

Explicabilité des recommandations en e-commerce : étude du modèle Zeplace.

Ousmane Diop*, Noura Benhajji*
Armelle Brun**, Mathieu d'Aquin**,
Tristan Viller*

*ThePlaceToWish, Nancy, France
ousmane.diop@thelacetowish.com,
<https://www.thelacetowish.com>
**Université de Lorraine, CNRS, LORIA, Nancy, France
<https://www.loria.fr>

Résumé. Cet article aborde les enjeux et défis de l'explicabilité dans les systèmes de recommandation appliqués au e-commerce, en se basant sur l'étude de cas de **Zeplace.**, un système développé par ThePlaceToWish. Dans un contexte où la transparence est à la fois une exigence réglementaire (EU RGPD, Raison 71, 2016) et un levier stratégique pour renforcer la confiance des utilisateurs (Theis et al., 2023), nous proposons une réflexion sur une approche intégrant l'explicabilité dès la conception du système. Notre modèle se distingue par l'utilisation exclusive de données déclaratives, fournies par les utilisateurs via un avatar personnalisé, pour offrir des recommandations transparentes et respectueuses de la vie privée. Nous analysons les défis techniques et éthiques rencontrés lors du développement de ce système dans un environnement industriel et présentons les solutions envisagées. En fournissant des explications simples et adaptées, nous visons à renforcer la confiance et l'engagement des utilisateurs dans un contexte où le choix d'un cadeau est souvent chargé d'émotions, d'attentes et de considérations financières. Cette étude ouvre de nouvelles perspectives pour la conception de systèmes de recommandation explicables et éthiques dans le domaine du e-commerce.

1 Introduction

Les systèmes de recommandation dans le e-commerce ont évolué, passant des méthodes de filtrage collaboratif (Linden et al., 2003; Gomez-Uribe et Hunt, 2015) aux approches basées sur le contenu (Wang et al., 2021; Liu et al., 2017). Face à cette évolution, Arrieta et Zhang soulignent l'importance d'intégrer le principe de "confiance dès la conception" (trust by design) pour répondre aux préoccupations croissantes concernant la transparence et la protection des données personnelles (Zhang et al., 2020). Cette approche permet de concevoir des systèmes responsables, où la transparence devient un levier stratégique pour renforcer la confiance des utilisateurs (Theis et al., 2023).

Explicabilité des recommandations en e-commerce : étude du modèle **Zeplace**.

Dans ce contexte, l'explicabilité joue un rôle crucial en garantissant que les recommandations sont non seulement personnalisées, mais aussi compréhensibles et acceptables pour les utilisateurs. Elle contribue à instaurer la confiance, réduire les biais et améliorer l'engagement, notamment dans le e-commerce, secteur où les recommandations influencent directement les décisions d'achat (Haque et al., 2023).

Afin d'illustrer cette approche, nous présentons **Zeplace**, un système de recommandation développé pour le e-commerce. Ce système se distingue par son approche centrée sur l'utilisateur, utilisant exclusivement des données déclaratives fournies par le biais d'un avatar personnalisé. Ce modèle permet de proposer des recommandations qui allient personnalisation et transparence, tout en respectant les principes de confidentialité dès la conception (Ferrari Dacrema et al., 2019).

L'un de nos principaux défis réside dans l'intégration d'un module d'explicabilité capable de fournir des explications claires et compréhensibles sur les recommandations, tout en permettant aux utilisateurs de personnaliser leurs préférences. Ce défi soulève la question de l'équilibre entre la précision des recommandations, la clarté des explications et la protection des informations personnelles.

Dans cet article, nous analysons les défis techniques, éthiques et stratégiques à prendre en compte pour concevoir un système de recommandation transparent et engageant.

2 État de l'art

2.1 Systèmes de recommandation

Les systèmes de recommandation jouent un rôle clé dans la gestion de la surcharge d'informations et la personnalisation de l'expérience utilisateur. Linden et al. (2003) ont présenté l'un des premiers systèmes à grande échelle avec le filtrage collaboratif d'Amazon. Depuis, des approches basées sur le contenu, des méthodes hybrides et l'apprentissage profond ont enrichi le domaine (Gao et al., 2020).

Les géants du web ont développé des systèmes sophistiqués qui ont transformé la consommation en ligne. Par exemple, Netflix combine plusieurs modèles pour personnaliser les suggestions de films (Gomez-Uribe et Hunt, 2015), tandis que YouTube utilise des réseaux de neurones pour recommander des vidéos basées sur l'historique de visionnage et les tendances (Covington et al., 2016). Dans le commerce électronique, eBay exploite des "embeddings" pour capturer les préférences des utilisateurs (Wang et al., 2021), et Pinterest a développé un système évolutif adapté à son partage d'images (Gurukar et al., 2022; Liu et al., 2017).

Malgré ces progrès, des défis subsistent. Ferrari Dacrema et al. (2019) soulignent la nécessité d'une évaluation rigoureuse des systèmes basés sur les réseaux de neurones. De plus, leur complexité croissante soulève des questions sur la transparence et l'interprétabilité, mettant en lumière l'importance de l'explicabilité dans les systèmes de recommandation, au-delà de leur performance. Ces enjeux ont suscité un intérêt croissant, que nous examinerons dans la section suivante.

2.2 Explicabilité dans les systèmes de recommandation

L'explicabilité est devenue un enjeu majeur en intelligence artificielle (IA), notamment dans les systèmes de recommandation. Arrieta et al. (2020) définissent l'explicabilité comme la capacité à fournir des explications compréhensibles sur le fonctionnement et les décisions d'un système d'IA. Dans ce contexte, l'explicabilité cherche à rendre transparentes les raisons des recommandations. Zhang et al. (2020) ont identifié plusieurs approches clés :

- **Explicabilité basée sur les caractéristiques** : met en évidence les attributs des produits recommandés.
- **Explicabilité basée sur les voisins** : justifie les recommandations par des utilisateurs ou produits similaires.
- **Explicabilité basée sur les règles** : utilise des règles d'association ou des arbres de décision.
- **Explicabilité basée sur l'attention** : identifie les éléments les plus influents des entrées dans les modèles d'apprentissage profond.

Dans le tableau 1, nous comparons les styles d'explications de différentes plateformes.

Plateforme	Approche de Re-commandation	Style d'Explication	Limites
Amazon	Filtrage collaboratif item-to-item	Basé sur les items, Humain, Hybride	Il existe des difficultés avec les nouveaux utilisateurs (cold start), et les recommandations peuvent être limitées si l'historique est peu développée.
Netflix	Apprentissage automatique, filtrage collaboratif, micro-tags	Hybride (Item/Utilisateur), Personnalisation	Crée des bulles de filtre et favorise des recommandations répétitives qui peuvent limiter la découverte de nouveaux contenus.
YouTube	Réseaux de neurones profonds (deep learning), génération de candidats, classement	Hybride (Item/Feature), Explique l'engagement (temps de visionnage)	Favorise les contenus "click-bait" ou encore renforce les biais algorithmiques, surtout avec des vidéos populaires.
Pinterest	Recommandation basée sur la cooccurrence, embeddings de contenu (Pin2Vec)	Hybride (Humain/Item)	Le système souffre de boucles de rétroaction qui peuvent limiter la diversité des recommandations. Des problèmes de contenu non connecté peuvent aussi apparaître (cold start).

TAB. 1 – Comparaison des approches d'explicabilité pour Amazon, YouTube, Netflix et Pinterest.

Récemment, des approches plus avancées ont émergé. Par exemple, Chen et al. (2022)

Explicabilité des recommandations en e-commerce : étude du modèle **Zeplace**.

ont proposé GREASE, une méthode générant des explications factuelles et contrefactuelles pour les recommandations basées sur les graphes neuronaux. Huang et al. (2022) ont introduit GraphLIME, une adaptation de la méthode LIME pour l'interprétation locale des graphes de réseaux de neurones.

L'évaluation de la qualité des explications demeure un défi majeur. Balog et Radlinski (2020) soulignent la tension entre la fidélité au modèle et l'accessibilité des explications pour l'utilisateur, proposant un cadre d'évaluation multidimensionnel. La recherche continue d'évoluer, avec un intérêt croissant pour les aspects éthiques et la confiance des utilisateurs. Guttman et Ge (2024) ont proposé un agenda de recherche sur l'IA explicable et les systèmes de recommandation éthiques.

2.2.1 Enjeux liés à l'expérience utilisateur

L'explicabilité dans les systèmes de recommandation influence fortement l'expérience utilisateur. Theis et al. (2023) soulignent l'importance de la transparence pour établir la confiance. Les explications affectent la satisfaction, la confiance et la propension des utilisateurs à suivre les recommandations (Balog et Radlinski, 2020). Haque et al. (2023) montrent que la compréhensibilité des explications est essentielle pour l'adoption des systèmes. De plus, Guttman et Ge (2024) insistent sur les considérations éthiques, notamment la protection de la vie privée et l'équité. Tsai et Brusilovsky (2021) ont démontré que des explications claires renforcent la confiance des utilisateurs et facilitent leur participation à l'amélioration du système.

2.2.2 Défis techniques et scientifiques de l'explicabilité

L'implémentation de l'explicabilité dans les systèmes de recommandation présente plusieurs défis techniques et scientifiques, identifiés par Zhang et al. (2020) :

- **Complexité des modèles** : les systèmes modernes basés sur l'apprentissage profond, sont souvent des "boîtes noires" difficiles à interpréter.
- **Mise à l'échelle** : générer des explications personnalisées pour des millions d'utilisateurs en temps réel est un défi majeur.
- **Évaluation des explications** : il n'existe pas de consensus sur les métriques pour évaluer la qualité des explications (Balog et Radlinski, 2020).
- **Gestion des biais** : les explications peuvent renforcer les biais présents dans les données ou les choix de modélisation (Roberts et al., 2022).

Concernant les modèles basés sur les graphes de réseaux de neurones (GNN), Kakkad et al. (2023) soulignent les défis liés à l'interprétation des représentations apprises et la nécessité de méthodes adaptées aux structures de graphes. Bien que la recherche avance, la littérature reste limitée concernant les méthodes d'explicabilité pour ces modèles complexes.

Ces méthodes d'explicabilité nécessitent encore des innovations pour être adaptées au e-commerce, c'est pourquoi nous présentons **Zeplace**, une approche alliant profils utilisateurs personnalisés et mécanismes explicatifs avancés.

3 Cas d'étude du modèle Zeplace.

Zeplace. est un système de recommandation développé pour répondre aux besoins des utilisateurs de ThePlaceToWish.com, un réseau social dédié aux envies et idées cadeaux. Né des retours des utilisateurs, le projet vise à résoudre les difficultés rencontrées pour trouver des cadeaux adaptés à leurs souhaits, en offrant des recommandations personnalisées tout en assurant la transparence et le respect de la vie privée.

3.1 Avantages stratégiques et transparence

Le modèle repose sur la création de profils utilisateurs sous forme d'avatars personnalisés. Le coût d'engagement pour la déclaration des préférences est justifié par le contexte du réseau social ThePlaceToWish.com et peut être soutenu dans d'autres contextes par une gestion optimale de l'expérience utilisateur, telle que la gamification, mais surtout par des garanties de transparence et d'éthique dans le traitement des données. Contrairement aux systèmes traditionnels, il n'utilise pas de données implicites telles que les notations de produits, l'historique d'achats ou de navigation, ni les similarités entre utilisateurs (Linden et al., 2003; Gomez-Uribe et Hunt, 2015). Ces méthodes peuvent introduire du "bruit" en raison d'achats non satisfaisants ou de navigations accidentelles (Ferrari Dacrema et al., 2019) et réduire la diversité des recommandations en favorisant les produits les mieux notés. En évitant les hypothèses implicites sur les préférences communes entre utilisateurs, ce modèle minimise les biais potentiels et assure une transparence dans l'utilisation des données.

L'approche se distingue par deux aspects clés : l'avatar personnalisé et une méthode basée sur le contenu. L'avatar permet à chaque utilisateur de définir précisément ses préférences, centres d'intérêt et valeurs, ou celles de ses proches, de manière indépendante. Il est possible de créer plusieurs avatars pour différentes personnes, facilitant ainsi la recherche de cadeaux adaptés à chaque occasion. La méthode basée sur le contenu compare les attributs de l'avatar aux produits, garantissant des recommandations pertinentes. En s'appuyant exclusivement sur des données déclaratives, ce modèle réduit les biais des méthodes traditionnelles fondées sur les comportements, tout en respectant les exigences du RGPD (EU RGPD, Raison 71, 2016). Cette approche améliore également la compréhension du processus de recommandation, renforçant ainsi l'explicabilité du système (Ferrari Dacrema et al., 2019).

3.2 Implémentation du module d'explicabilité

L'explicabilité du modèle **Zeplace.** est intégrée dans un module autonome, inspiré de méthodes factuelles telles que SHAP (Merrick et Taly, 2020).

Les principales fonctionnalités de ce module sont les suivantes :

- **Explications basées sur les préférences déclarées** : chaque recommandation est accompagnée d'une explication détaillée, reliant les préférences de l'utilisateur (déclarées lors de la création de l'avatar) aux caractéristiques du produit recommandé, avec des liens sémantiques quantifiés à l'aide des valeurs de SHapley.
- **Personnalisation des explications** : les explications sont ajustées selon le niveau de détail préféré par chaque utilisateur, offrant des résumés succincts ou des analyses détaillées sur l'impact des données de l'avatar sur les caractéristiques des produits recommandés.

3.3 Vers un système adapté aux attentes des utilisateurs

Les utilisateurs sont de plus en plus exigeants en matière de services personnalisés, tout en réclamant un respect strict de leurs données personnelles. Si la précision des recommandations reste un objectif fondamental, leur mise en production révèle une attente croissante sur la transparence des décisions et la justification des produits recommandés.

Le développement des systèmes de recommandation dans l'industrie pose le défi complexe de concilier précision et transparence. D'une part, les modèles avec des performances élevées mais avec une structure complexes, et par conséquent une interprétabilité réduite, sont souvent désavantagés par leur manque de transparence (Kakkad et al., 2023). D'autre part, comme soulevé par Wang et al. (2024), les utilisateurs exigent des recommandations non seulement personnalisées mais aussi explicables, ce qui souligne la nécessité de rendre ces modèles plus transparents et compréhensibles pour renforcer la confiance. Cela soulève la question d'un compromis à trouver pour rendre les plateformes attractives et utiles aux utilisateurs dans leurs prises de décisions.

Dans le contexte du réseau social ThePlaceToWish.com où l'obtention de données déclaratives est justifiée par la volonté des utilisateurs à utiliser le service, il apparaît que l'approche développée avec le modèle **Zeplace**, donne une nouvelle façon de trouver un meilleur compromis.

La question du temps de développement et de mise en production est également cruciale, surtout dans un environnement où les ressources humaines et matérielles sont limitées. L'intégration des utilisateurs finaux dans le processus de conception peut certes allonger les délais de développement, mais a l'avantage de garantir l'adoption du système par les utilisateurs finaux, comme le suggère la méthode de co-construction préconisée par Ries (2012). Il s'agit de trouver un juste équilibre entre la rapidité de développement pour répondre aux exigences du marché et l'implication des utilisateurs pour assurer le succès à long terme du système de recommandation.

4 Conclusion et perspectives

Cet article présente les enjeux de l'explicabilité dans les systèmes de recommandation e-commerce et explore l'approche du modèle **Zeplace**, pour répondre aux exigences de transparence, d'éthique et aux défis techniques rencontrés lors du développement de ces modèles, tout en visant un compromis qui satisfasse les attentes des utilisateurs finaux.

Notre approche intègre l'utilisateur tout au long du processus de création des explications, afin de garantir leur pertinence et le respect des données personnelles. Par ailleurs, dans un contexte où l'engagement des utilisateurs est crucial, une gestion optimale de l'expérience utilisateur via la gamification peut faciliter la collecte de données de qualité, essentielle pour affiner les recommandations.

En perspective, nous envisageons d'étendre cette approche à d'autres secteurs que le e-commerce et d'analyser plus en profondeur l'impact de l'explicabilité sur la satisfaction utilisateur. Des recherches futures pourraient également s'intéresser à l'évaluation des méthodes d'explicabilité en temps réel et à l'amélioration des algorithmes pour mieux capter l'évolution des préférences des utilisateurs sous la forme d'avatars dynamiques.

Références

- Arrieta, A. B., N. Díaz-Rodríguez, J. Del Ser, A. Bennetot, S. Tabik, A. Barbado, S. García, S. Gil-López, D. Molina, R. Benjamins, et al. (2020). Explainable artificial intelligence (xai) : Concepts, taxonomies, opportunities and challenges toward responsible ai. *Information fusion* 58, 82–115.
- Balog, K. et F. Radlinski (2020). Measuring recommendation explanation quality : The conflicting goals of explanations. In *Proceedings of the 43rd international ACM SIGIR conference on research and development in information retrieval*, pp. 329–338.
- Chen, Z., F. Silvestri, J. Wang, Y. Zhang, Z. Huang, H. Ahn, et G. Tolomei (2022). Grease : Generate factual and counterfactual explanations for gnn-based recommendations. *arXiv preprint arXiv :2208.04222*.
- Covington, P., J. Adams, et E. Sargin (2016). Deep neural networks for youtube recommendations. In *Proceedings of the 10th ACM conference on recommender systems*, pp. 191–198.
- EU RGPD, Raison 71 (2016). Parlement européen et conseil : Règlement (ue) 2016/679 relatif à la protection des données à caractère personnel. Journal officiel de l’Union européenne. Consolidé suite au rectificatif du 23 mai 2018.
- Ferrari Dacrema, M., P. Cremonesi, et D. Jannach (2019). Are we really making much progress ? a worrying analysis of recent neural recommendation approaches. In *Proceedings of the 13th ACM conference on recommender systems*, pp. 101–109.
- Gao, Y., Y.-F. Li, Y. Lin, H. Gao, et L. Khan (2020). Deep learning on knowledge graph for recommender system : A survey. *arXiv preprint arXiv :2004.00387*.
- Gomez-Uribe, C. A. et N. Hunt (2015). The netflix recommender system : Algorithms, business value, and innovation. *ACM Transactions on Management Information Systems (TMIS)* 6(4), 1–19.
- Gurukur, S., N. Pancha, A. Zhai, E. Kim, S. Hu, S. Parthasarathy, C. Rosenberg, et J. Leskovec (2022). Multibisage : A web-scale recommendation system using multiple bipartite graphs at pinterest. *Proceedings of the VLDB Endowment* 16(4), 781–789.
- Guttmann, M. et M. Ge (2024). Research agenda of ethical recommender systems based on explainable ai. *Procedia Computer Science* 238, 328–335, doi: <https://doi.org/10.1016/j.procs.2024.06.032>. The 15th International Conference on Ambient Systems, Networks and Technologies Networks (ANT) / The 7th International Conference on Emerging Data and Industry 4.0 (EDI40), April 23-25, 2024, Hasselt University, Belgium.
- Haque, A., A. Islam, et P. Mikalef (2023). Notion of explainable artificial intelligence—an empirical investigation from a users perspective. *arXiv preprint arXiv :2311.02102*.
- Huang, Q., M. Yamada, Y. Tian, D. Singh, et Y. Chang (2022). Graphlime : Local interpretable model explanations for graph neural networks. *IEEE Transactions on Knowledge and Data Engineering* 35(7), 6968–6972.
- Kakkad, J., J. Jannu, K. Sharma, C. Aggarwal, et S. Medya (2023). A survey on explainability of graph neural networks. *arXiv preprint arXiv :2306.01958*.

Explicabilité des recommandations en e-commerce : étude du modèle **Zeplace**.

- Linden, G., B. Smith, et J. York (2003). Amazon. com recommendations : Item-to-item collaborative filtering. *IEEE Internet computing* 7(1), 76–80.
- Liu, D. C., S. Rogers, R. Shiau, D. Kislyuk, K. C. Ma, Z. Zhong, J. Liu, et Y. Jing (2017). Related pins at pinterest : The evolution of a real-world recommender system. In *Proceedings of the 26th international conference on world wide web companion*, pp. 583–592.
- Merrick, L. et A. Taly (2020). The explanation game : Explaining machine learning models using shapley values. In *Machine Learning and Knowledge Extraction : 4th IFIP TC 5, TC 12, WG 8.4, WG 8.9, WG 12.9 International Cross-Domain Conference, CD-MAKE 2020, Dublin, Ireland, August 25–28, 2020, Proceedings 4*, pp. 17–38. Springer.
- Ries, E. (2012). *Lean startup : adoptez l'innovation continue*. Pearson.
- Roberts, C. V., E. Elahi, et A. Chandrashekar (2022). On the bias-variance characteristics of lime and shap in high sparsity movie recommendation explanation tasks. *arXiv preprint arXiv :2206.04784*.
- Theis, S., S. Jentzsch, F. Deligiannaki, C. Berro, A. P. Raulf, et C. Bruder (2023). Requirements for explainability and acceptance of artificial intelligence in collaborative work. In *International Conference on Human-Computer Interaction*, pp. 355–380. Springer.
- Tsai, C.-H. et P. Brusilovsky (2021). The effects of controllability and explainability in a social recommender system. *User Modeling and User-Adapted Interaction* 31, 591–627.
- Wang, S., X. Zhang, Y. Wang, et F. Ricci (2024). Trustworthy recommender systems. *ACM Transactions on Intelligent Systems and Technology* 15(4), 1–20.
- Wang, T., Y. M. Brovman, et S. Madhvanath (2021). Personalized embedding-based e-commerce recommendations at ebay. *arXiv preprint arXiv :2102.06156*.
- Zhang, Y., X. Chen, et al. (2020). Explainable recommendation : A survey and new perspectives. *Foundations and Trends® in Information Retrieval* 14(1), 1–101.

Summary

This paper investigates the challenges of explainability in recommendation systems for e-commerce, using the case study of **Zeplace**, a system developed by ThePlaceToWish. In a context where transparency is both a regulatory requirement (EU RGPD, Raison 71 , 2016) and a strategic factor for building user trust (Theis et al., 2023), we propose an approach that integrates explainability from the system's design phase. The model is distinguished by its exclusive use of declarative data provided by users via a personalized avatar, enabling transparent recommendations that uphold privacy. We examine the technical and ethical challenges encountered during the system's development in an industrial context and discuss the solutions implemented to address them. By offering clear and customized explanations, the system aims to enhance user trust and engagement, particularly in the emotionally charged context of gift selection, which involves both expectations and financial considerations. This work provides insights into the design of explainable and ethical recommendation systems within the e-commerce sector.