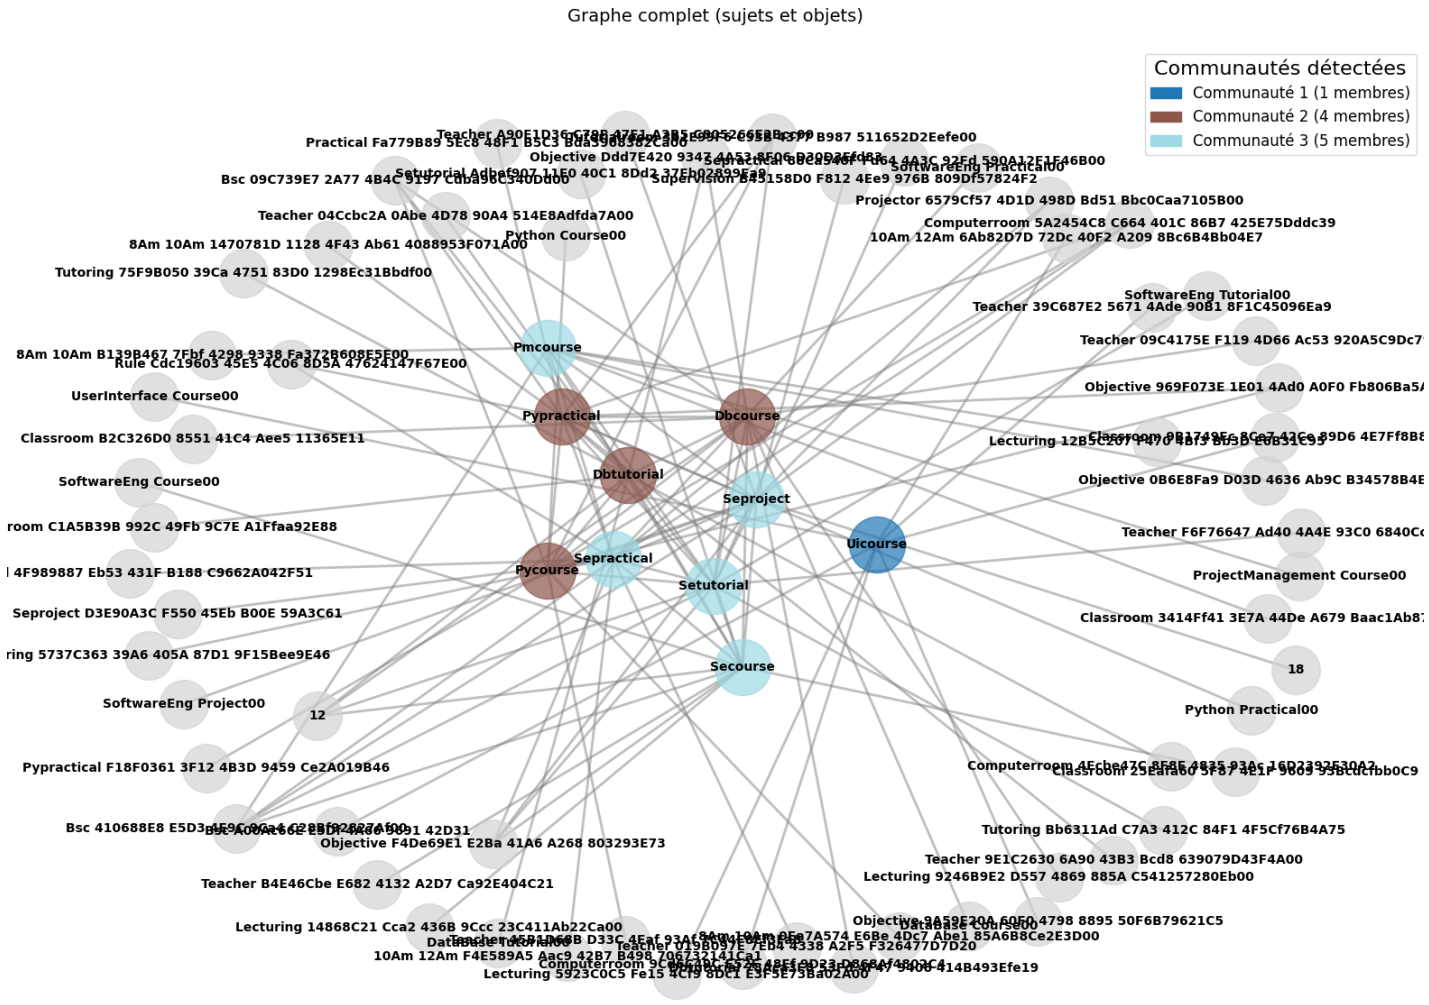

FIGURE 6 – Graphe de connaissance d'activités final obtenu en tenant compte du graphe d'activité simplifié indiquant les communautés de la Figure 5.

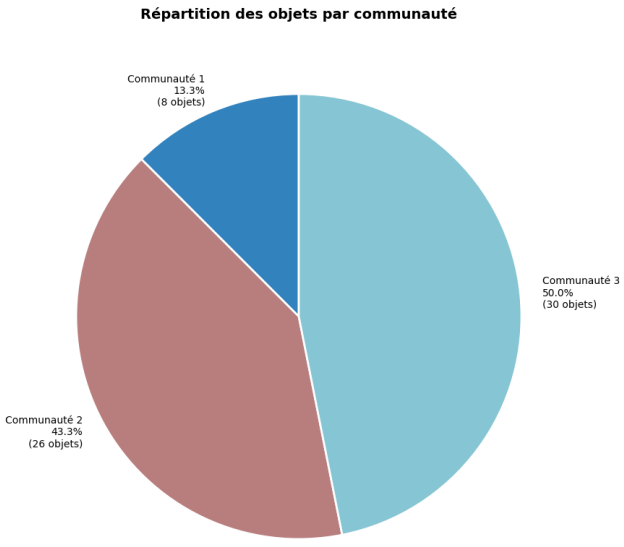

FIGURE 7 – Répartition des communautés détectées sous forme de dendrogramme dans un graphe éducatif.

Le diagramme circulaire de la Figure 7 présente la distribution des objets au sein de trois communautés distinctes. La communauté 3 domine avec 50% de la totalité des objets (30 objets), suivie de la communauté 2 représentant 43,3% (26 objets), tandis que la communauté 1 constitue la plus petite fraction avec 13,3% (8 objets). Cette répartition démontre une concentration significative des objets dans les communautés 2 et 3, qui regroupent ensemble plus de 90% des ressources, suggérant une distribution asymétrique mais potentiellement optimisée pour les besoins du système.

5 Conclusion

Dans cette étude, nous avons démontré l'importance de la détection de communautés dans les graphes de connaissances d'activités pour les organisations. Pour parvenir à la détection de communautés sur les graphes de connaissance d'activités, nous avons proposé une approche

constituée de trois (03) étapes : (1) un pré-traitement du graphe de connaissance d'activité qui permet de simplifier sa structure du graphe de connaissance d'activités initial tout en préservant une sémantique, (2) l'application de l'algorithme de Louvain pour détecter les communautés et (3) un post-traitement pour intégrer les communautés détectées dans le graphe de connaissance d'activités initial. Une application dans le domaine de l'éducation permet d'illustrer l'utilisation de notre approche et de montrer l'importance de la détection des communautés pour la compréhension des graphes de connaissance d'activités dans les organisations.

L'algorithme de Louvain s'est révélé efficace pour regrouper des activités similaires, offrant ainsi une visualisation claire des relations entre activités et facilitant l'analyse des informations pour des prises de décision dans une organisation. Dans notre cas d'étude dans le domaine de l'enseignement, les résultats obtenus soulignent la pertinence de cette méthode pour des applications concrètes.

Cette étude marque la première étape de l'abstraction et de la transformation d'un graphe de connaissance d'activités en une représentation plus digeste pour faciliter la prise de décision dans un domaine par les non-spécialistes. La suite de ce travail consiste d'une part à permettre la possibilité de spécifier la sémantique du type de communautés que l'on souhaite voir, de créer plusieurs niveaux de communautés, permettant de visualiser les communautés de communautés sur des graphes de connaissance d'activités plus complexes et d'autre part à permettre l'interrogation des connaissances inter et intra communautés, dans le but d'inférer des connaissances.

Références

[1] Majid Hameed Ahmed, Sabrina Tiun, Nazlia Omar, and Nor Samsiah Sani. Short text clustering algorithms, application and challenges : A survey. *Applied Sciences*, 13(1) :342, 2022.

[2] Vincent Blondel, Jean-Loup Guillaume, and Renaud Lambiotte. Fast unfolding of communities in large networks : 15 years later. *Journal of Statistical Mechanics : Theory and Experiment*, 2024(10) :10R001, 2024.

[3] Vincent D Blondel, Jean-Loup Guillaume, Renaud Lambiotte, and Etienne Lefebvre. Fast unfolding of communities in large networks. *Journal of statistical mechanics : theory and experiment*, 2008(10) :P10008, 2008.

[4] Cécile Bothorel. *Analyse de Réseaux Sociaux : Détection et Qualification de communautés*. PhD thesis, Université de Bretagne Occidentale (UBO), 2023.

[5] CNAM. Cours sur les graphes et les communautés, 2024.

[6] Jean Delahousse. Graphe de connaissance, ontologie, et vocabulaires contrôlés, 2022. Consulté le 29 Août 2024.

[7] Hossein Hajibabaei, Vahid Seydi, and Abbas Koochari. A motif-based probabilistic approach for community detection in complex networks. *Journal of Intelligent Information Systems*, pages 1–19, 2024.

[8] Abdul Majeed and Ibtisam Rauf. Graph theory : A comprehensive survey about graph theory applications in computer science and social networks. *Inventions*, 5(1) :10, 2020.

[9] Cédric Pruski, Louis Deladiennée, Emmanuel Scolan, and Marcos Da Silveira. Une plateforme de management des connaissances pour le domaine des ressources spatiales. In *Extraction et Gestion des Connaissances : Actes de la conférence EGC'2023*, volume 39. BoD-Books on Demand, 2023.

[10] Naw Safrin Sattar and Shaikh Arifuzzaman. Scalable distributed louvain algorithm for community detection in large graphs. *The Journal of Supercomputing*, 78(7) :10275–10309, 2022.

[11] Serge Sonfack Sounchio, Thierry Coudert, Bernard Kamsu Foguem, Laurent Geneste, Cédrick Beler, and Sina Namakiaraghi. Organizations' interpersonal activity knowledge representation. In *HHAI 2023 : Augmenting Human Intellect*, pages 254–262. IOS Press, 2023.

[12] Serge Sonfack Sounchio, Laurent Geneste, Bernard Kamsu-Foguem, Cédrick Béler, Sina Namaki Araghi, and Muhammad Raza Naqvi. An enterprise architecture for interpersonal activity knowledge management. In *Iberoamerican Knowledge Graphs and Semantic Web Conference*, pages 66–81. Springer, 2023.

[13] Serge Sonfack Sounchio, Trawina Halguieta, Baudelaire Ismael Nguekeu Tankeu, Laurent Geneste, and Bernard Kamsu-Foguem. Interpersonal activity knowledge graph for organizations. *Article*, 2023.

[14] Serge Sonfack Sounchio, Halguieta Trawina, Baudelaire Ismael Tankeu Nguekeu, Laurent Geneste, and Bernard Kamsu-Foguem. Activity knowledge graph (akg).

[15] Jiajing Wu. Construct a knowledge graph for china coronavirus (covid-19) patient information tracking. *Risk Management and Healthcare Policy*, pages 4321–4337, 2021.

[16] Bibao Yao, Peijie Zhu, Zhuand Ma, Kun Gao, and Xuezao Ren. A constrained louvain algorithm with a novel modularity. *Applied Sciences*, 13(6) :4045, 2023.

[17] Silvia Zaoli, Giovanni Scaini, and Lorenzo Castelli. Community detection for air traffic networks and its application in strategic flight planning. *Sustainability*, 13(16) :8924, 2021.