

# Apprentissage Multi-Échelle Global-Local de Représentations de Nœuds par Marches Aléatoires et Optimisation Guidée par Points de Repère

Ali Assi<sup>1</sup>, Nour Elislem Karabadji<sup>2</sup>, Mohamed Elati<sup>3</sup>, Wajdi Dhifli<sup>3</sup>

<sup>1</sup> Rochester Institute of Technology, Dubai, United Arab Emirates

<sup>2</sup> National Higher School of Technology and Engineering, Annaba, Algeria

<sup>3</sup> Univ. Lille, Inserm, CHU Lille, CNRS, U1366-UMR9020 – CRCLille – Cancer Research Center of Lille, Lille, F-59000, France

ali.assi@rit.edu, n.karabadji@ensti-annaba.dz,  
mohamed.elati@univ-lille.fr, wajdi.dhifli@univ-lille.fr

## Résumé

L'apprentissage de représentations vectorielles (*embeddings*) de nœuds en faible dimension est fondamental pour diverses tâches d'apprentissage sur graphes. Nous introduisons GLOW, une approche optimisant conjointement : 1) l'information structurelle locale et contextuelle, capturée via des marches aléatoires, et 2) le positionnement global, approximé par des nœuds de repère (*landmarks*). La méthode utilise la divergence de Kullback-Leibler pour aligner ces deux aspects dans l'espace des représentations. Évaluée sur la classification de nœuds et la prédiction de liens, GLOW démontre des améliorations substantielles par rapport à l'état de l'art. Cet article est un résumé de notre publication à CIKM 2025 [2].

## Mots-clés

Apprentissage de représentations, Embedding de nœuds, Marches aléatoires, Classification, Prédiction de liens.

## Abstract

Learning low-dimensional node representations is fundamental to graph learning tasks. We introduce GLOW, an approach that jointly optimizes : 1) local structural information captured through random walks, and 2) global positioning approximated using landmark nodes. Evaluated on node classification and link prediction, GLOW demonstrates substantial improvements over the state-of-the-art. This paper is a summary of our publication at CIKM 2025 [2].

## Keywords

Representation learning, Node embedding, Random walk, Link prediction, Node classification.

## 1 Introduction

Les graphes sont largement adoptés pour modéliser des données relationnelles dans divers domaines (réseaux sociaux, molécules, réseaux de citations, etc.). L'apprentis-

sage de représentations (*embeddings*) de nœuds en faible dimension est crucial pour des tâches telles que la classification de nœuds et la prédiction de liens. De nombreuses méthodes récentes s'appuient sur des marches aléatoires [1, 3, 7] pour capturer des voisinages locaux, ou sur les réseaux de neurones sur graphes (GNN) [4, 8] pour propager l'information entre nœuds voisins. Toutefois, ces approches peinent souvent à préserver simultanément les proximités locales et le positionnement global des nœuds dans le graphe.

Pour surmonter ces limites, nous proposons GLOW (Global-Local Optimization for random Walk and landmark-based node embeddings) [2]<sup>1</sup>, un algorithme non supervisé qui intègre l'information structurelle locale capturée via un modèle de langage appliqué sur des marches aléatoires [6], et affine ces représentations en utilisant un ensemble stratégiquement sélectionné de nœuds de repère (*landmarks*) pour approximer le positionnement global.

## 2 Apprentissage de représentations avec GLOW

Soit un graphe  $\mathcal{G} = (\mathcal{V}, \mathcal{E})$ . L'objectif de GLOW est d'apprendre une fonction d'*embedding*  $f: \mathcal{V} \rightarrow \mathbb{R}^d$  ( $d \ll |\mathcal{V}|$ ) qui préserve la structure locale et globale du graphe.

### 2.1 Information locale par marches aléatoires

Un ensemble de marches aléatoires est généré pour chaque nœud  $v \in \mathcal{V}$ . Ces séquences sont traitées comme des phrases dans un modèle sémantique de type Skip-gram [6], produisant une matrice de représentations initiale  $\mathbf{E} \in \mathbb{R}^{n \times d}$  capturant le voisinage direct (1-hop) et contextuel ( $N$ -hop) de chaque nœud.

1. <https://github.com/wajdidhifli/GLOW>

## 2.2 Positionnement global par nœuds de repère

Un sous-ensemble  $\mathcal{L} \subset \mathcal{V}$  de nœuds de repère ( $|\mathcal{L}| \ll |\mathcal{V}|$ ) est sélectionné de manière diversifiée : le premier landmark est le nœud de plus haut degré dans chaque composante connexe, puis les suivants sont choisis en maximisant la distance aux landmarks déjà sélectionnés. Pour les graphes à composantes déconnectées, un nœud “pont” est ajouté, relié au landmark de plus haut degré de chaque composante, afin de permettre le calcul des plus courts chemins inter-composantes (avec un terme de pénalité  $\gamma$  pour préserver la séparation structurelle).

Les distances des plus courts chemins entre chaque nœud et les landmarks forment une matrice  $\mathbf{SG} \in \mathbb{R}^{n \times |\mathcal{L}|}$ , représentant le positionnement global. Une matrice correspondante  $\mathbf{SEG} \in \mathbb{R}^{n \times |\mathcal{L}|}$  est calculée à partir des distances cosinus entre les *embeddings* des nœuds et ceux des landmarks dans l’espace  $\mathbf{E}$ . Après normalisation L1 ligne par ligne des deux matrices, la divergence de Kullback-Leibler (KL) [5] est utilisée comme fonction de perte :

$$Loss_{KL}(\mathbf{E}) = \sum_{i=1}^{|\mathcal{V}|} \sum_{j=1}^{|\mathcal{L}|} \mathbf{SG}_{ij} \log \left( \frac{\mathbf{SG}_{ij}}{\mathbf{SEG}_{ij}} \right) \quad (1)$$

En minimisant cette perte par descente de gradient, les représentations se raffinent itérativement pour aligner les relations de similarité dans l’espace d’*embedding* avec les distances structurelles du graphe.

## 3 Évaluation expérimentale

GLOW est évalué sur la classification de nœuds (Accuracy) et la prédiction de liens (AUC), sur sept jeux de données réels.

**Prédiction de liens.** Le Tableau 1 présente les résultats AUC (moyenne sur 10 exécutions) sur Cora, Citeseer et Pubmed. GLOW obtient systématiquement les meilleurs scores, surpassant toutes les approches concurrentes, y compris les méthodes GNN récentes (SEAL, NBF-net, HPLC) et les approches par marches aléatoires (NESS).

TABLE 1 – AUC de prédiction de liens (%  $\pm$  écart-type).

Approche	Cora	Citeseer	Pubmed
DeepWalk	83.10 $\pm$ 0.50	80.50 $\pm$ 0.80	84.40 $\pm$ 0.92
Node2Vec	84.49 $\pm$ 0.49	80.00 $\pm$ 0.68	80.32 $\pm$ 0.29
GCN (GAE)	88.68 $\pm$ 0.40	85.35 $\pm$ 0.60	95.80 $\pm$ 0.13
GraphSAGE	90.24 $\pm$ 0.34	87.37 $\pm$ 1.39	96.58 $\pm$ 0.11
SEAL	92.55 $\pm$ 0.50	85.82 $\pm$ 0.44	95.86 $\pm$ 0.28
HPLC	94.95 $\pm$ 0.18	96.15 $\pm$ 0.19	97.38 $\pm$ 0.34
NESS	98.13 $\pm$ 0.20	99.43 $\pm$ 0.10	96.60 $\pm$ 0.10
<b>GLOW</b>	<b>98.64 <math>\pm</math> 0.22</b>	<b>99.76 <math>\pm</math> 0.17</b>	<b>99.64 <math>\pm</math> 0.02</b>

**Classification de nœuds.** GLOW obtient les meilleures précisions sur 6 des 7 jeux de données évalués, surpassant des modèles GNN de pointe (GCN, GAT). Par exemple, GLOW atteint 85.8% sur Cora, 80.2% sur Citeseer, 93.3%

sur Coauthor Physics et 88.4% sur DBLP (soit +12.1% par rapport à la deuxième meilleure méthode SGC sur ce dernier). La seule exception est Coauthor CS où GCN obtient 91.0% contre 90.4% pour GLOW.

## 4 Conclusion

Nous avons présenté GLOW, une méthode d’*embedding* de nœuds qui fusionne les informations locales de voisinage et le positionnement global via une optimisation basée sur la divergence KL et des nœuds de repère. Nos résultats démontrent que GLOW surpasse de nombreuses méthodes de l’état de l’art en classification de nœuds et en prédiction de liens, confirmant l’intérêt de modéliser conjointement les dépendances structurelles multi-échelle.

## Références

- [1] Ali Assi and Wajdi Dhifli. Instance matching in knowledge graphs through random walks and semantics. *Future Generation Computer Systems*, 123 :73–84, 2021.
- [2] Ali Assi, Nour Elislem Karabadjji, Mohamed Elati, and Wajdi Dhifli. Learning global-local multi-scale node embeddings with random walks and landmark-guided optimization. In *Proceedings of the 34th ACM International Conference on Information and Knowledge Management (CIKM '25)*, pages 79–89, 2025.
- [3] Aditya Grover and Jure Leskovec. node2vec : Scalable feature learning for networks. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pages 855–864, 2016.
- [4] Thomas N. Kipf and Max Welling. Semi-Supervised Classification with Graph Convolutional Networks. In *Proceedings of the 5th International Conference on Learning Representations (ICLR)*, 2017.
- [5] S. Kullback and R. A. Leibler. On information and sufficiency. *The Annals of Mathematical Statistics*, 22 :79–86, 1951.
- [6] Tomas Mikolov, Ilya Sutskever, Kai Chen, Greg Corrado, and Jeffrey Dean. Distributed representations of words and phrases and their compositionality. In *Advances in Neural Information Processing Systems 26 (NIPS)*, pages 3111–3119, 2013.
- [7] Bryan Perozzi, Rami Al-Rfou, and Steven Skiena. Deepwalk : Online learning of social representations. In *Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pages 701–710, 2014.
- [8] Petar Veličković, Guillem Cucurull, Arantxa Casanova, Adriana Romero, Pietro Liò, and Yoshua Bengio. Graph attention networks. In *International Conference on Learning Representations (ICLR)*, 2018.