



Vers un système de recommandation explicable pour l'orientation scolaire

Nicolas Hubert, Armelle Brun, Davy Monticolo

► To cite this version:

Nicolas Hubert, Armelle Brun, Davy Monticolo. Vers un système de recommandation explicable pour l'orientation scolaire. Workshop EXPLAIN'AI - EGC Blois 2022, Jan 2022, Blois, France. <hal-03559471>

HAL Id: hal-03559471

<https://hal.science/hal-03559471v1>

Submitted on 6 Feb 2022

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



HAL Authorization

Vers un système de recommandation explicable pour l'orientation scolaire

Nicolas Hubert*, Armelle Brun**, Davy Monticolo*

*ERPI - Université de Lorraine

**Université de Lorraine, CNRS, Loria

nicolas.hubert@univ-lorraine.fr

armelle.brun@loria.fr

davy.monticolo@univ-lorraine.fr

Résumé. L'orientation scolaire est une problématique pour nombre de lycéens et d'étudiants qui se sentent désorientés devant la pléthore de cursus proposés. Afin de les guider dans leur réflexion, nous proposons un système de recommandation. L'orientation scolaire étant un domaine à fort enjeu, nous mettons l'accent sur l'explicabilité de notre système, laquelle sera rendue possible par la construction et l'utilisation d'un graphe de connaissance.

1 Introduction

Pour le choix d'une filière de formation, un grand nombre de facteurs d'influence entrent en jeu : pression familiale, débouchés professionnels, réputation et lieu de la formation, pour n'en citer que quelques uns ([Aydm, 2015](#)). Comparativement au choix des filières et enseignements de spécialité au lycée, l'offre de formation dans l'enseignement supérieur est plus variée et conséquente. Plusieurs études ont montré que les étudiants plébiscitent cette diversité des cursus proposés, mais seulement dans une certaine mesure ([Ackerman et Gross, 2006](#)). Un nombre croissant de dispositifs d'aide à l'orientation sont désormais à la disposition des élèves ([Barrère, 2013](#)). Mais ces dispositifs n'apportent que de l'information, ce qui n'aide pas à prendre une décision en connaissance de cause ([Daverne-Bailly, 2020](#)) car l'information qu'ils délivrent est souvent trop conséquente. Les systèmes de recommandation (SR) constituent alors un outil privilégié pour effectuer les « bons » choix ([Ricci et al., 2010](#)). Les SRs sont conçus pour faciliter une prise de décision parmi un éventail de choix proposés. Cependant, les SRs ne concernent souvent que des domaines à faible enjeu. Se tromper dans la recommandation d'un film ou d'un livre n'a pas une grande incidence pour l'utilisateur. Il en est tout autre dans le domaine éducatif, où le choix d'une formation est en partie irréversible et façonne la future identité professionnelle de l'élève. L'éducation est un domaine à fort enjeu.

L'objectif des recherches que nous menons, et dont un travail préliminaire est présenté ici, est de concevoir un SR pour l'orientation vers l'enseignement supérieur. Animés par l'objectif de satisfaire pleinement chaque élève, nous plaçons l'explicabilité des

sorties du SR au centre de nos recherches. Nous souhaitons rompre avec l'utilité très limitée des explications collaboratives telles que « Nous te recommandons ce cursus car les élèves ayant un profil similaire au tien ont majoritairement suivi cette voie avec succès ». Par ailleurs, nous pensons que la confiance dans la recommandation est plus élevée lorsque l'explication émane d'un interlocuteur humain - p. ex. un professeur principal - plutôt que d'un algorithme qui n'a qu'une connaissance superficielle de chaque élève. C'est pourquoi notre approche vise une compréhension fine des spécificités de chaque élève, afin de se rapprocher autant que possible d'un accompagnement de nature humaine. Un professeur principal argumenterait de façon personnelle, par exemple : « Je pense que tu devrais considérer cette formation, car elle est proche de chez toi et je sais que tu ne te sens pas encore prêt à t'éloigner géographiquement. Par ailleurs, il s'agit d'une formation courte, mais qui laisse la possibilité à une poursuite d'études. Au regard de ton incertitude vis-à-vis des études longues, cette formation me semble pertinente ». C'est vers ce type de justification plus personnalisée que nous souhaitons tendre.

La structure de ce papier est la suivante : la section 2 pose les objectifs, originalités et verrous scientifiques de nos travaux. La section 3 explicite l'approche envisagée pour répondre au besoin d'explicabilité des recommandations. Enfin, la section 4 présente des travaux connexes jugés pertinents au regard de nos contextes scientifique et applicatif.

2 Contexte et objectifs scientifiques

Les modèles de recommandation « boîte blanche » (arbres de décision, modèles de régression linéaire, etc.) sont interprétables de façon intrinsèque, mais sont souvent trop simplistes pour délivrer des recommandations compétitives avec les modèles « boîte noire » (les réseaux de neurones, les forêts aléatoires, etc.) (Alom et al., 2019). Cependant, ces modèles nécessitent généralement beaucoup de données. De plus, leur fonctionnement interne est opaque, ce qui complique toute tentative d'explication a posteriori (Rudin, 2019). Or l'explication est au centre de nos préoccupations. Nous approchons se fonde l'utilisation d'un graphe de connaissance (GC) qui, au regard de nos objectifs, présente de multiples avantages : (i) ils permettent de fusionner et projeter des données de sources hétérogènes dans un espace de représentation commun, à partir duquel il devient possible d'extraire de la connaissance nouvelle ; (ii) raisonner sur le graphe permet de générer des recommandations et des explications simultanément, au lieu de générer l'explication a posteriori. Ainsi, la fiabilité de l'explication est assurée ; (iii) enfin, les récentes avancées permettent à de nombreux modèles de recommandation basés sur les GC d'atteindre des performances très satisfaisantes (Guo et al., 2020).

Néanmoins, un certain nombre d'interrogations restent en suspens relativement à nos objectifs : (i) quelle place sera donnée au GC dans notre approche : viendra-t-il en complément d'autres représentations de nos données ? Sera-t-il au contraire notre unique forme de représentation, après la fusion des sources de données hétérogènes ? Quelles entités seront incluses dans notre GC : les élèves, les formations, ou les deux ? ; (ii) s'agira-t-il d'un GC objet-objet afin d'enrichir la connaissances sur les formations proposées, ou d'un GC fusionnant l'ensemble des sources de données hétérogènes ? ; (iii) à quel moment le GC sera-t-il utilisé pour générer des explications : simultanément

ment à la recommandation, ou a posteriori ? ; (iv) quelle méthode sera employée pour personnaliser nos explications ?

L'originalité et la portée de nos travaux sont les suivantes :

- **Choix du modèle** : Les graphes de connaissance ont déjà été appliqués dans le domaine de l'éducation. Néanmoins, soit le cas d'usage est très éloigné du nôtre ([Shi et al., 2020](#)), soit l'explicabilité du modèle n'est pas étudiée ([Xu et al., 2021](#)). A notre connaissance, notre travail est le premier à s'intéresser conjointement aux problèmes de recommandation de formations et d'explicabilité à l'aide d'un graphe de connaissance ;
- **Avis d'experts** : la majorité des cadres applicatifs de la littérature ne nécessitent pas une compréhension fine du contexte applicatif, en grande partie car il s'agit de contextes à faible enjeu décisionnel. A contrario, nous faisons le choix d'enrichir notre approche par une collaboration étroite avec des experts de l'éducation, dont la connaissance du terrain est pleinement intégrée ;
- **L'explication avant la précision** : notre approche accorde une importance primordiale à l'explication. En effet, l'explication est un moyen d'accroître la confiance de l'élève dans l'outil ([Tintarev et Masthoff, 2007](#)) et elle importe davantage que la capacité du modèle à recommander des formations dans lesquelles l'étudiant va réussir ;
- **Introduction de nouvelles métriques** : du fait de la remarque précédente, nous ne pouvons pas nous contenter des métriques traditionnellement utilisées pour mesurer l'efficacité d'un SR. Certains travaux tentent de définir de nouvelles métriques adaptées au contexte applicatif ([Gabbolini et Bridge, 2021](#)). Dans notre cas, la fonction objectif devra s'adapter au profil de chaque élève. Cette piste de recherche reste à notre connaissance inexplorée dans le domaine de l'éducation.

Plusieurs problématiques et verrous scientifiques seront à considérer :

- **Mesurer la pertinence des explications** : après la phase de recommandation, l'élève ne reviendra pas systématiquement vers le SR pour fournir un retour sur l'utilité perçue de l'explication. L'a-t-elle aidé dans sa prise de décision ? ;
- **Mesurer la fidélité des explications** : les approches d'apprentissage statistique génèrent souvent l'explication a posteriori. Dans ce contexte, comment s'assurer de la fiabilité de l'explication ? Autrement dit, comment vérifier qu'elle justifie pleinement la recommandation ? ;
- **Personnalisation des explications** : l'apprentissage des profils individuels devra être suffisamment personnalisé pour permettre de sélectionner la justification plus proche de la sensibilité personnelle de l'élève. En effet, chaque élève dispose de ses propres critères et préférences en matière d'orientation scolaire. Une piste à explorer serait d'inférer les probabilités de chaque chemin reliant un utilisateur à un objet à recommander. Le chemin de plus forte probabilité nous fournit alors les éléments à faire figurer dans la justification.

3 Approche envisagée

3.1 Collecte de données

Plusieurs SRs implémentés pour des usages similaires au nôtre se focalisent uniquement sur des données extraites de bases académiques (Aly et al., 2013 ; Al-Badarenah et Alsakran, 2016). Inspirés par les travaux de (Hu et Pu, 2011), nous sommes convaincus que les centres d'intérêts et la personnalité des élèves doivent faire partie intégrante de leur profil utilisateur. Nous avons conçu un questionnaire qui vise à cerner ces aspects à travers des questions relatives au contexte scolaire, aux appétences personnelles et à des mises en situations professionnelles. Les données collectées permettront d'enrichir la connaissance sur les profils individuels et ainsi de générer des justifications « sur-mesure ». L'offre de formation dans l'enseignement supérieur est connue et repertoriée ; nous utilisons les données publiques mises à disposition. Ensuite, la construction du GC - que nous détaillons dans la section 3.2 - nous permet de représenter toutes nos données dans un espace commun.

3.2 Construction du graphe de connaissance

Nous avons créé une première ontologie avec le logiciel protégé¹. Une ontologie peut être vue comme le schéma de construction du GC. Plus formellement, une ontologie spécifie pour un domaine applicatif donné un ensemble de classes liées entre elles par des relations (Gruber, 1993). Dans notre cas, « Lycéen », « Etudiant » et « Formation » sont des classes. « Habite à » et « Etudie à » sont des relations. Les classes peuvent aussi disposer d'attributs : un élève se caractérise par son âge, son sexe, etc. Nous convertirons ensuite chaque ligne des données sous la forme d'un triplet RDF² < sujet, prédicat, objet >. L'ontologie est finalement peuplée par les triplets générés pour donner place au GC. Un exemple de ce que pourrait être ce graphe est donné en Figure 1.

3.3 Génération des recommandations

Indépendamment de la structure des données et du modèle employé, la tâche de recommandation se formule ainsi : si l'on définit I l'ensemble des objets recommandables et U l'ensemble des utilisateurs, le modèle apprend une représentation \mathbf{u}_i et \mathbf{v}_j pour chaque utilisateur u_i et objet v_j , respectivement. Alors, une fonction d'utilité infère la relation entre l'utilisateur u_i et l'objet v_j : $f : \mathbf{u}_i \times \mathbf{v}_j \rightarrow y_{i,j}$. Le système présente les N meilleures recommandations, ou simplement la recommandation maximisant la fonction d'utilité f .

Pour effectuer une recommandation au sein d'un GC, deux approches sont majoritairement employées (Guo et al., 2020), sans que nous ayons encore déterminé celle la plus pertinente pour nos objectifs. La première approche consiste à projeter le GC dans un espace vectoriel continu de faible dimension (*embedding*). Entités et relations sont alors encodées sous forme vectorielle. Il devient ainsi possible d'utiliser des algorithmes

1. <https://protege.stanford.edu/>

2. <https://www.w3.org/RDF/>

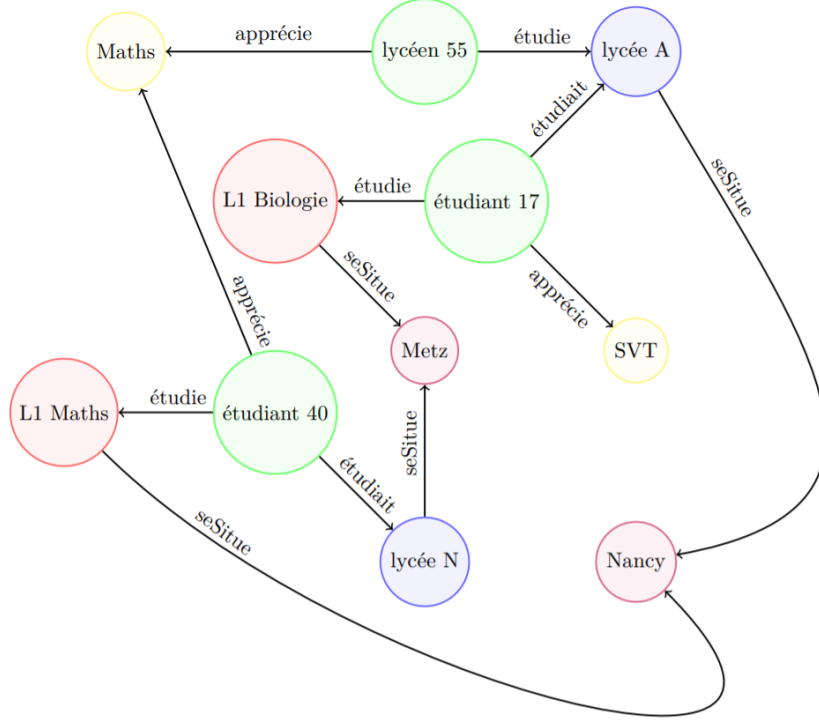


FIG. 1 – Exemple d'un graphe de connaissance.

d'apprentissage statistique sur les données encodées. Dans la seconde approche, aucune transformation du GC n'est opérée. De fait, il est possible de raisonner sur les entités et relations du graphe sans modifier leur espace de représentation. Cela permet d'exploiter directement le degré de connexion entre entités du graphe.

3.4 Expliquer une recommandation

L'approche d'*embedding* fait perdre l'interprétabilité naturelle du graphe. De plus, il n'existe aucune méthode consensuelle pour mesurer l'explicabilité d'un modèle fondé sur de l'*embedding* (Bianchi et al., 2020). L'approche basée sur les chemins n'effectue quant à elle aucune transformation du GC ; recommandation et explication ne sont alors plus deux tâches découplées. Par ailleurs, raisonner directement dans le GC nous permet d'extraire des méta-chemins (Chen et al., 2021), lesquels peuvent à la fois servir de schéma naturel d'explication comme de variables additionnelles pour enrichir les profils utilisateurs.

Relativement à notre objectif d'explicabilité, on peut donc a priori penser que les approches basées sur du raisonnement au sein du GC ont l'ascendant sur les approches d'*embedding*. Mais divers travaux font état du potentiel des méthodes de projection pour générer des explications fiables et pertinentes (Ai et al., 2018 ; Moon et al., 2019).

Dès lors, nous n'excluons pour l'instant aucune des deux approches mentionnées. Nous avançons ci-dessous nos pistes de recherche privilégiées, indexées par le type d'approche employée :

- **Raisonnement dans le GC** : cette approche nous permettrait, pour chaque élève, de pondérer chaque chemin ou méta-chemin menant à une formation donnée. Pondérer un chemin revient à déterminer l'utilité de l'explication pour chaque paire élève-formation. Pondérer un méta-chemin est plus généraliste : il s'agit pour chaque élève de déterminer le schéma explicatif qui lui correspond le mieux, indépendamment de la formation recommandée ;
- **Embedding** : L'absence de sémantique dans l'espace de projection entrave toute tentative d'explicabilité (Paulheim, 2018). Une piste d'exploration serait d'enrichir sémantiquement l'espace d'*embedding*, afin que chaque vecteur puisse disposer d'un sens clair et univoque. Une autre piste non nécessairement orthogonale à la première serait d'enrichir le profil de chaque élève par celui de ses voisins (Tran et al., 2021), afin d'accéder à une meilleure connaissance de chaque élève et lui délivrer des explications encore plus personnalisées. Cependant, nous pensons qu'il est plus judicieux d'aggréger les profils voisins dans l'espace de projection plutôt que dans le GC directement. En effet, deux élèves peuvent être éloignés dans le graphe, et donc inatteignables via un nombre de sauts maximal. Au contraire, ces deux élèves seront très proches dans l'espace d'*embedding*.

Enfin, si le contenu de l'explication importe, sa structure également. Plusieurs types d'explications existent : explications contextuelles, contrastives, basées sur les cas, etc. (Chari et al., 2020). Nous pensons qu'une représentation des données sous forme de GC rend possible la combinaison de plusieurs motifs d'explication, favorisant là encore la personnalisation des justifications apportées.

4 Travaux connexes

Un pan entier de la littérature se consacre à l'utilisation des GC pour expliquer les sorties des SRs. Nous mentionnons ici certains travaux dont l'approche employée constitue une source d'inspiration pour nos futurs travaux. (Ai et al., 2018) fusionnent utilisateurs et objets dans un même GC qu'ils projettent ensuite dans un espace de faible dimension, puis tentent d'expliquer leurs recommandations a posteriori à l'aide d'un algorithme de couplage sur les chemins utilisateurs-objets. Leur modèle permet de générer plusieurs chemins d'explications ordonnés par degré de confiance. (Yang et al., 2018) génèrent également leur explication a posteriori, mais leur modèle raisonne directement sur les chemins. Après avoir extrait l'ensemble des chemins potentiels, ces derniers sont pondérés puis ordonnés. L'importance attribuée à chaque chemin dépend de la combinaison de trois métriques introduites par les auteurs : la crédibilité, la clarté sémantique et la diversité des chemins. Contrairement aux deux précédents travaux, (Xian et al., 2019) recourent à l'apprentissage par renforcement pour garder en mémoire l'historique des arêtes traversées, ce qui permet de générer recommandation et explication de façon conjointe. Enfin, les travaux de (Wang et al., 2019) et (Zhong et al., 2019) utilisent des réseaux neuronaux récurrents (GRU et LSTM, respectivement) afin de pleinement capturer les dépendances séquentielles lors du cheminement sur les arêtes.

Cette approche leur permet de pondérer les contributions de chaque chemin pour une même recommandation, et de ne conserver que le meilleur d'entre eux.

5 Conclusion

Quand l'information disponible est abondante au point de compliquer les choix personnels, un système de recommandation peut soulager l'utilisateur dans son processus de traitement de l'information et de prise de décision. Mais lorsque le domaine applicatif est à fort enjeu - comme c'est le cas pour l'orientation scolaire -, l'explication importe autant si ce n'est davantage que la recommandation à laquelle elle est adossée. L'objectif de ce papier est ainsi de présenter un cas où l'explication à destination de l'utilisateur final est primordiale. Si certaines problématiques restent à adresser, nous résumons les travaux préliminaires réalisés jusqu'à maintenant, puis avançons nos futures pistes de recherche.

Références

- Ackerman, D. S. et B. L. Gross (2006). How many choices are good? measurement of the effects of course choice on perceptions of a marketing option. *Journal of Marketing Education* 28(1), 69–80.
- Ai, Q., V. Azizi, X. Chen, et Y. Zhang (2018). Learning heterogeneous knowledge base embeddings for explainable recommendation. *ArXiv*.
- Al-Badarenah, A. et J. Alsakran (2016). An automated recommender system for course selection. *International Journal of Advanced Computer Science and Applications* 7.
- Alom, M. Z., T. Taha, C. Yakopcic, S. Westberg, P. Sidike, M. Nasrin, M. Hasan, B. Essen, A. Awwal, et V. Asari (2019). A state-of-the-art survey on deep learning theory and architectures. 8, 292.
- Aly, W., O. Hegazy, et H. Rashad (2013). Automated student advisory using machine learning. *International Journal of Computer Applications* 81, 19–24.
- Aydin, O. (2015). University choice process : A literature review on models and factors affecting the process. *Yuksekokretim Dergisi* 5.
- Barrère, A. (2013). La montée des dispositifs : un nouvel âge de l'organisation scolaire. *Carrefours de l'éducation* 36(2), 95–116.
- Bianchi, F., G. Rossiello, L. Costabello, M. Palmonari, et P. Minervini (2020). Knowledge graph embeddings and explainable ai.
- Chari, S., D. Gruen, O. W. Seneviratne, et D. L. McGuinness (2020). Directions for explainable knowledge-enabled systems. In *Knowledge Graphs for eXplainable Artificial Intelligence*.
- Chen, H., Y. Li, X. Sun, G. Xu, et H. Yin (2021). Temporal meta-path guided explainable recommendation. WSDM '21, New York, NY, USA, pp. 1056–1064. Association for Computing Machinery.

- Daverne-Bailly, Carole et Bobineau, C. (2020). Orienter et s'orienter vers l'enseignement supérieur dans un contexte de changement des politiques éducatives : incertitudes, choix, inégalités. *Éducation et socialisation* 58.
- Gabbolini, G. et D. Bridge (2021). An interpretable music similarity measure based on path interestingness.
- Gruber, T. R. (1993). A translation approach to portable ontology specifications. *Knowledge Acquisition* 5, 199–220.
- Guo, Q., F. Zhuang, C. Qin, H. Zhu, X. Xie, H. Xiong, et Q. He (2020). A survey on knowledge graph-based recommender systems. *ArXiv*.
- Hu, R. et P. Pu (2011). Enhancing collaborative filtering systems with personality information. In *Proceedings of the Fifth ACM Conference on Recommender Systems, RecSys '11*, New York, NY, USA, pp. 197–204. Association for Computing Machinery.
- Moon, S., P. Shah, A. Kumar, et R. Subba (2019). Opendialkg : Explainable conversational reasoning with attention-based walks over knowledge graphs. In *ACL*.
- Paulheim, H. (2018). Machine learning with and for semantic web knowledge graphs.
- Ricci, F., L. Rokach, et B. Shapira (2010). *Recommender Systems Handbook*, Volume 1-35.
- Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intell.* 1, 206–215.
- Shi, D., T. Wang, H. Xing, et H. Xu (2020). A learning path recommendation model based on a multidimensional knowledge graph framework for e-learning. *Knowl. Based Syst.* 195, 105618.
- Tintarev, N. et J. Masthoff (2007). A survey of explanations in recommender systems. pp. 801–810.
- Tran, D. H., Q. Sheng, W. E. Zhang, A. Aljubairy, M. Zaib, S. A. Hamad, N. H. Tran, et N. L. D. Khoa (2021). Hetegraph : graph learning in recommender systems via graph convolutional networks. *Neural Computing and Applications*, 1–17.
- Wang, X., D. Wang, C. Xu, X. He, Y. Cao, et T.-S. Chua (2019). Explainable reasoning over knowledge graphs for recommendation. In *AAAI*.
- Xian, Y., Z. Fu, S. Muthukrishnan, G. de Melo, et Y. Zhang (2019). Reinforcement knowledge graph reasoning for explainable recommendation. *Proc. of the 42nd Int. ACM SIGIR Conference on Research and Development in Information Retrieval*.
- Xu, G., G. Jia, L. Shi, et Z. Zhang (2021). Personalized course recommendation system fusing with knowledge graph and collaborative filtering. *Computational Intelligence and Neuroscience* 2021, 1–8.
- Yang, F., N. Liu, S. Wang, et X. Hu (2018). Towards interpretation of recommender systems with sorted explanation paths. *2018 IEEE International Conference on Data Mining (ICDM)*, 667–676.
- Zhong, Y., X. Song, B. Yang, C. Jiang, et X. Luo (2019). An Interpretable Recommendations Approach Based on User Preferences and Knowledge Graph, pp. 326–337.