

Contextualisation des explications dans les systèmes de recommandation : une approche basée sur les schémas d'interprétation des utilisateurs

Contextualizing Explanations in Recommender Systems : An Approach Based on User Interpretive Schemas

Deo Munduku¹, Elsa Negre¹

¹LAMSADE (UMR CNRS 7243), Université Paris-Dauphine – PSL, Paris, France

deo.munduku@dauphine.psl.eu

RÉSUMÉ. Les systèmes de recommandation explicables cherchent à renforcer la transparence et la confiance des utilisateurs en accompagnant chaque recommandation d'une explication. Toutefois, ces explications ne sont pas interprétées de manière uniforme : une même explication peut être comprise par certains utilisateurs mais pas par d'autres. Les approches existantes basées sur le choix de l'utilisateur, la construction de profils explicatifs ou la mise en avant des contenus permettent de justifier une recommandation en s'appuyant sur différentes informations liées à l'usage ou au contenu. Cependant, elles ne prennent pas en compte la manière dont les utilisateurs interprètent ces explications. Pour répondre à cette limite, dans cet article, nous proposons deux pistes complémentaires : (i) identifier les facteurs humains internes qui influencent le plus la compréhension d'une explication, nous faisons l'hypothèse que le facteur central est le schéma d'interprétation, entendu comme une structure cognitive orientant la sélection et la compréhension de l'information ; (ii) exploiter ces facteurs pour adapter dynamiquement le type, le style et le niveau de détail des explications. Ce positionnement ouvre la voie à une nouvelle génération de systèmes de recommandation explicables, capables de contextualiser les explications en fonction du mode de compréhension propre à chaque utilisateur, et ainsi de renforcer à la fois leur utilité, leur lisibilité et la confiance qu'ils inspirent.

ABSTRACT. Explainable recommender systems aim to strengthen transparency and user trust by providing an explanation alongside each recommendation. However, these explanations are not interpreted uniformly : the same explanation may be understood by some users but not by others. Existing approaches based on user choice, the construction of explanatory profiles, or the highlighting of content justify a recommendation by relying on different information related to usage or content. Nevertheless, they do not take into account the way users actually interpret these explanations. To address this limitation, in this paper we propose two complementary directions : (i) identifying the internal human factors that most strongly influence the understanding of an explanation ; we hypothesize that the central factor is the interpretive schema, understood as a cognitive structure guiding the selection and understanding of information ; (ii) exploiting these factors to dynamically adapt the type, style, and level of detail of explanations. This positioning paves the way for a new generation of explainable recommender systems, capable of contextualizing explanations according to each user's own mode of understanding, and thereby reinforcing their usefulness, readability, and the trust they inspire.

MOTS-CLÉS. Systèmes de recommandation, explications, contextualisation, personnalisation, schéma d'interprétation
KEYWORDS. Recommender systems, explanations, contextualization, personalization, interpretive schema

Introduction

Avec la montée en puissance des plateformes numériques, les systèmes de recommandation sont devenus des outils essentiels pour aider les utilisateurs à faire des choix dans des environnements complexes et saturés d'informations. Ces systèmes reposent sur des algorithmes capables de filtrer et de proposer des contenus adaptés aux préférences et aux besoins des utilisateurs. Leur objectif est de fournir des suggestions à la fois pertinentes et compréhensibles afin de maximiser la satisfaction des utilisateurs (Negre, 2018).

Cependant, malgré ces avancées, le fonctionnement interne de nombreux systèmes de recommandation reste perçu comme une « boîte noire », c'est-à-dire difficile à comprendre. Par exemple, un utilisateur

peut recevoir la recommandation du film *Inception* sans qu'aucune explication ne soit fournie sur les raisons de ce choix. Confronté à une telle situation, il peut légitimement se demander : « Pourquoi ce film m'est-il recommandé ? », ce qui engendre incompréhension et parfois méfiance.

Pour surmonter ce problème, la recherche s'est orientée vers l'intégration d'explications dans les systèmes de recommandation, ce qui a conduit à l'émergence des systèmes de recommandation explicables, où chaque recommandation est accompagnée d'une explication destinée à renforcer la compréhension et la confiance des utilisateurs.

Par exemple, au lieu de simplement recommander le film *Inception* à un utilisateur, le système de recommandation ajoute une explication : « Le film *Inception* vous est recommandé parce que vous avez apprécié les films *Interstellar* et *The Matrix*, avec lesquels il partage un style narratif complexe et des thèmes de science-fiction. » Une telle explication favorise la compréhension et renforce la confiance de l'utilisateur envers le système de recommandation.

L'une des principales limites de cette intégration (des explications dans les systèmes de recommandation) réside dans le fait que les utilisateurs interprètent différemment les explications qui accompagnent les recommandations. Une même explication peut ainsi être perçue de manière différente selon l'expérience, les attentes ou encore la façon dont l'utilisateur traite l'information. Par exemple, l'explication donnée pour le film *Inception* « Le film *Inception* vous est recommandé parce que vous avez apprécié les films *Interstellar* et *The Matrix*, avec lesquels il partage un style narratif complexe et des thèmes de science-fiction. » pourra sembler suffisante et claire pour un spectateur ordinaire, qui recherche simplement un lien narratif. En revanche, un cinéphile expérimenté ou un critique de cinéma attendra une explication plus technique (par exemple un score de similarité ou une analyse des thèmes), et pourra juger cette explication trop superficielle.

En effet, les individus ne reçoivent pas passivement une explication : ils la filtrent et l'assimilent selon leur propre cadre de compréhension cognitif. Ce cadre de compréhension cognitif, qui influence directement la manière dont les explications sont comprises, est désigné sous le terme de schéma d'interprétation, défini comme un filtre cognitif implicite et préexistant à travers lequel un individu perçoit le monde : le schéma d'interprétation oriente la sélection des données entrantes, façonne la compréhension et organise ces informations en connaissances utilisables par l'individu (Arduin, 2013).

Le schéma d'interprétation ne se limite pas à guider la compréhension des explications : il structure plus largement notre manière de percevoir et d'atteindre toute information, qu'elle provienne de notre environnement quotidien ou d'un système numérique, y compris les explications générées par un système de recommandation (Hébert, 1999 ; Hubert et al., 2022).

Ainsi, la prise en compte du contexte utilisateur devient essentielle pour intégrer le schéma d'interprétation dans le système de recommandation et affiner l'adaptation des explications. En suivant la définition proposée par Dey (2001), le contexte utilisateur correspond à toute information permettant de caractériser sa situation. Dans le cadre des systèmes de recommandation, ces informations peuvent être externes (moment, lieu, appareil utilisé, contexte social) ou internes (préférences, état émotionnel, connaissances mobilisées, cadre cognitif). Le schéma d'interprétation s'inscrit ainsi dans cette dimension interne et, plus précisément, dans le cadre cognitif, avec un rôle de filtre actif qui sélectionne, organise et oriente la compréhension des informations entrantes qu'il s'agisse d'un texte, d'une image, d'une vidéo, d'une explication générée par le système, etc.

Dès lors, une question centrale se pose : Comment contextualiser les explications dans les systèmes de recommandation en intégrant les facteurs contextuels les plus impactants, afin d'adapter leur contenu et leur niveau de détail aux besoins spécifiques de chaque utilisateur ?

Afin d'éclairer cette question centrale, notre article s'organise en trois volets complémentaires. Dans un premier temps, un état de l'art analyse les principales approches d'explication dans les systèmes de recommandation, en mettant en évidence leurs apports et leurs limites. Dans un second temps, la problématique est clarifiée et déclinée en sous-questions de recherche destinées à orienter la suite de l'analyse. Enfin, une discussion avance des hypothèses et esquisse des pistes concrètes pour répondre à ces interrogations et progresser vers des systèmes de recommandation mieux alignés sur la manière dont les utilisateurs interprètent les explications.

1. État de l'art

La question des explications dans les systèmes de recommandation attire de plus en plus l'attention des chercheurs (Zhang & Chen, 2020 ; Nunes & Jannach, 2017 ; Tintarev & Masthoff, 2015).

À partir de notre analyse critique de la littérature, nous proposons de regrouper les approches existantes en trois grandes familles : (i) celles qui reposent sur le choix explicite de l'utilisateur, (ii) celles qui exploitent des profils ou des préférences explicatives, et (iii) celles qui s'appuient sur les contenus recommandés.

1.1. *Approches basées sur le choix de l'utilisateur*

La manière dont une explication est comprise dépend fortement du niveau de détail fourni et des différences entre utilisateurs (Zhang & Chen, 2020). Pour tenir compte de cette diversité, certaines approches proposent des interfaces où l'utilisateur peut choisir lui-même, parmi plusieurs explications disponibles, celle qui lui semble la plus compréhensible (Chatti, 2022 ; Guesmi, 2023). Par exemple, pour une même recommandation de film, le système peut proposer plusieurs formulations alternatives, telles que : « Ce film vous est recommandé car il ressemble aux films que vous avez déjà appréciés », « Ce film vous est recommandé avec un score de similarité de 0,85 », ou encore « Ce film vous est recommandé car il partage le même réalisateur et les mêmes thèmes narratifs que vos films préférés ». Dans ce cas, c'est l'utilisateur qui sélectionne lui-même l'explication qu'il juge la plus utile ou la plus compréhensible.

Cependant, ces approches reposent sur une hypothèse forte : elles supposent que l'utilisateur sait dès le départ ce dont il a besoin, par exemple s'il préfère une explication courte, chiffrée ou détaillée. En pratique, ce n'est pas toujours le cas, car les préférences évoluent selon la tâche ou le moment. Ainsi, des travaux plus récents (Kouki, 2020 ; Antognini & al., 2021) montrent que le besoin d'explication apparaît souvent progressivement, au fil de l'usage, plutôt qu'au moment du premier choix.

En synthèse, ces approches mettent en évidence les différences entre utilisateurs et ouvrent la voie à une personnalisation plus fine des explications. Cependant, elles soulèvent une question essentielle : comment ajuster les explications de manière continue et fiable, sans dépendre uniquement des choix immédiats de l'utilisateur ?

Pour répondre à cette question, une deuxième famille d'approches cherche à construire des profils explicatifs ou à capter les préférences des utilisateurs de manière plus durable. Ces travaux visent à alléger la charge de décision de l'utilisateur en modélisant directement ses besoins en explications.

1.2. Approches basées sur les profils explicatifs de l'utilisateur

Au lieu de demander à l'utilisateur de choisir une explication à chaque fois, certaines approches essaient de créer un profil qui décrit directement ses préférences en matière d'explications. Ce profil sert ensuite de base pour générer des explications adaptées à son style préféré. Par exemple, si le profil d'un utilisateur indique une préférence pour des explications synthétiques et quantitatives, le système pourra formuler : « Ce restaurant vous est recommandé car il obtient un score de correspondance de 92% avec vos préférences ». À l'inverse, pour un utilisateur dont le profil révèle une préférence pour des explications plus descriptives, le système pourra produire : « Ce restaurant vous est recommandé car il correspond à vos goûts en matière de cuisine calme, proche et abordable ». Ici, l'explication n'est pas choisie au moment de l'interaction, mais générée à partir d'un profil explicatif préalable. Par exemple, Ramos (2024) illustre cette idée en exploitant les avis rédigés par les utilisateurs pour construire automatiquement un profil en langage naturel. Ce profil permet de personnaliser la formulation des explications de manière à mieux correspondre aux attentes de chaque utilisateur. De leur côté, Antognini et al. (2021) montrent qu'un utilisateur peut critiquer une explication pour ajuster implicitement son profil de préférences, tandis que Kouki et al. (2020) proposent de combiner à la fois les préférences déclarées par l'utilisateur (par exemple ses choix exprimés) et ses comportements observés (clics, temps de lecture, réactions aux explications) afin de construire un profil plus complet et fidèle à ses attentes.

Ces approches présentent deux avantages principaux : elles donnent plus de transparence et réduisent l'effort de choix immédiat pour l'utilisateur. Cependant, elles montrent aussi plusieurs limites : les profils restent souvent figés et ne s'adaptent pas facilement à l'évolution des attentes ; ils reposent sur des données parfois incomplètes ou peu fiables, et peuvent poser des problèmes de confidentialité. De plus, les profils sont rarement mis à jour en temps réel, ce qui réduit leur capacité à suivre les besoins changeants des utilisateurs.

En synthèse, cette famille d'approches cherche à anticiper les préférences de l'utilisateur grâce à un profil explicatif construit à partir de ses retours ou de ses comportements. Elles facilitent donc l'usage au quotidien, mais leur manque d'adaptation limite leur efficacité sur le long terme.

1.3. Approches basées sur les contenus recommandés

Une troisième famille d'approches ne se centre pas directement sur l'utilisateur, mais sur les contenus recommandés eux-mêmes. L'idée est de générer une explication en mettant en avant les points communs visibles (comme le genre d'un film, l'auteur d'un livre ou les ingrédients d'une recette) ou implicites (comme le style narratif, l'ambiance, etc.) entre les contenus déjà appréciés et la nouvelle recommandation. Par exemple, un système peut expliquer : « Ce film vous est recommandé car il est du même genre que ceux que vous avez aimés », ou encore : « Cette recette vous est suggérée car elle contient des ingrédients similaires à ceux que vous cuisinez souvent ». De manière générale, dans cette famille, l'explication est construite à partir des propriétés du contenu recommandé lui-même et de ses ressemblances avec des contenus appréciés auparavant. Ainsi, pour un livre, le système peut indiquer qu'il appartient

au même genre que ceux déjà lus par l'utilisateur ; pour un film, il peut mettre en avant un réalisateur commun, un univers narratif proche ou un style visuel comparable.

Dans cette approche, plusieurs travaux proposent des déclinaisons complémentaires. Verma et al. (2024) montrent qu'il est possible d'apprendre automatiquement quelles caractéristiques explicitées des contenus sont perçues comme les plus pertinentes, afin de générer des explications ciblées et convaincantes. De Pauw et al. (2022) s'appuient sur les informations descriptives disponibles (par exemple le genre, l'auteur, des mots-clés) pour formuler des explications plus riches et compréhensibles. Enfin, Göpfert et al. (2022) mettent en évidence des similarités implicites entre le contenu proposé et ceux déjà appréciés par l'utilisateur, au-delà des critères explicités comme le genre ou l'auteur, en intégrant également des aspects de style et d'ambiance (par exemple, en cinéma : intrigue non linéaire, tonalité sombre, rythme lent ; en musique : atmosphère mélancolique, tempo proche). Ces points communs, qui ne figurent pas explicitement dans les informations affichées sur la page du contenu, sont ensuite restitués dans un langage accessible pour expliquer la recommandation.

Ces approches présentent plusieurs avantages. Elles sont plus automatisées que les deux familles précédentes, car elles s'appuient directement sur les caractéristiques des contenus, ce qui permet de produire facilement des explications claires et lisibles. Elles offrent aussi une transparence immédiate : l'utilisateur peut comprendre rapidement le lien entre ce qu'il connaît déjà et ce qui lui est proposé.

Cependant, elles présentent également des limites. Elles restent centrées sur les contenus et ne prennent pas en compte la manière dont l'utilisateur préfère comprendre une explication. Par exemple, certains utilisateurs privilégient des explications chiffrées ou comparatives, tandis que d'autres préfèrent des explications narratives ou qualitatives. Si le système ne s'appuie que sur les points communs explicites ou implicites entre contenus, il peut donner une explication correcte mais jugée peu pertinente ou insuffisante par l'utilisateur.

En synthèse, ces approches enrichissent la lisibilité des recommandations en mettant en avant des points communs entre contenus, mais elles négligent la diversité des façons dont les utilisateurs donnent du sens à une explication.

Pris ensemble, ces travaux mettent en évidence trois grandes familles d'approches. La première montre que laisser le choix à l'utilisateur révèle la diversité des besoins, mais reporte toute la charge de décision sur lui. La deuxième cherche à anticiper ces besoins grâce à des profils explicatifs, ce qui réduit l'effort immédiat mais reste souvent trop figé ou incomplet. La troisième automatise la génération d'explications en mettant en avant des points communs entre contenus, mais néglige la manière propre à chaque utilisateur de donner du sens à une explication.

Le **Tableau 1** ci-dessus présente une vue d'ensemble des trois familles, en mettant en évidence leur logique, leurs points forts et leurs limites au regard de la contextualisation des explications.

Ces trois familles d'approches ont permis d'améliorer l'explicabilité des systèmes de recommandation en rendant les explications plus accessibles, plus personnalisées ou plus compréhensibles selon les cas. Elles ont ainsi posé les bases d'une meilleure transparence et contribué à renforcer la confiance des utilisateurs.

Cependant, elles partagent une limite commune : aucune ne modélise véritablement le facteur interne qui conditionne la manière dont une explication est comprise. C'est précisément ce rôle que peut jouer

Famille	Idée principale	Forces	Limites
Approches basées sur le choix de l'utilisateur (Section 1.1)	L'utilisateur sélectionne lui-même le niveau de détail ou le type d'explication.	Met en évidence la diversité des besoins.	Charge de décision sur l'utilisateur ; suppose qu'il sache dès le départ ce qu'il veut.
Approches basées sur les profils explicatifs (Section 1.2)	Construire un profil décrivant les préférences explicatives de l'utilisateur, à partir de ses retours ou comportements.	Réduit l'effort immédiat ; augmente la transparence.	Profils souvent figés, incomplets, rarement mis à jour en temps réel ; risques de confidentialité.
Approches basées sur les contenus recommandés (Section 1.3)	Générer une explication en mettant en avant les points communs visibles ou implicites entre contenus appréciés et recommandation.	Explications claires, automatisées, faciles à comprendre ; transparence immédiate.	Néglige la manière dont l'utilisateur préfère comprendre une explication (style narratif, chiffres, comparaison, etc.)

TABLEAU 1. *Comparaison des trois principales familles d'approches d'explication dans les systèmes de recommandation.*

le schéma d'interprétation, entendu comme le cadre cognitif qui oriente la compréhension, détermine le type de justification jugé pertinent et fixe le niveau de détail considéré utile.

Il convient donc d'examiner si, et comment, cette notion a déjà fait l'objet de tentatives de formalisation dans la littérature en systèmes d'information. C'est l'objet de la section suivante

1.4. Tentative de formalisation du schéma d'interprétation

Parmi les rares travaux ayant tenté de formaliser explicitement le schéma d'interprétation, citons Arduin et al. (2013b), à travers le cadre DITEK (*Data-Information-Tacit & Explicit Knowledge*). Ce cadre repose sur une idée centrale : une même donnée n'est pas transformée en information de manière identique pour tous les utilisateurs, car cette transformation dépend de leur état interne, notamment de leurs connaissances et de leur manière d'interpréter ce qui leur est présenté.

Dans cette perspective, les données perçues correspondent aux éléments fournis par le système à l'utilisateur, par exemple une recommandation accompagnée d'une explication. L'information, quant à elle, correspond au sens effectivement construit par l'utilisateur à partir de ces données. Autrement dit, la donnée perçue est ce qui est présenté ; l'information est ce qui est compris.

Le cadre DITEK souligne également que cet état interne n'est pas figé : il peut évoluer au fil des interactions, en fonction des réactions de l'utilisateur et de son retour d'expérience. Cette idée est importante pour notre travail, car elle justifie qu'une explication ne doive pas être adaptée une fois pour toutes, mais réajustée progressivement.

Dans la continuité de cette perspective, nous proposons d'opérationnaliser le schéma d'interprétation de manière plus directement exploitable dans les systèmes de recommandation. Dans notre approche, ce schéma est approché par un ensemble ordonné d'éléments que l'utilisateur considère comme saillants ou prioritaires dans une explication :

$$\hat{S}_u = (c_1, c_2, \dots, c_n) \quad [1]$$

où c_1, c_2, \dots, c_n désignent les éléments jugés les plus importants par l'utilisateur, ordonnés selon leur priorité interprétative. Ainsi, \hat{S}_u représente une estimation du schéma d'interprétation de l'utilisateur u .

Cette estimation peut être construite à partir de plusieurs types d'indices complémentaires : des préférences déclarées par l'utilisateur, des réactions explicites recueillies après la lecture d'une explication, ainsi que des traces d'interaction telles que le temps de lecture, les clics ou les demandes d'explications supplémentaires. L'objectif n'est donc pas de prétendre observer directement le schéma d'interprétation, mais d'en proposer une approximation exploitable pour l'adaptation des explications.

Par exemple, pour la recommandation de restaurants, un utilisateur peut indiquer que la distance, le prix et le type de cuisine sont les premiers critères qu'il regarde. Si les explications qui commencent par ces éléments sont jugées plus claires, plus utiles ou plus convaincantes que celles qui mettent d'abord en avant d'autres informations, alors ces régularités peuvent servir à estimer un schéma d'interprétation propre à cet utilisateur. Ce schéma estimé peut ensuite être utilisé pour adapter le contenu, l'ordre de présentation ou le niveau de détail des explications futures.

Ainsi, le cadre DITEK fournit une base théorique pour penser le rôle de l'état interne dans la construction du sens, tandis que notre proposition cherche à en donner une traduction plus opérationnelle dans le contexte des systèmes de recommandation explicables.

2. Problématique

Les travaux sur les systèmes de recommandation explicables ont permis d'améliorer la transparence et de renforcer la confiance des utilisateurs (Zhong, 2023). Cependant, les explications ne sont pas comprises de la même manière par tous les utilisateurs : ce qui paraît clair et utile pour l'un peut sembler insuffisant pour un autre. Cette disparité renvoie à un facteur interne identifié dans la littérature sous le nom de *schéma d'interprétation*.

En continuité avec la question centrale formulée dans l'introduction (« Comment contextualiser les explications dans les systèmes de recommandation en intégrant les facteurs contextuels les plus impactants, afin d'adapter leur contenu et leur niveau de détail aux besoins spécifiques de chaque utilisateur ? »), nous déclinons notre démarche en deux sous-questions :

- q1. Comment identifier les facteurs contextuels ayant le plus d'impact sur les recommandations ?
- q2. Comment exploiter ces facteurs pour produire des explications contextualisées, adaptées aux besoins spécifiques des utilisateurs ?

Il convient de préciser que le schéma d'interprétation n'est pas une variable directement observable. Nous le considérons plutôt comme une structure interne de compréhension, accessible uniquement de manière indirecte à travers plusieurs types d'indices complémentaires : des traces d'interaction, des retours explicites recueillis après la consultation d'une explication, ainsi que, lorsque cela est possible, des préférences déclarées par l'utilisateur lui-même. L'enjeu n'est donc pas de mesurer ce schéma de façon immédiate, mais d'en proposer une estimation progressive à partir d'indices observables, tels que le temps de lecture d'une explication, les clics effectués après consultation, les demandes d'informations supplémentaires, les rejets rapides, les évaluations déclarées de clarté, d'utilité ou de satisfaction, ou encore les éléments que l'utilisateur indique comme les plus importants pour lui dans une explication. Par exemple, si un utilisateur déclare que la distance et le prix sont les premiers critères qu'il regarde, lit jusqu'au bout les explications qui commencent par ces éléments, et juge moins utiles celles qui mettent d'abord en avant d'autres informations, ce comportement peut signaler une manière relativement stable de sélectionner et de comprendre l'information. L'agrégation de ces différents indices permet alors de construire un profil interprétatif évolutif, révisé au fil des usages.

En posant ces deux questions, nous définissons le cadre de notre démarche et ouvrons la voie à la discussion qui suit.

3. Discussion

Cette discussion s'organise autour des deux sous-questions posées dans la section 2. Elle propose d'abord une piste pour identifier les facteurs internes liés au schéma d'interprétation (q1), puis une piste pour exploiter ces facteurs afin de générer des explications contextualisées (q2).

3.1. Piste pour répondre à q1 : identifier les facteurs et leurs indicateurs

Pour répondre à q1, l'objectif est de trouver des moyens pour repérer ce qui influence réellement la manière dont un utilisateur comprend une explication. Plutôt que d'utiliser des questionnaires complexes ou des données sensibles, nous proposons de nous appuyer sur des traces d'usage non intrusives, comme : le temps de lecture d'une explication, le fait de cliquer ou non après lecture, les rejets rapides, ou encore les demandes répétées d'explications supplémentaires. Ces signaux, une fois collectés et anonymisés, constituent des indices (ou indicateurs) du mode de réception de l'utilisateur. Nous soulignons toutefois qu'aucun de ces signaux ne peut être interprété isolément de manière univoque. Par exemple, un temps de lecture court peut traduire une compréhension immédiate, mais aussi un manque d'attention, une contrainte temporelle ou une consultation sur un appareil mobile. De même, un temps de lecture long peut refléter soit un engagement élevé, soit une difficulté de compréhension. En outre, ce temps de lecture ne peut être interprété de manière brute lorsque les explications ont des longueurs différentes ou lorsque les utilisateurs présentent des rythmes de lecture hétérogènes. Pour cette raison, son analyse doit être rapportée à la longueur de l'explication consultée, par exemple au moyen d'un temps de lecture normalisé, et interprétée en tenant compte des différences interindividuelles. L'objectif n'est donc pas de comparer directement tous les utilisateurs sur une même base temporelle absolue, mais d'identifier des régularités relatives dans leur manière de lire, d'évaluer et d'accepter les explications. Nous ne proposons donc pas d'inférer le schéma d'interprétation à partir d'un signal unique, mais à partir de la combinaison de plusieurs indices convergents.

À ce stade, il convient de distinguer les signaux observables des facteurs interprétatifs eux-mêmes. Les premiers correspondent aux traces directement mesurables laissées par l'utilisateur lors de son interaction avec le système ; les seconds renvoient à des propriétés plus profondes de sa manière de comprendre une explication. Notre objectif n'est donc pas d'identifier directement ces facteurs à partir d'un seul comportement, mais d'estimer progressivement un profil interprétatif à partir de régularités observées dans plusieurs situations. Une première étape consiste alors à analyser les relations entre les signaux collectés et les réactions de l'utilisateur, telles que l'utilité perçue, la satisfaction ou l'acceptation de la recommandation. Cette étape, inspirée de Ferdousi (2020), permet de repérer les indices les plus informatifs. Toutefois, comme certaines interactions peuvent être plus complexes, cette analyse pourra être complétée par des méthodes plus flexibles issues de l'apprentissage automatique, afin d'identifier des configurations récurrentes de signaux associées à certaines préférences interprétatives.

L'objectif final est d'obtenir un ensemble d'indicateurs fiables, faciles à observer et à mettre à jour en temps réel, qui permettent d'estimer le « profil d'interprétation » d'un utilisateur. Par exemple, un utilisateur qui lit attentivement les explications narratives mais ignore rapidement les explications chiffrées montre une préférence claire pour un certain style d'explication.

3.2. Piste pour répondre à q2 : exploiter les facteurs pour adapter les explications

Une fois les facteurs contextuels internes identifiés à l'étape précédente (réponse à q1), l'idée est de les exploiter pour ajuster la manière dont les explications sont produites et ainsi les contextualiser en fonction des besoins spécifiques de chaque utilisateur. Autrement dit, le schéma d'interprétation estimé sert de repère pour orienter le type, le niveau de détail et le style des explications que le système de recommandation doit produire, afin qu'elles restent en adéquation avec le niveau de compréhension de l'utilisateur.

Par exemple, si un utilisateur montre qu'il comprend mieux des formulations narratives, le système privilégiera des phrases claires et descriptives. Si un autre comprend mieux les formulations avec des chiffres, le système lui proposera plutôt des scores de similarité ou des pourcentages.

Les résultats attendus sont des explications plus proches de la manière dont chaque utilisateur construit sa compréhension, ce qui devrait améliorer la compréhension, réduire les efforts de lecture et renforcer la confiance dans le système. L'évaluation se fera en combinant des analyses hors ligne (sur des traces d'interaction) et des tests utilisateurs en conditions réelles, avec des mesures telles que l'utilité perçue, la satisfaction, la confiance et les comportements observés (clics, demandes ou rejets).

Dans la continuité de cette proposition, l'évaluation devra comparer les explications contextualisées à plusieurs baselines représentatives de la littérature, par exemple : (i) une explication unique identique pour tous les utilisateurs, (ii) une personnalisation fondée uniquement sur les contenus recommandés, et (iii) une personnalisation fondée sur des préférences explicites déclarées. L'analyse pourra être menée à la fois hors ligne, sur des traces d'interaction, et en ligne, dans le cadre de tests utilisateurs. Les métriques d'évaluation devront couvrir plusieurs dimensions complémentaires : la compréhension perçue de l'explication, son utilité pour la décision, la satisfaction, la confiance envers le système, ainsi que des indicateurs comportementaux tels que le taux de clic, le temps de lecture normalisé, les demandes d'explication supplémentaire ou les rejets rapides. Une telle évaluation permettra de déterminer si l'inté-

gration du schéma d'interprétation améliore effectivement l'adéquation entre l'explication produite et la manière dont l'utilisateur la comprend.

Ainsi, q1 et q2 forment un tout : répondre à q1 permet de repérer comment les utilisateurs comprennent les explications, et répondre à q2 consiste à utiliser ces informations pour générer des explications adaptées à leurs besoins réels.

Conclusion

Les systèmes de recommandation explicables ont permis des avancées significatives en matière de transparence et de confiance des utilisateurs. Toutefois, un constat demeure : les explications générées ne sont pas comprises de manière uniforme. Une explication jugée compréhensible par un utilisateur peut sembler incompréhensible pour un autre, en raison de différences dans leur niveau de compréhension et dans la manière dont ils interprètent l'information.

Cette variabilité met en évidence les limites des approches existantes qu'elles reposent sur le choix explicite de l'utilisateur, la construction de profils explicatifs ou la mise en avant des contenus recommandés. Ces approches n'intègrent pas pleinement les différences individuelles qui conditionnent la compréhension des explications.

Dans cette perspective, deux pistes principales ont été proposées : (i) identifier les facteurs contextuels internes qui influencent la compréhension des explications. Nous faisons l'hypothèse que le schéma d'interprétation, défini dans la littérature comme une structure cognitive orientant la compréhension et l'interprétation des informations, constitue ce facteur contextuel interne ; (ii) exploiter ces facteurs par l'intégration du schéma d'interprétation dans les systèmes de recommandation, afin de contextualiser les explications et de les rapprocher de la compréhension propre à chaque utilisateur.

Ce positionnement ouvre la voie à des systèmes de recommandation explicables de nouvelle génération, capables de générer des explications ajustées aux différents niveaux de compréhension. Un tel alignement renforcerait non seulement la confiance des utilisateurs, mais aussi leur engagement et l'adoption des systèmes à plus grande échelle.

Bibliographie

- D. Antognini, C. Musat, B. Faltings. Interacting with Explanations through Critiquing. In *Proceedings of the Thirtieth International Joint Conference on Artificial Intelligence (IJCAI-21)*, pp. 515–521. International Joint Conferences on Artificial Intelligence Organization, 2021.
- P.-E. Arduin, M. Grundstein, C. Rosenthal-Sabroux. From knowledge sharing to collaborative decision making. *International Journal of Information and Decision Sciences*, 5(3) :295–311, 2013.
- P.-E. Arduin, M. Grundstein, E. Negre, C. Rosenthal-Sabroux. Formalizing an empirical model : a way to enhance the communication between users and designers. In *Proceedings of the 7th IEEE International Conference on Research Challenges in Information Science (RCIS)*. IEEE, 2013.
- M. A. Chatti, M. Guesmi, L. Vorgerd, T. Ngo, S. Joarder, Q. Ul Ain, A. Muslim. Is More Always Better? The Effects of Personal Characteristics and Level of Detail on the Perception of Explanations in a Recommender System. In *Proceedings of UMAP*, pp. 254–264. ACM, 2022.
- J. De Pauw, K. Ruymbeek, B. Goethals. Modelling Users with Item Metadata for Explainable and Interactive Recommendation. In *Proceedings of RecSys*. ACM, 2022.
- A. K. Dey. Understanding and Using Context. *Personal and Ubiquitous Computing*, 5(1) :4–7, 2001.

- Z. V. Ferdousi, E. Negre, D. Colazzo. Context factors in context-aware recommender systems. In *Proceedings of AISR*. 2017.
- Z. V. Ferdousi. From Traditional to Context-Aware Recommendations by Correlation-Based Context Model. Thèse de doctorat, Université Paris-Dauphine, 2020.
- J. Feng. Generality and explainability in recommender systems. Thèse de doctorat, Université Paris-Dauphine PSL, 2023.
- C. Göpfert, W. Wörndl, M. Elsholz, U. Nissen. Discovering Personalized Semantics for Soft Attributes in Recommender Systems using Concept Activation Vectors. In *Proceedings of WWW*, pp. 1613–1623. ACM, 2022.
- M. Guesmi, M. A. Chatti, S. Joarder, Q. Ul Ain, R. Alatrash, C. Siepmann, T. Vahidi. Interactive Explanation with Varying Level of Details in an Explainable Scientific Literature Recommender System. *International Journal of Human–Computer Interaction*, 40(22) :7248–7269, 2024.
- X. He, Q. Liu, S. Jung. The Impact of Recommendation System on User Satisfaction : A Moderated Mediation Approach. *Journal of Theoretical and Applied Electronic Commerce Research*, 19 :448–466, 2024.
- L. Hébert. Schéma de l'interprétation et nombre d'interprétations adéquates. *Semiotica*, 126(1–4) :97–120, 1999.
- N. Hubert, A. Brun, D. Monticolo. Vers un système de recommandation explicable pour l'orientation scolaire. In *Workshop EXPLAIN'AI - EGC*. 2022.
- P. Kouki, J. Schaffer, S. Roy, A. Arora, L. Getoor. Personalized Explanations for Hybrid Recommender Systems. In *Proceedings of WSDM*, pp. 36–44. ACM, 2020.
- L. Lando, P.-E. Arduin. Should I Share or Should I Go? A Study of Tacit Knowledge Sharing Behaviors in Extended Enterprises. In *Proceedings of the 6th International Conference on Information and Knowledge Systems (ICIKS 2023)*, Lecture Notes in Business Information Processing, vol. 486, pp. 179–196. Springer, 2024.
- E. Negre. Les systèmes de recommandation : une catégorisation. *Interstices*, INRIA, 2018.
- I. Nunes, D. Jannach. A systematic review and taxonomy of explanations in decision support and recommender systems. *User Modeling and User-Adapted Interaction*, 27 :393–444, 2017.
- J. Ramos, H. A. Rahmani, X. Wang, X. Fu, A. Lipani. Transparent and Scrutable Recommendations Using Natural Language User Profiles. In *Proceedings of ACL*, pp. 13971–13984. ACL, 2024.
- M. H. Syed, T. Q. B. Huy, S.-T. Chung. Context-Aware Explainable Recommendation Based on Domain Knowledge Graph. *Big Data and Cognitive Computing*, 6(1) :11, 2022.
- N. Tintarev, J. Masthoff. A Survey of Explanations in Recommender Systems. In *Proceedings of ICDEW*, pp. 801–810. IEEE, 2007.
- N. Tintarev, J. Masthoff. Explaining Recommendations : Design and Evaluation. In F. Ricci, L. Rokach, B. Shapira (eds.), *Recommender Systems Handbook* (2nd ed.), pp. 353–382. Springer, 2015.
- S. Verma, C. Shah, J. P. Dickerson, A. Beniwal, N. Sadagopan, A. Seshadri. RecXplainer : Amortized Attribute-based Personalized Explanations for Recommender Systems. In *Proceedings of AAAI*. AAAI Press, 2024.
- Y. Zhang, X. Chen. Explainable Recommendation : A Survey and New Perspectives. *Foundations and Trends in Information Retrieval*, 14(1) :1–101, 2020.
- J. Zhong. Generality and explainability in recommender systems. Thèse de doctorat, Université Paris Dauphine-PSL, 2023.