



REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE  
MINISTERE DE L'ENSEIGNEMENT SUPERIEURE ET DE LA RECHERCHE SCIENTIFIQUE

**UNIVERSITE IBN KHALDOUN - TIARET**

# MEMOIRE

Présenté à :

FACULTÉ DES MATHÉMATIQUES ET DE L'INFORMATIQUE  
DÉPARTEMENT D'INFORMATIQUE

Pour l'obtention du diplôme de :

**MASTER**

Spécialité : Génie informatique

Par :

**AMEUR WALID  
BENHAOUCHE BOUZIANE**

Sur le thème

---

## **Vers une approche de recommandation sociale à base de préférence**

---

Soutenu publiquement le 24/06/2024 à Tiaret devant le jury composé de :

M. Berber El Mahdi	MAA	Université Ibn-Khaldoun	Président
M. Kouadria Abderrahmane	MCB	Université Ibn-Khaldoun	Encadrant
M <sup>me</sup> Kermass nawel	MCA	Université Ibn-Khaldoun	Examineur

2023-2024

## ***Remerciements***

Nous tenons tout d'abord à remercier le bon Dieu de nous avoir donné la force et le courage de mener ce projet à terme, ainsi que de nous avoir permis de surmonter toutes les difficultés. Nous avons ressenti sa guidance chaque jour, et c'est grâce à lui que nous avons pu réussir nos études. Nous continuerons à lui faire confiance pour notre avenir.

Nous souhaitons exprimer nos sincères remerciements à notre encadrant de mémoire, M. KOUADRIA Abderrahmane Nous tenons également à lui témoigner notre gratitude pour sa patience et son soutien précieux, qui nous ont aidés à mener notre travail à bien. Ses conseils avisés et son assistance tout au long de cette période ont été d'une grande aide.

Nous souhaitons également remercier les membres du jury et nos professeurs pour la qualité de leur enseignement tout au long de ces cinq années passées au département d'informatique. Leur contribution a été essentielle à notre formation.

Enfin, nous tenons à exprimer notre reconnaissance sincère et profonde envers nos familles, qui nous ont toujours soutenu et nous ont donné les moyens de poursuivre nos aspirations. Leur confiance nous a été une source d'inspiration constante. Nous souhaitons également remercier tous ceux qui ont contribué, de près ou de loin, à la réalisation de ce mémoire.

### ***Dédicace***

Tous les mots ne sauraient exprimer la gratitude, l'amour, Le respect, la reconnaissance, c'est tout simplement que je dédie ce mémoire. À mes parents car ils m'ont inculqué un esprit de persévérance et qu'ils m'ont toujours poussé et motivé dans mes études. Sans eux, certainement je ne serais pas à ce niveau. Ils ont tout fait pour mon bonheur et ma réussite. Nulle dédicace ne puisse exprimer ce que je leur dois. Que dieu leur réserve la bonne santé et une longue vie.

À mes frères et sœurs, qu'ils restent pour moi des exemples de persévérance, de courage et de générosité. Et à tous ceux qui me sont chers et qui ont contribué à mes encouragements.

**AMEUR WALID**

Je dédie cet humble travail à celui qui m'a donné la vie. Qui s'est sacrifiée pour mon bonheur et ma réussite pour ma mère, symbole de tendresse. A mon père, mon professeur d'enfance, qui m'a soutenu tout au long de mes années scolaires, et qui a été là pour m'aider et me protéger, que Dieu les préserve.

**BENHAOUCHE BOUZIANE**

## Résumé

Durant les dernières années, la recommandation sociale a suscité un intérêt significatif dans le domaine de la recherche en raison de sa capacité à résoudre efficacement les problèmes de rareté des données et de démarrage à froid auxquels sont confrontées les méthodes traditionnelles de recommandation. Le concept central de la recommandation sociale repose sur l'hypothèse que le comportement des utilisateurs au sein d'un réseau social est fortement influencé par leurs relations sociales, permettant ainsi une inférence plus précise de leurs préférences. Les algorithmes de recommandation personnalisée dans les réseaux sociaux sont devenus cruciaux tant dans l'industrie que dans le milieu académique. Ces systèmes doivent apprendre les préférences des utilisateurs en utilisant leurs comportements passés ainsi que leurs relations sociales. Les modèles d'apprentissage profond, capables de représenter précisément les profils des utilisateurs et des items recommandés, sont de plus en plus utilisés. Récemment, les réseaux de neurones graphiques (GNN) ont prouvé leur efficacité pour l'apprentissage sur des données graphiques, intégrant les informations des nœuds et la structure topologique, ce qui est prometteur pour améliorer les recommandations sociales en représentant les données sous forme de graphes sociaux. Cependant, la construction de systèmes de recommandation sociale basés sur les GNN est complexe en raison des interactions et opinions dans le graphe utilisateur-item, des relations sociales hétérogènes et de l'implication des utilisateurs dans deux graphes distincts. Pour relever ces défis, le framework GraphRec est présenté. Il capture conjointement les interactions et opinions dans le graphe utilisateur-item et modélise de manière cohérente les deux graphes ainsi que leurs relations hétérogènes.

**Mots clés :** Système de recommandation, Deep learning, Filtrage collaboratif, Démarrage à froid.

## **Abstract**

In recent years, social recommendation has garnered significant interest in the research field due to its ability to effectively address the issues of data sparsity and cold start faced by traditional recommendation methods. The central concept of social recommendation is based on the assumption that user behavior within a social network is heavily influenced by their social relationships, allowing for a more precise inference of their preferences. Personalized recommendation algorithms in social networks have become crucial in both industry and academia. These systems need to learn users' preferences by using their past behaviors as well as their social relationships. Deep learning models, capable of accurately representing user profiles and recommended items, are increasingly used. Recently, Graph Neural Networks (GNN) have proven effective for learning on graph data, integrating node information and topological structure, which is promising for improving social recommendations by representing data in the form of social graphs. However, building social recommendation systems based on GNN is complex due to interactions and opinions in the user-item graph, heterogeneous social relationships, and user involvement in two distinct graphs. To address these challenges, the GraphRec framework is presented. It jointly captures interactions and opinions in the user-item graph and coherently models the two graphs as well as their heterogeneous relationships.

**Keywords:** Recommendation System, Deep Learning, Collaborative Filtering, Cold Start.

## SOMMAIRE

Remerciements .....	II
Dédicace .....	III
Résumé .....	IV
Abstract .....	V
Liste des figures .....	IX
Liste des tableaux .....	X
Liste des abréviations .....	XI
Introduction Générale.....	1
<b>Chapitre I : Les systèmes de recommandation et les recommandations sociales</b> .....	<b>3</b>
I.1 Introduction.....	4
I.2 Définition des systèmes de recommandations .....	4
I.3 Processus de recommandation .....	4
I.3.1 Acquisition d'informations.....	5
I.3.2 Profil utilisateur.....	5
I.3.3 Catalogue de suggestions .....	5
I.4 Domaines d'application des systèmes de recommandation.....	6
I.5 Techniques de recommandation.....	8
I.5.1 Recommandation collaborative.....	8
I.5.1.1 Approche basée sur la mémoire .....	9
I.5.1.2 Approche basée sur le modèle.....	11
I.5.2 Recommandation basée sur le contenu .....	12
I.5.3 Recommandation démographique.....	13
I.5.4 Recommandation basée sur la connaissance.....	13
I.5.5 Recommandation hybride .....	14
I.6 Recommandations sociales .....	15
I.6.1 Classification des systèmes de recommandation sociale .....	16
I.6.1.1 Contexte .....	16
I.6.1.2 Confiance .....	16
I.6.1.3 Tags.....	17
I.6.1.4 Groupe.....	17
I.6.1.5 Réseaux sociaux croisés.....	18
I.6.1.6 Dynamique temporelle.....	18
I.6.1.7 Connexions sociales hétérogènes.....	18
I.6.1.8 Filtrage sémantique .....	19
I.6.2 Difficultés des systèmes de recommandation sociale .....	20
I.7. Défis liés aux systèmes de recommandation.....	20
I.8. Conclusion .....	22
<b>Chapitre II :Les principaux algorithmes de deep learning et leurs applications dans la recommandation sociale</b> .....	<b>23</b>

II.1 Introduction .....	24
II.2 Intelligence artificielle .....	24
II.3 Apprentissage automatique.....	25
II.3.1 Les types d'apprentissage automatique .....	26
II.3.1.1 Apprentissage supervisé .....	26
II.3.1.2 Apprentissage non supervisé .....	27
II.3.1.3 Apprentissage par renforcement .....	27
II.4 L'apprentissage profond .....	28
II.5 Les algorithmes d'apprentissage profond.....	29
II.5.1 Réseaux de neurones artificiels.....	29
II.5.2 Réseaux de neurones convolutifs (CNN).....	29
II.5.3 Réseaux de neurones récurrents (RNN).....	30
II.5.4 AutoEncodeurs (AE) .....	31
II.5.5 Réseaux de neurones graphiques ( GNN ).....	31
II.5.5.1 Notions de base en théorie des graphes .....	32
II.5.5.2 Applications .....	33
II.5.5.3 Architectures .....	34
II.5.5.4 Limitations .....	35
II.6. Recommandation sociale basée sur le deep learning .....	36
I.6.1 DiffNet++.....	37
II.6.2 DSCF ( Deep Social Collaborative Filtering ).....	38
II.7 Conclusion .....	40
<b>Chapitre III : Recommandation Sociale Basée sur les Réseaux de Neurones Graphiques .....</b>	<b>41</b>
III.1 Introduction .....	42
III.2 Réseau de neurones graphiques dans la recommandation sociale.....	42
III.2.1 Modèle de graphe unifié.....	42
III.2.2 Modèle de graphe séparé.....	44
III.3 Présentation du modèle GraphRec .....	46
III.3.1 Modélisation de l'utilisateur .....	47
III.3.2 Modélisation de l'item.....	51
III.3.3 Prédiction .....	52
III.4 Expérimentations.....	53
III.4.1 Jeux de données.....	53
III.4.2 Nettoyage de l'ensembles de données FilmTrust.....	54
III.4.3 Métriques d'évaluation.....	55
III.4.3.1 Erreur quadratique moyenne (RMSE).....	55
III.4.3.2 Erreur absolue moyenne (MAE) .....	55
III.5 Présentation de l'application .....	56
III.6 Résultats et analyse .....	57

III.7 Conclusion.....	58
Conclusion générale .....	59
Bibliographies .....	60

## Liste des figures

Figure I.1 : Domaines d'application des systèmes de recommandation .....	6
Figure I.2 : Différentes techniques de systèmes de recommandation .....	8
Figure I.3 : Filtrage collaboratif basé sur l'utilisateur .....	9
Figure I.4 : Technique de factorisation matricielle .....	11
Figure I.5 : Recommandation basée sur le contenu.....	12
Figure I.6 : Le système hybride utilise deux approches de recommandation.....	15
Figure II.1 : Qu'est-ce que l'intelligence artificielle ? .....	25
Figure II.2 : Les types d'apprentissage automatique.....	26
Figure II.3 : Fonctionnement de l'apprentissage profond.....	28
Figure II.4 : Fonctionnement d'un réseau de neurones convolutifs .....	29
Figure II.5 : Forme générale pour le RNN .....	30
Figure II.6 : Processus de base d'un GNN, de l'entrée à la sortie .....	32
Figure II.7 : Convolution en 2D par rapport à convolution de graphe .....	34
Figure II.8 : Architecture globale de DiffNet++ .....	37
Figure II.9 : Architecture globale de DSCF .....	38
Figure III.1 : Architecture du modèle de graphe unifié.....	42
Figure III.2 : Architecture du modèle de graphe séparé.....	43
Figure III.3 : Architecture du modèle GraphRec.....	46
Figure III.4 : Agrégation d'items pour la modélisation d'utilisateur à partir du graph utilisateur-item	47
Figure III.5 : Agrégation sociale pour la modélisation d'utilisateurs à partir du graphe social .....	48
Figure III.6 : Facteur latent final de l'utilisateur.....	49
Figure III.7 : Modélisation d'un item à partir du graphe utilisateur-item .....	50
Figure III.8 : Calcul de la prédiction de notation $r_{ij}'$ .....	51
Figure III.9 : Importation de datasets Filmtrust.....	55

## Liste des tableaux

Tableau III.1 Notations utilisées .....	45
Tableau III.2 Informations statistiques sur l'ensemble de données FilmTrust .....	52
Tableau III.3 Comparaison des résultats de différentes méthodes en termes MAE et RMSE .....	56

## **Liste des abréviations**

**SR** : Système de recommandations

**FBC** : Le filtrage basé sur le contenu

**FC** : Filtrage collaboratif

**SRs** : Les systèmes de recommandations

**SRS** : Système de recommandation sociale

**FM** : Factorisation matricielle

**RMSE**: Root Mean Square Error

**MAE**: Mean absolute error

# *Introduction Générale*

Les systèmes de recommandation (SRs) ont révolutionné la manière dont les utilisateurs découvrent et interagissent avec du contenu. Ces systèmes jouent un rôle crucial dans de nombreux domaines en fournissant des recommandations personnalisées aux utilisateurs individuels, telles que des recommandations de produits sur des plateformes de commerce électronique (par exemple, Amazon, Walmart et Target), des listes de lecture personnalisées sur des plateformes de streaming (par exemple, YouTube et Spotify), des publicités ciblées dans la publicité en ligne, et bien d'autres.

Le but principal des systèmes de recommandation est de proposer des produits ou des services intéressants que les utilisateurs n'ont pas encore découverts. Pour résoudre le problème de la surcharge d'informations, les SRs ont été développés pour aider les utilisateurs à prendre les meilleures décisions possibles en examinant leurs intérêts et en recommandant des éléments intrigants basés sur ces intérêts. Les SRs ont en effet été développés en utilisant une variété d'approches. Le filtrage basé sur le contenu (FBC), le filtrage collaboratif (FC) et les stratégies hybrides sont parmi les méthodologies les plus couramment utilisées [1], [2]. Chacune de ces stratégies a été analysée dans diverses applications et s'est révélée efficace. Cependant, les SRs traditionnels présentent plusieurs lacunes, telles que le problème du démarrage à froid, où il est difficile de fournir des recommandations pertinentes pour de nouveaux utilisateurs ou de nouveaux items en raison du manque de données historiques sur leurs préférences. La rareté des données est également un problème fréquent dans les SRs, car les utilisateurs n'interagissent qu'avec une petite fraction des items disponibles, ce qui rend les matrices utilisateur-item extrêmement clairsemées [1], [3].

Pour pallier ces limitations, les systèmes de recommandation sociale ont émergé en intégrant des informations auxiliaires provenant des interactions sociales et des réseaux sociaux. Ces informations sociales offrent un contexte supplémentaire qui peut enrichir les modèles de recommandation, améliorant ainsi leur précision et leur capacité à faire face aux problèmes de démarrage à froid et de rareté.

Récemment, les avancées en deep learning ont ouvert de nouvelles perspectives pour les systèmes de recommandation. En particulier, les Graph Neural Networks (GNN) ont montré un potentiel prometteur pour exploiter les structures complexes et les relations dans les données sociales. Les GNN permettent de capturer les dépendances hautement non linéaires entre les utilisateurs et les items à travers les graphes sociaux, offrant ainsi une solution innovante pour

améliorer les recommandations sociales.

Ce travail s'intéresse à la mise en œuvre d'un système de recommandation sociale basé sur le deep learning, plus précisément sur les Graph Neural Networks. L'objectif est de démontrer comment l'intégration d'informations sociales et l'utilisation de GNN peuvent surmonter les problèmes de démarrage à froid et de sparsité des données, tout en améliorant la qualité des recommandations. Nous explorerons les concepts fondamentaux des systèmes de recommandation traditionnels et sociaux, analyserons les défis spécifiques associés et présenterons une solution basée sur les dernières avancées en apprentissage profond.

Ce mémoire est organisé en trois chapitres comme suit :

- **Chapitre I** : Présentation de l'état de l'art sur les systèmes de recommandation et les recommandations sociales.
- **Chapitre II** : Exploration approfondie des principaux algorithmes de Deep Learning utilisés dans le domaine de la recommandation sociale.
- **Chapitre III** : Présentation des réseaux de neurones graphiques (GNN) dans le cadre de la recommandation sociale.

# ***Chapitre I***

Les systèmes de recommandation et les recommandations  
sociales

## I.1 Introduction

Les systèmes de recommandation (SRs) sont des outils essentiels qui visent à fournir des suggestions personnalisées pour des articles ou des services qui sont les plus pertinents et utiles pour un utilisateur donné. Ils sont devenus omniprésents dans divers domaines tels que le commerce électronique, le divertissement, l'éducation et les médias sociaux, où ils aident les utilisateurs à faire face au problème de surcharge d'informations et à découvrir de nouveaux produits ou contenus. En simplifiant le processus de prise de décision, ils offrent ainsi une expérience utilisateur améliorée et plus engageante.

Dans ce chapitre, nous présentons l'évolution des systèmes de recommandation, en mettant particulièrement l'accent sur leur rôle croissant dans la recommandation sociale. Alors que les systèmes de recommandation traditionnels se concentrent souvent sur les préférences individuelles des utilisateurs, la recommandation sociale élargit cette perspective en intégrant les interactions sociales et les influences entre utilisateurs. Nous explorerons les différentes techniques et modèles utilisés dans les systèmes de recommandation, ainsi que les défis et opportunités associés à l'intégration de la recommandation sociale. En outre, nous discuterons de la classification des systèmes de recommandation sociale.

## I.2 Définition des systèmes de recommandations

Un Système de Recommandation (SR) est un type de système de filtrage d'informations qui fournit des suggestions pour des items susceptibles d'intéresser un utilisateur particulier. Ces items peuvent être de divers types : produits, films, musique, livres ou contenu en ligne. Les suggestions sont basées sur différentes sources d'informations telles que les préférences des utilisateurs, les évaluations, les retours, le comportement ou les caractéristiques des items. Généralement, la sortie d'un SR est une liste ordonnée d'items que l'utilisateur pourrait apprécier ou trouver utiles.

D'après Burke [4], un système de recommandation doit être capable de fournir des recommandations individualisées et de guider les utilisateurs de manière personnalisée. La définition de Burke introduit de nouvelles notions telles que l'individualisation et la personnalisation [5].

## I.3 Processus de recommandation

Un système de recommandation requiert généralement trois (03) étapes :

- La première consiste à recueillir de l'information sur l'utilisateur.
- La deuxième consiste à bâtir une matrice ou un modèle utilisateur contenant l'information

recueillie.

- La troisième consiste à extraire, à partir de cette matrice, une liste de recommandations.

### I.3.1 Acquisition d'informations

Pour être pertinent, un système de recommandation doit pouvoir faire des prédictions sur les intérêts des utilisateurs. Il faut donc collecter un certain nombre de données sur ceux-ci afin de construire un profil pour chaque utilisateur. Une distinction peut être faite entre deux (02) formes de collecte de données :

**a) Données explicites :** Ces données sont fournies directement par les utilisateurs. Elles peuvent inclure des évaluations, des critiques, des notations ou des préférences déclarées sur des produits, des services ou des contenus.

**Exemple :** Sur des plateformes comme Amazon, les utilisateurs peuvent attribuer des étoiles et écrire des critiques pour les produits qu'ils ont achetés.

**Avantage :** Fournissent des informations directes sur les préférences des utilisateurs.

**Inconvénient :** Peuvent être biaisées ou peu fiables, certains utilisateurs peuvent ne pas partager leurs préférences.

**b) Données implicites :** Ces données sont collectées à partir des actions et des comportements des utilisateurs lorsqu'ils interagissent avec le système. Cela peut inclure des données telles que les articles consultés, les achats effectués, les chansons écoutées, les vidéos regardées, les temps de navigation, les clics, les mouvements de souris, etc.

**Exemple :** Les interactions sur les réseaux sociaux, telles que les "j'aime", les partages, les commentaires, peuvent également fournir des informations sur les intérêts des utilisateurs. Par exemple, Facebook peut utiliser les interactions de l'utilisateur avec des pages ou des publications pour recommander du contenu similaire.

**Avantage :** Collectées passivement, moins intrusives pour les utilisateurs.

**Inconvénient :** Ne reflètent pas toujours les véritables préférences des utilisateurs et peuvent être sujettes à des erreurs d'interprétation.

### I.3.2 Profil utilisateur

Le modèle utilisateur, couramment représenté sous forme de matrice d'usages, se présente comme un tableau contenant des données collectées sur les utilisateurs et associées aux produits disponibles sur le site web.

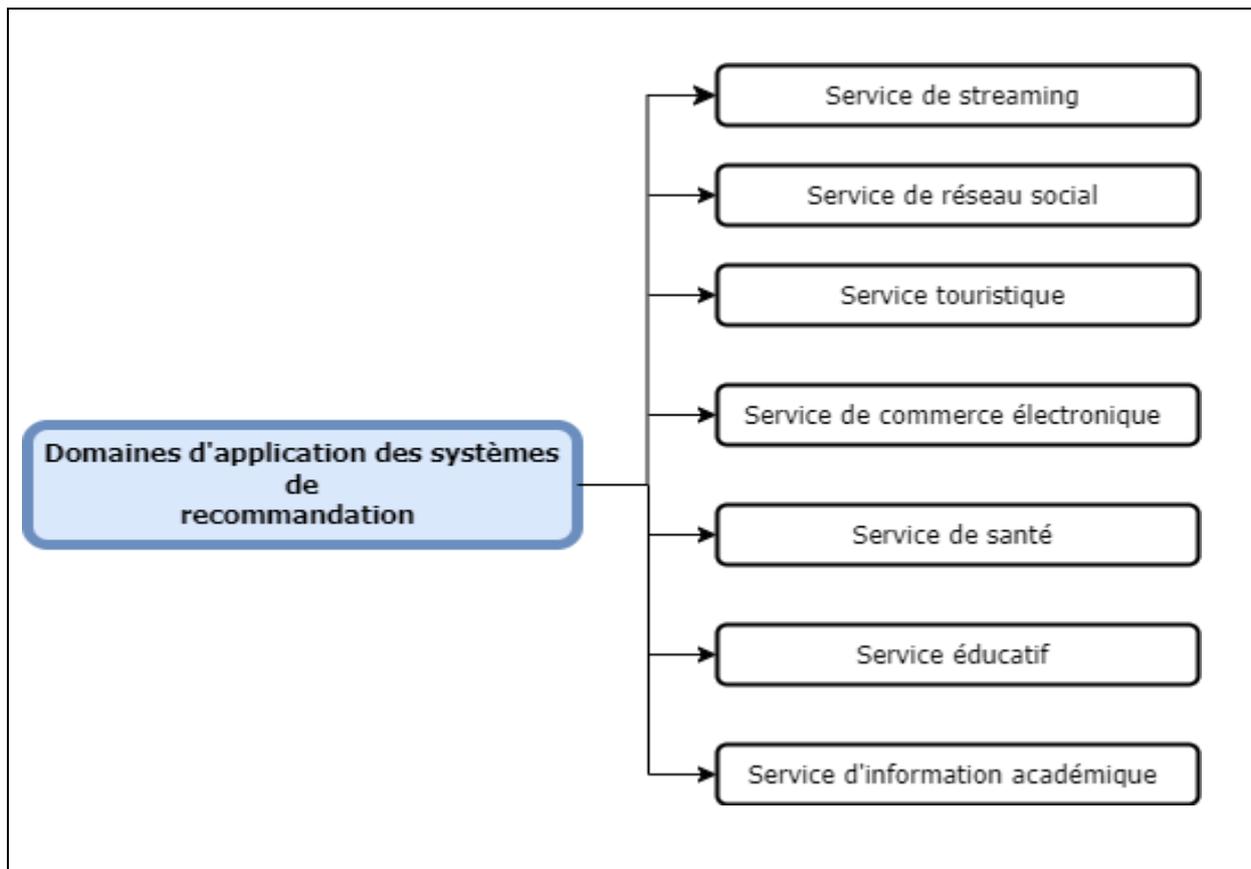
### I.3.3 Catalogue de suggestions

Pour générer un catalogue ou une liste de recommandations à partir d'un modèle utilisateur, les algorithmes se fondent sur la notion de similarité entre les objets ou les personnes décrites

dans le modèle. La similarité vise à quantifier la ressemblance entre deux éléments. Plus la ressemblance est élevée, plus la valeur de similarité est grande, et vice versa. Dans la suite de ce texte, nous examinerons quelques exemples illustrant ce concept.

#### I.4 Domaines d'application des systèmes de recommandation

Les systèmes de recommandation ont un large éventail d'applications dans divers domaines, notamment :



*Figure I.1 Domaines d'application des systèmes de recommandation [4]*

➤ **Service de streaming** : Autrefois, le contenu vidéo, comme les films, était principalement consommé via la télévision ou les cinémas. Récemment, une part significative du visionnage de vidéos se fait via des plateformes de streaming telles que Netflix et YouTube. Pour le contenu audio, la tendance évolue également : on passe du téléchargement et de la consommation de fichiers sur l'appareil local de l'utilisateur à la diffusion en continu via des plateformes comme Spotify. Les services de streaming média se sont développés en parallèle avec des systèmes de recommandation pour atténuer les préoccupations des utilisateurs face au choix parmi une vaste quantité de contenu et pour fournir un contenu adapté à chaque utilisateur. Dans ce domaine, les données sur les préférences des utilisateurs sont

généralement collectées en se basant sur leur historique d'utilisation du service de contenu média. Ensuite, en associant ces préférences

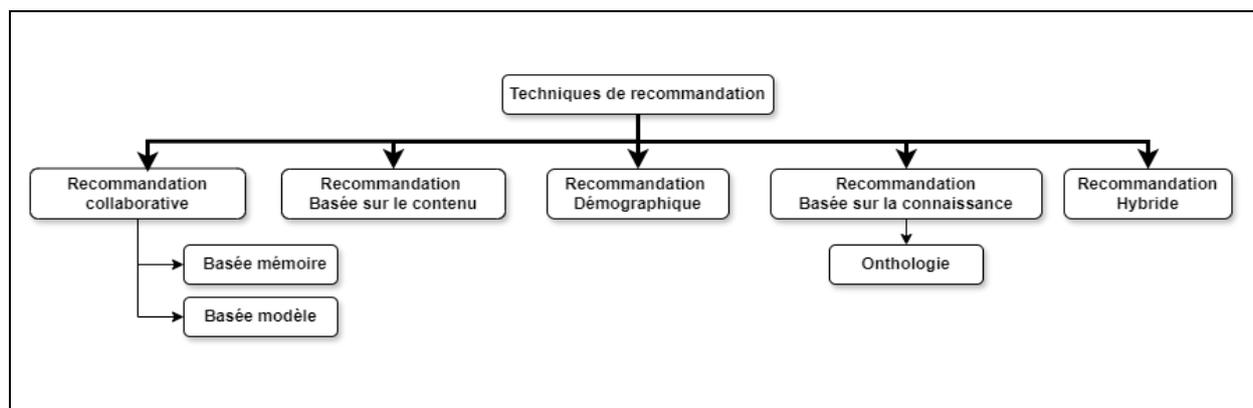
à l'ensemble du contenu disponible, des recommandations sont générées pour proposer du contenu qui correspond le mieux aux goûts de l'utilisateur.

- **Service de réseau social** : Les services de réseau social en ligne (SRS) tels que Facebook, Instagram, Twitter et LinkedIn sont de vastes plateformes d'échanges sociaux numériques où les utilisateurs peuvent enregistrer leur vie quotidienne, leurs passe-temps, leurs intérêts, et interagir avec d'autres utilisateurs. L'énorme augmentation de l'utilisation des SRS a entraîné une augmentation massive des données liées aux utilisateurs.
- **Service touristique** : Avec la demande croissante de voyages, les systèmes de recommandation ont commencé à être utilisés dans les services touristiques pour recommander des destinations, des itinéraires et des modes de transport. Ces systèmes utilisent des données situationnelles telles que les avis, la localisation de l'utilisateur, l'heure et la météo, souvent collectées via les réseaux sociaux, ce qui a conduit à une augmentation de la recherche sur les systèmes de recommandation dans les services touristiques.
- **Service de commerce électronique** : Autrefois, des articles tels que des vêtements, de la nourriture et des livres étaient principalement consommés via des magasins physiques. Ces dernières années, avec le développement de plateformes numériques telles qu'Amazon, eBay et Alibaba, la consommation de ces articles a évolué vers le commerce électronique. Cette dernière offre aux consommateurs une large variété d'articles ainsi que diverses options en ligne, tout en offrant aux vendeurs un moyen facile de vendre. Pendant la pandémie de COVID-19, l'incapacité d'utiliser les magasins physiques a conduit à une augmentation exponentielle de la consommation via les plateformes numériques, avec une diversification des catégories d'articles vendus.
- **Service de santé** : Avec l'augmentation de l'intérêt pour la santé, l'utilisation de dispositifs portables intelligents a augmenté grâce à leur compatibilité avec les smartphones et leur facilité d'utilisation. Ces dispositifs peuvent surveiller l'état biologique des utilisateurs, et les montres intelligentes, par exemple, mesurent régulièrement les données corporelles, aidant à prévenir les maladies et permettant l'auto-diagnostic. Ces dispositifs collectent une grande quantité de données biométriques pour aider à la recherche sur les maladies et fournir des recommandations de traitement. Les systèmes de recommandation dans le domaine de la santé se divisent en recommandations de santé et santé électronique, soutenant un traitement professionnel selon l'application du système.

- **Service éducatif** : À partir de l'éducation traditionnelle en salle de classe, une nouvelle tendance éducative, appelée Apprentissage Intelligent, s'est formée grâce à l'apprentissage en ligne. Avec l'augmentation des appareils intelligents et des réseaux sans fil, l'éducation intelligente permet un accès à de vastes ressources numériques et un apprentissage personnalisé adapté aux besoins et intérêts des apprenants, sans contraintes de temps et d'espace. Les systèmes de recommandation dans les services éducatifs fournissent des ressources d'apprentissage en tenant compte du style et du niveau de connaissance des apprenants, offrant une expérience d'apprentissage efficace.
- **Service d'information académique** : L'augmentation exponentielle des informations académiques oblige les chercheurs à consacrer beaucoup de temps et d'efforts à la recherche d'informations pertinentes. Dans ce domaine, des systèmes de recommandation ont été développés pour fournir des informations et des technologies utiles aux chercheurs.

### I.5 Techniques de recommandation

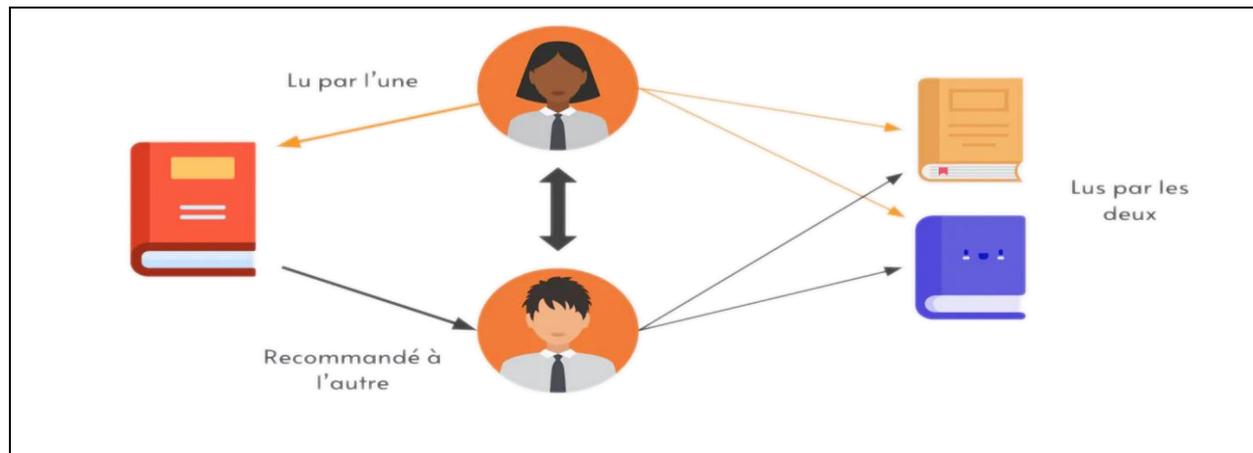
Selon la figure I.2, différentes techniques ont été introduites pour générer des recommandations personnalisées, présentées comme suit :



*Figure I.2 Différentes techniques de systèmes de recommandation*

#### I.5.1 Recommandation collaborative

L'idée principale des approches de recommandation collaborative est d'exploiter les informations sur le comportement passé ou les opinions d'une communauté d'utilisateurs existante afin de prédire quels items l'utilisateur actuel du système est le plus susceptible d'apprécier ou de trouver intéressants. Ces types de systèmes sont largement utilisés dans l'industrie aujourd'hui, notamment comme outil sur les sites de vente en ligne pour personnaliser le contenu en fonction des besoins d'un client particulier, favorisant ainsi la promotion d'articles supplémentaires et l'augmentation des ventes. [11].



**Figure I.3 :** Filtrage collaboratif basé sur l'utilisateur [5]

On distingue deux catégories d’algorithmes de filtrage collaboratif : les algorithmes basés sur la mémoire et ceux basés sur un modèle.

### I.5.1.1 Approche basée sur la mémoire

Les méthodes de filtrage collaboratif basées sur la mémoire les plus connues sont les algorithmes de voisinage le plus proche. Ces algorithmes utilisent la matrice utilisateur-item pour générer des prédictions. Il existe deux types d’algorithmes : ceux orientés utilisateur et ceux orientés item. Les algorithmes orientés utilisateur recherchent des utilisateurs ayant des comportements ou des préférences similaires à ceux de l'utilisateur d'intérêt. Ces utilisateurs similaires sont appelés voisins et sont utilisés pour générer des prédictions pour l'utilisateur d'intérêt. En revanche, les algorithmes de voisinage le plus proche basés sur les items fondent leurs prédictions sur les similarités entre les items, plutôt que sur les similarités entre les utilisateurs.

#### I.5.1.1.1 Filtrage collaboratif basé sur les utilisateurs

Le filtrage collaboratif basé sur les utilisateurs a été introduit pour la première fois dans le système GroupLens . Son principe de fonctionnement est très simple : déterminer les utilisateurs similaires à l'utilisateur courant, puis calculer une valeur de prédiction pour chaque item candidat à la recommandation en analysant les notes que les voisins de l'utilisateur courant ont attribuées à cet item. Calculer la similarité utilisateur-utilisateur est une étape cruciale pour les méthodes orientées utilisateur. De nombreuses techniques ont été proposées pour aborder ce problème, telles que le coefficient de corrélation de Pearson, la similarité cosinus, et la similarité basée sur la probabilité. Parmi ces méthodes, le coefficient de corrélation de Pearson et la similarité cosinus sont les plus largement utilisées.

- **Coefficient de corrélation de Pearson** : Chaque utilisateur est représenté par un vecteur d'évaluations. Par exemple, le  $i$ -ème utilisateur sera noté  $R_i$ . Le coefficient de corrélation de Pearson mesure dans quelle mesure deux variables sont linéairement reliées. Le coefficient de corrélation de Pearson entre  $u_i$  et  $u_j$  peut être calculé comme suit :

$$\frac{\sum_{k \in I} (R_{ik} - \bar{R}_i) \cdot (R_{jk} - \bar{R}_j)}{\sqrt{\sum_{k \in I} (R_{ik} - \bar{R}_i)^2} \sqrt{\sum_{k \in I} (R_{jk} - \bar{R}_j)^2}} \quad \text{I.1}$$

Où  $I$  désigne l'ensemble des items évalués à la fois par  $u_i$  et  $u_j$  et  $S \in \mathbb{R}^{n \times n}$  représente la matrice de similarité utilisateur-utilisateur.  $\bar{R}_i$ : Désigne la note moyenne de  $u_i$ .

- **Similarité cosinus** : La similarité cosinus calcule le cosinus de l'angle formé par les vecteurs de notation [6]. Par exemple, la similarité cosinus entre  $u_i$  et  $u_j$  peut être calculée comme suit :

$$S_{ij} = \frac{\sum_{k \in I} R_{ik} \cdot R_{jk}}{\sqrt{\sum_{k \in I} R_{ik}^2} \sqrt{\sum_{k \in I} R_{jk}^2}} \quad \text{I.2}$$

Où  $I$  désigne l'ensemble des items évalués à la fois par  $u_i$  et  $u_j$ , et  $S \in \mathbb{R}^{n \times n}$  représente la matrice de similarité utilisateur-utilisateur.  $\bar{R}_i$  Désigne la note moyenne de  $u_i$ .

- **Calcul de prédiction** : Après avoir obtenu une matrice de similarité utilisateur-utilisateur, les méthodes orientées utilisateur prédiront une note manquante pour un utilisateur donné en agrégeant les notes des utilisateurs similaires à celui-ci. Diverses stratégies d'agrégation ont été proposées, et la stratégie la plus largement utilisée est la note moyenne pondérée comme suit :

$$\hat{R}_{ij} = \hat{R}_i + \frac{\sum_{u_k \in N_i} S_{ik} (R_{kj} \cdot \bar{R}_k)}{\sum_{u_k \in N_i} S_{ik}} \quad \text{I.3}$$

Où  $N_i$  est l'ensemble des utilisateurs qui ont évalué le  $j$ -ème item  $v_j$ .

#### I.5.1.1.2 Filtrage collaboratif basé sur les items

Le filtrage collaboratif basé sur les items a été introduit par Sarwar et al. [7]. La prédiction de la note de l'utilisateur  $u$  pour un item candidat  $i$  est calculée à partir de ses notes pour les items voisins (similaires) de  $i$ . Son principe de fonctionnement est le suivant : pour l'item  $i$  candidat à la recommandation, on détermine les voisins les plus proches (les items similaires) en calculant sa similarité avec les autres items disponibles, puis on calcule la prédiction de la

note de l'utilisateur  $u$  pour l'item  $i$  à partir des notes que  $u$  a attribuées aux voisins de  $i$ .

La prédiction de note qu'un utilisateur  $u$  peut donner à un item  $i$  est donnée par :

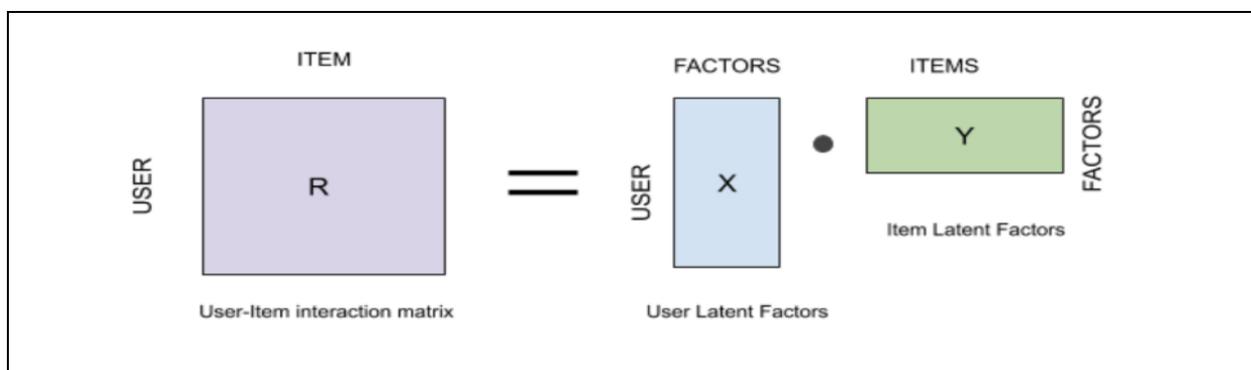
$$p(u, i) = \frac{\sum_{j \in I_u} \text{sim}(i, j) \times r_{u,j}}{\sum_{j \in I_u} |\text{sim}(i, j)|} \quad \text{I.4}$$

### I.5.1.2 Approche basée sur le modèle

Les approches basées sur des modèles visent à apprendre un modèle prédictif à partir des évaluations existantes et à l'utiliser pour prédire des évaluations inconnues. Plusieurs techniques sont employées dans les méthodes de recommandation basées sur des modèles. Parmi les plus avancées, on trouve les méthodes de réduction de dimension telles que la factorisation matricielle (FM), les approches de clustering, les méthodes probabilistes et les approches basées sur les règles d'association.[6].

- **Factorisation Matricielle**

Les modèles de factorisation matricielle sont une catégorie d'algorithmes de filtrage collaboratif basés sur des modèles qui fonctionnent en décomposant la matrice d'interaction utilisateur-item en le produit de deux matrices de dimension inférieure. Ces matrices représentent des caractéristiques ou des facteurs latents qui capturent les préférences des utilisateurs et les caractéristiques des items [8].



**Figure I.4** Technique de factorisation matricielle [9]

Les modèles de factorisation matricielle peuvent être formulés comme un problème d'optimisation, où l'objectif est de minimiser l'erreur de reconstruction entre la matrice d'origine et le produit des matrices de caractéristiques latentes, tout en incorporant certains termes de régularisation. Ce problème d'optimisation peut être résolu par diverses méthodes telles que l'algorithme de descente de gradient.

Les modèles de factorisation matricielle présentent plusieurs avantages par rapport aux techniques de filtrage collaboratif basées sur la mémoire :

- Ils peuvent gérer plus efficacement les données clairsemées en remplissant les valeurs manquantes avec des estimations raisonnables basées sur les caractéristiques latentes.
- Ils peuvent réduire la dimensionnalité et le bruit en n'extrayant que les caractéristiques pertinentes des données de haute dimension.
- Ils peuvent améliorer la scalabilité et la performance en utilisant des méthodes numériques efficaces pour résoudre des problèmes à grande échelle.

### I.5.2 Recommandation basée sur le contenu

Les approches de filtrage basé sur le contenu utilisent des informations externes sur les items, telles que des mots-clés, des tags, ou des profils écrits sous forme de texte dans la langue réelle, pour effectuer des recommandations. En utilisant les caractéristiques des items, le système peut recommander des items non expérimentés qui ont un thème similaire à ceux qu'il a aimés par le passé. Par exemple, si un utilisateur donne un retour positif sur un artiste musical dont la description contient les tags "rock" et "années 90", le système de recommandation est capable de proposer d'autres artistes avec les mêmes tags (ou des tags similaires), car l'utilisateur sera probablement intéressé par eux aussi.

Les approches basées sur le contenu effectuent une analyse des items pour lesquels l'utilisateur a exprimé une préférence dans le passé. En se basant sur la description de ces items, ces approches peuvent construire un profil des intérêts de l'utilisateur. Ensuite, ce profil utilisateur est comparé à la description d'autres items pour décider quel item recommander. Un avantage de cette méthode est qu'elle ne nécessite pas la création de profils d'utilisateurs explicites, ni de connaissances spécifiques dans un domaine. Cependant, certaines limitations des systèmes de recommandation basés sur le contenu sont les suivantes : premièrement, l'analyse de contenu est limitée aux caractéristiques qui peuvent être extraites des items. Deuxièmement, il y a un risque de surspécialisation, où le système recommande des éléments très similaires, limitant ainsi l'exploration d'autres intérêts de l'utilisateur.

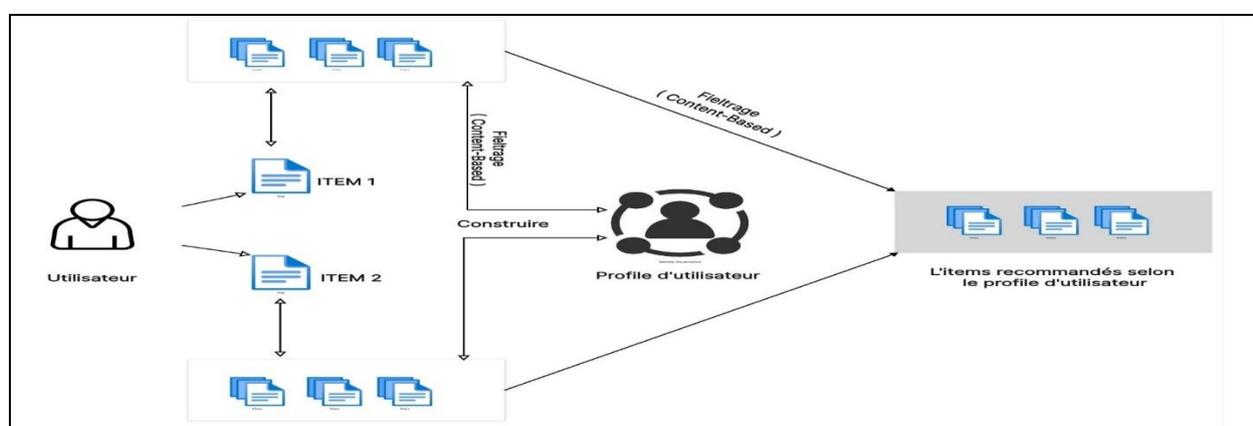


Figure I.5 Recommandation basée sur le contenu

### **I.5.3 Recommandation démographique**

Un système de recommandation démographique est un type de système de recommandation qui utilise les données démographiques des utilisateurs, telles que l'âge, le sexe, la localisation géographique, le niveau d'éducation, etc., pour leur proposer des éléments susceptibles de les intéresser. Ce type de système repose sur l'hypothèse que les utilisateurs ayant des profils démographiques similaires ont des goûts et des préférences comparables. Ainsi, en identifiant les utilisateurs ayant un profil démographique similaire à celui de l'utilisateur cible, le système peut leur recommander des items que ces utilisateurs ont appréciés.

Une limite de ce type de système de recommandation réside dans le fait que les données démographiques peuvent ne pas toujours refléter pleinement les préférences individuelles des utilisateurs. Par exemple, deux personnes du même âge et du même sexe peuvent avoir des goûts très différents. De plus, les données démographiques peuvent être statiques et ne pas tenir compte des évolutions des préférences des utilisateurs au fil du temps. Par conséquent, les systèmes de recommandation démographiques peuvent ne pas être aussi précis ou efficaces pour recommander du contenu personnalisé.

### **I.5.4 Recommandation basée sur la connaissance**

Ce type de recommandation utilise des informations spécifiques sur les produits ou services ainsi que les préférences explicites des utilisateurs pour offrir des recommandations pertinentes. Contrairement à d'autres systèmes de recommandation, tels que les systèmes collaboratifs ou basés sur le contenu, les systèmes basés sur les connaissances reposent sur une compréhension approfondie des besoins des utilisateurs et des caractéristiques des items (produits, services, etc.) à recommander.

Le fonctionnement d'un tel système repose sur plusieurs principes. D'une part, la connaissance explicite permet au système de posséder des informations détaillées sur les items. Par exemple, dans un système de recommandation pour des voitures, il connaît des caractéristiques spécifiques comme la marque, le modèle, la consommation de carburant, le prix, etc. Il dispose également d'informations sur les préférences des utilisateurs obtenues via des questionnaires où ces derniers expriment leurs besoins et contraintes spécifiques.

D'autre part, le système utilise des règles et des heuristiques pour associer les besoins des utilisateurs avec les caractéristiques des items. Par exemple, si un utilisateur recherche une voiture économique, le système privilégiera les voitures avec une faible consommation de carburant. De plus, il peut utiliser des techniques de résolution de contraintes pour trouver des solutions qui satisfont un ensemble de conditions imposées par l'utilisateur. Par exemple, si un utilisateur cherche une voiture sous un certain budget, avec une bonne consommation de

carburant et suffisamment d'espace pour une famille de quatre personnes, le système identifiera les options répondant à toutes ces contraintes.

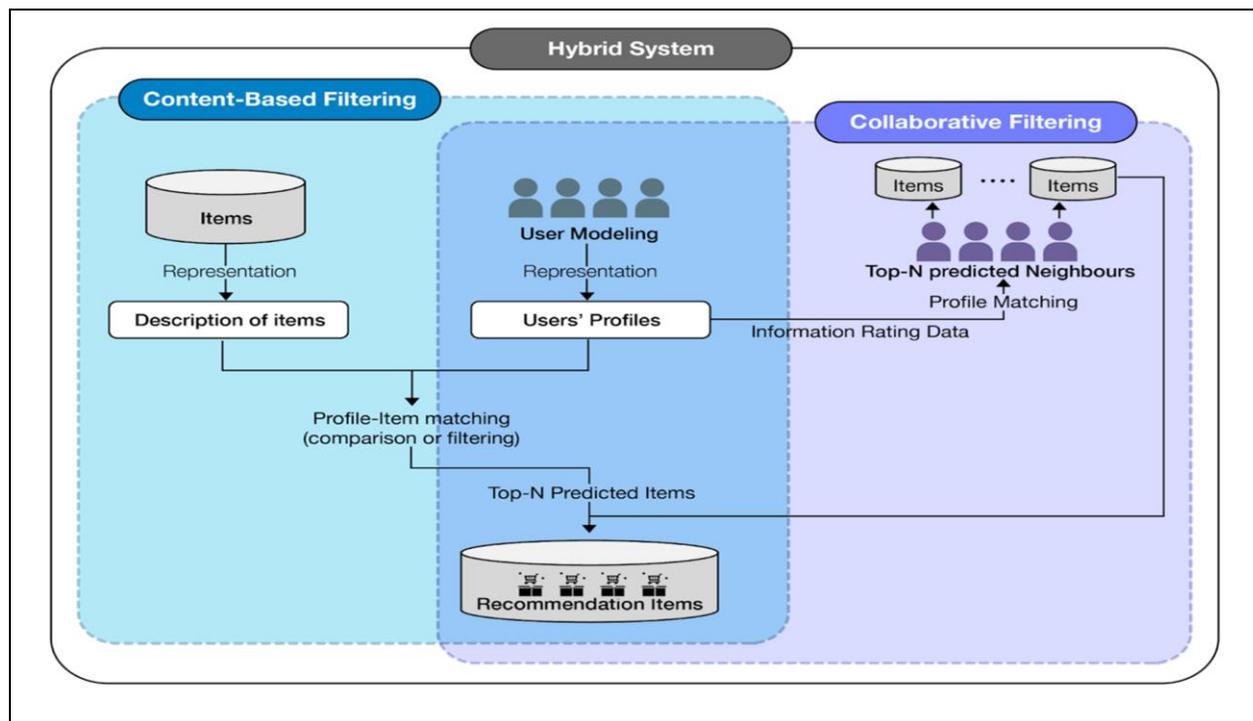
Les avantages des systèmes de recommandation basés sur les connaissances sont nombreux. Ils offrent une pertinence accrue en fournissant des recommandations très précises, basées sur des connaissances explicites et structurées. De plus, ils peuvent expliquer clairement pourquoi un item spécifique est recommandé, en se basant sur les règles et les préférences des utilisateurs. Ces systèmes sont également adaptables à des domaines où les choix sont influencés par des critères spécifiques et complexes, comme les soins de santé, l'éducation ou les achats de produits techniques.

Cependant, ces systèmes présentent aussi des limitations. L'acquisition de connaissances nécessite une collecte et une maintenance détaillée des informations sur les items et les préférences des utilisateurs, ce qui peut être coûteux et laborieux. De plus, ils peuvent devenir complexes à gérer et à mettre à jour, surtout dans des domaines avec de nombreux items et critères. Enfin, ils peuvent manquer de flexibilité pour des besoins ou des préférences non anticipées, ou pour des items très nouveaux sans beaucoup de données historiques.

### **I.5.5 Recommandation hybride**

Les systèmes de recommandation hybrides combinent deux ou plusieurs approches pour obtenir de meilleures performances. Leur objectif principal est d'améliorer les recommandations en combinant les forces de différentes méthodes [10]. Burke identifie sept techniques principales :

- Pondérée (Weighted)
- Commutation (Switching)
- Mixte (Mixed)
- Combinaison de fonctionnalités (Feature Combination)
- Cascade (cascade)
- Augmentation des fonctionnalités (Feature Augmentation)
- Niveau méta (Meta-level).



**Figure I.6** Le système hybride utilise deux approches de recommandation[4]

## I.6 Recommandations sociale

Le système de recommandation sociale intègre les médias sociaux aux systèmes de recommandation (SRs). Les réseaux sociaux et les SRs bénéficient mutuellement l'un de l'autre. L'expansion considérable des réseaux sociaux a ouvert des opportunités aux chercheurs pour analyser ces réseaux et utiliser leurs découvertes dans les systèmes de recommandation. Les réseaux sociaux représentent un domaine de recherche majeur depuis de nombreuses années, mais les SRs traditionnels ne prennent pas en compte l'influence sociale [11]. Les réseaux sociaux sont devenus un domaine d'investigation important pour le partage de contenu et la communication. Des millions d'utilisateurs actifs passent une partie de leur temps quotidien sur ces plateformes de réseautage social [12]. Ces entités sociales créent des profils, se connectent avec des amis, rejoignent des communautés, publient des commentaires, taguent des ressources et donnent des évaluations. Les utilisateurs des réseaux sociaux partagent leurs informations personnelles telles que leurs hobbies, leur éducation, leurs intérêts et leur genre, fournissant ainsi une quantité considérable de données informatives. Les utilisateurs partageant des goûts et des préférences similaires dans un réseau social tendent à former des groupes.

Les réseaux sociaux offrent une variété de sources d'information qui n'étaient pas accessibles il y a quelques années. Les médias sociaux génèrent une énorme quantité d'informations sous forme de relations, de commentaires, d'évaluations et de tags. Ces données sociales facilement accessibles peuvent être exploitées dans les systèmes de recommandation

pour améliorer les performances prédictives. De plus, les systèmes de recommandation sociale jouent un rôle majeur dans l'amélioration des recommandations dans les médias sociaux et abordent des problématiques excitantes comme la recommandation d'amis et l'engagement social. Par conséquent, ces systèmes de recommandation sont cruciaux pour l'application réussie des médias sociaux. Le système de recommandation sociale résout le problème de la surcharge d'informations en fournissant des recommandations robustes aux utilisateurs, en utilisant le concept d'influence sociale pour déterminer les préférences des utilisateurs. Les recommandations dans le système de recommandation sociale sont influencées par les évaluations des amis plutôt que par celles des utilisateurs anonymes.

### **I.6.1 Classification des systèmes de recommandation sociale**

La classification des systèmes de recommandation sociale repose sur plusieurs paramètres qui définissent les caractéristiques de ces systèmes. Parmi les aspects identifiés figurent le contexte, les tags, la confiance, les groupes, les réseaux sociaux croisés, la dynamique temporelle, les connexions sociales hétérogènes et filtrage sémantique.

#### **I.6.1.1 Contexte**

Les systèmes de recommandation sociaux, intégrant à la fois les réseaux sociaux et les systèmes de recommandation traditionnels, peuvent fournir des recommandations plus pertinentes en utilisant le contexte utilisateur. Les informations contextuelles telles que le temps, la situation et l'emplacement sont essentielles pour proposer des recommandations appropriées. D'autres approches intègrent les informations contextuelles et sociales afin d'améliorer la qualité des recommandations. La régularisation sociale aide à gérer l'hétérogénéité des goûts parmi les amis sociaux. Les réseaux sociaux basés sur la localisation utilisent des données géographiques pour recommander des lieux d'intérêt en fonction des préférences et des emplacements des utilisateurs. Les recommandations de lieux d'intérêt sont personnalisées et tiennent compte du contexte, en exploitant des techniques telles que la factorisation matricielle et l'analyse de texte.

#### **I.6.1.2 Confiance**

Un système de recommandation fiable est indispensable pour distinguer les utilisateurs authentiques des utilisateurs malveillants [13]. La confiance peut être définie comme un terme générique englobant plusieurs sens. Elle peut être considérée comme le niveau de crédibilité des évaluations fournies par l'utilisateur. Dans un réseau social, la confiance évalue la propension d'un utilisateur à se comporter conformément aux attentes [14]. Dans le contexte des systèmes de recommandation, elle représente la précision des recommandations générées par le système. Une relation de confiance se forme dans un réseau social sur la base des liens

sociaux entre les individus [15]. Les relations de confiance entre les utilisateurs dans un réseau social constituent un réseau de confiance. Lorsque ces liens sociaux sont annotés avec des données de confiance, cela donne naissance à un nouveau type de système de recommandation, appelé système de recommandation sociale conscient de la confiance. Il est crucial de connaître le niveau de confiance dans ces relations pour prendre des décisions éclairées. C'est pourquoi les utilisateurs préfèrent les systèmes de recommandation qui reposent sur des relations de confiance plutôt que sur des mesures de similarité. Un système de recommandation sociale conscient de la confiance peut résoudre les problèmes de démarrage à froid, de rareté des données, d'intégrité des évaluations et d'évolutivité, car les utilisateurs familiers sont généralement plus dignes de confiance que les utilisateurs inconnus [16], [17].

### **I.6.1.3 Tags**

Les sites de réseaux sociaux permettent aux utilisateurs de télécharger diverses informations ou ressources telles que des images, des documents et des vidéos. Ces ressources sont associées à une étiquette appelée "tag" et la pratique d'assigner des tags est connue sous le nom de "tagging". Les tags sont des mots personnalisés par les utilisateurs pour exprimer divers aspects tels que leur opinion, leur emplacement, leur humeur, l'heure, etc. Ils établissent un lien entre une ressource et un utilisateur, et leur utilisation fréquente reflète l'intérêt d'un utilisateur pour cette ressource[18]. Le tagging social joue un rôle crucial en révélant les préférences des utilisateurs, ce qui améliore les performances des systèmes de recommandation sociale[19]. L'objectif du tagging est de faciliter le partage et la découverte de ressources. Avec l'essor des sites de réseaux sociaux, les tags sociaux ont gagné en popularité. Les préférences d'une personne pour certaines ressources évoluent avec le temps, et les ressources ou les tags récemment ajoutés reflètent l'intérêt actuel de l'utilisateur. Ainsi, les tags récents sont privilégiés pour des recommandations plus pertinentes.

### **I.6.1.4 Groupe**

La plupart des systèmes de recommandation fournissent des recommandations d'items aux utilisateurs individuellement. Cependant, il existe des circonstances et des domaines où les utilisateurs travaillent en groupe pour réaliser certaines activités, telles que mener des recherches dans un domaine spécifique, lire un roman, partir en pique-nique ou assister à une conférence. Un système de recommandation qui génère des recommandations pour un groupe d'utilisateurs est appelé système de recommandation de groupe [20]. On a observé une croissance rapide du développement de systèmes de recommandation de groupe ces dernières années. Dans les réseaux sociaux, les communautés sont des groupes d'utilisateurs ayant des préférences similaires.

Quijano-Sanchez et al.[21] utilisent des facteurs de confiance sociale et la composition de la personnalité du groupe pour développer une méthode de recommandation de groupe. Christensen et al.[22] se concentrent sur l'exercice de l'influence sociale pour améliorer la précision des systèmes de recommandation dans le domaine du tourisme. Ils présentent une approche hybride qui intègre le filtrage collaboratif, le filtrage basé sur le contenu et le filtrage démographique pour la recommandation de groupe, et utilisent les relations sociales ainsi que les préférences individuelles et de groupe.

#### **I.6.1.5 Réseaux sociaux croisés**

Il est courant de constater que les gens créent des comptes sur plusieurs réseaux sociaux. Par exemple, un utilisateur ayant un compte sur le site MovieLens peut également en avoir un sur le site Epinion. L'intuition derrière l'utilisation de données provenant de plusieurs domaines est que les éléments d'un domaine peuvent être corrélés avec ceux d'autres domaines. Supposons qu'un utilisateur ait un compte sur MovieLens depuis longtemps mais soit nouveau sur Epinion ; les informations sur l'utilisateur provenant de MovieLens peuvent être utilisées comme connaissances supplémentaires par Epinion. Reconnaître les individus sur plusieurs réseaux sociaux améliore la précision des profils d'utilisateur et, en fin de compte, renforce la qualité des recommandations [23].

#### **I.6.1.6 Dynamique temporelle**

Les préférences des utilisateurs et la popularité des articles sont largement non stationnaires dans les scénarios réels. L'exactitude d'un système de recommandation repose principalement sur ces effets temporels [24]. Par exemple, une mère intéressée par l'achat de jouets pour bébés peut plus tard modifier ses préférences pour acheter des livres. De même, les relations dans les réseaux sociaux évoluent avec le temps : un utilisateur peut nouer de nouvelles relations avec d'autres utilisateurs ou mettre fin à des relations existantes. La mise à jour des connexions sociales influence les évaluations des articles. De Pessemier et al. (2010) ont expérimentalement démontré que les données anciennes ont un impact négatif sur la précision des systèmes de recommandation. Pham et al.[25] soulignent l'importance des dynamiques temporelles sur le comportement des utilisateurs dans les réseaux sociaux orientés vers les événements. Ils introduisent un modèle basé sur un graphe pour recommander plusieurs types d'informations dans ces réseaux.

#### **I.6.1.7 Connexions sociales hétérogènes**

Les réseaux sociaux étant de nature hétérogène, il existe de multiples types de connexions sociales entre les utilisateurs. Ces connexions sociales sont un mélange de relations allant de positives à négatives, de pondérées à non pondérées, d'importantes à ordinaires, et de dirigées

à non dirigées. Différents types de relations influencent les personnes de manière diverse. Par exemple, le sujet de recherche d'un chercheur peut être influencé par son directeur, mais cela peut ne pas affecter sa vie quotidienne. Les connexions libres, rapides et en croissance rapide sur les réseaux sociaux ont créé un nombre superflu de connexions sociales sous forme d'amis. Il n'est pas nécessaire que toutes les relations soient également importantes. Les amis proches établissent des connexions importantes, les amis ordinaires développent des relations moins importantes et les amis d'événements forment des relations triviales. Le mélange de relations importantes et inutiles peut introduire du bruit et produire des résultats négatifs.

Une étude montre que les systèmes de recommandation sociale utilisant toutes les relations produisent des résultats plus défavorables que les systèmes de recommandation traditionnels [26]. Les utilisateurs emploient et expriment à la fois des relations négatives et positives. Les relations positives sont largement utilisées dans la plupart des systèmes de recommandation sociale existants. Cependant, des relations négatives existent également sous forme de dégoût, de suspicion ou de méfiance. De plus, la plupart des réseaux sociaux contiennent des données de pondération. Les poids attribués aux liens ou aux arêtes indiquent la proximité ou la force de la relation entre les utilisateurs. Les relations pondérées expriment plus de confiance dans la génération de recommandations efficaces. Une revue récente de la littérature dans ce domaine a révélé que de nombreux systèmes de recommandation sociale considèrent les connexions sociales comme étant du même type. Mais dans le monde réel, un utilisateur peut avoir différents types de relations avec différentes personnes dans différents domaines. Zhang et al. [27] examinent les problèmes liés aux recommandations dans les réseaux hétérogènes et développent un modèle de marche aléatoire qui approxime l'importance des objets dans ces réseaux. Ils proposent un algorithme d'apprentissage par paires pour ajuster les poids des différents liens dans les réseaux sociaux hétérogènes. Tang et al. [6] soulignent la nécessité de forces hétérogènes pour la recommandation dans un contexte social local. Zhou et al. [28] expliquent les avantages des données de méfiance des utilisateurs pour améliorer la précision des systèmes de recommandation sociale.

#### **I.6.1.8 Filtrage sémantique**

Le filtrage sémantique est une fonctionnalité essentielle des systèmes de recommandation (SRs) permettant de recommander des données importantes en filtrant les données non pertinentes et en améliorant la qualité des SRs [29]. Le filtrage sémantique atténue le problème du démarrage à froid en exploitant les similitudes sémantiques pour offrir des recommandations logiques. Les SRs utilisant le filtrage sémantique sont compétents pour répondre aux besoins et aux préférences à long terme des utilisateurs. Grâce à la technologie sémantique, il devient

possible de reconnaître les entités du monde réel à partir des informations textuelles, et les propriétés de ces informations sont utilisées comme connaissances de fond [30]. De nombreux chercheurs ont étudié l'utilisation du web sémantique dans les SRs. Dans l'analyse des réseaux sociaux, il est essentiel de découvrir des relations sociales sémantiques pour établir des relations significatives.

### **I.6.2 Difficultés des systèmes de recommandation sociale**

Les systèmes de recommandation sociale présentent des difficultés dans plusieurs aspects :

- **Diversité des relations sociales** : Les utilisateurs peuvent avoir différents types de relations sociales, comme des amis proches, des connaissances occasionnelles, etc., ce qui complique la modélisation de l'influence de ces relations sur les recommandations.
- **Gestion des données contextuelles** : Les recommandations doivent être sensibles au contexte, comme le temps, le lieu, l'humeur, etc., ce qui rend la prise en compte de ces données complexe.
- **Modélisation des relations de confiance** : Établir la confiance entre utilisateurs est crucial pour fournir des recommandations fiables, mais modéliser ces relations de manière précise est difficile.
- **Pondération adéquate des caractéristiques** : Différentes caractéristiques influencent les recommandations de diverses manières, et trouver la pondération appropriée de ces caractéristiques est un défi.
- **Prise en compte des informations temporaires** : Les recommandations doivent être basées sur les activités récentes des utilisateurs, ce qui nécessite une gestion efficace des informations temporaires.
- **Gestion des données provenant de multiples plateformes sociales** : Les utilisateurs interagissent sur différentes plateformes sociales, et intégrer ces données de manière cohérente pour fournir des recommandations précises est complexe.

### **I.7. Défis liés aux systèmes de recommandation**

Évaluer la performance des systèmes de recommandation pose des défis, notamment en raison des besoins divers des organisations qui les déploient. En général, la satisfaction des utilisateurs reste la mesure la plus pertinente, bien qu'elle ne puisse être réduite à une formule simple. Pour évaluer les performances des systèmes de recommandation, nous nous appuyons sur leur capacité à résoudre plusieurs défis clés tels que le démarrage à froid, la précision, la rareté des données, l'évolutivité et la diversité.

- **Démarrage à froid** : ce problème survient lors de l'introduction d'un nouvel élément dans le système de recommandation, que ce soit un utilisateur ou un item. Le système doit traiter ce cas comme spécial. Le principal défi du démarrage à froid réside dans le manque d'informations disponibles pour formuler des recommandations [31].
- **Parcimonie (Sparsity – rareté des données)** : Le problème de rareté est lié à l'indisponibilité d'un grand nombre d'items notés pour chaque utilisateur actif. En général, le nombre d'items candidats à la recommandation est énorme et les utilisateurs ne notent qu'un petit sous-ensemble des items disponibles. Ainsi, la matrice des notes est souvent très creuse, avec un taux de valeurs manquantes pouvant atteindre jusqu'à 95% du total des valeurs [32].
- **Évolutivité** : Les problèmes d'évolutivité ont été considérablement soulevés en raison de la croissance rapide des sites de commerce électronique. Les systèmes de recommandation modernes doivent être capables de générer des résultats rapidement pour des applications à grande échelle. Ils doivent pouvoir rechercher de nombreux voisins potentiels en temps réel, mais les exigences des sites de commerce électronique modernes les obligent à rechercher un nombre encore plus grand de voisins. Les algorithmes rencontrent également des problèmes de performance lorsque les utilisateurs possèdent de vastes quantités de données [33]. Par exemple, sur un site avec des dizaines de milliers de points de données par utilisateur, il peut être difficile et fastidieux de trouver des voisins pertinents pour chaque utilisateur. Les algorithmes de filtrage basés sur les plus proches voisins nécessitent une puissance de calcul accrue en raison de l'énorme augmentation du nombre de produits ou d'utilisateurs. Pour une plate-forme comptant des millions d'utilisateurs et de produits, l'évolutivité devient un problème sérieux[10].
- **Diversité** : Dans diverses situations, les systèmes de recommandation peuvent fournir des suggestions d'items similaires ou plus variés. Pour obtenir des résultats plus précis, il est souvent préférable de recommander des items en se basant sur la similarité entre utilisateurs ou entre items. La personnalisation se traduit par l'unicité des listes de recommandations pour différents utilisateurs, connue sous le nom de diversité inter-utilisateurs. La distance inter-listes peut-être facilement calculée pour évaluer cela. Il est essentiel de maintenir un seuil de précision pour résoudre les problèmes de diversité tout en conservant la qualité des recommandations d'items [34] [10].
- **Effet d'accoutumance** : Effet d'accoutumance : Les interfaces de recommandation sont considérées comme un élément essentiel des stratégies marketing, servant à diffuser le contenu marketing. Pour optimiser les performances de ces interfaces, plusieurs éléments peuvent être explorés, tels que le nombre de recommandations et les images des items

recommandés. Les clients étant souvent submergés par une quantité importante d'informations, y compris du contenu marketing, il se produit généralement un effet d'accoutumance, conduisant au phénomène de cécité des bannières. Ainsi, même si les recommandations sont optimisées d'un point de vue algorithmique, elles peuvent fournir des résultats inexacts à moins d'être présentées de manière plus visible pour l'utilisateur. Pour contrer le phénomène de cécité des bannières, les spécialistes du marketing utilisent souvent des techniques visuelles renforcées, telles que l'augmentation de l'intensité visuelle [35], l'utilisation d'animations et d'effets de scintillement [36] [10].

## **I.8. Conclusion**

Dans ce chapitre, nous avons d'abord défini les systèmes de recommandation en détaillant leurs fonctions. Ensuite, nous avons présenté les domaines d'application des SRs ainsi que les techniques de recommandation les plus utilisées, en nous concentrant particulièrement sur le filtrage collaboratif et en détaillant ses concepts de base. De plus, nous avons discuté des systèmes de recommandation sociale, de leur classification ainsi que des défis auxquels ils font face. Ce chapitre offre un état de l'art complet sur les SRs en général, avec un focus particulier sur la recommandation sociale. Nous avons particulièrement examiné l'apprentissage profond. Dans le chapitre suivant, nous continuerons notre état de l'art en abordant principalement les principaux algorithmes de deep learning et leurs applications dans la recommandation sociale.

## ***Chapitre II***

Les principaux algorithmes de deep learning et leurs applications  
dans la recommandation sociale

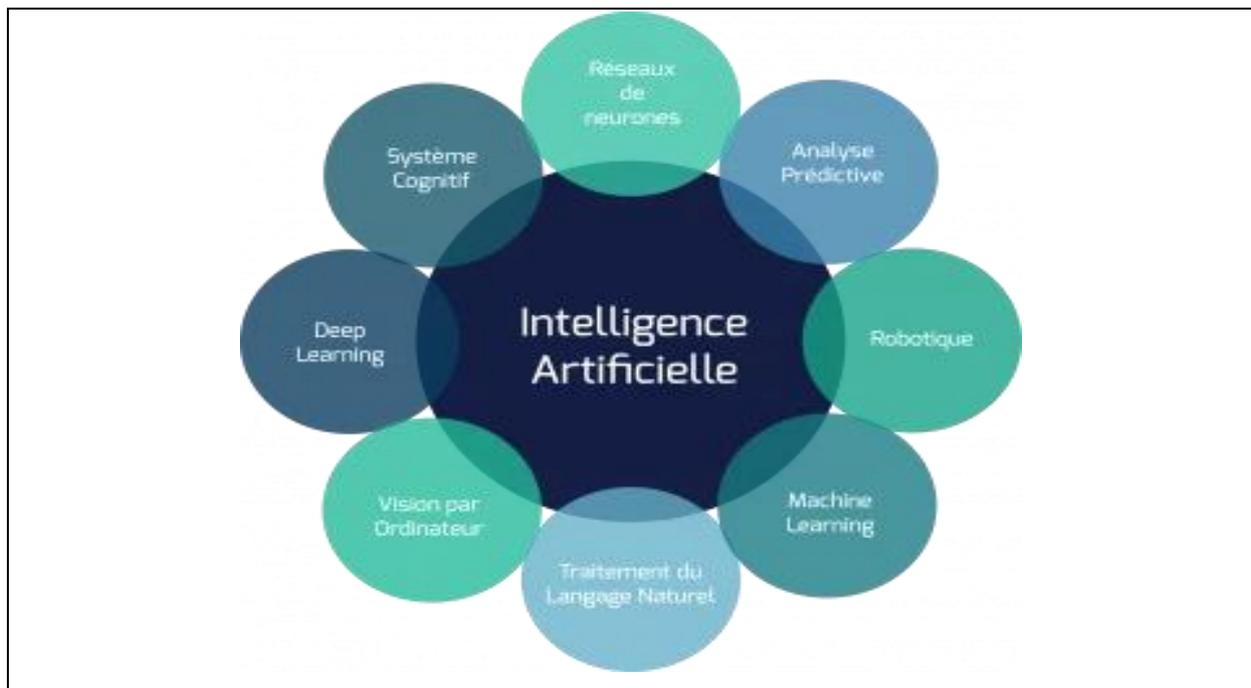
**II.1 Introduction**

L'augmentation des données nous offre l'opportunité de construire des systèmes complexes capables de modéliser avec plus de précision les interactions des utilisateurs et d'extraire des caractéristiques sophistiquées pour fournir des recommandations plus précises. Pour construire ces modèles complexes, le deep learning émerge comme l'un des outils les plus puissants. Il a été utilisé dans les systèmes de recommandation pour résoudre le problème du démarrage à froid, améliorer l'estimation des fonctions d'interaction et extraire des représentations profondes des caractéristiques, parmi d'autres aspects qui influencent les systèmes de recommandation traditionnels.

Ce chapitre vise à explorer en profondeur les principaux algorithmes de Deep Learning utilisés dans le domaine de la recommandation sociale. Nous commencerons par établir les bases théoriques du Deep Learning, en décrivant les concepts essentiels tels que les réseaux de neurones artificiels, l'apprentissage supervisé et non supervisé, ainsi que les mécanismes fondamentaux des algorithmes de Deep Learning. Ensuite, nous présenterons les systèmes de recommandation sociale basés sur le Deep Learning.

**II.2 Intelligence artificielle**

L'intelligence artificielle (IA) est un domaine de l'informatique qui vise à créer des systèmes capables d'imiter certaines capacités cognitives humaines, telles que l'apprentissage, la résolution de problèmes, la compréhension du langage et la perception visuelle. Ces systèmes utilisent des algorithmes et des modèles pour traiter des données et prendre des décisions de manière autonome. L'objectif principal de l'IA est de développer des machines capables d'accomplir des tâches nécessitant habituellement l'intelligence humaine, mais de manière plus rapide et efficace. L'IA trouve des applications dans de nombreux domaines, tels que la santé, la finance, les transports, et bien d'autres, transformant ainsi notre façon de vivre et de travailler.



*Figure II.1* Qu'est-ce que l'intelligence artificielle ?

### II.3 Apprentissage automatique

L'apprentissage automatique (Machine Learning en anglais) est une branche de l'intelligence artificielle (IA) qui consiste à développer des algorithmes et des techniques permettant aux ordinateurs d'apprendre et de s'améliorer automatiquement à partir de données et d'expériences sans être explicitement programmés. L'objectif principal est de créer des modèles capables de faire des prédictions ou de prendre des décisions basées sur des données d'entrée. Aujourd'hui, avec la montée des big data, de l'Internet des objets (IoT) et de l'informatique omniprésente, l'apprentissage automatique est devenu essentiel pour résoudre des problèmes dans de nombreux domaines, tels que [37] :

- Finance computationnelle (évaluation du crédit, trading algorithmique)
- Vision par ordinateur (reconnaissance faciale, suivi de mouvement, détection d'objets)
- Biologie computationnelle (séquençage de l'ADN, détection de tumeurs cérébrales, découverte de médicaments)
- Automobile, aérospatiale et fabrication (maintenance prédictive)
- Traitement du langage naturel (reconnaissance vocale)

### II.3.1 Les types d'apprentissage automatique

Les algorithmes d'apprentissage automatique peuvent être entraînés de nombreuses façons, chaque méthode ayant ses avantages et ses inconvénients. En fonction de ces méthodes et des manières d'apprendre, l'apprentissage automatique est généralement catégorisé en trois types principaux :

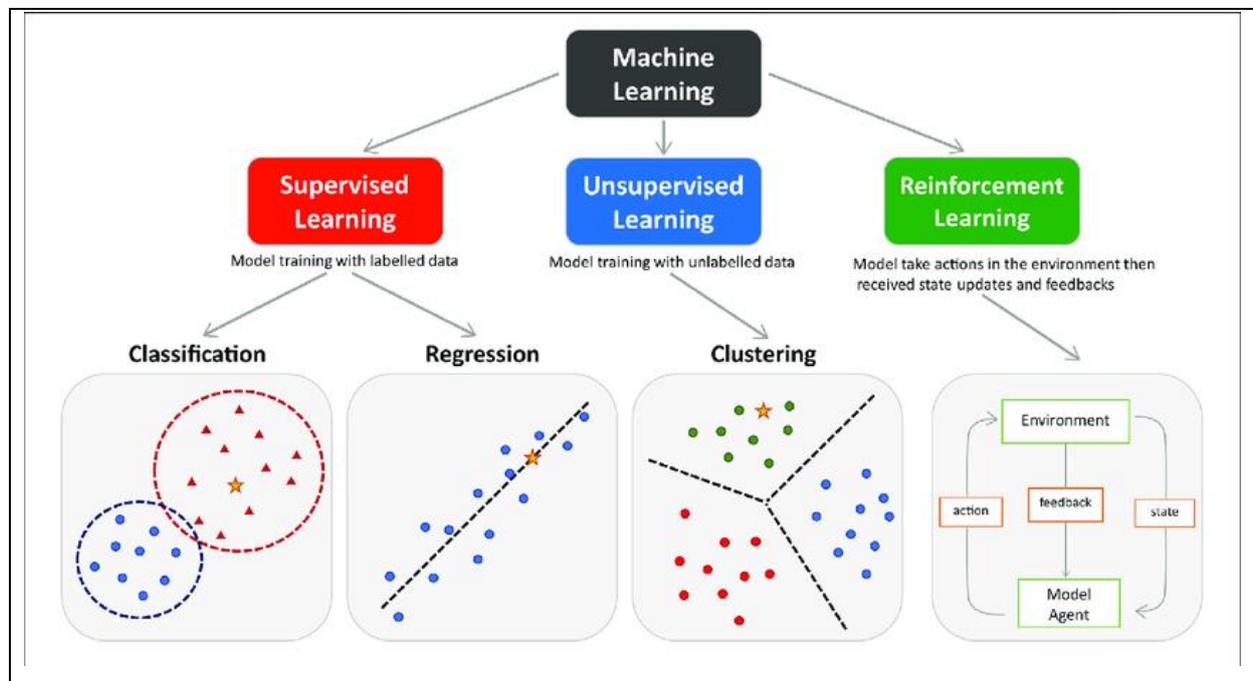


Figure II.2 Les types d'apprentissage automatique [37]

#### II.3.1.1 Apprentissage supervisé

Ce type d'apprentissage automatique implique une supervision, où les machines sont entraînées sur des ensembles de données étiquetées et habilitées à prédire des résultats basés sur la formation fournie. L'ensemble de données étiquetées spécifie que certains paramètres d'entrée et de sortie sont déjà mappés. Ainsi, la machine est entraînée avec les entrées et les sorties correspondantes. Un appareil est conçu pour prédire le résultat en utilisant l'ensemble de données de test dans les phases ultérieures [37].

L'objectif principal de la technique d'apprentissage supervisé est de mapper la variable d'entrée (a) avec la variable de sortie (b). L'apprentissage supervisé est en outre classé en deux grandes catégories :

- **Classification** : Ces algorithmes traitent des problèmes de classification où la variable de sortie est catégorielle ; par exemple, oui ou non, vrai ou faux, masculin ou féminin, etc. Des applications concrètes de cette catégorie sont évidentes dans la détection de spam et le filtrage des emails. Certains algorithmes de classification connus incluent l'algorithme de
- Forêt Aléatoire, l'algorithme de l'Arbre de Décision, l'algorithme de Régression Logistique et l'algorithme de la Machine à Vecteurs de Support.

- **Régression** : Les algorithmes de régression traitent des problèmes de régression où les variables d'entrée et de sortie ont une relation linéaire. Ceux-ci sont connus pour prédire des variables de sortie continues. Des exemples incluent la prédiction météorologique, l'analyse des tendances du marché, etc. Les algorithmes de régression populaires incluent l'algorithme de Régression Linéaire Simple, l'algorithme de Régression Multivariée, l'algorithme de l'Arbre de Décision et l'algorithme de Régression Lasso.

### II.3.1.2 Apprentissage non supervisé

L'apprentissage non supervisé fait référence à une technique d'apprentissage dépourvue de supervision. Dans ce contexte, la machine est entraînée en utilisant un ensemble de données non étiquetées et est capable de découvrir des structures dans les données sans aucune supervision explicite. Un algorithme d'apprentissage non supervisé vise à regrouper l'ensemble de données non triées en fonction des similitudes, des différences et des motifs des entrées.

L'apprentissage non supervisé se divise en deux types principaux :

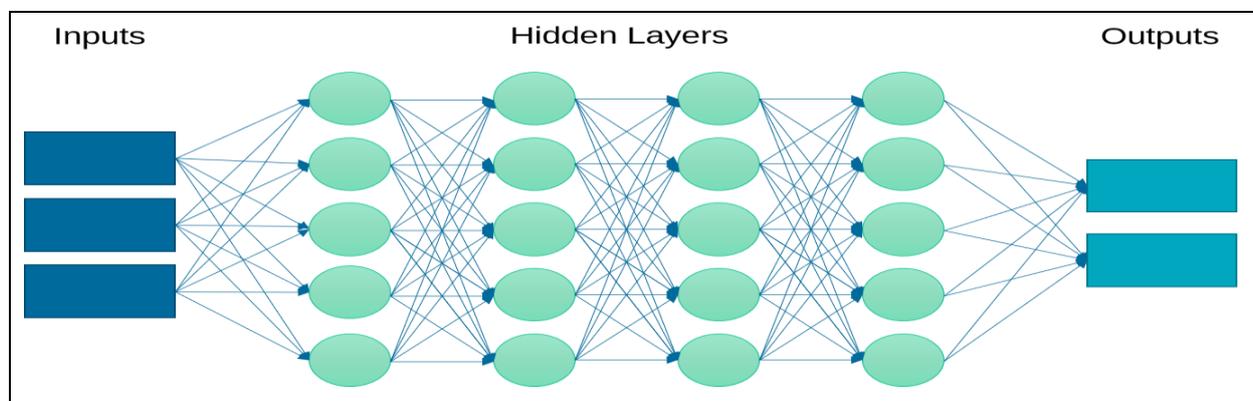
- **Clustering** : La technique de clustering consiste à regrouper des objets en clusters basés sur des critères tels que les similitudes ou les différences entre les objets. Par exemple, on peut regrouper des clients en fonction des produits qu'ils achètent. Parmi les algorithmes de clustering connus, on trouve l'algorithme K-Means, l'algorithme Mean-Shift, l'algorithme DBSCAN, l'analyse en composantes principales (PCA) et l'analyse en composantes indépendantes (ICA).
- **Association** : L'apprentissage d'association consiste à identifier les relations typiques entre les variables d'un grand ensemble de données. Il détermine la dépendance entre divers éléments de données et cartographie les variables associées. Les applications typiques incluent l'exploration de l'utilisation du web et l'analyse des données de marché. Parmi les algorithmes populaires d'association, on trouve l'algorithme Apriori, l'algorithme Eclat et l'algorithme FP-Growth.

### II.3.1.3 Apprentissage par renforcement

L'apprentissage par renforcement est un processus basé sur les retours d'information. Ici, le composant d'IA prend automatiquement en compte son environnement par la méthode d'essais et d'erreurs, prend des mesures, apprend des expériences et améliore ses performances. Le composant est récompensé pour chaque bonne action et pénalisé pour chaque mouvement erroné. Ainsi, le composant d'apprentissage par renforcement vise à maximiser les récompenses en effectuant de bonnes actions. L'apprentissage par renforcement est appliqué dans différents domaines tels que la théorie des jeux, la théorie de l'information et les systèmes multi-agents.

## II.4 L'apprentissage profond

L'apprentissage profond, ou deep learning en anglais, est une sous-discipline du machine learning. Il s'agit d'une nouvelle approche de l'apprentissage des représentations à partir des données, qui met l'accent sur l'apprentissage de couches successives de représentations de plus en plus abstraites. En d'autres termes, c'est une forme avancée de réseau de neurones artificiels qui utilise de nombreuses couches de neurones pour résoudre des problèmes plus difficiles et complexes. Sa popularité en tant que technologie a considérablement augmenté depuis 2005, encouragée par l'échec des algorithmes traditionnels d'apprentissage automatique à résoudre des tâches d'IA complexes telles que la reconnaissance de la parole ou des objets. L'apprentissage profond s'est déjà révélé utile dans divers domaines, allant de la vision par ordinateur aux moteurs de recherche, et est souvent utilisé pour catégoriser des informations telles que des images, du texte ou du son.



*Figure II.3 Fonctionnement de l'apprentissage profond*

## II.5 Les algorithmes d'apprentissage profond

Il existe différents types d'algorithmes d'apprentissage profond, chacun ayant ses propres forces et faiblesses :

### II.5.1 Réseaux de neurones artificiels

Un réseau de neurones artificiels, également appelé Artificial Neural Network (ANN), est un système informatique qui s'inspire du fonctionnement du cerveau humain pour apprendre. L'architecture des réseaux de neurones artificiels regroupe un ensemble d'unités élémentaires appelées « neurones formels ». Ces neurones sont connectés entre eux pour former un graphe orienté. En analogie avec les réseaux biologiques de neurones, les connexions entre les nœuds du graphe symbolisent les synapses. Ces connexions sont pondérées par des poids ajustés durant la phase d'apprentissage grâce à un algorithme dédié. Ce type d'algorithmes adapte les poids afin de minimiser la différence entre la sortie du réseau (l'hypothèse) et la sortie attendue.

## II.5.2 Réseaux de neurones convolutifs (CNN)

Les réseaux de neurones convolutifs, également appelés convnets pour "Convolutional Network" ou CNN pour "Convolutional Neural Network", se sont révélés très efficaces pour les tâches impliquant des données étroitement liées, principalement dans le domaine de la vision par ordinateur. On distingue deux parties dans un CNN : une première partie, appelée la partie convolutive du modèle, et une seconde partie, que l'on va appeler la partie classification du modèle, correspondant à un modèle MLP (Multi Layers Perceptron) [38].

C'est un réseau de neurones multicouches, plus précisément un réseau profond composé de quatre types de couches : la couche de convolution, la couche de pooling, la couche de correction ReLU et la couche fully connected.

- **La couche de convolution** : est la plus essentielle et le point central des éléments constitutifs du réseau convolutif. Elle est également responsable des calculs les plus complexes, ayant pour but de repérer la présence d'une série de propriétés dans les images reçues en entrée.

- **La couche de pooling** : souvent située entre deux couches de convolution, reçoit plusieurs cartes de caractéristiques en entrée et applique l'opération de pooling à chacune d'entre elles. L'opération de pooling (ou sous-échantillonnage) consiste à réduire la taille des images tout en préservant leurs caractéristiques importantes.

- **La couche de correction ReLU** : remplace toutes les valeurs négatives reçues en entrée par des zéros. Elle joue le rôle de fonction d'activation.

- **La couche fully connected** : constitue toujours la dernière couche d'un réseau de neurones, convolutifs ou non. Ce type de couche reçoit un vecteur en entrée et produit un nouveau vecteur en sortie. Pour cela, elle applique une combinaison linéaire puis éventuellement une fonction d'activation aux valeurs reçues en entrée.

La figure suivante montre l'architecture d'un réseau de neurones de type CNN :

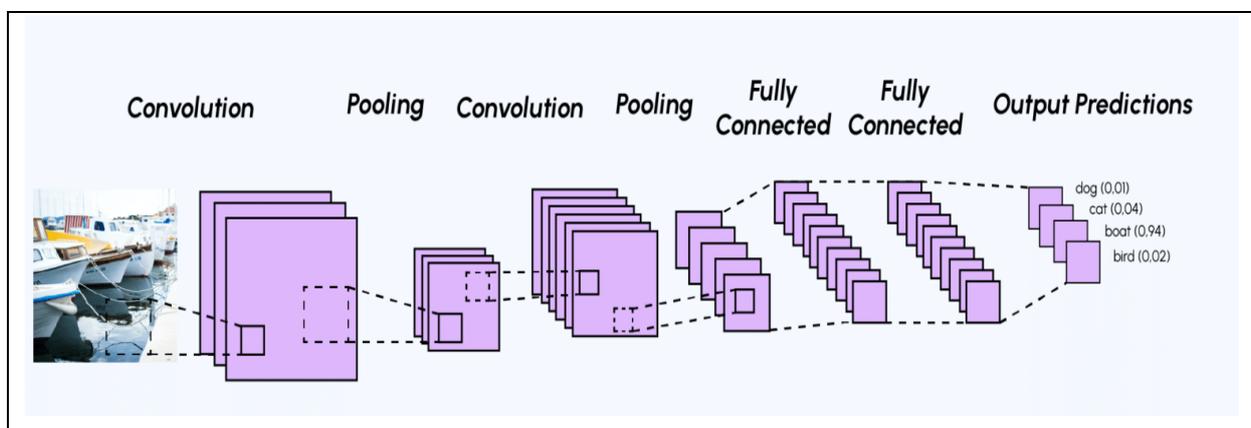


Figure II.4 Fonctionnement d'un réseau de neurones convolutifs[39]

Les réseaux de neurones de type CNN sont utilisés notamment dans :

- La reconnaissance faciale.
- Identifier et classer les objets du quotidien en images.
- Alimenter la vision dans les robots et les véhicules autonomes.
- Reconnaître les scènes et suggérer des légendes pertinentes.

### II.5.3 Réseaux de neurones récurrents (RNN)

Un réseau de neurones récurrent (RNN) est un type de réseau de neurones artificiels conçu pour traiter des données séquentielles, c'est-à-dire des données qui se déroulent dans le temps [40]. Contrairement aux réseaux de neurones artificiels traditionnels, qui traitent chaque entrée indépendamment des autres, les RNN prennent en compte les entrées précédentes pour traiter l'entrée actuelle. Cela leur permet de capturer des dépendances temporelles dans les données, ce qui les rend particulièrement adaptés à des tâches telles que [41] :

- **La reconnaissance vocale** : les RNN peuvent être utilisés pour apprendre à reconnaître des mots ou des phrases dans un discours parlé, en tenant compte de la séquence des sons entendus.
- **Le traitement du langage naturel** : les RNN peuvent être utilisés pour des tâches de traitement du langage naturel (NLP) telles que la traduction automatique, la génération de texte et la réponse aux questions.
- **La prédiction de séries temporelles** : les RNN peuvent être utilisés pour prédire des événements futurs, tels que le prix d'une action ou la météo, en tenant compte des tendances passées.

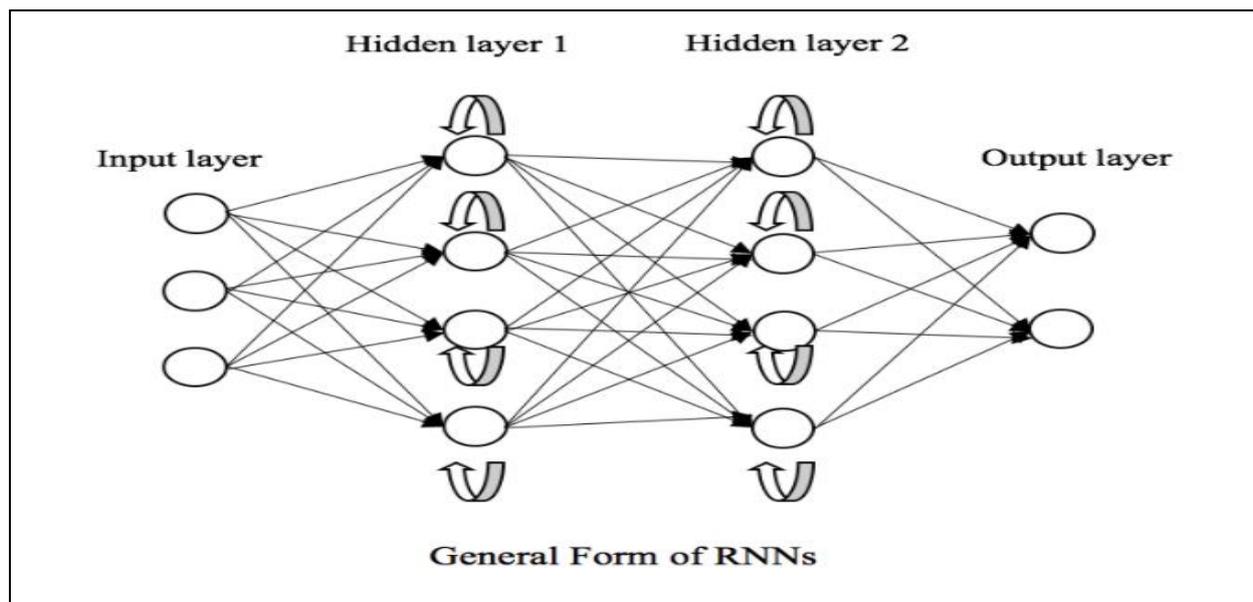


Figure II.5 Forme générale pour le RNN

### II.5.4 AutoEncodeurs (AE)

Les autoencodeurs sont généralement des réseaux neuronaux non supervisés qui sont entraînés à reproduire leur entrée en tant que sortie. Ils se composent typiquement de trois couches : la couche d'entrée, la couche cachée et la couche de sortie. La couche d'entrée reçoit les représentations complexes du jeu de données, et dans la couche cachée, ces représentations sont transformées en représentations de basse dimension. Fondamentalement, cela fonctionne comme un encodeur, qui réduit les dimensions des représentations complexes et de haute dimension en représentations plus simples et de basse dimension. Inversement, lors de la phase de décodage, les représentations de basse dimension sont converties en représentations de haute dimension à mesure que les données passent de la couche cachée à la couche de sortie, agissant alors comme un décodeur.

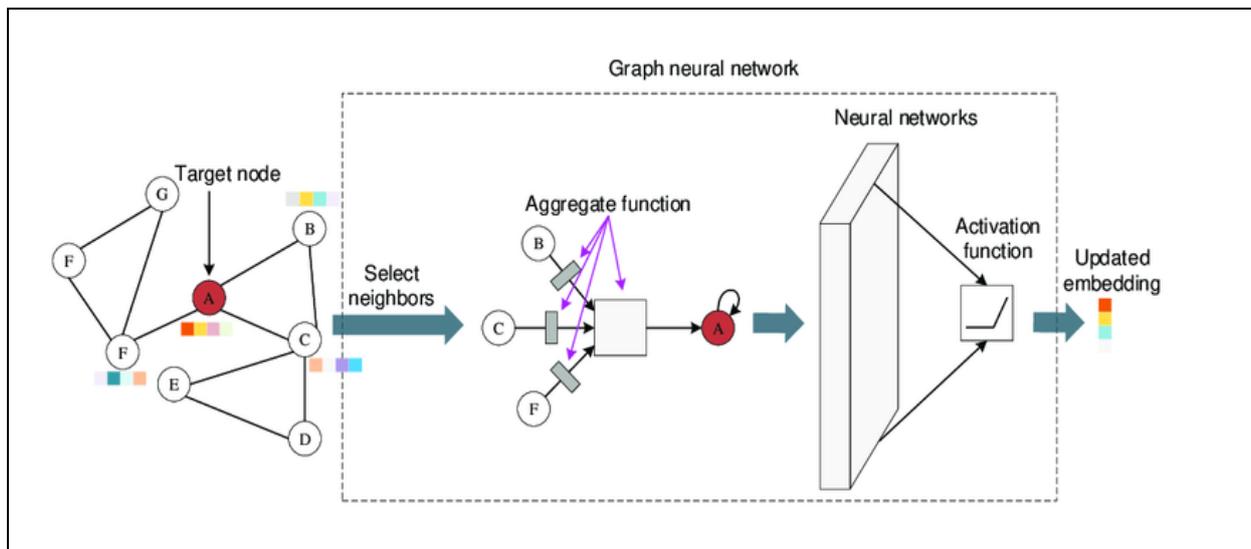
### II.5.5 Réseaux de neurones graphiques (GNN)

Les réseaux de neurones graphiques, également connus sous le nom de Graph Neural Networks (GNN), sont une classe de modèles d'apprentissage automatique spécifiquement conçus pour traiter des données structurées sous forme de graphes. Les GNN sont utiles pour analyser des données complexes et interconnectées qui ne peuvent pas être facilement traitées par les réseaux de neurones traditionnels en raison du problème d'invariance par permutation. Ils exploitent à la fois les caractéristiques et la structure des graphes pour apprendre des représentations riches et expressives qui capturent les motifs et les dépendances dans les données. De plus, ils peuvent généraliser efficacement à des graphes non observés ou nouveaux en apprenant à partir des voisinages locaux plutôt que des structures globales.

Une façon simple de construire un modèle pour traiter les graphes est d'utiliser la matrice d'adjacence comme entrée d'un réseau de neurones profond. Cependant, cette méthode présente l'inconvénient de dépendre de l'ordre arbitraire des nœuds dans la matrice d'adjacence. En d'autres termes, un tel modèle manque d'invariance ou d'équivariance par permutation, des propriétés essentielles pour la conception de réseaux de neurones adaptés aux graphes. Mathématiquement, toute fonction opérant sur une matrice d'adjacence devrait idéalement satisfaire l'une des deux propriétés suivantes :

- **Invariance par permutation** : Cette propriété signifie que la fonction est indépendante de l'ordre arbitraire des lignes/colonnes dans la matrice d'adjacence.
- **Équivariance par permutation** : Cette propriété signifie que la sortie de la fonction est permutée de manière cohérente lorsque la matrice d'adjacence est permutée.

Le composant clé d'une couche GNN (Graph Neural Network) est la fonction d'agrégation, qui prend comme entrée les représentations des voisins d'un nœud et produit une nouvelle représentation pour ce nœud.



*Figure II.6* Processus de base d'un GNN, de l'entrée à la sortie[42]

### II.5.5.1 Notions de base en théorie des graphes pour les GNN

La théorie des graphes est une branche des mathématiques qui étudie les propriétés et les applications des graphes, des structures composées d'un ensemble de sommets et d'un ensemble d'arêtes. Les sommets sont les unités de base d'un graphe, et les arêtes sont les connexions entre eux. Pour comprendre les GNN (Graph Neural Networks), il est essentiel de maîtriser certaines notions fondamentales de la théorie des graphes :

- **Graphe** : Un graphe  $G$  est défini par un ensemble de nœuds (ou sommets)  $V$  et un ensemble d'arêtes  $E$  reliant certains couples de nœuds. Un graphe peut être dirigé ou non dirigé, selon que les arêtes ont une direction ou non.
- **Matrice d'adjacence** : Une matrice  $A$  qui représente les connexions entre les nœuds. Si  $A_{ij}$  est différent de zéro, cela signifie qu'il y a une arête entre le nœud  $i$  et le nœud  $j$ .
- **Degré** : Le degré d'un nœud est le nombre de connexions (arêtes) qu'il a avec d'autres nœuds. Pour un graphe non dirigé, c'est le nombre total d'arêtes incidentes à ce nœud. Pour un graphe dirigé, on distingue le degré entrant et le degré sortant.
- **Chemin** : Une séquence de nœuds où chaque paire consécutive est connectée par une arête. La longueur du chemin est le nombre d'arêtes qu'il contient.
- **Cycle** : Un chemin qui commence et se termine au même sommet. Un graphe est acyclique s'il n'a pas de cycles.
- **Graphe dirigé** : Un graphe où chaque arête a une direction, indiquant l'ordre des sommets. Un graphe dirigé est acyclique s'il n'a pas de cycles dirigés.
- **Graphe non dirigé** : Un graphe où chaque arête n'a pas de direction, ce qui signifie que l'ordre des sommets n'a pas d'importance. Un graphe non dirigé est connexe s'il existe un chemin entre chaque paire de sommets.

### II.5.5.2 Applications des GNN

Il existe de nombreuses applications pratiques des réseaux de neurones graphiques (GNN). Voici quelques exemples[43] :

- **Découverte de médicaments** : Les GNN peuvent être utilisés pour prédire la puissance de médicaments potentiels en modélisant graphiquement les interactions entre les atomes et les molécules.
- **Analyse des réseaux sociaux** : Les GNN peuvent être utilisés pour analyser et comprendre la structure et la dynamique des réseaux sociaux. Par exemple, ils peuvent prédire la diffusion d'informations et la formation de communautés.
- **Traitement automatique du langage naturel** : Les GNN peuvent analyser du texte en modélisant les relations entre les mots ou les phrases sous forme de graphes.
- **Systèmes de recommandation** : Les GNN peuvent être utilisés pour développer des systèmes de recommandation personnalisés qui suggèrent des articles aux utilisateurs en fonction de leur comportement et de leurs préférences.

Les GNN ont montré des résultats prometteurs dans divers domaines, et leurs applications continuent de s'étendre avec le développement de nouvelles architectures et algorithmes de GNN.

### II.5.5.3 Architectures des GNN

Il existe une grande diversité d'architectures de réseaux de neurones graphiques (GNN), chacune adaptée à des tâches spécifiques. Voici quelques exemples courants d'architectures utilisées en fonction des besoins.

#### II.5.5.3.1 Réseaux convolutifs graphiques (GCN)

GCN est un type spécifique de GNN qui utilise des opérations de convolution pour propager l'information entre les nœuds dans un graphe. Les GCN exploitent une agrégation locale des caractéristiques des nœuds voisins pour mettre à jour leurs représentations. Ils s'inspirent de l'opération de convolution utilisée en traitement d'image, adaptée au domaine des graphes. Les couches d'un GCN appliquent généralement une opération de convolution sur le graphe suivie de fonctions d'activation non linéaires. Les GCNs ont connu du succès dans diverses tâches, telles que la classification des nœuds où les nœuds sont étiquetés en fonction de leurs caractéristiques et de la structure du graphe [44].

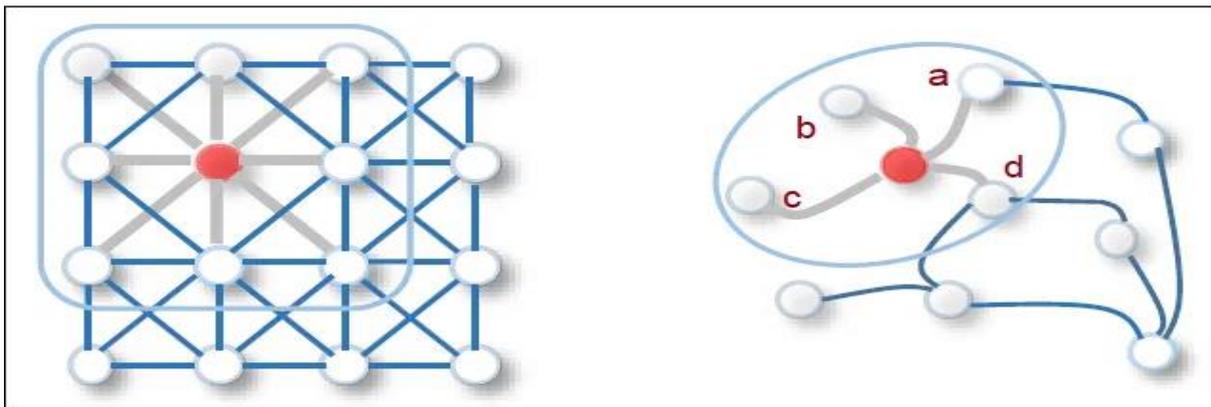
Les GCN utilisent principalement l'opération d'agrégation pour intégrer les informations des nœuds voisins  $w$  du nœud  $v$  dans le graphe afin d'aider à mettre à jour l'état caché de  $n_i$ . Différentes opérations d'agrégation spécifiques, telles que l'agrégation moyenne et l'agrégation maximale, peuvent être utilisées en fonction des scénarios spécifiques.

$$\widehat{h}_v^t = \text{pooling}(h_w^{(t-1)} | w \in N(v)) \quad \text{II.1}$$

La différence principale entre les GCN (Graph Convolutional Networks) et les CNN (Convolutional Neural Networks) réside dans les mécanismes de convolution utilisés[45].

Dans les CNN, chaque pixel peut être considéré comme un nœud, et un filtre (par exemple, un filtre 3\*3) est utilisé pour définir ses voisins. La convolution implique la combinaison pondérée des valeurs de pixels du nœud central et de ses 8 voisins, dans le cas d'une opération de convolution typique appliquée à une image.

Dans les GCN, les valeurs de chaque nœud et de ses voisins sont également prises en compte, sans égard à l'ordre dans lequel les voisins sont considérés. Contrairement aux CNN, la taille des ensembles de voisins peut varier pour chaque nœud, et il n'y a pas d'ordre prédéfini pour les voisins d'un nœud donné. Par exemple, dans une convolution GCN, les nœuds a, b, c et d n'ont pas de relation d'ordre spécifique. Cette flexibilité permet aux GCN de s'adapter à une variété de structures de graphes sans être contraints par une structure de voisinage fixe comme dans les CNN.



**Figure II.7** Convolution en 2D par rapport à convolution de graphe[45]

La différence illustrée dans la Figure II.7 a en fait inspiré le développement des GCN. Plus précisément, dans les GCN, nous pouvons agréger les informations des nœuds a, b, c et d pour créer un nouveau message vers le nœud rouge, en suivant la philosophie du passage de messages.

### II.5.5.3.2 Réseaux d'Attention Graphiques (GAT)

Les GAT utilisent l'attention pour pondérer l'importance des nœuds voisins lors de la propagation de l'information. L'opération de convolution graphique selon GAT est définie comme suit :

$$h_v^t = \text{Attention}(h_w^{(t-1)}, w \in N(v)) \quad \text{II.2}$$

Le module d'attention est un composant générique qui peut être configuré avec différentes opérations telles que l'auto-attention, l'attention multi-têtes, etc. Ce module d'attention effectue

---

essentiellement deux étapes : (1) le calcul des scores de pertinence pour chaque nœud dans le voisinage, et (2) la combinaison des états cachés des nœuds voisins en fonction de leurs scores de pertinence.

#### II.5.5.4 Limitations des GNN

Les GNN ont attiré l'attention en tant que modèles puissants pour apprendre des représentations et faire des prédictions sur des données structurées en graphe. Cependant, ils présentent également certaines limitations. Voici quelques-unes des limitations clés des GNN :

- **Complexité computationnelle** : Les GNN peuvent être très coûteux en termes de temps et de puissance de calcul, notamment pour des graphes de grande taille.
- **Risque de sur-apprentissage** : Les GNN peuvent être sujets au sur-apprentissage, particulièrement lorsqu'ils sont utilisés avec des graphes de petite taille.
- **Besoin de données de grande qualité** : Les GNN nécessitent des données de grande qualité pour fonctionner correctement. Des graphes mal structurés ou bruyants peuvent conduire à des résultats incohérents.

#### II.6. Recommandation sociale basée sur le deep learning

La technologie de l'apprentissage profond est devenue un axe de recherche de premier plan dans le domaine de l'intelligence artificielle et a été appliquée aux systèmes de recommandation. Contrairement aux modèles de recommandation traditionnels, l'apprentissage profond est capable de capturer efficacement les relations non linéaires et non triviales entre les utilisateurs et les items, permettant ainsi la codification d'abstractions plus complexes en tant que représentations des données dans les couches supérieures. Récemment, les systèmes de recommandation basés sur l'apprentissage profond ont suscité un intérêt considérable et une augmentation significative des publications de recherche. Différentes études ont été menées pour examiner ces systèmes [8],[10].

Certains travaux tentent d'appliquer la technique de l'autoencodeur uniquement sur la base des évaluations pour la recommandation [46], [47]. Dans [46], le modèle AutoRec est proposé selon le paradigme de l'autoencodeur en reconstruisant les évaluations à partir d'elles-mêmes, soit du point de vue des articles, soit des utilisateurs. Un autre modèle similaire, CFN, est proposé en injectant des informations auxiliaires dans l'autoencodeur et en adoptant un nouveau bruit pour les entrées clairsemées[47]. Leurs résultats démontrent que le modèle d'autoencodeur peut améliorer significativement les performances du système de recommandation par rapport aux méthodes précédentes [48], [49].

Les systèmes de recommandation introduisent souvent des informations supplémentaires pour améliorer encore la précision. La recommandation sociale est un exemple typique

d'introduction d'informations côté utilisateur dans la recommandation. Ces modèles supposent souvent que les préférences des utilisateurs sont similaires à celles de leurs voisins ou influencées par eux, et l'introduction d'informations supplémentaires peut mieux modéliser les utilisateurs. De plus, l'introduction d'informations sociales peut résoudre efficacement le problème du démarrage à froid.

Ces dernières années, la performance puissante des réseaux neuronaux de graphes a favorisé le développement de divers domaines liés à la structure des graphes. L'interaction dans le domaine de la recommandation peut être naturellement abstraite en une structure de graphe hétérogène, ce qui est très adapté en combinaison avec les réseaux neuronaux de graphes. La recommandation sociale combinée au réseau neuronal de graphes est souvent basée sur ces deux structures. Fan et al.[50] proposent un cadre de réseau neuronal pour la recommandation sociale sur ces deux graphes, qui utilise la structure du graphe pour agréger les caractéristiques du voisinage et apprend la représentation des caractéristiques des utilisateurs et des items. Mu et al. [51] proposent le Neural Social Recommendation Graph Attention Network (GAT-NSR), qui introduit un mécanisme d'attention multi-tête pour réaliser l'agrégation des caractéristiques entre deux graphes. De plus, en utilisant les caractéristiques de la propagation des graphes, Wu et al. proposent un modèle de recommandation sociale, SocialGCN [52], basé sur des réseaux de neurones convolutifs de graphes efficaces. Ce modèle introduit les GCN, qui visent à utiliser les GCN pour simuler le processus de diffusion des préférences des utilisateurs dans les réseaux sociaux, puis à apprendre une meilleure expression des caractéristiques. La littérature [53] propose un réseau d'attention à double graphe, qui distingue différentes attentions sous l'influence de l'homogénéité et de la diffusion sociale dans les deux domaines des utilisateurs et des projets, et considère pleinement les différentes utilités sociales entre utilisateurs et projets.

### **I.6.1 DiffNet++**

Le modèle neuronal de diffusion de l'influence pour la recommandation sociale (DiffNet++) est une méthode avancée de recommandation basée sur l'apprentissage profond qui utilise des réseaux neuronaux de diffusion pour intégrer efficacement les effets des réseaux sociaux dans le processus de recommandation. DiffNet++ améliore son prédécesseur DiffNet en capturant non seulement les interactions utilisateur-objet, mais aussi les influences sociales et les effets de diffusion dans les réseaux sociaux.

Wu et al. proposent l'architecture neuronale globale de DiffNet dans la figure II.8 En prenant une paire utilisateur-item  $\langle u, i \rangle$  comme entrée, cette architecture produit la probabilité  $\hat{r}_{ui}$  que l'utilisateur  $u$  aime l'item  $i$ . L'architecture neuronale globale de DiffNet se compose de quatre

parties principales : la couche d'incorporation, la couche de fusion, les couches de diffusion de l'influence couche par couche, et la couche de prédiction.

Plus précisément, en prenant des entrées connexes, la couche d'incorporation produit des incorporations libres des utilisateurs et des éléments. Pour chaque utilisateur (ou élément), la couche de fusion génère une incorporation hybride de l'utilisateur (ou de l'élément) en fusionnant à la fois l'incorporation libre d'un utilisateur (ou d'un élément) et les caractéristiques associées. L'incorporation d'utilisateur fusionnée est ensuite envoyée aux couches de diffusion de l'influence. Ces couches sont construites avec une structure couche par couche pour modéliser le processus de diffusion sociale récursif dans le réseau social, ce qui est l'idée clé de DiffNet. Après que le processus de diffusion de l'influence atteigne un état stable, la couche de sortie génère la préférence finale prédite [54].

Ils définissent chaque partie comme suit :

- **Embeddings** : les utilisateurs et les items sont représentés par des vecteurs d'embeddings latents. Ces embeddings sont initialisés et mis à jour au fur et à mesure que le modèle apprend.
- **Propagation d'Influence (Influence Diffusion)** : les informations d'influence sociale sont propagées à travers les couches du réseau en utilisant des mécanismes de diffusion. Chaque couche capte les influences des voisins dans le réseau social et met à jour les embeddings des utilisateurs en conséquence.
- **Interactions Utilisateur-item** : les interactions explicites (évaluations) et implicites (clics, vues) entre les utilisateurs et les items sont utilisées pour ajuster les embeddings et améliorer la précision des recommandations.
- **Fusion et Prédiction** : les représentations mises à jour des utilisateurs et des items sont fusionnées pour prédire les préférences des utilisateurs pour les items.

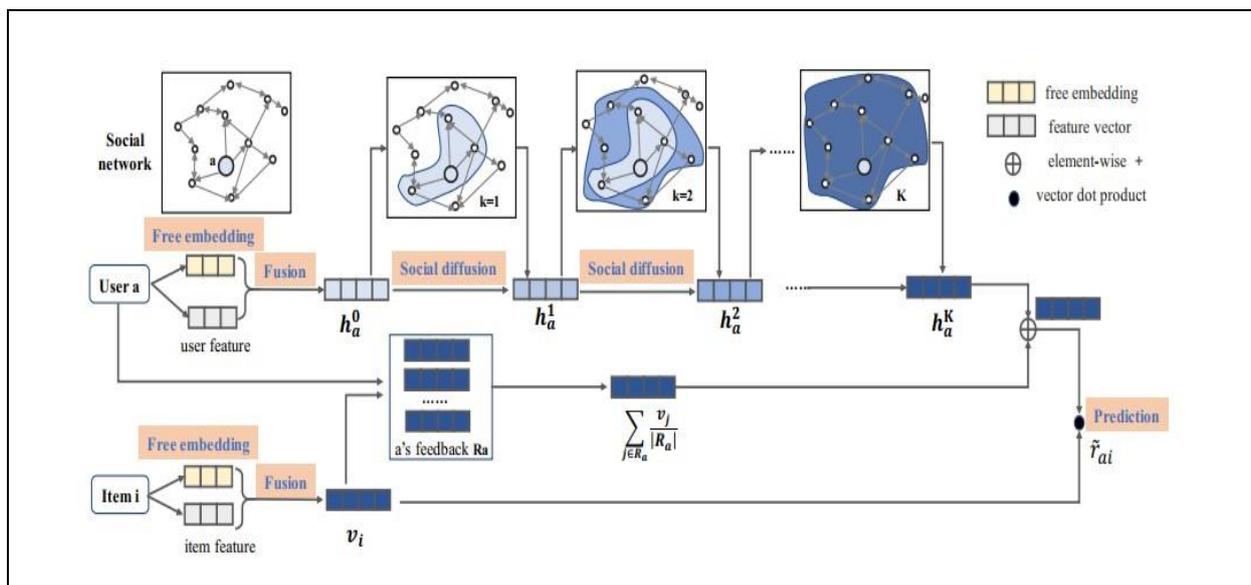


Figure II.8 Architecture globale de DiffNet++ [54].

**II.6.2 DSCF ( Deep Social Collaborative Filtering )**

Deep Social Collaborative Filtering (DSCF) est une approche avancée pour la recommandation sociale basée sur l'apprentissage profond qui combine les techniques de filtrage collaboratif avec les réseaux neuronaux profonds et les informations sociales. DSCF exploite les relations sociales pour améliorer les prédictions de préférence des utilisateurs, en intégrant ces informations dans un cadre de réseau neuronal profond.

Wenqi Yao et Dawei [55] proposent le cadre de filtrage collaboratif social profond DSCF pour exploiter les réseaux sociaux dans les recommandations. Pour cela, nous devons (a) prendre en compte les informations non seulement des voisins directs mais aussi des voisins éloignés ; (b) sélectionner les informations pertinentes de chaque voisin pour recommander un item spécifique ; et (c) capturer les opinions des voisins sur les items lors de la modélisation des interactions utilisateur-item. Une vue d'ensemble du cadre proposé est présentée dans la Figure II.9. Il se compose de quatre couches : la couche de marche aléatoire conçue pour relever les défis (a) et (b), la couche d'incorporation conçue pour résoudre le défi (c), la couche d'apprentissage de séquence et la couche de sortie. Ensuite, nous donnerons des détails sur chaque couche.

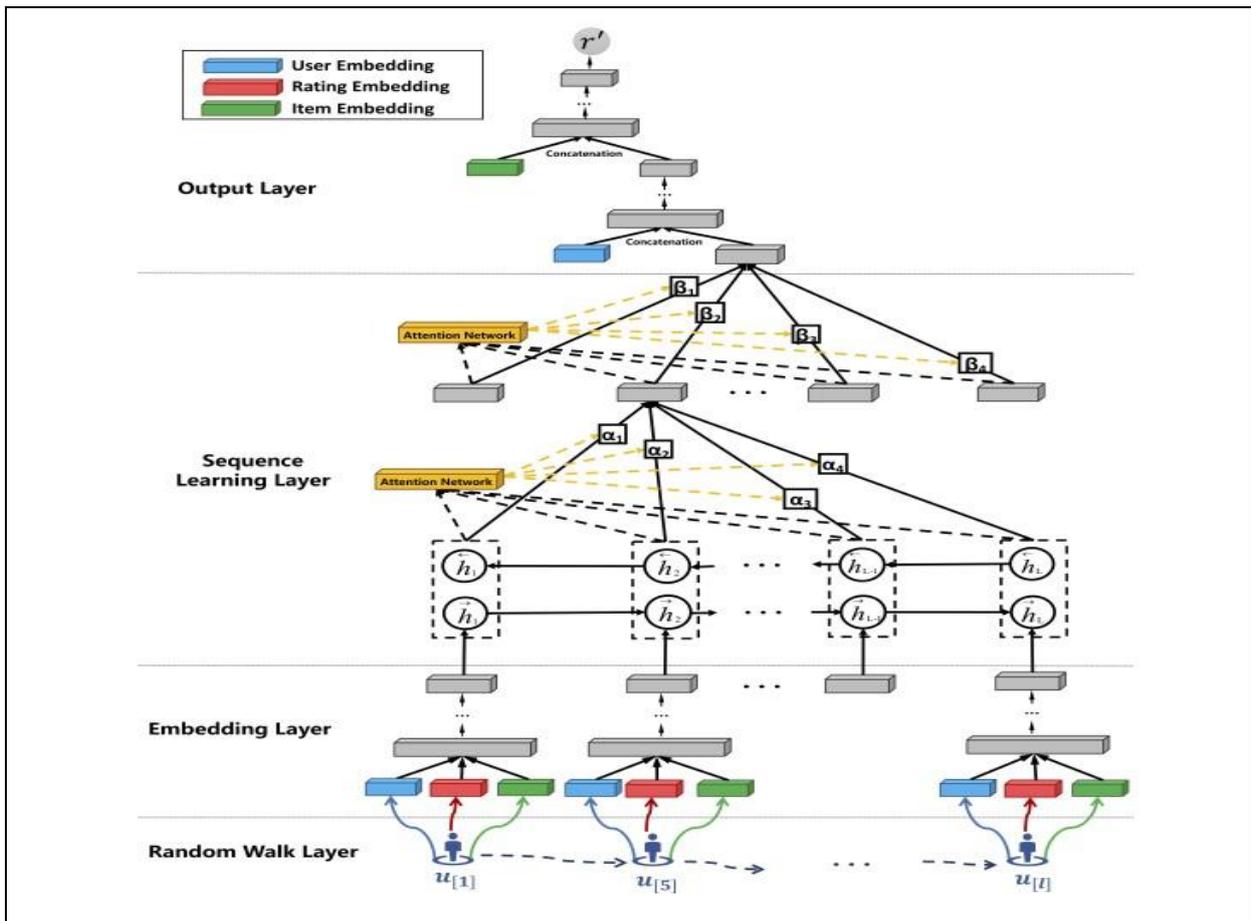


Figure II.9 Architecture globale de DSCF

L'architecture de DSCF se compose des éléments suivants [55] :

**Couche de marche aléatoire (Random Walk) :** Dans le domaine de la recommandation sociale, la couche Random Walk (RWL) est une technique innovante pour générer des séquences sociales conscientes des objets (items). Cette méthode exploite les structures de graphe pour capturer des informations pertinentes sur les interactions utilisateur-objet et les influences sociales. Une marche aléatoire est un processus stochastique qui parcourt les nœuds d'un graphe de manière aléatoire. En partant d'un nœud initial, à chaque étape, la marche se déplace vers un voisin choisi au hasard.

**Couche d'embedding :** Les utilisateurs et les items sont représentés par des vecteurs d'embeddings, qui sont des représentations latentes apprises par le réseau neuronal. Ces embeddings sont initialisés puis affinés pendant l'entraînement pour mieux représenter les préférences des utilisateurs et les caractéristiques des objets.

**Couche d'apprentissage de séquences :** Cette composante est cruciale dans les modèles de recommandation basés sur les interactions utilisateur-item et les influences sociales. Elle transforme les séquences sociales conscientes des items générés par des techniques comme la marche aléatoire en représentations latentes riches, capturant ainsi des motifs complexes et non linéaires dans les données.

**Couche de sortie (Output layer) :** Elle est essentielle pour prédire les notes ou scores des objets pour les utilisateurs. Cette couche transforme les représentations latentes apprises par les couches précédentes en une prédiction de note.

## II.7 Conclusion

Ce chapitre avait pour objectif d'approfondir l'étude des principaux algorithmes de Deep Learning appliqués dans le domaine de la recommandation sociale. Nous avons débuté en établissant les bases théoriques du Deep Learning, en détaillant des concepts clés tels que les réseaux de neurones artificiels, l'apprentissage supervisé et non supervisé, ainsi que les mécanismes fondamentaux des algorithmes de Deep Learning. Ensuite, nous avons exploré les systèmes de recommandation sociale qui reposent sur le Deep Learning.

## ***Chapitre III***

### Recommandation Sociale Basée sur les Réseaux de Neurones Graphiques

### III.1 Introduction

En raison de l'importance de la valeur applicative des systèmes de recommandation, il y a toujours eu des travaux émergents dans ce domaine. Des recommandations de haute qualité peuvent aider les utilisateurs à découvrir rapidement du contenu intéressant et à augmenter les ventes de produits. Ces dernières années, avec l'essor des réseaux neuronaux graphiques, les systèmes de recommandation basés sur ces derniers ont reçu une attention considérable[56]. Cependant, le réseau d'interaction utilisateur-item traditionnel présente le problème de la rareté des données [57], ce qui affecte les performances du système de recommandation. La recommandation sociale[58] améliore la représentation de l'utilisateur en introduisant des informations utilisateur-utilisateur supplémentaires et renforce davantage la représentation de l'item grâce à l'agrégation d'informations du réseau neuronal graphique. De plus, le système de recommandation souffre également du problème du démarrage à froid [59], c'est-à-dire que la quantité d'informations sur les nouveaux utilisateurs est trop faible pour permettre une recommandation personnalisée. La recommandation sociale attribue un vecteur de préférence initial aux nouveaux utilisateurs grâce aux informations utilisateur-utilisateur. Ce vecteur est utilisé pour recommander des items adaptés aux nouveaux utilisateurs. Dans ce chapitre, nous présentons les réseaux de neurones graphiques (GNN) dans le cadre de la recommandation sociale. Nous expliquons les raisons d'utiliser les GNN dans ces systèmes, introduisons le modèle GraphRec, passons en revue les outils de développement utilisés, précisons les métriques d'évaluation et, enfin, présentons les résultats des différentes expériences réalisées sur le jeu de données FilmTrust.

### III.2 Réseau de neurones graphiques dans la recommandation sociale

Dans le contexte de la recommandation sociale, les utilisateurs acquièrent des informations à partir du réseau social ainsi que du réseau d'interaction utilisateur-item. Selon différentes méthodes d'intégration, le modèle de recommandation sociale basé sur les réseaux neuronaux graphiques peut être catégorisé en deux types : le modèle de graphe unifié et le modèle de graphe séparé [60].

#### III.2.1 Modèle de graphe unifié

Le modèle de graphe unifié combine le réseau social avec le réseau d'interaction utilisateur-item et extrait directement les informations conjointes des deux réseaux à travers le réseau neuronal graphique. Comme illustré dans la figure III.1, dans le graphe unifié, le réseau social et le réseau d'interaction utilisateur-item partagent la même représentation de l'utilisateur, garantissant ainsi efficacement la cohérence des mises à jour d'informations dans les deux

réseaux. En tenant compte des différences d'information entre les utilisateurs et les items, le filtrage collaboratif de graphes neuronaux [61] a conçu différentes méthodes d'agrégation pour les utilisateurs voisins et les items voisins. Cependant, la conception artificielle ne peut pas toujours s'adapter efficacement à l'environnement de réseau complexe. Diffnet++ [62] et SEFrame [63] ont utilisé un mécanisme d'attention pour capturer de manière adaptative l'interaction d'information entre les utilisateurs voisins, entre les items voisins et entre les utilisateurs voisins et les items voisins. Cependant, le réseau est souvent clairsemé, avec un grand nombre de connexions de bord inconnues, ce qui entraîne un biais d'information, en particulier après l'utilisation de l'attention pour agréger fortement les voisins. Par conséquent, certains modèles de réseau social ont utilisé la similarité des utilisateurs [64], des réseaux génératifs antagonistes [65] et d'autres méthodes pour compléter les relations du réseau. Les réseaux sociaux et les réseaux d'interaction utilisateur-item ont chacun leurs propres informations uniques. Le modèle de graphe unifié souffre d'un manque de représentations séparées des deux réseaux, ce qui affecte dans une certaine mesure la performance de la représentation.

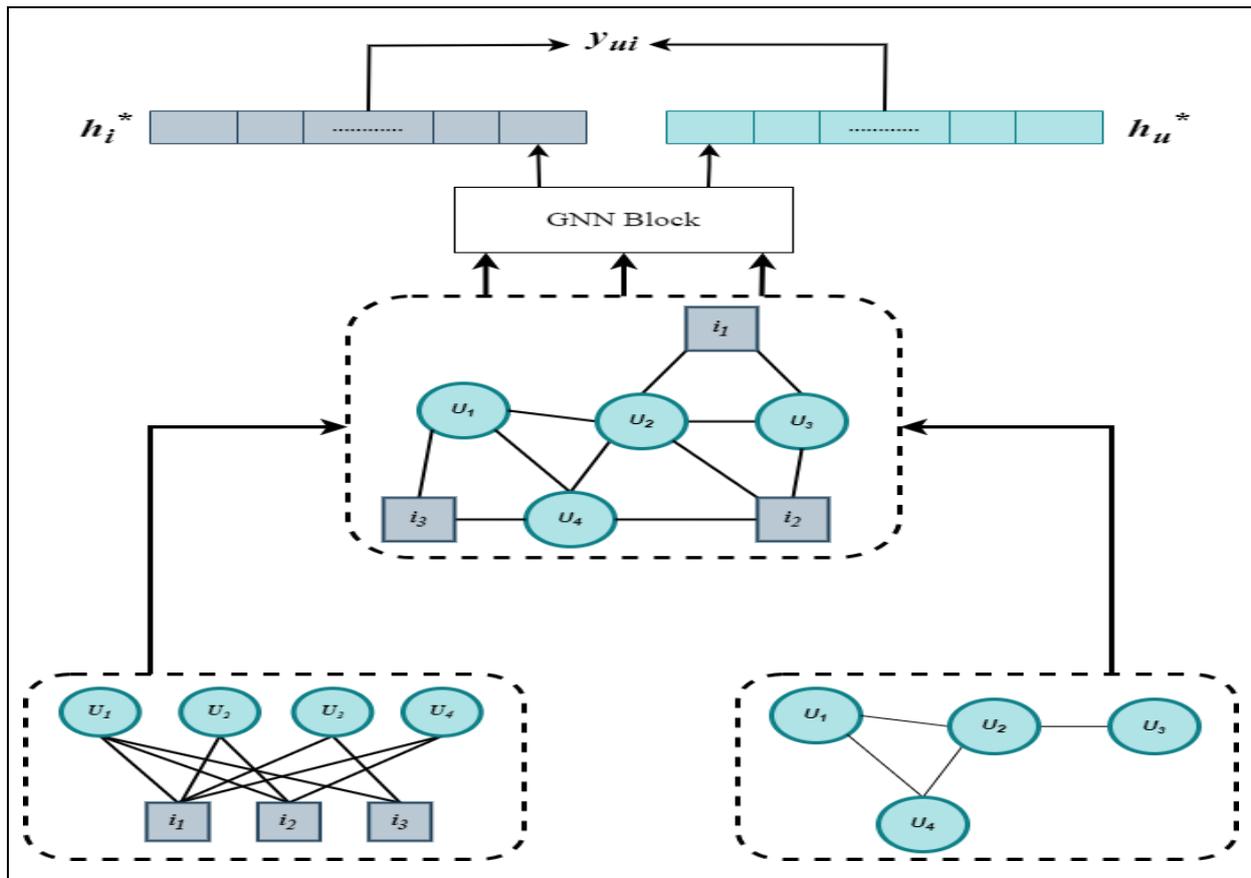


Figure III.1 Architecture du modèle de graphe unifié

### III.2.2 Modèle de graphe séparé

Le modèle de graphe séparé gère les informations du réseau social et du réseau d'interaction utilisateur-item séparément, et extrait les informations des deux réseaux à travers différents réseaux neuronaux graphiques. Par conséquent, le choix des réseaux neuronaux graphiques est plus flexible sous le modèle de graphe séparé. Contrairement au cadre de recommandation sociale basé sur les réseaux neuronaux graphiques (GNN-SoR) [66] et à SocialLGN [67] qui ont utilisé un modèle classique de réseau neuronal graphique, AGREE [68] a regroupé les nœuds et a utilisé l'attention pour chaque groupe afin de capturer les informations locales. DANSER [69] a ensuite proposé une double attention pour capturer l'interaction entre les deux réseaux neuronaux graphiques. Les représentations des utilisateurs des réseaux sociaux et des réseaux d'interaction utilisateur-item obtenues à partir des modèles de graphe séparés ci-dessus sont capables de capturer efficacement les différences entre les deux réseaux. Comme illustré dans la figure III.2, dans le graphe séparé, les représentations des utilisateurs des deux réseaux doivent être fusionnées. Diffnet [54] a simplement additionné les deux types de représentations d'utilisateurs pour réduire considérablement la complexité computationnelle. Cependant, la méthode doit garantir que la quantité d'informations contenues dans les deux types de représentations d'utilisateurs ne peut pas être significativement différente. GraphRec [50] a utilisé un réseau neuronal multi-couches pour explorer davantage les informations potentielles des deux types de représentations d'utilisateurs. Cela peut améliorer la performance des représentations, mais peut entraîner un surajustement.

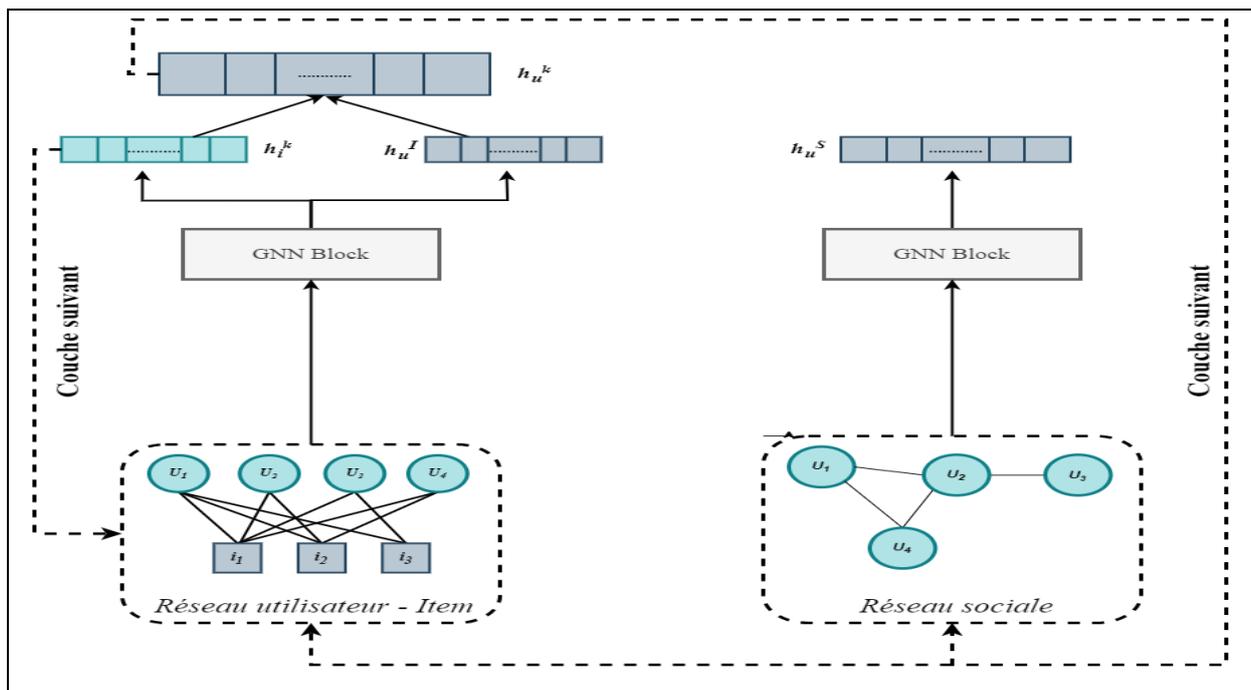


Figure III.2 Architecture du modèle de graphe séparé

### Quelles sont les raisons d'appliquer les réseaux de neurones graphiques dans la recommandation sociale ?

Ces dernières années, nous avons assisté à des développements pionniers dans les réseaux de neurones graphiques (GNNs) qui peuvent naturellement intégrer des informations de nœuds et la structure topologique. Il a été démontré qu'ils sont puissants pour l'apprentissage sur des données de graphes. Les GNNs offrent un grand potentiel pour faire progresser les recommandations sociales, car les données dans les systèmes de recommandation sociale peuvent être représentées en utilisant deux graphes : un graphe utilisateur-utilisateur indiquant les relations entre les utilisateurs, et un graphe utilisateur-item indiquant les interactions entre les utilisateurs et les items, comme le montre la Figure III.2. Les utilisateurs sont simultanément impliqués dans les deux graphes, ce qui leur permet de faire le lien entre eux. L'apprentissage des représentations des items et des utilisateurs est la clé pour construire des systèmes de recommandation sociale. Les GNNs peuvent aider à capturer les informations nécessaires à la recommandation sous leur forme naturelle, le graphe.

Il existe certains défis dans la construction de systèmes de recommandation sociale utilisant les GNNs, notamment :

- Le graphe utilisateur-item encode à la fois les interactions et les opinions associées.
- Les relations sociales ont des forces hétérogènes.
- Les utilisateurs sont impliqués dans deux graphes (par exemple, le graphe social utilisateur-utilisateur et le graphe utilisateur-item).

Pour relever ces défis simultanément, les auteurs de [50] ont proposé un nouveau cadre de réseau neuronal de graphes (GraphRec) pour les recommandations sociales. Certaines des contributions majeures de ce cadre sont résumées comme suit :

- Il peut modéliser de manière cohérente les données graphiques dans les recommandations sociales.
- Il fournit une approche raisonnée pour capturer conjointement les interactions et les opinions dans le graphe utilisateur-item.
- Il introduit une méthode permettant de considérer mathématiquement les forces hétérogènes des relations sociales.

### III.3 Présentation du modèle GraphRec

Soient  $U = \{u_1, u_2, \dots, u_n\}$  et  $V = \{v_1, v_2, \dots, v_m\}$  les ensembles d'utilisateurs et d'items respectivement, où  $n$  est le nombre d'utilisateurs et  $m$  est nombre d'items. Considérons également  $O = \{ \langle u_i, v_j \rangle \mid r_{ij} \neq 0 \}$ , qui est l'ensemble des évaluations connues, et  $T = \{ \langle u_i, v_j \rangle \mid r_{ij} = 0 \}$ , l'ensemble des évaluations inconnues. Le tableau ci-dessous résume toutes les notations qui seront utilisées par la suite.

Symboles	Définitions et descriptions
$r_{ij}$	Valeur de ratings de l'item $v_j$ par l'utilisateur $u_i$
$q_j$	Embedding de l'item $v_j$
$p_i$	Embedding de l'utilisateur $u_i$
$e_r$	Matrice des facteurs latents pour les métadonnées des items
$d$	la longueur du vecteur d'intégration
$C(i)$	L'ensemble d'items avec lesquels l'utilisateur $u_i$ a interagi
$N(i)$	l'ensemble des amis avec lesquels l'utilisateur $u_i$ est directement connecté
$B(j)$	l'ensemble des utilisateurs qui ont interagi avec l'item $v_j$
$h_i^I$	le facteur latent de l'utilisateur dans l'espace d'item de l'ensemble d'item $C(i)$ de l'utilisateur $u_i$
$h_i^S$	le facteur latent de l'utilisateur de l'espace social de l'ensemble d'amis $N(i)$ de l'utilisateur $u_i$
$h_i$	le facteur latent de l'utilisateur de l'utilisateur $u_i$ , combinant l'espace d'éléments $h_i^I$ et l'espace social $h_i^S$
$x_{ia}$	La représentation interactive de l'item $v_j$ pour l'utilisateur $u_i$
$f_{jt}$	La représentation interactive de l'utilisateur $u_i$ pour l'item $v_j$
$z_j$	le facteur latent de item de l'item $v_j$
$\alpha_{ia}$	L'attention de l'item $v_a$ dans la contribution à $h_i^I$
$\beta_{io}$	L'attention sociale de l'utilisateur voisin $u_o$ en contribuant à $h_i^S$
$\mu_{jt}$	L'attention de l'utilisateur $u_t$ dans contribuer à $z_j$
$r'_{ij}$	La valeur de poids prévue de l'item $v_j$ par l'utilisateur $u_i$
$\oplus$	L'opérateur de concaténation de deux vecteurs
$T$	Le graphe social utilisateur-utilisateur
$R$	La matrice des item-utilisateur (user-item graph)
$W.b$	Le rating et les biais dans le réseau neuronal

Tableau III.1 Notations utilisées[70]

La Figure III.3 , représentant l'architecture du modèle GraphRec, ce dernier se compose de trois composants : la modélisation de l'utilisateur, la modélisation de l'item et la prédiction des notations.

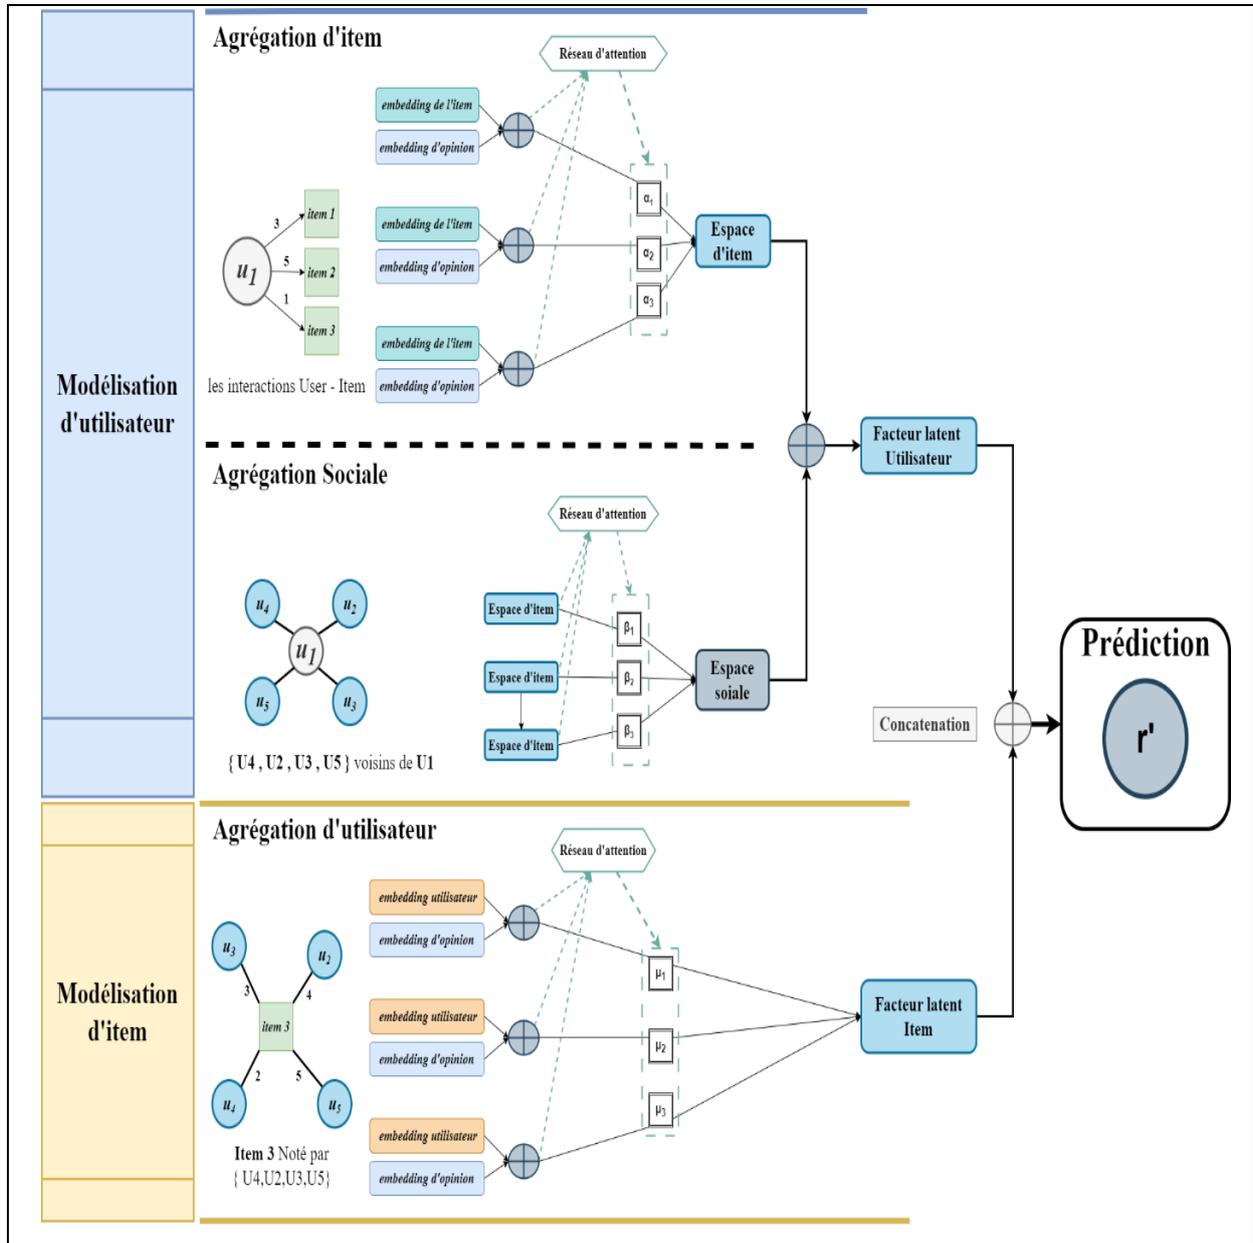


Figure III.3 Architecture du modèle GraphRec

### III.3.1 Modélisation de l'utilisateur

Le premier composant est la modélisation de l'utilisateur, qui consiste à apprendre les facteurs latents de l'utilisateur, désignés par  $h_i \in \mathbb{R}^d$  pour l'utilisateur  $u_i$ . Le modèle utilise deux types d'agrégation pour apprendre les facteurs à partir de deux graphiques (utilisateur-utilisateur et utilisateur-item)[70], qui sont :

- **Agrégation d'item** : le facteur latent de l'utilisateur dans l'espace d'item  $h_i^I \in \mathbb{R}^d$ , pour l'utilisateur  $u_i$ , est appris à partir du graphe utilisateur-item, en considérant les items avec lesquels l'utilisateur  $u_i$  a interagi, donnés par  $C(i)$  et les opinions des utilisateurs associés sur ces items (voir figure ci-dessous).

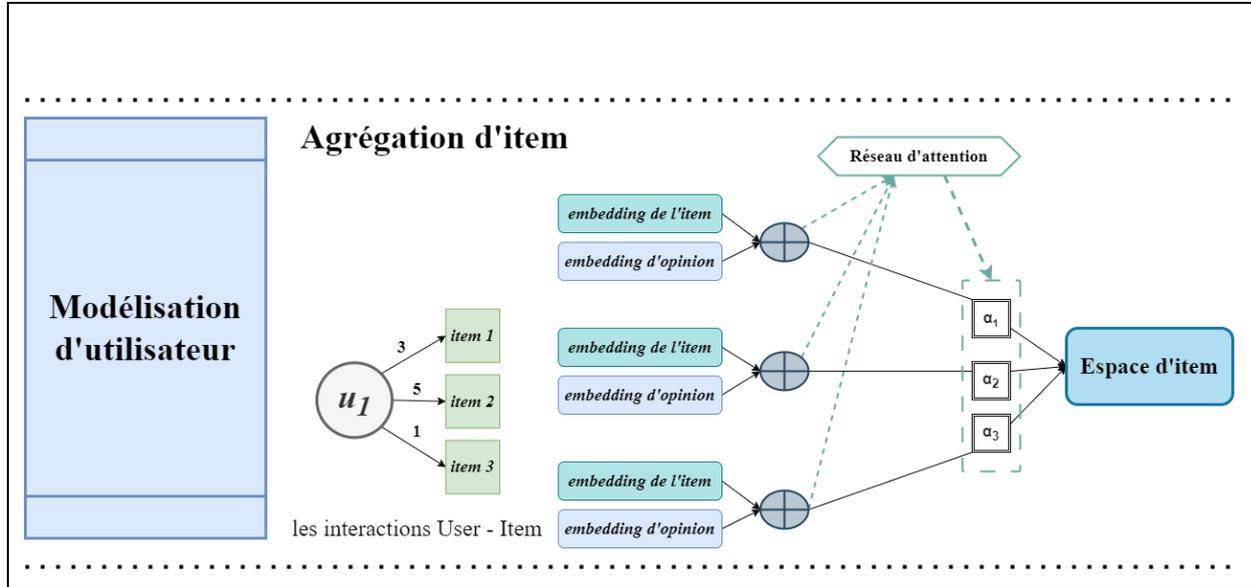


Figure III.4 Agrégation d'items pour la modélisation d'utilisateur à partir du graphe utilisateur-item

Pour un utilisateur  $u_i$  dans le graphe utilisateur-item :

- Pour chacun des items voisins  $v_a \in C(i)$  de l'utilisateur  $u_i$ , le message  $x_{ia}$  ou la représentation de l'interaction tenant compte de l'opinion est calculé en concaténant l'embedding de l'item  $q_a$  et l'embedding d'opinion associé  $e_r$  que l'utilisateur a donné à cet item, puis en le passant à travers un MLP. Cela est donné par :

$$x_{ia} = g_v([q_a \oplus e_r]) \tag{III.1}$$

Où  $\oplus$  désigne l'opération de concaténation entre deux vecteurs.

- La prochaine étape consiste à agréger les messages pour chaque utilisateur  $u_i$  à partir de ses voisins d'items dans  $C(i)$ . Cela est donné par :

$$h_i^I = \sigma(W \cdot Aggre_{item}(\{x_{ia}, \forall a \in C(i)\}) + b) \tag{III.2}$$

Où  $Aggre_{item}$  est la fonction d'agrégation des items,  $\sigma$  désigne une fonction d'activation non linéaire, et  $W$  et  $b$  sont les poids et le biais d'un réseau de neurones.

- Nous ne pouvons pas utiliser l'agrégation moyenne (poids uniformes) car l'influence des interactions entre les items sur les utilisateurs peut varier. Au lieu de cela, nous devrions permettre aux interactions de contribuer différemment au facteur latent d'un utilisateur en

attribuant à chaque interaction un poids. Ces poids sont modélisés en utilisant un réseau d'attention (voir figure III.4). L'attention aux items  $\alpha_{ia}$  est paramétrée avec un MLP à deux couches, qui prend en entrée le message  $x_{ia}$  et l'incorporation de l'utilisateur  $p_i$ . En bref, l'agrégation des items est donnée par :

$$h_i^l = \sigma( W . \{ \sum_{a \in C(i)} \alpha_{ia} x_{ia} \} + b ) \tag{III.3}$$

$$\alpha_{ia}^* = w_2^T . \sigma( W_1 . [ x_{ia} \oplus p_i ] + b_1 ) + b_2 \tag{III.4}$$

$$\alpha_{ia} = \frac{\exp(\alpha_{ia}^*)}{\sum_{a \in C(i)} \exp(\alpha_{ia}^*)} \tag{III.5}$$

- **Agrégation sociale :** Facteur latent de l'utilisateur dans l'espace social  $h_i^S \in \mathbb{R}^d$  est appris à partir du graphe social utilisateur-utilisateur, qui est calculé en agrégeant les facteurs latents des utilisateurs dans l'espace des items des utilisateurs voisins du graphe social[70].

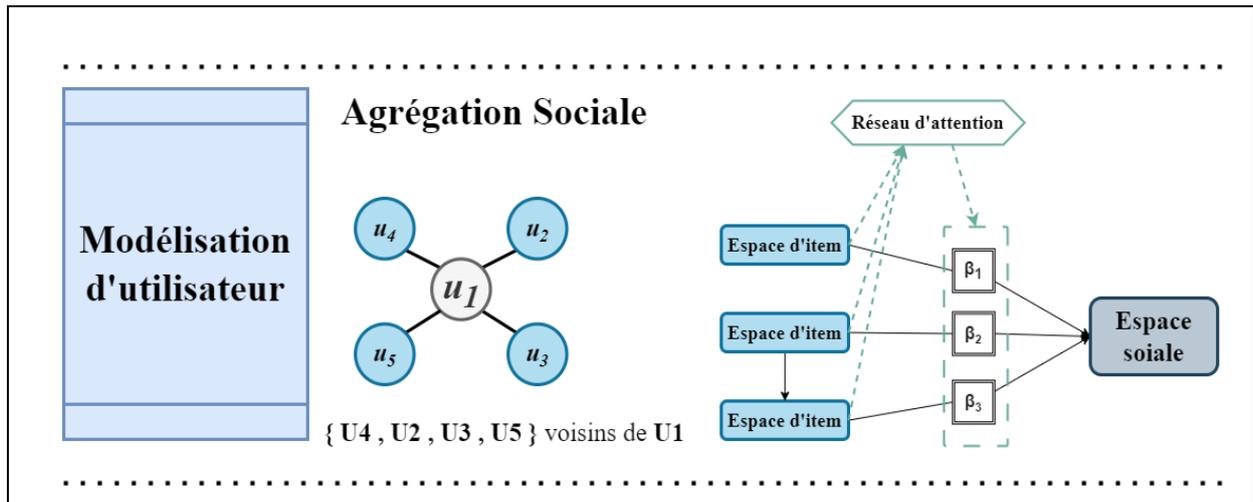


Figure III.5 Agrégation sociale pour la modélisation d'utilisateurs à partir du graphe social

Pour un utilisateur  $u_i$  dans le graphe social utilisateur-utilisateur,

- Le message entre l'utilisateur  $u_i$  et son voisin utilisateur  $u_o$  dans  $N(i)$  est considéré comme le vecteur latent de l'utilisateur dans l'espace des items de l'utilisateur.
- L'étape suivante consiste à agréger les messages pour chaque utilisateur  $u_i$  de ses voisins utilisateurs  $N(i)$ . Cela est donné par,

$$h_i^S = \sigma( W . Aggre_{neighbors}(\{h_o^l, \forall o \in N(i)\}) + b ) \tag{III.6}$$

iii) Dans le réseau social, nous devons prendre en compte les forces hétérogènes des relations sociales. Ainsi, une agrégation pondérée peut être utilisée à la place de l'agrégation moyenne (poids uniformes). Les poids peuvent être modélisés en utilisant un réseau d'attention (voir figure III.5). L'attention sociale  $\beta_{io}$  entre l'utilisateur  $u_i$  et  $u_o$  est paramétrée par un MLP à deux couches, qui prend le message  $h_o^I$  et l'embedding de l'utilisateur cible  $p_i$  comme entrée. En incorporant ces éléments, l'agrégation sociale est donnée comme suit :

$$h_i^S = \sigma(W \cdot \{\sum_{o \in N(i)} \beta_{io} h_o^I\} + b) \tag{III.7}$$

$$\beta_{io}^* = w_2^T \cdot \sigma(W_1 \cdot [h_o^I \oplus p_i] + b_1) + b_2 \tag{III.8}$$

$$\beta_{io}^* = \frac{\exp(\beta_{io}^*)}{\sum_{a \in C(i)} \exp(\beta_{io}^*)} \tag{III.9}$$

- Enfin, nous concaténons le facteur latent de l'utilisateur dans l'espace des items  $h_i^I$  et le facteur latent de l'utilisateur dans l'espace social  $h_i^S$  puis nous introduisons ce facteur concaténé dans un MLP (réseau multicouche) pour obtenir le facteur latent final de l'utilisateur

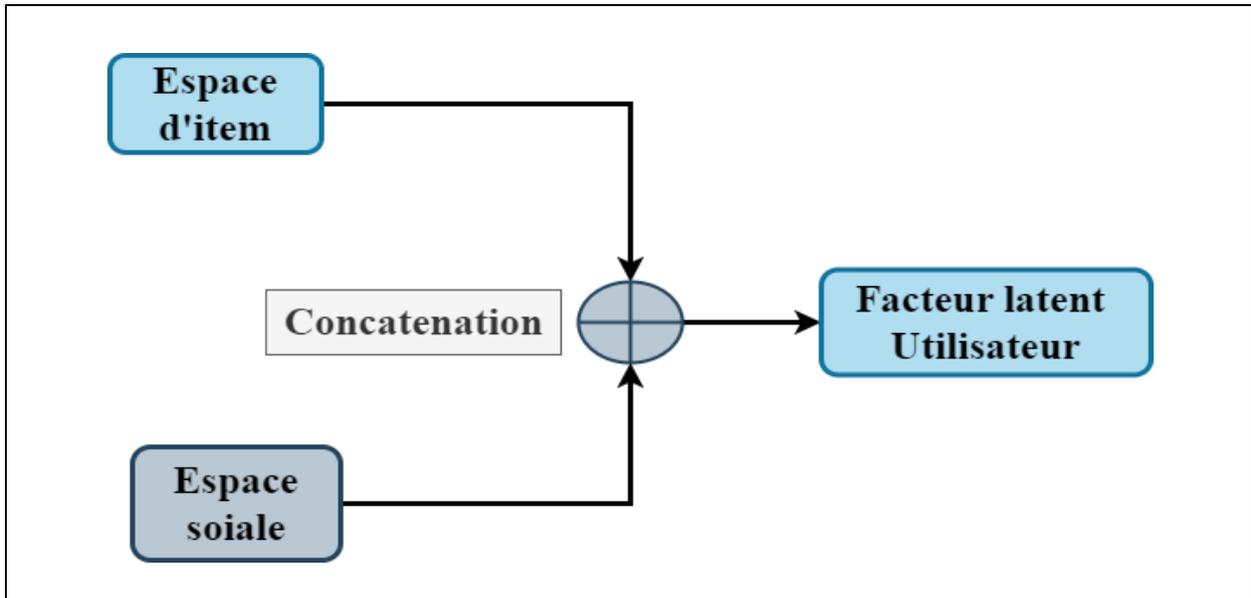


Figure III.6 Facteur latent final de l'utilisateur

$$c_1 = [h_i^I \oplus h_i^S] \tag{III.10}$$

$$c_2 = \sigma(W_2 \cdot c_1 + b_2) \tag{III.11}$$

$$h_i = \sigma(W_l \cdot c_{l-1} + b_l) \tag{III.12}$$

### III.3.2 Modélisation de l'item

- Ce module (partie en bas de la figure III.3) vise à apprendre le facteur latent de l'item, noté  $z_j$  pour l'item  $v_j$  par agrégation des utilisateurs.
- Les items sont associés au graphe utilisateur-item, qui contient à la fois les interactions et les opinions des utilisateurs. Ceux-ci doivent être capturés conjointement pour apprendre davantage les facteurs latents des items.
- Nous pouvons utiliser une méthode similaire à celle de l'apprentissage des facteurs latents des utilisateurs dans l'espace des items via l'agrégation des items.

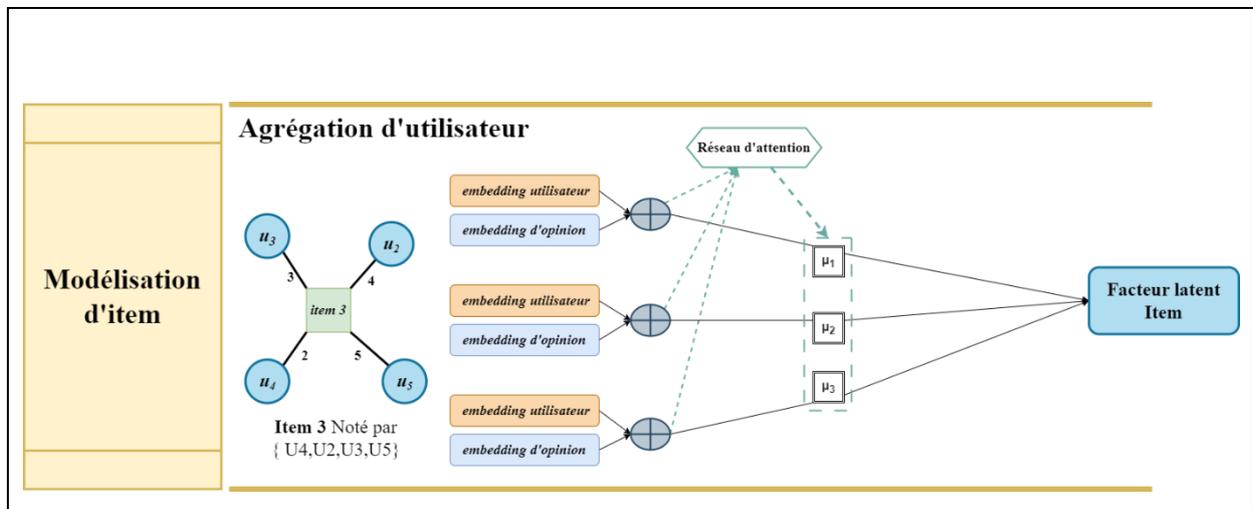


Figure III.7 Modélisation d'un item à partir du graphe utilisateur-item

Pour un item  $v_j$  dans le graphe utilisateur-item,

- Pour chacun des voisins utilisateurs  $u_t \in B(j)$  de l'item , le message  $f_{jt}$  ou l'interaction prenant en compte l'opinion est obtenu à partir de l'embedding utilisateur de base  $p_t$  et de l'embedding d'opinion  $e_r$  via un MLP. Ceci est donné par,

$$f_{jt} = g_u([p_t \oplus e_r]) \tag{III.13}$$

- Pour l'agrégation pondérée, les auteurs utilisent un mécanisme d'attention pour capturer l'influence hétérogène des interactions utilisateur-item sur l'apprentissage du facteur *latent* de l'item. L'attention utilisateur  $\mu_{jt}$  des utilisateurs  $j$  et  $t$  est modélisée avec un réseau d'attention neuronale à deux couches, prenant le message  $f_{jt}$  et l'embedding de l'item  $q_j$

comme entrée. Enfin, en incorporant ces éléments, le facteur latent de l'item  $\mathbf{z}_j$  est donné par,

$$z_j = \sigma(W \cdot \{\sum_{t \in B(j)} \mu_{jt} f_{jt}\} + b) \quad (\text{III.14})$$

$$\mu_{jt}^* = w_2^T \cdot \sigma(W_1 \cdot [f_{jt} \oplus q_j] + b_1) + b_2 \quad (\text{III.15})$$

$$\mu_{jt} = \frac{\exp(\mu_{jt}^*)}{\sum_{t \in B(j)} \exp(\mu_{jt}^*)} \quad (\text{III.16})$$

### III.3.3 Prédiction

Enfin, définissons la tâche de recommandation qui sera utilisée pour apprendre les paramètres du modèle. Les auteurs utilisent la prédiction de notation comme tâche de recommandation.

- La prédiction de notation  $r'_{ij}$  entre l'utilisateur  $u_i$  et l'item  $v_j$  peut être obtenue en concaténant d'abord le facteur latent de l'utilisateur  $\mathbf{h}_i$  et le facteur latent de l'item  $\mathbf{z}_j$ , puis en faisant passer ce facteur concaténé à travers un MLP multicouche comme indiqué ci-dessous :

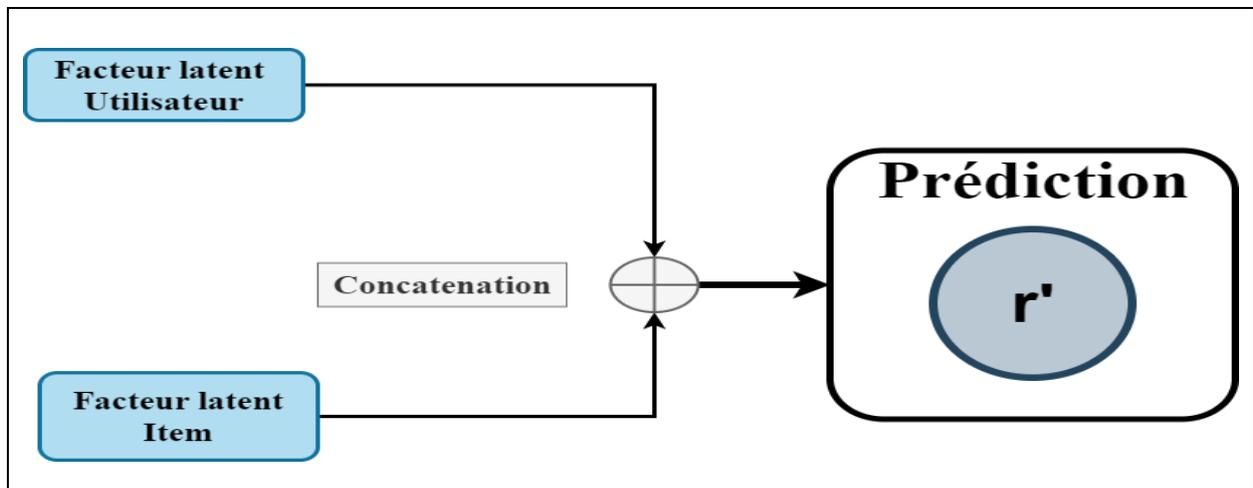


Figure III.8 Calcul de la prédiction de notation  $r'_{ij}$

$$g_1 = [h_i \oplus z_j] \quad (\text{III.17})$$

$$g_2 = \sigma(W_2 \cdot g_1 + b_2) \quad (\text{III.18})$$

$$g_{l-1} = \sigma(W_l \cdot g_{l-1} + b_l) \quad (\text{III.19})$$

$$r'_{ij} = w^T \cdot g_{l-1} \quad (\text{III.20})$$

### III.4 Expérimentations

#### III.4.1 Jeux de données

Nous menons des expériences sur l'ensemble de données public nommé Filmtrust pour évaluer le modèle utilisé. L'ensemble de données Filmtrust provient d'un petit jeu de données de notation de films du site Web FilmTrust. Cet ensemble de données fournit des informations sur les notations et les relations sociales des utilisateurs. Le niveau de notation dans l'ensemble de données varie de 1 à 5. Lors de l'incorporation des informations de notation, chaque niveau de notation est initialement représenté par un vecteur d'incorporation aléatoire.

Dataset	FilmTrust
Nombre d'utilisateurs	1508
Nombre d'items	2071
Nombre d'évaluations Utilisateurs-Items	35497
Échelle des évaluations	0.5 – 4
Densité	1.14%
Nombre de relations de confiance entre utilisateurs	1853

**Tableau III.2** Informations statistiques sur l'ensemble de données FilmTrust[47].

Selon le tableau III.2, nous expliquerons chaque caractéristique couverte dans cet ensemble de données :

**Utilisateurs** : L'ensemble de données comprend des informations sur les utilisateurs qui ont fourni des évaluations pour des films. Chaque utilisateur est généralement représenté par un identifiant unique.

**Items (Films)** : Il contient des détails sur les films que les utilisateurs ont évalués. Ces informations peuvent inclure le titre du film, le genre, l'année de sortie et éventuellement

d'autres attributs.

**Évaluations :** La partie principale de l'ensemble de données consiste en des évaluations d'utilisateurs pour des films. Les utilisateurs notent les films sur une échelle donnée, telle qu'une échelle numérique ou un ensemble de catégories prédéfinies.

**Réseau de confiance :** Une des caractéristiques distinctives de l'ensemble de données FilmTrust est l'inclusion d'un réseau de confiance entre les utilisateurs. Ce réseau de confiance représente les relations entre les utilisateurs en fonction de leur confiance ou de leur méfiance à l'égard des opinions des autres. Par exemple, si l'utilisateur A fait confiance aux opinions de l'utilisateur B, il peut y avoir un lien dirigé de A vers B dans le réseau de confiance.

Les chercheurs utilisent souvent l'ensemble de données FilmTrust pour évaluer les algorithmes de recommandation, en particulier ceux qui incorporent des informations sur le réseau social ou les relations de confiance entre les utilisateurs. Il fournit un scénario réaliste pour tester les algorithmes de filtrage collaboratif et étudier l'impact de l'influence sociale sur la précision des recommandations.

#### III.4.2 Nettoyage de l'ensembles de données FilmTrust

Le nettoyage du dataset FilmTrust est une étape essentielle pour garantir la qualité et la précision des modèles de recommandation. Tout d'abord, il est crucial de supprimer les doublons en identifiant et en éliminant les entrées dupliquées, afin d'éviter les biais dans les résultats. Chaque utilisateur et chaque film doivent avoir un identifiant unique pour assurer la cohérence des données. Ensuite, la gestion des valeurs manquantes est primordiale : les évaluations manquantes doivent être identifiées et soit imputées, soit supprimées, de même que les informations manquantes concernant les utilisateurs ou les films. La normalisation des évaluations est également nécessaire pour s'assurer que toutes les évaluations sont sur une même échelle, par exemple de 1 à 5.

En outre, il est important de filtrer les utilisateurs et les films pour éliminer ceux ayant très peu d'évaluations, car ils n'apportent pas suffisamment d'informations pertinentes pour le modèle. Le nettoyage des données de confiance inclut la vérification et la suppression des relations de confiance invalides ou non réciproques, ainsi que la normalisation des poids de confiance, si ceux-ci sont utilisés, afin qu'ils soient dans une plage cohérente et logique. Enfin, la conversion des formats de données doit être effectuée pour assurer que toutes les données sont dans un format cohérent et utilisable pour l'analyse et la modélisation.

### III.4.3 Métriques d'évaluation

La qualité d'un algorithme de recommandation peut être évaluée à l'aide de différents types de mesures. Des métriques de précision statistique évaluent la précision d'une technique de filtrage en comparant directement les notes prédites aux notes réelles de l'utilisateur. L'erreur absolue moyenne (MAE) et l'erreur quadratique moyenne (RMSE) sont généralement utilisées comme mesures de précision statistique.

#### III.4.3.1 Erreur quadratique moyenne (RMSE)

L'erreur quadratique moyenne a pour caractéristique principale qu'elle tend à pénaliser davantage les erreurs importantes puisqu'elles sont mises au carré. Cela signifie que la métrique RMSE est plus susceptible d'être affectée par des valeurs aberrantes ou de mauvaises prédictions. Par définition, la métrique RMSE ne sera jamais aussi petite que la métrique MAE. De plus, la métrique RMSE n'utilise pas de valeurs absolues, ce qui est beaucoup plus pratique mathématiquement lors du calcul de la distance, du gradient ou d'autres mesures. C'est pourquoi la plupart des fonctions de coût de l'apprentissage automatique évitent d'utiliser la métrique MAE.

$$RMSE = \sqrt{\frac{\sum_{i=0}^N (y_i - \hat{y}_i)^2}{N}} \quad (III.21)$$

Où  $N$  est le nombre d'évaluations utilisées dans le test,  $y_i$  est l'évaluation réelle faite par l'utilisateur  $u$  pour l'item  $i$ , et  $\hat{y}_i$  est la note prédite correspondante. Cette mesure est plus sensible à l'erreur parce que la différence est mise au carré avant qu'elle soit sommée.

#### III.4.3.2 Erreur absolue moyenne (MAE)

L'erreur moyenne absolue a pour caractéristique qu'elle ne donne aucun biais aux erreurs extrêmes. S'il y a des valeurs aberrantes ou des termes d'erreur importants, leur erreur pèsera de la même manière que les autres erreurs de prédictions. Par conséquent, la métrique MAE doit être privilégiée lorsque l'on recherche davantage l'exactitude des notes plutôt que de donner de l'importance aux valeurs aberrantes. Pour obtenir une vue ou une représentation holistique du système de recommandation, on utilisera donc la métrique MAE

$$MAE = \frac{1}{N} \sum_{i=0}^N |y_i - \hat{y}_i| \quad (III.22)$$

Où,  $\hat{y}_i$  est la valeur estimée par le modèle pour l'évaluation faite par l'utilisateur  $u$  à l'item  $i$ , et  $N$  le nombre total des évaluations utilisées dans le test. Plus MAE est petite, plus la

performance est meilleure.

### III.5 Présentation de l'application

Nous allons présenter dans cette section quelques captures d'écrans de notre application.

- **Lecture de données :**

Premièrement on va charger de l'ensemble de données FilmTrust :

- **Rating-info** : qui contient les utilisateurs, les items et les ratings.
- **Trust-info** : qui contient les utilisateurs et leur amis.

```
import pandas as pd

rating_info = np.loadtxt('C:/Users/PC/Desktop/filmtrust/ratings.txt')
trust_info = np.loadtxt('C:/Users/PC/Desktop/filmtrust/trust.txt')
```

*Figure III.9 Importation de datasets Filmtrust*

- **Méthodes de référence :**

Le modèle utilisé est évalué et comparé aux méthodes de référence suivantes :

**SocialRec** : Ce modèle intègre des informations sociales dans le système de recommandation. Il s'agit d'un travail classique dans le domaine de la recommandation sociale. Il apprend la représentation des caractéristiques potentielles des utilisateurs en décomposant conjointement la matrice de notation des utilisateurs et des objets, ainsi que la matrice des relations sociales entre les utilisateurs [71].

**SocialMF** : En tant que l'un des modèles classiques de recommandation sociale, ce modèle introduit un mécanisme de propagation de la confiance et propose un algorithme de recommandation sociale basé sur la décomposition matricielle. Il est prouvé que l'introduction de la propagation de la confiance dans le système de recommandation peut améliorer efficacement la précision des recommandations [72].

**SocialReg** : Le modèle explore plus en profondeur les différences entre les systèmes de recommandation sociale et les systèmes de recommandation conscients de la confiance. Il modélise l'impact social des utilisateurs en tant que fonction de régularisation sociale pour réaliser des contraintes sociales [73].

**CUNE** : Le modèle combine la méthode d'apprentissage de la représentation du réseau. Afin de résoudre le problème du démarrage à froid sur les réseaux sociaux, le modèle restreint la

recommandation en extrayant les Top-k amis des utilisateurs à partir du graphe utilisateur-utilisateur [50].

### III.6 Résultats et analyse

Dans ce travail, nous avons divisé l'ensemble de données de manière aléatoire en ensembles d'apprentissage et de test en utilisant un rapport de 80/20. Le modèle a été évalué avec différentes combinaisons de valeurs d'hyper-paramètres. Les valeurs pour lesquelles le RMSE et le MAE sont minimaux ont été choisies comme valeurs optimales des hyper-paramètres. Nous avons comparé les méthodes de référence citées ci-dessus, telles que SocialRec[71], SocialMF[72], SocialReg[73], CUNE[50], avec le modèle utilisé, et nous avons constaté que le modèle GraphRec est plus efficace que les méthodes de référence. En outre, nous avons évalué ce modèle en utilisant une validation croisée à 10 reprises, et les résultats sont présentés dans le tableau III.3. Nous constatons que le modèle utilisé obtient de meilleurs résultats avec une validation croisée à 10 reprises. Sur la base de ces résultats, nous tirons les conclusions suivantes.

Modèles	FilmTrust	
	RMSE	MAE
SocialRec	1.0518	0.8480
SocialMF	1.0503	0.8472
SocialReg	0.9920	0.7884
CUNE	1.0310	0.8320
GraphRec	0.8712	0.6846

**Tableau III.3** Comparaison des résultats de différentes méthodes en termes MAE et RMSE

- Les résultats expérimentaux indiquent que la méthode GraphRec surpasse systématiquement toutes les méthodes de référence. Comparé à SocialRec, SocialMF, SocialReg et CUNE, le modèle GraphRec fournit des composants de modèle avancés pour intégrer les informations sur les notes et les réseaux sociaux. De plus, GraphRec propose une manière de prendre en compte à la fois les interactions et les opinions dans le graphe utilisateur-item.
  - En résumé, les résultats de comparaison suggèrent que :
    1. Les informations sur les réseaux sociaux sont utiles pour les recommandations.
    2. Les modèles de réseaux neuronaux peuvent améliorer les performances de recommandation.
    3. La méthode GraphRec surpasse les références représentatives.

**III.7 Conclusion**

Dans ce chapitre, nous avons abordé les réseaux de neurones graphiques dans le contexte de la recommandation sociale. Nous avons discuté des raisons d'utiliser les GNN dans les systèmes de recommandation sociale, présenté le modèle GraphRec, examiné les outils de développement utilisés, détaillé les métriques d'évaluation, et enfin, présenté les résultats obtenus pour les différentes expériences menées sur l'ensemble de données de FilmTrust.

# *Conclusion générale*

Les systèmes de recommandation jouent un rôle essentiel dans la manière dont les utilisateurs découvrent et interagissent avec le contenu sur diverses plateformes numériques. Nous avons commencé cette étude par une exploration des approches traditionnelles des systèmes de recommandation, telles que le filtrage collaboratif, qui repose sur les préférences passées des utilisateurs pour formuler des recommandations. Cependant, les limites de ces approches ont conduit à l'émergence de systèmes de recommandation plus avancés, intégrant des sources d'informations supplémentaires comme le contexte utilisateur et les données des réseaux sociaux.

Nous avons présenté un modèle de réseau de graphes (GraphRec) pour modéliser la recommandation sociale en vue de la prédiction des évaluations. En particulier, ce modèle est basé sur une approche méthodique pour capturer conjointement les interactions et les opinions dans le graphe utilisateur-item. Les expériences montrent que les informations d'opinion jouent un rôle crucial dans l'amélioration des performances de ce modèle. De plus, GraphRec est capable de différencier les forces des liens en tenant compte des forces hétérogènes des relations sociales. Les résultats expérimentaux sur le jeu de données FilmTrust montrent que GraphRec surpasse les méthodes de l'état de l'art.

Notre objectif futur est d'améliorer le modèle actuel en intégrant des informations auxiliaires cruciales, telles que les bases de connaissances, les avis des utilisateurs, les signaux temporels et les données multimodales, y compris les images fixes et la sémantique visuelle. Ces informations permettront de mieux comprendre les préférences des utilisateurs, augmentant ainsi le niveau de personnalisation. Jusqu'à présent, les modèles de personnalisation étaient centrés sur les individus. Notre travail pourrait être élargi pour inclure un système de recommandation de groupe, facilitant la prise de décision au sein des groupes sociaux. En outre, nous traitons actuellement les informations de notation et les données sociales comme statiques, bien qu'elles soient naturellement dynamiques. Ainsi, nous envisageons de développer des réseaux neuronaux de graphes dynamiques pour des recommandations sociales plus adaptatives.

## Bibliographies

- [1] « Sinha BB, Dhanalakshmi R (2019) Evolution of recommender system over the time. *Soft Comput* 23(23):12169–12188 ».
- [2] « Kuanr M, Mohapatra P (2021) Recent challenges in recommender systems: a survey. In: *Progress in advanced computing and intelligent engineering*. Springer, Singapore, pp 353–365 ».
- [3] « Moradi P, Ahmadian S (2015) A reliability-based recommendation method to improve trust-aware recommender systems. *Expert Syst Appl* 42(21):7386–7398 ».
- [4] H. Ko, S. Lee, Y. Park, et A. Choi, « A Survey of Recommendation Systems: Recommendation Models, Techniques, and Application Fields », *Electronics*, vol. 11, n° 1, p. 141, janv. 2022, doi: 10.3390/electronics11010141.
- [5] P. Massa et P. Avesani, « Trust-aware recommender systems », in *Proceedings of the 2007 ACM Conference on Recommender Systems*, in RecSys '07. New York, NY, USA: Association for Computing Machinery, 2007, p. 17-24. doi: 10.1145/1297231.1297235.
- [6] J. Tang, X. Hu, et H. Liu, « Social recommendation: a review », *Soc. Netw. Anal. Min.*, vol. 3, n° 4, p. 1113-1133, déc. 2013, doi: 10.1007/s13278-013-0141-9.
- [7] B. Sarwar, G. Karypis, J. Konstan, et J. Riedl, « Item-based Collaborative Filtering Recommendation Algorithms », *Proceedings of ACM World Wide Web Conference*, vol. 1, août 2001, doi: 10.1145/371920.372071.
- [8] G. Shani et A. Gunawardana, « Evaluating Recommendation Systems », in *Recommender Systems Handbook*, vol. 12, 2011, p. 257-297. doi: 10.1007/978-0-387-85820-3\_8.
- [9] 관심있는 주제, « 추천) Latent Matrix Factorization - 기본 컨셉 이해 », 18. 12:38 2021, [En ligne]. Disponible sur: <https://data-newbie.tistory.com/766>
- [10] Z. Fayyaz, M. Ebrahimian, D. Nawara, A. Ibrahim, et R. Kashef, « Recommendation Systems: Algorithms, Challenges, Metrics, and Business Opportunities », *Applied Sciences*, vol. 10, n° 21, p. 7748, nov. 2020, doi: 10.3390/app10217748.
- [11] P. Chu, D. Saucier, et E. Hafner, « Meta-Analysis of the Relationships Between Social Support and Well-Being in Children and Adolescents », *Journal of Social and Clinical Psychology*, vol. 29, p. 624-645, juin 2010, doi: 10.1521/jscp.2010.29.6.624.
- [12] S. Bellman, G. Lohse, et E. Johnson, « Predictors of Online Buying Behavior. », *Commun. ACM*, vol. 42, p. 32-38, déc. 1999, doi: 10.1145/322796.322805.
- [13] M. S., M. S., et V. K., « Trust Aware System for Social Networks: A Comprehensive Survey », *IJCA*, vol. 162, n° 5, p. 34-43, mars 2017, doi: 10.5120/ijca2017913307.
- [14] J. Shokeen et C. Rana, « A study on features of social recommender systems », *Artif. Intell. Rev.*, vol. 53, n° 2, p. 965-988, févr. 2020, doi: 10.1007/s10462-019-09684-w.
- [15] A. Lumbreras, « Towards trust-aware recommendations in social networks », juin 2012.
- [16] H. Gao *et al.*, « High-throughput screening using patient-derived tumor xenografts to predict clinical trial drug response », *Nature medicine*, vol. 21, oct. 2015, doi: 10.1038/nm.3954.
- [17] H. Tian et L. Peifeng, « Improved Recommendations Based on Trust Relationships in Social Networks », *Future Internet*, vol. 9, p. 9, mars 2017, doi: 10.3390/fi9010009.
- [18] N. Zheng et Q. Li, « A recommender system based on tag and time information for social tagging systems », *Expert Syst. Appl.*, vol. 38, p. 4575-4587, avr. 2011, doi: 10.1016/j.eswa.2010.09.131.
- [19] A. Milicevic et M. Ivanovic, « Social tagging in recommender systems: A survey of the state-of-the-art and possible extensions », *Artif. Intell. Rev.*, vol. 33, p. 187-209, mars 2010, doi: 10.1007/s10462-009-9153-2.
- [20] J. Masthoff, « Group Recommender Systems: Combining Individual Models », in *Recommender Systems Handbook*, 2011, p. 677-702. doi: 10.1007/978-0-387-85820-3\_21.
- [21] L. Quijano-Sanchez, J. Recio-García, B. Diaz-Agudo, et G. Jimenez-Diaz, « Social Factors in Group Recommender Systems », *ACM Transactions on Intelligent Systems and Technology (TIST)*, vol. 4, févr. 2013, doi: 10.1145/2414425.2414433.
- [22] I. Christensen, S. Schiaffino, et M. G. Armentano, « Social group recommendation in the tourism domain », *Journal of Intelligent Information Systems*, vol. 47, oct. 2016, doi: 10.1007/s10844-016-0400-0.
- [23] R. Zafarani et H. Liu, « Connecting users across social media sites: a behavioral-modeling

- approach », in *Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, in KDD '13. New York, NY, USA: Association for Computing Machinery, 2013, p. 41-49. doi: 10.1145/2487575.2487648.
- [24] Y. Koren, *Collaborative filtering with temporal dynamics*, vol. 53. 2009, p. 456. doi: 10.1145/1557019.1557072.
- [25] T.-A. Pham, X. Li, G. Cong, et Z. Zhang, « A general graph-based model for recommendation in event-based social networks », *Proceedings - International Conference on Data Engineering*, vol. 2015, p. 567-578, mai 2015, doi: 10.1109/ICDE.2015.7113315.
- [26] C. Yeung et T. Iwata, *Strength of social influence in trust networks in product review sites*. 2011, p. 504. doi: 10.1145/1935826.1935899.
- [27] J. Zhang *et al.*, *Recommendation over a Heterogeneous Social Network*. 2008, p. 316. doi: 10.1109/WAIM.2008.71.
- [28] T. Ma *et al.*, « Social Network and Tag Sources Based Augmenting Collaborative Recommender System », *IEICE Transactions on Information and Systems*, vol. E98.D, p. 902-910, avr. 2015, doi: 10.1587/transinf.2014EDP7283.
- [29] V. Codina et L. Ceccaroni, *Taking Advantage of Semantics in Recommendation Systems.*, vol. 220. 2010, p. 172. doi: 10.3233/978-1-60750-642-3-163.
- [30] I. Lašek et P. Vojtáš, « Semantic Information Filtering-Beyond Collaborative Filtering », janv. 2011.
- [31] A. M. Rashid *et al.*, « Getting to know you , 2002 International Conference on intelligent User Interfaces (IUI 02) », 2002, p. 127-134, 2002.
- [32] M. Papagelis, D. Plexousakis, et T. Kutsuras, « Alleviating the Sparsity Problem of Collaborative Filtering Using Trust Inferences », in *Trust Management*, P. Herrmann, V. Issarny, et S. Shiu, Éd., Berlin, Heidelberg: Springer Berlin Heidelberg, 2005, p. 224-239.
- [33] G. Guo, J. Zhang, et D. Thalmann, « Merging trust in collaborative filtering to alleviate data sparsity and cold start », *Knowledge-Based Systems*, vol. 57, p. 57-68, févr. 2014, doi: 10.1016/j.knosys.2013.12.007.
- [34] M. B. Karanam, « TACKLING THE PROBLEMS OF DIVERSITY IN RECOMMENDER SYSTEMS ».
- [35] J. Lee, J.-H. Ahn, et B. Park, « The effect of repetition in Internet banner ads and the moderating role of animation », *Computers in Human Behavior*, vol. 46, p. 202-209, mai 2015, doi: 10.1016/j.chb.2015.01.008.
- [36] J. Jankowski, J. Hamari, et J. Wątróbski, « A gradual approach for maximising user conversion without compromising experience with high visual intensity website elements », *INTR*, vol. 29, n° 1, p. 194-217, févr. 2019, doi: 10.1108/IntR-09-2016-0271.
- [37] Vijay Kanade, « What Is Machine Learning? Definition, Types, Applications, and Trends », avr. 2022, [En ligne]. Disponible sur: <https://www.spiceworks.com/tech/artificial-intelligence/articles/what-is-ml/>
- [38] Shiksha Online, « What is a multilayer perceptron (MLP) neural network? », janv. 2024, [En ligne]. Disponible sur: <https://www.shiksha.com/online-courses/articles/understanding-multilayer-perceptron-mlp-neural-networks/>
- [39] Jérémy Robert, « Convolutional Neural Network : Tout ce qu'il y a à savoir », juin 2020, Consulté le: 21 juin 2024. [En ligne]. Disponible sur: <https://datascientest.com/convolutional-neural-network>
- [40] « content.pdf ». Consulté le: 18 mars 2024. [En ligne]. Disponible sur: <https://dspace.ummto.dz/server/api/core/bitstreams/104cd8ce-d9ff-477d-adca-c8cea3f7f5dd/content>
- [41] « content.pdf ». Consulté le: 5 mars 2024. [En ligne]. Disponible sur: <https://dspace.ummto.dz/server/api/core/bitstreams/d3b6a008-9f37-46a9-8200-0e42fc3ef636/content>
- [42] « RLC-GNN: An Improved Deep Architecture for Spatial-Based Graph Neural Network with Application to Fraud Detection - Scientific Figure on ResearchGate. Available from: [https://www.researchgate.net/figure/A-typical-and-basic-architecture-and-processing-procedures-of-GNN-First-GNN-selects\\_fig2\\_352526255](https://www.researchgate.net/figure/A-typical-and-basic-architecture-and-processing-procedures-of-GNN-First-GNN-selects_fig2_352526255) [accessed 21 Jun, 2024] ».
- [43] Dr. Jagreet Kaur Gill, « Graph Neural Network Applications and its Future », mai 2023, Consulté

- le: 10 juin 2024. [En ligne]. Disponible sur: <https://www.xenonstack.com/blog/graph-neural-network-applications>
- [44] Tiya Vaj, « GNN vs GCN vs GAN (Graph networks) », mai 2023, [En ligne]. Disponible sur: <https://vtiya.medium.com/gnn-vs-gcn-vs-gan-grap-cf7a790848ad>
- [45] Faxi Yuan, PhD, « Graph Neural Networks (GNNs): Comparison between CNNs and GNNs », mai 2023, [En ligne]. Disponible sur: <https://medium.com/@ds-faxi-yuan/graph-neural-networks-gnn-comparison-between-cnn-and-gnn-5c97fdfb3e31#:~:text=The%20difference%20between%20CNNs%20and,for%20the%20convolutions%20of%20GCNs.&text=The%20difference%20shown%20in%20Figure%204%20actually%20inspired%20the%20development%20of%20GCNs>
- [46] S. Sedhain, A. K. Menon, S. Sanner, et L. Xie, « AutoRec: Autoencoders Meet Collaborative Filtering », in *Proceedings of the 24th International Conference on World Wide Web*, Florence Italy: ACM, mai 2015, p. 111-112. doi: 10.1145/2740908.2742726.
- [47] F. Strub, R. Gaudel, et J. Mary, « Hybrid Recommender System based on Autoencoders », in *Proceedings of the 1st Workshop on Deep Learning for Recommender Systems*, sept. 2016, p. 11-16. doi: 10.1145/2988450.2988456.
- [48] A. Mnih et R. R. Salakhutdinov, « Probabilistic Matrix Factorization ».
- [49] R. Salakhutdinov, A. Mnih, et G. Hinton, *Restricted Boltzmann machines for collaborative filtering*, vol. 227. 2007, p. 798. doi: 10.1145/1273496.1273596.
- [50] W. Fan *et al.*, « Graph Neural Networks for Social Recommendation ». arXiv, 22 novembre 2019. Consulté le: 5 juin 2024. [En ligne]. Disponible sur: <http://arxiv.org/abs/1902.07243>
- [51] N. Mu, D. Zha, Y. He, et Z. Tang, « Graph Attention Networks for Neural Social Recommendation », in *2019 IEEE 31st International Conference on Tools with Artificial Intelligence (ICTAI)*, nov. 2019, p. 1320-1327. doi: 10.1109/ICTAI.2019.00183.
- [52] L. Wu, P. Sun, R. Hong, Y. Fu, X. Wang, et M. Wang, *SocialGCN: An Efficient Graph Convolutional Network based Model for Social Recommendation*. 2018.
- [53] Q. Wu *et al.*, « Dual Graph Attention Networks for Deep Latent Representation of Multifaceted Social Effects in Recommender Systems », in *The World Wide Web Conference*, mai 2019, p. 2091-2102. doi: 10.1145/3308558.3313442.
- [54] L. Wu, P. Sun, Y. Fu, R. Hong, X. Wang, et M. Wang, « A Neural Influence Diffusion Model for Social Recommendation ». arXiv, 20 avril 2019. Consulté le: 12 mars 2024. [En ligne]. Disponible sur: <http://arxiv.org/abs/1904.10322>
- [55] W. Fan, Y. Ma, D. Yin, J. Wang, J. Tang, et Q. Li, « Deep Social Collaborative Filtering ». arXiv, 16 juillet 2019. Consulté le: 8 juin 2024. [En ligne]. Disponible sur: <http://arxiv.org/abs/1907.06853>
- [56] S. Wang, L. Hu, Y. Wang, L. Cao, Q. Z. Sheng, et M. Orgun, « Sequential Recommender Systems: Challenges, Progress and Prospects », in *Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence*, Macao, China: International Joint Conferences on Artificial Intelligence Organization, août 2019, p. 6332-6338. doi: 10.24963/ijcai.2019/883.
- [57] Z. Liu *et al.*, « AutoAssign+: Automatic Shared Embedding Assignment in streaming recommendation », *Knowl. Inf. Syst.*, vol. 66, n° 1, p. 89-113, août 2023, doi: 10.1007/s10115-023-01951-1.
- [58] G. Guo, J. Zhang, et N. Yorke-Smith, « TrustSVD: Collaborative Filtering with Both the Explicit and Implicit Influence of User Trust and of Item Ratings », *Proceedings of the Twenty-Ninth AAAI Conference on Artificial Intelligence*, vol. 29, p. 123-129, févr. 2015, doi: 10.1609/aaai.v29i1.9153.
- [59] O. Wahab, G. Rjoub, J. Bentahar, et R. Cohen, « Federated against the Cold: A Trust-based Federated Learning Approach to Counter the Cold Start Problem in Recommendation Systems », *Information Sciences*, vol. 601, avr. 2022, doi: 10.1016/j.ins.2022.04.027.
- [60] S. Wu, F. Sun, W. Zhang, X. Xie, et B. Cui, « Graph Neural Networks in Recommender Systems: A Survey », *ACM Computing Surveys*, vol. 55, mai 2022, doi: 10.1145/3535101.
- [61] X. Wang, X. He, M. Wang, F. Feng, et T.-S. Chua, « Neural Graph Collaborative Filtering », in *Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval*, in SIGIR'19. New York, NY, USA: Association for Computing Machinery, 2019, p. 165-174. doi: 10.1145/3331184.3331267.

- [62] L. Wu, J. Li, P. Sun, R. Hong, Y. Ge, et M. Wang, « DiffNet++: A Neural Influence and Interest Diffusion Network for Social Recommendation ». arXiv, 5 janvier 2021. Consulté le: 20 juin 2024. [En ligne]. Disponible sur: <http://arxiv.org/abs/2002.00844>
- [63] T. Chen et R. Wong, *An Efficient and Effective Framework for Session-based Social Recommendation*. 2021, p. 408. doi: 10.1145/3437963.3441792.
- [64] C. Song, B. Wang, Q. Jiang, Y. Zhang, R. He, et Y. Hou, *Social Recommendation with Implicit Social Influence*. 2021, p. 1792. doi: 10.1145/3404835.3463043.
- [65] J. Yu, M. Gao, H. Yin, J. Li, Q. Wang, et C. Gao, *Generating Reliable Friends via Adversarial Training to Improve Social Recommendation*. 2019. doi: 10.1109/ICDM.2019.00087.
- [66] Z. Guo et H. Wang, « A Deep Graph Neural Network-Based Mechanism for Social Recommendations », *IEEE Transactions on Industrial Informatics*, vol. PP, p. 1-1, avr. 2020, doi: 10.1109/TII.2020.2986316.
- [67] J. Liao *et al.*, « SocialLGN: Light Graph Convolution Network for Social Recommendation », *Information Sciences*, vol. 589, janv. 2022, doi: 10.1016/j.ins.2022.01.001.
- [68] X. Hou *et al.*, « Quality assessment of kidney cancer clinical practice guidelines using AGREE II instrument: A critical review », *Medicine*, vol. 98, n° 40, 2019, [En ligne]. Disponible sur: [https://journals.lww.com/md-journal/fulltext/2019/10040/quality\\_assessment\\_of\\_kidney\\_cancer\\_clinical.10.aspx](https://journals.lww.com/md-journal/fulltext/2019/10040/quality_assessment_of_kidney_cancer_clinical.10.aspx)
- [69] D. Luo, Y. Bian, X. Zhang, et J. Huan, « Attentive Social Recommendation: Towards User And Item Diversities ». arXiv, 14 novembre 2020. Consulté le: 19 juin 2024. [En ligne]. Disponible sur: <http://arxiv.org/abs/2011.04797>
- [70] Chaitanya, « Graph Neural Networks for Social Recommendation | GraphRec », oct. 2022, [En ligne]. Disponible sur: <https://medium.com/@chaitanya6575/graph-neural-networks-for-social-recommendation-summary-9e6bf7dfbf76>
- [71] H. Ma, H. Yang, M. R. Lyu, et I. King, « SoRec: social recommendation using probabilistic matrix factorization », in *Proceedings of the 17th ACM Conference on Information and Knowledge Management*, in CIKM '08. New York, NY, USA: Association for Computing Machinery, 2008, p. 931-940. doi: 10.1145/1458082.1458205.
- [72] M. Jamali et M. Ester, « A matrix factorization technique with trust propagation for recommendation in social networks », in *Proceedings of the Fourth ACM Conference on Recommender Systems*, in RecSys '10. New York, NY, USA: Association for Computing Machinery, 2010, p. 135-142. doi: 10.1145/1864708.1864736.
- [73] H. Ma, D. Zhou, C. Liu, M. R. Lyu, et I. King, « Recommender systems with social regularization », in *Proceedings of the Fourth ACM International Conference on Web Search and Data Mining*, in WSDM '11. New York, NY, USA: Association for Computing Machinery, 2011, p. 287-296. doi: 10.1145/1935826.1935877.