

Graph Neural Networks et dynamique pour les systèmes de recommandation

Contexte scientifique

Les systèmes de recommandation ont pour but de mettre en relation des utilisateurs et des éléments de contenu d'un catalogue (films, livres, articles de presse). Le système peut être représenté comme une matrice *utilisateurs-articles*, avec des valeurs indiquant les préférences des utilisateurs, ou une simple consommation, et le problème de la recommandation consiste à prédire le contenu ultérieur de cases non remplies.

Des méthodes comme la factorisation de matrices sont très efficaces, mais leur passage à l'échelle est parfois délicat. Les méthodes modélisant le problème comme un graphe, biparti ou non, dirigé ou non, existent aussi depuis longtemps [8] : les métriques de graphes servent d'entrées complémentaires à d'autres modèles, ou la tâche de recommandation consiste à faire de la prédiction de lien dans le graphe.

Récemment, les approches reposant sur l'apprentissage profond ont renouvelé les approches de la recommandation. En particulier, l'apprentissage de représentations sur les graphes s'est considérablement développé avec les *Graph Neural Networks* [2, 3, 4]. Il s'agit de trouver comment encoder dans des structures efficaces des représentations des nœuds, de leurs attributs et ceux de leurs voisinages plus ou moins élargis, afin de transposer les mécanismes connus sur des données classiques. On apprend des *embeddings*, de faible dimension (pour passer à l'échelle).

Démarche

L'objectif du stage est d'étudier l'apport des GNNs dans un contexte de recommandation, sur le modèle de GraphRec [1] et NGCF [6], avec l'ambition de prendre en compte la dimension temporelle des données. Dans ces articles séminaux, comme dans beaucoup d'autres travaux, les données sont agrégées, et avoir consommé un contenu au début ou à la fin de la capture des données est considéré comme identique, et les arrivées et départs d'utilisateurs et produits sont invisibilisées : le graphe, initialement dynamique, est considéré comme statique. Une architecture comme [5] propose d'incorporer cette dimension temporelle, en vue de faire de la prédiction de lien (testée sur des données Twitter, Wikipedia et Reddit). L'approche est modulaire, avec un encodage du temps repris de [7]. L'ambition applicative est toutefois légèrement différente, l'accent étant mis sur la vitesse davantage que sur la qualité de la recommandation.

Nous étudierons donc comment concilier recommandation avec GNN et dynamique (ou temporalité), formellement et par l'expérimentation. Ainsi, en début du stage, outre la familiarisation avec la littérature, le travail consistera à réimplémenter un framework comme GraphRec et obtenir des performances similaires sur des datasets de référence comme Epinions. Dans un deuxième temps, nous étudierons si des manières différentes d'encoder le temps sont efficaces, en vue de faire de la recommandation. La troisième étape consistera évaluer ces recommandations avec des métriques appropriées.

Profil

Les candidats recherchés font preuve de très bonnes compétences en programmation, notamment en Python. Ils ont une connaissance théorique du machine learning et du deep learning. Une familiarité avec les frameworks du deep learning (comme pytorch) est évidemment un atout.

Les candidats sont en mesure de lire de la littérature scientifique et de s'approprier un domaine de recherche récent et actif, par de l'expérimentation et de l'abstraction. Ils font preuve d'esprit de synthèse à l'écrit et à l'oral.

Lieu de travail et gratification

Le stage se déroulera au laboratoire CÉDRIC et sera co-encadré par Raphaël Fournier-S'niehotta¹ et Nicolas Thome². Une gratification incluant le remboursement de la moitié du coût de transport est prévue.

Contact

Merci d'envoyer votre demande accompagnée d'un CV aux adresses `fournier@cnam.fr` et `nicolas.thome@cnam.fr`.

Mots-clefs

Machine learning – Systèmes de recommandation – Graphes – apprentissage profond

Références

- [1] W. Fan, Y. Ma, Q. Li, Y. He, Y. E. Zhao, J. Tang, and D. Yin. Graph neural networks for social recommendation. In *WWW*, pages 417–426. ACM, 2019.
- [2] W. Hamilton, Z. Ying, and J. Leskovec. Inductive representation learning on large graphs. In *Advances in Neural Information Processing Systems*, pages 1024–1034, 2017.
- [3] W. L. Hamilton, R. Ying, and J. Leskovec. Representation learning on graphs : Methods and applications. *arXiv preprint arXiv:1709.05584*, 2017.
- [4] T. N. Kipf and M. Welling. Semi-supervised classification with graph convolutional networks. *arXiv preprint arXiv:1609.02907*, 2016.
- [5] E. Rossi, B. Chamberlain, F. Frasca, D. Eynard, F. Monti, and M. Bronstein. Temporal graph networks for deep learning on dynamic graphs. *arXiv preprint arXiv:2006.10637*, 2020.
- [6] X. Wang, X. He, M. Wang, F. Feng, and T.-S. Chua. Neural graph collaborative filtering. *SIGIR*, 2019.
- [7] D. Xu, C. Ruan, E. Korpeoglu, S. Kumar, and K. Achan. Inductive representation learning on temporal graphs. In *ICLR*, 2020.
- [8] T. Zhou, J. Ren, M. c. v. Medo, and Y.-C. Zhang. Bipartite network projection and personal recommendation. *Phys. Rev. E*, 76:046115, Oct 2007.

1. <http://raphael.fournier-sniehotta.fr/apropos>

2. <http://cedric.cnam.fr/~thomen/>