



**HAL**  
open science

## A 3 R: Explications argumentées pour les recommandations

Jinfeng Zhong, Elsa Negre

► **To cite this version:**

Jinfeng Zhong, Elsa Negre. A 3 R: Explications argumentées pour les recommandations. ATELIER EXPLAIN'AI Hébergé à la conférence EGC 2023 à Lyon, Jan 2023, Lyon, France. hal-03984015v3

**HAL Id: hal-03984015**

**<https://hal.science/hal-03984015v3>**

Submitted on 9 Oct 2023

**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.

# $A^3R$ : Explications argumentées pour les recommandations

Jinfeng Zhong\*, Elsa Negre\*

\*Paris-Dauphine University, PSL Research University,  
CNRS UMR 7243, LAMSADE, 75016 Paris France  
jinfeng.zhong@dauphine.eu  
elsa.negre@lamsade.dauphine.fr

**Résumé.** Les systèmes de recommandation existants appliquent souvent des modèles basés sur la factorisation, qui se sont avérés efficaces pour la prédiction de scores. Cependant, la sémantique explicite des facteurs latents appris n'est pas claire, ce qui rend difficile l'explication des recommandations retournées. Par ailleurs, les méthodes basées sur l'argumentation sont devenues des outils importants de l'intelligence artificielle explicable. Dans cet article, nous proposons un modèle de recommandation argumentative sensible aux attributs (*Attribute-Aware Argumentative Recommender -  $A^3R$* ) qui combine la factorisation et l'argumentation. Avec l'aide des systèmes d'argumentation, chaque étape de  $A^3R$  est dotée d'une sémantique explicite, permettant à  $A^3R$  de générer des explications facilement compréhensibles par les utilisateurs. Nos expériences sur cinq jeux de données provenant de trois domaines différents (films, musiques et livres) montrent que  $A^3R$  est capable de prédire les scores de manière aussi précise que des méthodes à base de factorisation, et que  $A^3R$  améliore largement la prédiction de scores par rapport aux méthodes existantes de recommandation argumentative.

## 1 Introduction

Le présent article résume notre papier accepté à la conférence DSAA 2022 (*9th IEEE International Conference on Data Science and Advanced Analytics*) (Zhong et Negre, 2022a). Dans ce travail, nous étudions comment combiner une méthode à base de factorisation et une à base d'argumentation pour donner une sémantique explicite à chaque étape du processus de recommandation.

Les systèmes de recommandation (ci-après RS) sont devenus omniprésents dans la vie quotidienne des utilisateurs, car ils permettent d'atténuer la surcharge d'informations et aident donc les utilisateurs à trouver des éléments qui les intéressent. Se contenter de recommander des éléments sans expliquer pourquoi ces éléments ont été générés rend les RSs moins transparents. De plus, cela contredit les demandes des utilisateurs. C'est pourquoi expliquer les recommandations a suscité un intérêt profond dans la communauté scientifique (Zhang et al., 2020). Les RSs existants reposent souvent sur des méthodes basées sur la factorisation, telles que SVD (Koren et al., 2009), FM (Rendle, 2010), AFM (Xiao et al., 2017), etc. Ces méthodes

sont capables de faire des prédictions précises. Cependant, la sémantique explicite des facteurs latents appris n'est pas claire.

Par ailleurs, l'argumentation (AF ci-après) a été appliquée pour améliorer l'explicabilité de l'intelligence artificielle (Čyras et al., 2021). AF représente le processus de prise de décision de manière graphique et les propriétés prédéfinies aident à raisonner sur la façon d'atteindre les meilleures décisions (Vassiliades et al., 2021). AF comprend également des moyens pour définir des arguments pondérés et des relations dialectiques entre les arguments, qui contiennent une sémantique permettant de définir la force et l'acceptabilité de ces arguments (Čyras et al., 2021). Les méthodes basées sur l'argumentation ont été appliquées au domaine juridique (Karafilis et al., 2019), médical (Sassoon et al., 2019), etc. Dans le domaine des RSs, il y a eu plusieurs travaux (Teze et al., 2015; Rago et al., 2021) qui construisent des RSs explicables à l'aide de AF.

Dans notre travail, nous visons à construire un RS capable de fournir des explications intrinsèques au modèle. Pour ce faire, nous proposons un modèle de recommandation argumentative sensible aux attributs (*Attribute-Aware Argumentative Recommender -  $A^3R$* ). L'idée principale de  $A^3R$  est que les scores des utilisateurs envers les éléments dépendent des attributs des éléments. A titre exemple, dans la recommandation de films, les attributs des films comprennent principalement les acteurs, les genres et les réalisateurs. L'importance des types d'attributs varie selon les utilisateurs. Il se peut que certains utilisateurs aient une préférence particulière pour certains genres de films, tandis que d'autres préfèrent les films de certains acteurs. Il est donc important de capturer cette différence pour modéliser les préférences des utilisateurs.  $A^3R$  calcule l'importance des différents types d'attributs, ceci est ensuite utilisé pour calculer les scores des utilisateurs envers les attributs des éléments. Les scores des utilisateurs envers les différents attributs des éléments sont pondérés par l'importance des types d'attributs et sont agrégés pour calculer les scores finaux envers les éléments. Nous définissons un AF lié à l'interaction utilisateur-élément, où les attributs des éléments sont des arguments et les scores des utilisateurs envers ces attributs sont la force de ces arguments, ces derniers peuvent favoriser, attaquer ou neutraliser les recommandations. Cela signifie que le calcul de  $A^3R$  est doté d'une sémantique explicite, et donc il est possible de tracer la prédiction des scores, conduisant à des explications intrinsèques au modèle.

Les principales contributions de (Zhong et Negre, 2022a) sont les suivantes : (i) en passant en revue l'état de l'art, nous soulignons la capacité de AF à améliorer l'explicabilité des RSs ; (ii) nous proposons  $A^3R$  qui combine deux méthodes : l'une à base de factorisation et l'autre à base d'argumentation. Notre méthode peut générer des explications intrinsèques au modèle en modélisant les préférences des utilisateurs envers les attributs des éléments ; (iii) nous menons des expériences sur cinq jeux de données provenant de trois domaines différents (films, musiques et livres), et les résultats montrent que  $A^3R$  est compétitif dans la prédiction des scores et peut fournir des explications qui sont fidèles à  $A^3R$  lui-même.

## 2 Notre proposition

Dans cette section, nous présentons un modèle de recommandation argumentative sensible aux attributs (*Attribute-Aware Argumentative Recommender -  $A^3R$* ), et comment générer des explications intrinsèques au modèle en utilisant  $A^3R$ , nous comparons ensuite notre méthode avec des travaux existants, puis nous présentons les résultats de nos expériences.

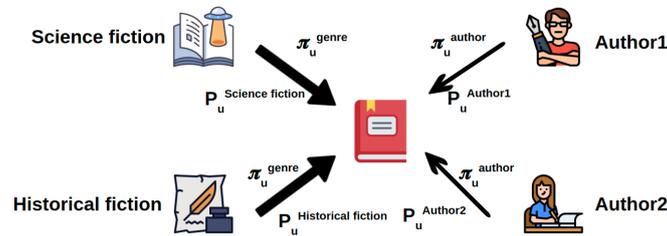


FIG. 1 – Exemple de recommandation de livres montrant le fonctionnement de  $A^3R$ . L'épaisseur de la flèche reflète l'importance du type d'attribut. Dans cet exemple, l'utilisateur accorde plus d'importance au genre du livre.

## 2.1 Modèle de recommandation argumentative sensible aux attributs - *Attribute-aware argumentative recommender*

L'idée essentielle de  $A^3R$  provient des RSs basés sur le contenu : les scores des utilisateurs envers les éléments dépendent des attributs des éléments et les scores des utilisateurs envers les éléments sont calculés en agrégeant leurs scores envers les attributs des éléments.  $A^3R$  adopte cette idée et la prédiction des scores se fait principalement en trois étapes :

1.  $A^3R$  calcule d'abord l'importance de chaque type d'attribut pour chaque utilisateur.
2. Les scores des utilisateurs envers chaque attribut sont calculés. Pour ce faire, nous adoptons simplement le produit scalaire comme dans les méthodes de factorisation de matrice.
3. Les scores pour chaque attribut sont agrégés selon l'importance de chaque type d'attribut pour obtenir les scores envers les éléments.

La figure 1 montre comment  $A^3R$  prédit le score qu'un utilisateur pourrait donner à un livre. Dans la phase d'explication, les scores de chaque attribut sont transformés pour appartenir à l'intervalle  $[-1, 1]$  comme dans (Rago et al., 2018, 2021) pour représenter la force des arguments. Les scores transformés déterminent la polarité des arguments qui favorisent, attaquent ou neutralisent la recommandation d'un élément. Ainsi, le fait que les utilisateurs aiment/n'aiment pas/indiffèrent un attribut reflète leurs préférences envers un élément. Pour plus de détails, nous invitons les lecteurs à lire (Zhong et Negre, 2022a). L'étape d'explication sera discutée dans la section 2.2.

## 2.2 Comment expliquer les recommandations ?

L'idée essentielle est que toute information représentant des relations dialectiques (accord ou désaccord) peut être considérée comme un argument (Cayrol et Lagasque-Schieux, 2005) : l'accord correspondant aux soutiens et le désaccord correspondant aux attaques. Dans ce sens, les attributs des éléments sont considérés comme des arguments qui peuvent favoriser, attaquer ou neutraliser la recommandation d'un élément. Les polarités des arguments sont définies par les scores des utilisateurs envers les attributs : (i) si, selon  $A^3R$ , un utilisateur donne un score élevé à un attribut, alors cet attribut est considéré comme un argument qui favorise la

### $A^3R$ : Explications argumentées pour les recommandations

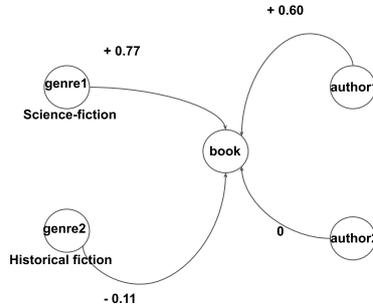


FIG. 2 – Représentation TAF de la figure 1. La valeur de l’arc correspond à la force de l’argument. “+” dénote un soutien, “-” dénote une attaque, “0” dénote une neutralisation.

recommandation de cet élément; (ii) si, selon  $A^3R$ , un utilisateur donne un score très bas à un attribut, alors cet attribut est considéré comme un argument qui attaque la recommandation de cet élément; (iii) si, selon  $A^3R$ , un utilisateur donne un score nul (0) à un attribut, alors cet attribut est considéré comme un argument qui n’a pas d’impact sur la recommandation.

Une relation de neutralisation est nécessaire pour représenter les attributs qui ne favorisent ni n’attaquent la recommandation de l’élément, ce qui signifie que ces attributs n’influencent pas les scores des utilisateurs envers les éléments. Donc, le système d’argumentation dans notre papier est un système d’argumentation tripolaire (Gabbay, 2016) (TAF ci-après) défini comme suit :  $\langle \mathcal{A}, \mathcal{R}^-, \mathcal{R}^+, \mathcal{R}^0 \rangle$ , où  $\mathcal{A}$  est un ensemble d’arguments, étant donné  $a, b \in \mathcal{A}$ ,  $\mathcal{R}^-(a, b)$  signifie que  $a$  attaque  $b$ ;  $\mathcal{R}^+(a, b)$  signifie que  $a$  favorise/soutient  $b$ ;  $\mathcal{R}^0(a, b)$  signifie que  $a$  neutralise  $b$ . Le système d’argumentation défini dans notre papier satisfait les propriétés suivantes : (i) *Weak balance (équilibre)* (Baroni et al., 2018) : énonce le fait que les attaques (ou les soutiens) peuvent être considérés comme des liens entre les impactants et les impactés de manière telle que si un impactant est isolé comme le seul argument qui affecte l’impacté, alors le premier réduit (augmente, resp.) le score prédit du second par rapport au point neutre (la force du premier est fixée à 0); (ii) *Weak monotonicity (monotonie)* (Baroni et al., 2019) : caractérise les attaques/soutiens/neutralisations comme des liens entre les arguments tels que si l’on enlève la force de l’argument d’un impactant, la force de l’argument affecté augmente/réduit/ne change pas, respectivement, mettant en évidence l’effet négatif/positif/neutre, respectivement, entre les deux.

La figure 2 présente le TAF correspondant à l’interaction  $(u, i)$  extraite de la figure 1. Notez que ce TAF est lié à une interaction  $(u, i)$ . Comme on peut le voir sur la figure 2, chaque attribut du livre est représentée sur le TAF en tant qu’argument, la force de chaque argument représente la préférence de l’utilisateur envers l’attribut. Par exemple, la force de *genre1* est +0.77. Cela montre que l’utilisateur a une forte préférence pour les livres de science-fiction, cela favorise la recommandation de ce livre. Au contraire, la force de *genre2* est -0.11, signifiant une attaque. On peut en déduire que l’utilisateur n’aime pas les livres de fiction historique. La force de *auteur1* est +0.60, ce qui indique que cet utilisateur préfère les livres écrits par l’auteur1. La force de *auteur2* est 0, signifiant neutre. Cela peut être interprété comme suit : la

TAB. 1 – Comparaison entre  $SVD$ ,  $FM$ ,  $AFM$ ,  $A - I$ ,  $A^3R$ 

	Interactions utilisateur-élément	Attributs des éléments	Explications intrinsèques
$SVD$	Oui	Non	Non
$FM$	Oui	Oui	Non
$AFM$	Oui	Oui	Non
$A - I$	Oui	Oui	Oui
$A^3R$	Oui	Oui	Oui

préférence de cet utilisateur envers l'auteur2 n'est pas claire en raison du manque de données. Par conséquent, si ce livre est recommandé à l'utilisateur, cette recommandation peut être expliquée comme suit "Le système vous recommande ce livre car il s'agit d'une science-fiction écrite par l'auteur1". Dans le cas où ce livre n'est pas recommandé, l'explication peut être la suivante : "Le système ne vous recommande pas ce livre car il s'agit d'un livre de fiction historique, que vous ne préférez peut-être pas".

### 2.3 Comparaison avec d'autres méthodes

Le tableau 1 présente la comparaison entre  $A^3R$  et d'autres méthodes.  $A^3R$  prend en compte à la fois les interactions utilisateur-élément et les attributs des éléments comme  $FM$  et  $AFM$ . Néanmoins,  $A^3R$  est capable de fournir des explications intrinsèques au modèle.

Par rapport au modèle  $A - I$  (Rago et al., 2018, 2021), une méthode capable d'expliquer les recommandations en utilisant le système d'argumentation,  $A^3R$  se différencie de  $A - I$  comme suit : (i) nous n'explorons pas directement les "utilisateurs similaires" des utilisateurs ciblés, qui sont définis par les préférences des utilisateurs envers les genres des films dans  $A - I$ . L'importance du type d'attribut pour tous les utilisateurs est la même, alors que  $A^3R$  apprend l'importance pour chaque utilisateur de manière supervisée par les interactions utilisateur-élément ; (ii) le système d'argumentation de  $A^3R$  s'appuie sur les interactions, alors que dans  $A - I$  le système d'argumentation s'appuie sur les utilisateurs. Par conséquent, dans  $A^3R$ , tous les arguments (attributs) sont directement liés aux éléments et influencent directement les scores des utilisateurs envers les éléments. De ce fait, il n'est pas nécessaire d'extraire des sous-graphes du système d'argumentation pour expliquer les recommandations comme dans  $A - I$ .

### 2.4 Expérimentations

Pour évaluer notre méthode, nous avons utilisé **Netflix**, un sous-ensemble du défi Netflix<sup>1</sup> ; **MovieLens Development (Dev.)** et **MovieLens 100K** (Harper et Konstan, 2015) ; **Carmusic** (Baltrunas et al., 2011) un jeu de données pour la recommandation de musique ; **DBook2014**, le jeu de donnée de *Linked Open Data-enabled Recommender Systems Challenge*<sup>2</sup>.

Les résultats de nos expériences montrent que :

- $A^3R$  surpasse les méthodes traditionnelles de filtrage collaboratif telles que  $SVD$ . En effet, ces méthodes traditionnelles ne prennent en compte que les interactions entre

1. <https://www.netflixprize.com/>

2. <https://2014.eswc-conferences.org/important-dates/call-RecSys.html>

## $A^3R$ : Explications argumentées pour les recommandations

- l'utilisateur et l'élément, ignorant les attributs des éléments qui peuvent influencer les préférences des utilisateurs.
- Par rapport à  $A - I$ ,  $A^3R$  améliore largement la prédiction des scores sur les cinq jeux de données. Notre interprétation est la suivante : (i) premièrement,  $A^3R$  calcule l'importance de chaque type d'attribut pour chaque utilisateur, ce qui n'est pas le cas de  $A - I$ . Par conséquent,  $A^3R$  est capable de modéliser la préférence de chaque utilisateur d'une manière plus précise. D'autres analyses montrent que  $A^3R$  regroupe les utilisateurs en fonction de l'importance qu'ils accordent à chaque type d'attribut ; (ii)  $A^3R$  n'explore pas explicitement les "utilisateurs similaires" comme  $A - I$ . Le choix des  $k$  utilisateurs les plus similaires est un problème qui reste non résolu. Lorsque  $k$  est trop petit, il se peut que certains "utilisateurs similaires" soient ignorés alors qu'un  $k$  trop grand apporte du bruit provenant d'utilisateurs moins similaires.  $A^3R$  explore les attributs des éléments, qui sont directement liés aux éléments.
  - Par rapport à  $FM$  et  $AFM$ ,  $A^3R$  atteint des performances légèrement inférieures dans la prédiction des scores, cependant,  $A^3R$  reste compétitif car l'écart n'est pas très important.  $A^3R$  ne prend en compte que les interactions des vecteurs représentant les utilisateurs et les attributs, alors que  $FM$  et  $AFM$  ajoutent les interactions suivantes : interactions entre les éléments et les attributs, interactions entre les attributs, etc. Nous soutenons que bien que  $A^3R$  capture moins d'interactions, chacune d'entre elles est dotée d'une sémantique explicite, qui reflète les préférences des utilisateurs envers les attributs des éléments.
  - Pour analyser plus en profondeur l'impact de l'importance des attributs, nous représentons chaque utilisateur par l'importance du type d'attribut. Nous avons fait une étude de cas dans le jeu de données **Netflix** : chaque utilisateur est représenté par un vecteur à 3 dimensions. Nous exécutons K-means (Velmurugan et Santhanam, 2010) et il s'avère que 3 clusters correspondent le mieux à ce jeu de données : les utilisateurs de ce jeu de données sont divisés en trois clusters. Ensuite, le résultat du clustering est visualisé à travers t-SNE (Van der Maaten et Hinton, 2008). Les préférences des utilisateurs dans les trois clusters sont différentes. Cela confirme notre affirmation que  $A^3R$  est capable de différencier les préférences des utilisateurs envers différents types d'attributs, donnant ainsi des prédictions plus précises.

## 3 Conclusion et perspectives

Dans cet article (Zhong et Negre, 2022a), nous proposons un modèle de recommandation argumentative sensible aux attributs (*Attribute-Aware Argumentative Recommender -  $A^3R$* ), qui combine deux méthodes, l'une basée sur la factorisation et l'autre sur l'argumentation. Pour chaque interaction utilisateur-élément, nous définissons un système d'argumentation tripolaire (TAF), où les attributs sont considérés comme des arguments, et les scores des utilisateurs envers les attributs sont définis comme la force de ces arguments. Des explications intrinsèques au modèle peuvent être générées pour chaque interaction à l'aide du TAF. Nos expériences sur cinq jeux de données montrent que  $A^3R$  surpasse les méthodes de factorisation traditionnelles telles que  $SVD$  ;  $A^3R$  est compétitif par rapport à  $FM$  et  $AFM$  ;  $A^3R$  surpasse largement  $A - I$ , un modèle de recommandation argumentative.

Nos travaux futurs incluent : (i) nous prévoyons d'explorer s'il est possible d'étendre  $A^3R$  à d'autres domaines tels que la recommandation de caméras/appareils photos, d'hôtels et de restaurants où le choix des utilisateurs est fortement influencé par les attributs et des explications sont généralement nécessaires pour justifier de telles recommandations; (ii) nous prévoyons d'explorer si  $A^3R$  peut obtenir les mêmes performances dans la prédiction du classement; (iii) nous prévoyons d'évaluer la méthode d'explication proposée dans cet article avec des utilisateurs réels et de comparer notre méthode avec d'autres qui n'impliquent pas d'argumentation; (iv) les explications contextuelles qui expliquent les recommandations adaptées aux contextes des utilisateurs sont également une direction intéressante (Zhang et al., 2020; Zhong et Negre, 2022b), nous prévoyons donc d'étendre  $A^3R$  pour générer des explications contextuelles.

## Références

- Baltrunas, L., M. Kaminskas, B. Ludwig, O. Moling, F. Ricci, A. Aydin, K.-H. Lüke, et R. Schwaiger (2011). Incarmusic : Context-aware music recommendations in a car. In *International conference on electronic commerce and web technologies*, pp. 89–100. Springer.
- Baroni, P., A. Rago, et F. Toni (2018). How many properties do we need for gradual argumentation? In *Proceedings of the AAAI Conference on Artificial Intelligence*, Volume 32.
- Baroni, P., A. Rago, et F. Toni (2019). From fine-grained properties to broad principles for gradual argumentation : A principled spectrum. *International Journal of Approximate Reasoning* 105, 252–286.
- Cayrol, C. et M.-C. Lagasquie-Schiex (2005). On the acceptability of arguments in bipolar argumentation frameworks. In *European Conference on Symbolic and Quantitative Approaches to Reasoning and Uncertainty*, pp. 378–389. Springer.
- Čyras, K., A. Rago, E. Albin, P. Baroni, et F. Toni (2021). Argumentative xai : a survey. *arXiv preprint arXiv :2105.11266*.
- Gabbay, D. M. (2016). Logical foundations for bipolar and tripolar argumentation networks : preliminary results. *Journal of Logic and Computation* 26(1), 247–292.
- Harper, F. M. et J. A. Konstan (2015). The movielens datasets : History and context. *Acm transactions on interactive intelligent systems (tiis)* 5(4), 1–19.
- Karafili, E., L. Wang, et E. C. Lupu (2019). An argumentation-based reasoner to assist digital investigation and attribution of cyber-attacks. *arXiv preprint arXiv :1904.13173*.
- Koren, Y., R. Bell, et C. Volinsky (2009). Matrix factorization techniques for recommender systems. *Computer* 42(8), 30–37.
- Rago, A., O. Cocarascu, C. Bechlivanidis, D. Lagnado, et F. Toni (2021). Argumentative explanations for interactive recommendations. *Artificial Intelligence* 296, 103506.
- Rago, A., O. Cocarascu, et F. Toni (2018). Argumentation-based recommendations : Fantastic explanations and how to find them. In *Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence*, pp. 1949–1955.
- Rendle, S. (2010). Factorization machines. In *2010 IEEE International conference on data mining*, pp. 995–1000. IEEE.

$A^3R$ : Explications argumentées pour les recommandations

- Sassoon, I., N. Kökciyan, E. Sklar, et S. Parsons (2019). Explainable argumentation for wellness consultation. In *International Workshop on Explainable, Transparent Autonomous Agents and Multi-Agent Systems*, pp. 186–202. Springer.
- Teze, J. C., S. Gottifredi, A. J. García, et G. R. Simari (2015). Improving argumentation-based recommender systems through context-adaptable selection criteria. *Expert Systems with Applications* 42(21), 8243–8258.
- Van der Maaten, L. et G. Hinton (2008). Visualizing data using t-sne. *Journal of machine learning research* 9(11).
- Vassiliades, A., N. Bassiliades, et T. Patkos (2021). Argumentation and explainable artificial intelligence : a survey. *The Knowledge Engineering Review* 36.
- Velmurugan, T. et T. Santhanam (2010). Computational complexity between k-means and k-medoids clustering algorithms for normal and uniform distributions of data points. *Journal of computer science* 6(3), 363.
- Xiao, J., H. Ye, X. He, H. Zhang, F. Wu, et T.-S. Chua (2017). Attentional factorization machines : Learning the weight of feature interactions via attention networks. *arXiv preprint arXiv :1708.04617*.
- Zhang, Y., X. Chen, et al. (2020). Explainable recommendation : A survey and new perspectives. *Foundations and Trends® in Information Retrieval* 14(1), 1–101.
- Zhong, J. et E. Negre (2022a). A 3 r : Argumentative explanations for recommendations. In *2022 IEEE 9th International Conference on Data Science and Advanced Analytics (DSAA)*, pp. 1–9. IEEE.
- Zhong, J. et E. Negre (2022b). Towards improving user-recommender systems interactions. In *2022 IEEE/SICE International Symposium on System Integration (SII)*, pp. 816–820. IEEE.

## Summary

Existing recommender systems often apply factorization-based models, which have been proved to be efficient in rating prediction. However, the explicit semantics of the learned latent factors are not clear, which makes it difficult to explain the recommendations returned. In another line of research, argumentation-based methods have become an important tool in explainable artificial intelligence. In this work, we propose an Attribute-Aware Argumentative Recommender ( $A^3R$ ) that combines factorization-based methods and argumentation. With the help of argumentation framework, each step of  $A^3R$  is endowed with explicit semantics, enabling  $A^3R$  to generate easily understandable explanations for recommendations. Experiments on five datasets from three different domains (movie, music, and book) show that  $A^3R$  can achieve competitive rating prediction when compared with factorization-based methods;  $A^3R$  can largely improve prediction accuracy when compared with state-of-art argumentative recommendation methods.