

Une méthode à base de réseaux de neurones pour la simplification des graphes multicouches dans un contexte de classification des noeuds

Cheick Tidiane Ba*, Roberto Interdonato **
Dino Ienco ***, Sabrina Gaito*

* University of Milan, Italy, {cheick.ba,sabrina.gaito}@unimi.it

** CIRAD, UMR TETIS, France, roberto.interdonato@cirad.fr

***INRAE, UMR TETIS, France, dino.ienco@inrae.fr

Résumé. Les réseaux multicouches sont un modèle largement utilisé, conçu pour fournir une représentation plus réaliste des relations hétérogènes qui peuvent caractériser un système complexe. Néanmoins, la prise en compte de ces informations complexes est un défi majeur du fait du bruit contenu dans les données et du choix des entités et des relations à tenir en compte dans l'analyse. Pour cette raison, des techniques de simplification multicouches ont été proposées afin de sélectionner les informations importantes, améliorer les temps de calculs et la qualité de l'analyse ainsi que la visualisation des informations contenues dans ces réseaux multicouches. Néanmoins, ces techniques sont agnostiques et reposent sur des heuristiques non supervisées. Dans ce travail, nous proposons un cadre pour simplifier des réseaux multicouches en fonction de la tâche d'analyse finale. Nous nous appuyons sur deux composants principaux : i) un module de simplification des relations entre noeuds et ii) un réseau neuronal à graphe (multicouche) pour générer des plongements de nœuds dans le but de résoudre une tâche spécifique. Ici, nous nous attaquons à la tâche de classification des nœuds mais la méthode est directement transposable à d'autres tâches (supervisées) d'analyse de réseaux multicouches. Les résultats expérimentaux sur différents réseaux multicouches réels prouvent l'importance de notre approche qui fournit une simplification adaptée à la tâche de classification des nœuds.

1 Introduction

Le domaine de recherche de l'analyse et de l'exploitation des réseaux complexes a gagné en popularité au cours des deux dernières décennies grâce à la capacité des réseaux à modéliser un large éventail de phénomènes de la vie réelle, des systèmes physiques aux systèmes biologiques et sociaux, des données scientifiques aux données financières, des voies de transport, et bien d'autres encore. À cet égard, le modèle de réseau multicouche est largement utilisé comme un outil puissant pour représenter l'organisation et les relations de systèmes complexes couvrant de nombreux domaines différents. Les réseaux multicouches sont conçus pour fournir une représentation plus réaliste des relations différentes et hétérogènes qui peuvent caractériser une entité dans le système, en utilisant les données disponibles décrivent les systèmes

complexes (Interdonato et al., 2020b). Néanmoins, la collecte d'un large ensemble de relations hétérogènes entre des nombreuses entités peut facilement entraîner une quantité importante de *bruit* ou d'informations redondantes causées par le choix des entités et des relations à inclure dans les données (le problème de la spécification des limites (Dickison et al., 2016)). Des cadres comme (Zangari et al., 2021), suggèrent l'importance d'introduire des approches de simplification pour le réseau multicouche. L'application directe d'approches monocouche aux réseaux multicouches n'est pas triviale : si une approche monocouche peut être appliquée à chaque couche indépendamment, l'interaction entre les différentes couches serait perdue. Un cadre de simplification spécifiquement adapté à cette famille de modèles de réseaux est d'une importance capitale pour tirer pleinement parti de la structure multicouche.

C'est pourquoi plusieurs techniques de prétraitement ont été proposées afin de simplifier un réseau multicouche avec l'objectif d'améliorer la qualité des données, les performances de calcul et la visualisation des informations. Malheureusement, les quelques méthodes de simplification proposées jusqu'à maintenant (Interdonato et al., 2020b) sont entièrement non supervisées et agnostique d'une tâche particulière. Ceci peut limiter l'utilisation des réseaux multicouche simplifiés pour des applications de classification de noeuds ou de prédiction de liens, par exemple. Pour palier à la problématique de simplification d'un réseau multicouche pour la tâche de classification des noeuds, dans ce travail, nous proposons un nouveau cadre méthodologique. Par rapport à d'autres approches de simplification pour les réseaux multicouches, cette approche a l'avantage d'être adaptée aux spécificités du réseaux multicouches. L'évaluation sur différents jeux de données montre que la solution proposée conduit à une augmentation des performances, tandis que l'utilisation d'un graphe réduit peut conduire à une réduction des coûts de calcul, promouvoir l'explicabilité des modèles d'apprentissage automatique ainsi qu'une meilleure visualisation des informations pour l'exploration des réseaux. En raison du large éventail de données qui peuvent être modélisées sous la forme d'un réseau multicouche, le cadre proposé a, potentiellement, un large champ d'application couvrant différents domaines comme la biologie, la physique et l'analyse médicale/santé, où une robustesse accrue est nécessaire pour faire face au bruit provenant de l'acquisition de données.

2 État de l'art

Réseaux de neurones à graphe. Dans le domaine de l'apprentissage profond pour les données structurées en graphes, les réseaux neuronaux à graphe (GNN) se sont imposés comme l'approche de pointe dans de nombreuses tâches, telles que la classification des noeuds, la prédiction des liens, la détection des communautés et la classification des graphes. Les GNN redéfinissent les opérations de base de l'apprentissage profond, comme la convolution, pour les données structurées en graphe. Dans le modèle de réseau convolutif de graphes (GCN) proposé par (Kipf et Welling, 2016), l'opération de convolution sur les graphes est effectuée par une agrégation des valeurs des caractéristiques de chaque noeud avec celles de ses voisins. Le modèle de réseau d'attention aux graphes (GAT) (Veličković et al., 2017) apprend les poids entre chaque paire de noeuds connectés ; un mécanisme d'auto-attention est utilisé pour découvrir les parties les plus représentatives de l'entrée.

Réseaux de neurones pour graphe multicouche. Les réseaux multicouches sont conçus pour fournir une représentation plus réaliste des relations différentes et hétérogènes qui peuvent caractériser une entité dans le système de réseau, en utilisant les riches données disponibles des

systèmes complexes (Interdonato et al., 2020b). Les tâches d'apprentissage profond sont plus difficiles sur ces réseaux en raison de la présence de relations intra-couche et inter-couche, des différentes caractéristiques des couches, ainsi que des caractéristiques des nœuds. Des tentatives ont été faites pour concevoir des méthodes et des cadres d'apprentissage profond pour les réseaux multicouches. Des résultats de pointe ont été obtenus par le cadre présenté dans (Zangari et al., 2021). Ce cadre reformule la règle de propagation du composant GNN (c'est-à-dire GCN ou GAT) pour agréger les informations de voisinage topologique provenant de différentes couches. Alors que dans le GCN, l'agrégation fait intervenir les caractéristiques d'un nœud et celles de ses voisins, dans le ML-GCN, l'agrégation est effectuée à la fois sur ses voisins dans cette couche (appelée voisinage interne à la couche) et sur ses voisins situés dans d'autres couches où l'entité est présente (appelée voisinage externe à la couche).

Simplification du réseau. La simplification des graphes consiste à supprimer les arêtes redondantes tout en conservant presque toutes les informations du graphe d'entrée (Rong et al., 2020). Parmi les méthodes récentes, DropEdge (Rong et al., 2020) simplifie le réseau pour un modèle GNN (par exemple GCN, GAT) en supprimant de manière aléatoire une fraction des arêtes du graphe d'entrée pendant la phase de formation. NeuralSparse (Zheng et al., 2020) propose un processus de simplification effectué par le biais d'un réseau neuronal profond : pendant la phase d'entraînement, le réseau neuronal profond apprend une stratégie de simplification qui favorise les tâches en aval. Dans la phase de test, ce réseau est utilisé pour sélectionner les arêtes à supprimer du graphe d'entrée, sur la base de la stratégie apprise. Dans AdaptiveGCN (Li et al., 2021), le processus de simplification est mené par un DNN comme dans NeuralSparse, mais une étape de simplification est effectuée avant chaque étape de convolution du graphe. D'autres travaux (Wickman et al., 2021; Wang et al., 2019) ont conçu des cadres pour la simplification avec l'apprentissage par renforcement profond. Mais tous ces travaux sont conçus pour des réseaux à une seule couche.

Simplification des réseaux multicouche. Bien que les réseaux multicouches offrent une représentation plus réaliste et plus riche des systèmes complexes (Interdonato et al., 2020b), ils présentent certains inconvénients : la collecte d'un large ensemble de relations différentes entre un grand nombre d'entités peut facilement entraîner une quantité importante de *bruit* ou d'informations redondantes causées par le choix des entités et des relations à inclure dans les données (le problème de la spécification des limites (Dickison et al., 2016)). Pour cette raison, plusieurs techniques de prétraitement ont été proposées afin de *simplifier* un réseau multicouche : ces méthodes permettent d'améliorer la qualité des données, les performances de calcul et la visualisation des informations (Interdonato et al., 2020b). Cependant, il y a un manque de travaux adaptés pour les graphes multicouche.

3 Méthodologie proposée

Dans ce travail, nous proposons un framework pour attaquer la simplification d'un réseaux multicouches finalisée à l'amélioration des performances d'une tâche de classification. Plus précisément, nous nous concentrons sur la tâche de classification des nœuds dans un réseaux multicouche.

Définition du problème. Étant donné un ensemble \mathcal{V} d'entités, et un ensemble de couches $\mathcal{L} = L_1, \dots, L_l$ avec $|\mathcal{L}| = L \geq 2$, un réseau multicouche est défini comme $\mathcal{G}_{\mathcal{L}} = (\mathcal{V}_{\mathcal{L}}, \mathcal{E}_{\mathcal{L}}, \mathcal{V}, \mathcal{L})$, où $\mathcal{V}_{\mathcal{L}} \subseteq \mathcal{V} \times \mathcal{L}$ est l'ensemble des paires entité-couche ou nœuds (c'est-à-dire, pour indiquer


quels utilisateurs sont présents dans quelles couches), et $\mathcal{E}_{\mathcal{L}} = \mathcal{V}_{\mathcal{L}} \times \mathcal{V}_{\mathcal{L}}$ est l'ensemble des arêtes dirigées entre les nœuds, au sein des couches (*within layer* ou *intra-layer*) et entre les couches (*across layers* ou *inter-layer*). Nous voulons évaluer l'impact des approches de simplification de réseau dans les tâches de classification de nœuds. Le problème de simplification de réseau sur les graphes à couche unique peut être défini comme suit : étant donné un graphe $G(V, E, X_E, X_V)$, où V est un ensemble de n nœuds, $E \subset V \times V$ est l'ensemble des arêtes ; X_V est un ensemble d'attributs de nœuds, X_E est un ensemble d'attributs d'arêtes. La simplification vise à obtenir un sous-graphe de G , qui serait $G' = G(V', E', X_E, X_V)$, où $V' \subset V \vee E' \subset E$. Alors que sur les réseaux multicouches, on peut définir la simplification comme suit : le problème d'obtention d'un réseau $f_{\theta_S}(\mathcal{G}_{\mathcal{L}}) = \mathcal{G}_{\mathcal{L}'} = (\mathcal{V}_{\mathcal{L}'}, \mathcal{E}_{\mathcal{L}'}, \mathcal{V}, \mathcal{L}')$ tel que la disjonction de conditions suivante soit vérifiée : $|\mathcal{V}| < |\mathcal{V}'| \vee |\mathcal{L}| < |\mathcal{L}'| \vee |\mathcal{V}_{\mathcal{L}'}| < |\mathcal{V}_{\mathcal{L}}| \vee |\mathcal{E}_{\mathcal{L}'}| < |\mathcal{E}_{\mathcal{L}}|$.

Simplification Layer-by layer (couche par couche). Afin d'effectuer une simplification multicouche avec des méthodes conçus pour les réseaux à une seule couche, nous pouvons utiliser une approche couche par couche (cf. Fig. 1a). Nous définissons un graphe de couches $G[\ell]$ où chaque arête relie les nœuds de la même couche ℓ . Par conséquent, à chaque couche ℓ , un réseau de simplification f_{θ_S} détecte les liens bruyants sur $G[\ell]$, générant une nouvelle version du graphe $G[\ell']$. Par conséquent, pour chaque couche, nous pouvons entraîner un réseau neuronal à graphe (GNN) $f_{W_{\ell}}$, afin de générer des plongements de nœuds pour la tâche en aval. Dans le cas spécifique de la classification des nœuds, nous pouvons obtenir une prédiction en utilisant un système de vote majoritaire (i.e., sur les prédictions produits par chaque couche).


Multilayer network simplification. Afin de définir une méthodologie de simplification expressément conçue pour une réseau multicouche, en prenant en compte toute la complexité structurelle de ce modèle, on propose d'utiliser un réseau neuronal de simplification f_{θ} qui détecte les liens bruyants et un réseau neuronal à graphe multicouche f_W qui est utilisé pour générer des plongements de nœuds pour une tâche de classification en aval (cf. Fig. 1b). Plus précisément, dans ce travail on va utiliser ML-GCN (Zangari et al., 2021) pour generer les plongements multicouche, et DropEdge (Rong et al., 2020) pour détecter les liens bruyants.

4 Évaluation expérimentale

Données. Les jeux de données sélectionnés pour notre évaluation expérimentale, provenant de différents domaines et caractérisés par différentes caractéristiques structurelles, ont déjà été utilisés pour l'évaluation du modèle ML-GCN dans (Zangari et al., 2021). Nous disposons d'un premier ensemble de réseaux multiplexés, c'est-à-dire de réseaux dans lesquels les connexions inter-couches sont uniquement des arêtes de couplage, reliant un nœud et ses homologues dans d'autres couches. Ces réseaux ne fournissent pas non plus d'attributs associés aux entités - nous les initialisons avec du bruit. Font partie de cette catégorie les réseaux : CKM-Social (informations sociales provenant d'une réseau des physiciens), Congress (16 votes effectués par le congrès américain en 1984), DKPol (un réseau avec trois types de relations entre les membres du Parlement Danois sur Twitter), Starwars (interactions entre les personnages de Star Wars dans les 6 premiers épisodes de la saga), Terrorist (interactions entre les terroristes provenant du réseau Nordin), Vickers (relations sociales entre 29 étudiants). Un deuxième sous-ensemble est composé de réseaux avec des caractéristiques de nœuds réelles, le jeu de données du réseau Koumbia (Interdonato et al., 2020a) : les réseaux sont générés avec le framework geo2net (In-



(a) Simplification du réseau couche par couche : à chaque couche ℓ , un réseau de simplification $f_{\theta_S}^\ell$ détecte les liens bruyants et tandis qu'un GNN f_{W^ℓ} génère des plongements de nœuds pour une tâche en aval.



(b) Simplification d'un réseau multicouche : un réseau de simplification f_θ détecte les liens bruyants et un réseau neuronal à graphe multicouche f_W est utilisé pour générer des plongements de nœuds pour une tâche de classification en aval.

FIG. 1 – Aperçu des approches proposées pour la simplification des réseaux multicouches.

terdonato et al., 2020a), qui est conçu pour construire un réseau multicouche (avec un nombre arbitraire de couches) à partir d'une série temporelle d'images satellites. Par conséquent, nous pouvons tester différentes versions du réseau avec un nombre variable de couches (c'est-à-dire 2, 5, 10). Nous considérons une version multiplex de ce jeu de données, obtenue en éliminant les connexions intercouches autres que celles de couplage), appelée "Koumbia MPX 1" avec $l=2,5,10$. Tab. 1 résume les propriétés structurelles des réseaux utilisés.

Cadre expérimental. Dans ce travail, nous testons un total de 4 méthodes : pour évaluer l'impact de la simplification couche par couche, nous entraînons la version de base **MAJ-GCN** et une version avec simplification DropEdge **MAJ-GCN-DE**; tandis que pour vérifier les effets de la simplification multicouche, nous exécutons le modèle **ML-GCN** et une version avec DropEdge **ML-GCN-DE**. Le taux de suppression de DropEdge pour MLGCN est fixé à 20% alors que pour MAJ-GCN il est fixé à 10%. Nous effectuons toutes les expériences avec un cadre d'apprentissage transductif comme dans (Zangari et al., 2021). Dans un cadre transductif, tous les attributs des nœuds et les informations topologiques peuvent être utilisés pour l'apprentissage, alors que seulement 25% de l'ensemble des étiquettes sont visibles pour le modèle GNN. Tous les modèles ont été entraînés à l'aide de l'algorithme d'optimisation d'Adam avec une taille de batch complète, pour 1000 epochs, avec un taux d'apprentissage fixé à 0.005,

TAB. 1 – Résumé des caractéristiques structurelles des jeux de données : type de réseau, nombre de couches (l), nombre d’entités ou d’acteurs (a), nombre de noeuds (n), nombre d’arêtes (e), densité moyenne/DS sur les couches et nombre de classes (c).

dataset	couche	noeuds	arêtes	intra arêtes	densité	n. de classes
CKM SOCIAL	3	723	4909	3463	0.0200 ± 0.0011	4
CONGRESS	16	6960	1527104	1422704	0.4710 ± 0.0242	2
DKPOL	3	1470	42175	41235	0.0574 ± 0.0765	10
STARWARS	6	552	1397	1147	0.0228 ± 0.0087	3
TERRORIST	4	316	2529	2049	0.0831 ± 0.0520	2
VICKERS	3	87	1001	827	0.3395 ± 0.0999	2
KOUMBIA MPX 2	2	4492	8257	8257	0.0008 ± 0.0001	2
KOUMBIA MPX 5	5	11230	20022	16646	0.0007 ± 0.0002	2
KOUMBIA MPX 10	10	22460	52888	34624	0.0007 ± 0.0002	2

TAB. 2 – Accuracy (moyenne et écart-type sur 10 exécutions) obtenus par les méthodes proposées et les concurrents pour chaque modèle, configuration fixe.

	Baseline		DE Sparsification	
	MLGCN	MAJ-GCN	MLGCN-DE	MAJ-GCN-DE
CKM SOCIAL	82.91 ± 2.42	91.87 ± 1.71	84.67 ± 4.05	93.08 ± 1.51
CONGRESS	93.67 ± 1.14	87.74 ± 0.62	94.10 ± 1.18	88.10 ± 1.15
DKPOL	79.92 ± 1.89	48.16 ± 10.50	81.78 ± 2.04	57.08 ± 15.66
STARWARS	72.46 ± 3.55	82.32 ± 0.61	68.99 ± 6.23	82.46 ± 0.82
TERRORIST NORDIN	72.17 ± 9.62	75.00 ± 3.33	74.33 ± 8.25	77.33 ± 4.46
VICKERS	98.64 ± 3.07	97.73 ± 3.21	96.36 ± 3.59	98.64 ± 2.20
KOUMBIA MPX 2	75.12 ± 1.13	80.81 ± 0.93	79.37 ± 1.21	81.40 ± 0.43
KOUMBIA MPX 5	82.34 ± 1.21	83.74 ± 0.77	83.01 ± 1.25	82.85 ± 1.99
KOUMBIA MPX 10	81.63 ± 0.97	79.58 ± 3.72	83.07 ± 1.16	78.33 ± 4.48

une régularisation de poids L2 fixée à 0.0005 et une technique de régularisation dropout avec $p = 0.6$ appliquée aux couches cachées. Pour chaque réseau et méthode, l’accuracy moyenne a été calculée sur 10 exécutions indépendantes, où chaque exécution correspondait à une répartition différente entre le train et le test set, avec 25% d’entités d’entraînement. Pour les réseaux sans information externe, les attributs des noeuds ont été initialisés de manière aléatoire en échantillonnant chaque attribut à partir d’une distribution gaussienne.

5 Résultats

Dans cette section, nous présentons les résultats de l’évaluation expérimentale pour chaque réseau et méthode. Nous séparons les résultats sur les réseaux sans caractéristiques réelles et les réseaux et avec caractéristiques réelles (i.e., les trois variants de *Koumbia*). Le tableau 2 présente les scores d’accuracy moyens obtenus par les méthodes proposées et les méthodes de référence. Nous pouvons observer que : ML-GCN-DE obtient de meilleures performances que ML-GCN sur tous les jeux de données. Pour la version couche par couche, l’effet n’est pas aussi évident. De plus, MAJ-GCN est plus performant que l’approche MLGCN sur certains jeux de données (e.g., ckm, koumbia mpx2, vickers). Le tableau 3 rapporte les scores

TAB. 3 – Accuracy (moyenne et écart-type sur 10 exécutions) obtenue par les méthodes proposées et les concurrents pour chaque modèle, configuration fixe.

	Baseline		DE Sparsification	
	MLGCN	MAJ-GCN	MLGCN-DE	MAJ-GCN-DE
KOUMBIA 2	88.68 ± 0.92	89.11 ± 0.61	89.60 ± 0.62	89.03 ± 1.08
KOUMBIA 5	93.94 ± 0.37	93.79 ± 0.73	93.75 ± 0.41	93.72 ± 0.53
KOUMBIA 10	94.04 ± 0.43	94.43 ± 0.67	94.22 ± 0.61	94.49 ± 0.52

d’accuracy moyens avec les réseaux avec caractéristiques réelles. On peut noter comment les méthodes de simplification entraînent des améliorations sur KOUMBIA 2 (MLGCN-DE) et KOUMBIA 10 (MAJ-GCN-DE). Nous pouvons noter que MAJ-GCN et MAJ-GCN-DE montrent souvent les meilleures performances sur les 3 jeux de données. Le fait que l’approche couche par couche soit meilleure ne dépend pas de la simplification DE, mais il est en accord avec les observations des auteurs dans le travail (Zangari et al., 2021), c’est-à-dire que le GCN simple pour les réseaux à couche unique peut être plus performante que sa version multicouche sur certains jeux de données. Dans MAJ-GCN, les modèles GCN semblent être déjà efficaces sur les couches séparées, tandis que le vote d’ensemble majoritaire conduit à une prédiction encore plus robuste - soulignant la valeur ajoutée d’une structure de réseau multicouche. Cependant, avec d’autres ensembles de données, les modèles à couche unique sont peu performants sur les couches, alors que les modèles MLGCN sont capables de surmonter ce problème. Une raison de ce phénomène peut résider dans le fait que dans certains cas, les couches sont complémentaires les unes des autres (c’est-à-dire que l’approche couche par couche ne sera pas efficace), alors que dans d’autres cas, chaque couche peut apporter suffisamment d’informations pour aboutir à un résultat fiable. Dans l’ensemble, le résultat clé est que la simplification du réseau conduit à une amélioration généralisée de la performance, tant avec les modèles à couche unique qu’avec les modèles multicouches.

6 Conclusions

Dans ce travail de recherche nous avons proposé un cadre pour simplifier des réseaux multicouches en fonction de la tâche d’analyse finale, dans notre cas la classification de noeuds. Nous nous sommes appuyés sur deux composants principaux : i) un module de simplification des relations entre noeuds et ii) un réseau neuronal à graphe (multicouche) pour générer des plongements de nœuds dans le but de résoudre une tâche spécifique. Les résultats expérimentaux sur différents réseaux multicouches réel ont prouvé l’importance de notre approche qui fournit une simplification adaptée à la tâche de classification des nœuds. Dans des travaux futurs, nous prévoyons d’étendre notre étude à d’autres tâches en aval (i.e. la détection d’arêtes) ainsi que d’étendre d’autres méthodes de simplification au cas de réseaux multicouches.

Références

Dickison, M. E., M. Magnani, et L. Rossi (2016). *Multilayer social networks*. Cambridge University Press.

- Interdonato, R., R. Gaetano, D. L. Seen, M. Roche, et G. Scarpa (2020a). Extracting multilayer networks from sentinel-2 satellite image time series. *Network Science* 8(S1), S26–S42.
- Interdonato, R., M. Magnani, D. Perna, A. Tagarelli, et D. Vega (2020b). Multilayer network simplification : approaches, models and methods. *Comput. Sci. Rev.* 36, 100246.
- Kipf, T. N. et M. Welling (2016). Semi-supervised classification with graph convolutional networks. *arXiv preprint arXiv :1609.02907*.
- Li, D., T. Yang, L. Du, Z. He, et L. Jiang (2021). Adaptivegcn : Efficient gcn through adaptively sparsifying graphs. *Proceedings of the 30th ACM International Conference on Information & Knowledge Management*.
- Rong, Y., W. Huang, T. Xu, et J. Huang (2020). Dropedge : Towards deep graph convolutional networks on node classification. In *ICLR*.
- Veličković, P., G. Cucurull, A. Casanova, A. Romero, P. Lio, et Y. Bengio (2017). Graph attention networks. *arXiv preprint arXiv :1710.10903*.
- Wang, L., W. Yu, W. Wang, W. Cheng, W. Zhang, H. Zha, X. feng He, et H. Chen (2019). Learning robust representations with graph denoising policy network. *2019 IEEE International Conference on Data Mining (ICDM)*, 1378–1383.
- Wickman, R., X. Zhang, et W. Li (2021). Sparrl : Graph sparsification via deep reinforcement learning. *ArXiv abs/2112.01565*.
- Zangari, L., R. Interdonato, A. Calió, et A. Tagarelli (2021). Graph convolutional and attention models for entity classification in multilayer networks. *Applied Network Science* 6(1), 1–36.
- Zheng, C., B. Zong, W. Cheng, D. Song, J. Ni, W. Yu, H. Chen, et W. Wang (2020). Robust graph representation learning via neural sparsification. In *ICML*.

Summary

Multilayer networks are a widely used model that provide a more realistic representation of the heterogeneous relationships that can characterise a complex system. Nevertheless, taking into account this complex information is a major challenge due to the noise contained in the data and the choice of entities and relationships to be taken into account in the analysis. For this reason, multi-layer simplification techniques have been proposed in order to select important information, reduce the computational burden and ameliorate the quality of the analysis as well as the visualisation of the information contained in these multilayer networks. Unfortunately, all the techniques proposed so far are task-agnostic and rely on unsupervised heuristics. In this work, we propose a framework to simplify multi-layer networks according to the final downstream task. We rely on two main components: i) a node relationship simplification module and ii) a (multi-layer) graph neural network to generate node embeddings for the purpose of solving a specific task. Here, we tackle the node classification task as goal but the method is directly transposable to other (supervised) multilayer network analysis tasks. Experimental results on different real multilayer networks prove the quality of our approach which provides a suitable simplification for the node classification task.