



REVUE ALGERIENNE DES SCIENCES

Section -A-

- Sciences de la Nature et de la Vie
- Sciences techniques

<http://univ-eltarf.dz/fr/>



Un système de recommandation hybride basé flou adapté à l'apprentissage amélioré par la technologie

Majda Maâtallah^{a*}, Hassina Séridi^b, Abdelmadjid Benmachiche^c, Amina Makhoulf^c

^aLaboratoire de Gestion de Document Electronique(LabGED), Département d'Informatique, Université Chadli Bendjedid- El Tarf, Algérie.

^bLaboratoire de Gestion de Document Electronique (LabGED), Département d'Informatique, Université Badji Mokhtar- Annaba, Algérie.

^cLaboratoire de Recherche en Informatique (LRI), Département d'Informatique, Université Chadli Bendjedid- El Tarf, Algérie.

Informations	Résumé
Mots clés : Apprentissage amélioré par la technologie Systèmes de Recommandation Filtrage Collaboratif Filtrage basé sur le Contenu profil apprenant FCM Factorisation Matricielle. *Correspondance : majda_maatallah@yahoo.fr Reçu le 02 avril 2018, Révisé le 13 mai 2018, Accepté le 14 mai 2018.	Les systèmes de recommandation (SR) sont largement utilisés de nos jours dans de nombreux domaines pour générer les items d'intérêt. Récemment, ils ont été appliqués dans le domaine de l'apprentissage amélioré par la technologie (Technology Enhanced Learning TEL) afin de permettre la recommandation des ressources d'apprentissage pertinentes pour aider les enseignants et les apprenants. Dans cet article, nous proposons une nouvelle technique de recommandation qui combine un algorithme de filtrage collaboratif flou avec un algorithme basé contenu pour améliorer la recommandation, en utilisant les préférences des apprenants et l'importance de la connaissance, pour recommander des items avec différents contextes, afin de réduire l'effet du problème célèbre de la stabilité des SR par rapport à la dynamique du profil de l'apprenant. Les évaluations empiriques montrent que la technique proposée est réalisable et efficace.

1. Introduction

Le développement Web a créé un besoin de nouvelles techniques pour aider les utilisateurs à trouver ce qu'ils veulent et aussi pour savoir que l'information existe, ces techniques sont appelées Systèmes de Recommandation (RS). Les SR sont généralement construits sur la base de deux types de méthodes différentes : le Filtrage basé sur le Contenu (FBC) et le Filtrage Collaboratif (FC). Les SR souffrent de plusieurs problèmes définis dans [1], où l'un d'eux est le problème de la stabilité du système par rapport au profil dynamique de l'utilisateur (Dynamicity vs. Plasticity Problem) [1]. Ce problème résulte de l'incapacité du système à suivre l'évolution du comportement de l'utilisateur, car dans les SR une fois que le profil d'un utilisateur a été établi, il est difficile de le changer.

Les RS sont largement utilisés dans de nombreux domaines, en particulier dans le commerce électronique [2-3-4]. Récemment, cette technologie a été appliquée dans le domaine de l'apprentissage en ligne (e-learning), plus particulièrement, dans *l'apprentissage amélioré par la technologie* (TEL) [5], afin de personnaliser le contenu d'apprentissage et de connecter les apprenants appropriés en fonction de leurs besoins, préférences et objectifs d'apprentissage.

L'apprentissage amélioré par la technologie peut être différencié en apprentissage formels et non formels. Dans l'apprentissage non formel, les apprenants agissent de manière plus autonome et sont responsables de leur propre apprentissage. Le processus d'apprentissage n'est pas conçu par une institution ou des enseignants responsables

comme dans l'apprentissage formel, mais il dépend des préférences et des choix des apprenants, qui sont similaires aux consommateurs qui recherchent des produits sur Internet. Ainsi, les apprenants tout au long de la vie doivent avoir une vue d'ensemble des activités d'apprentissage disponibles et décider lesquels correspondent le mieux à leurs besoins personnels, leurs préférences, leurs connaissances antérieures et leur situation actuelle. Ce qui rend nécessaire l'utilisation des systèmes de recommandation personnalisée (SRP), capables de proposer des ressources et des activités d'apprentissage en fonction des besoins individuels des apprenants, leurs objectifs d'apprentissage, leur contexte et permettent une collaboration accrue entre eux.

Cependant, les besoins et les préférences d'un apprenant peuvent changer au cours d'une période de temps, même dans le même temps où il veut apprendre des ressources avec un contexte différent. Cela crée le besoin de concevoir des RS adaptatifs (SRA) capables de générer des recommandations avec des goûts différents en fonction de l'évolution du profil de l'apprenant. La conception des SRA est un grand défi en raison du problème de la stabilité Vs. plasticité de ces systèmes.

Cependant, les recommandations dans le domaine de l'apprentissage amélioré par la technologie dépendent non seulement des préférences de l'apprenant mais aussi du contexte [6]; ce qui rend de plus en plus important l'utilisation du FBC dans le processus de recommandation. À cette fin, nous élaborons une technique hybride qui combine un algorithme du FC hybride flou avec le FBC, en utilisant des informations taxonomiques pour générer des recommandations multi-contexte avec de meilleures performances.

L'article est organisé comme suit. La section deux, présente le domaine des SR et la troisième section, contient quelques systèmes de recommandation déployés dans le domaine de l'apprentissage amélioré par la technologie. Ensuite, nous décrivons notre technique hybride floue proposée pour recommander des ressources d'apprentissage avec des goûts différents, dans la section quatre. Les résultats empiriques sont présentés dans la cinquième section. À la fin, nous donnons quelques conclusions et perspectives.

2. Les Systèmes de Recommandation

Les SR fournissent des informations adéquates aux besoins des personnes d'une

manière passive, car l'utilisateur ne rend pas explicite ses besoins à travers une requête (ou l'expression d'un besoin spécifique) comme c'est le cas dans la recherche d'information. Dans les SR, une représentation de l'utilisateur appelée "Profil utilisateur" est utilisée pour lui envoyer des informations. Ces informations proviennent généralement d'un flux dynamique ou obtenues via un agent [7]. Elles sont ensuite comparées avec les différents profils disponibles pour déterminer ceux auxquels ils correspondent [8]. Ainsi, les SR ont l'intention d'envoyer, à partir d'une grande quantité d'informations générées dynamiquement, les informations jugées pertinentes. Par conséquent, le filtrage est interprété comme l'élimination des données indésirables sur un flux entrant, plutôt que la recherche de données spécifiques sur ce flux.

Les RS sont généralement construits sur la base de deux types de méthodes différentes : le Filtrage Basé sur le Contenu (FBC) et le Filtrage Collaboratif (FC). L'approche du FBC génère des recommandations de contenu basées sur les caractéristiques des utilisateurs ou des items, tandis que la méthode du FC utilise simplement les évaluations effectuées par les utilisateurs sur les items pour prédire les évaluations inconnues des nouvelles paires utilisateur-item. De son côté, le FC est catégorisé en deux classes : les méthodes basées mémoire (voisinage) et les méthodes basées modèles, où se trouvent les méthodes de factorisation. Les algorithmes basés sur la factorisation sont, généralement, considérés comme plus efficaces que ceux basés sur la mémoire. Néanmoins, ils sont souvent complémentaires et la meilleure performance est obtenue en les combinant [9]. L'hybridation [10] entre les approches du FC et du FBC a fait l'objet d'intérêt dans de nombreux travaux sur les SR, pour en profiter de leurs avantages.

L'un des problèmes majeurs des SR est le problème de la stabilité des SR par rapport au profil dynamique de l'utilisateur (Problème de Stabilité vs. Plasticité) [2]. Pour surmonter ce problème, nous avons proposé une approche hybride combinant l'approche basée contenu, et qui utilise l'information taxonomique pour représenter le contenu des items, et l'approche collaborative, qui utilise les préférences des utilisateurs similaires (voisins) pour prédire les préférences de l'utilisateur, générant ainsi des recommandations diversifiées qui correspondent à ses besoins en fonction de son degré d'appartenance à différents clusters. Ces valeurs d'appartenance à différents clusters peuvent être obtenues dans la phase du FC en appliquant la logique floue [11], ou également l'algorithme Fuzzy C-means (FCM) [12].

En raison des deux défis majeurs pour les systèmes basés sur le FC, qui sont les problèmes de scalabilité et de Sparsity, l'application de l'algorithme FCM traditionnel peut faire face à certaines difficultés. De ce point, notre objectif était de concevoir un algorithme du FC efficace qui garantisse une affectation multiple d'un utilisateur à différents clusters, en modifiant la fonction objective du FCM à une fonction de factorisation matricielle (FM) [13].

3. Etat de l'art

Beaucoup de SR ont été déployés dans le domaine de l'apprentissage amélioré par technologie, comme l'a montré Manouselis et al. [5], pour avoir recommandé des matériels d'apprentissage et des ressources aux apprenants dans un environnement d'apprentissage formel et informel [14]. Concrètement, Garcia et al. [15] ont utilisé les règles d'association sous la forme de règles IF-THEN pour découvrir les informations d'intérêt à travers les données de performance des étudiants, puis générer la recommandation basée sur ces règles. Bobadilla et al. [16] ont utilisé un système basé FC où ils ont incorporé le score de test des apprenants dans la fonction de prédiction d'item. Dans Soonthornphisaj et al. [17], le FC est appliqué pour prédire les objets d'apprentissage les plus appropriés aux apprenants ; alors que Ge et al. [18] ont combiné entre FC et FBC pour faire une recommandation personnalisée pour un module de sélection de didacticiels. Enfin, Thay-Nghe et al. [19] ont appliqué la technique de FM dans le contexte éducatif, pour prédire les performances des élèves. Une étude critique des techniques de recommandation concernant leur applicabilité et leur utilité dans le domaine TEL a été présentée dans [14], fournissant un aperçu des avantages et des inconvénients de chaque technique, et rend compte de l'utilité envisagée de chacune pour les recommandataires de TEL. Pour plus de détails sur les systèmes de recommandation appliqués dans le domaine TEL, veuillez vous reporter à [5].

Généralement, les SR dans l'apprentissage en ligne traitent de l'information sur les apprenants et les activités d'apprentissage et pourraient suivre l'évolution du profil de l'apprenant (comportement) au cours de ses différents niveaux d'apprentissage. Pour ce faire, nous proposons une nouvelle technique hybride qui combine le FC (en utilisant la méthode de FM) et le FBC pour mieux prédire les besoins de l'apprenant. La technique proposée permet de générer des recommandations de ressources d'apprentissage pour les apprenants tout au long

de la vie qui correspondent à leurs différents intérêts, en suivant l'évolution de leurs profils.

4. Contribution

Pour améliorer la qualité de la recommandation, l'objectif principal de notre travail est de concevoir un algorithme de clustering pour améliorer la précision du FC dans les systèmes de recommandation, en commençant par la création des clusters dans le système. Ensuite, en affectant les nouveaux apprenants aux groupes pertinents, qui sont les plus similaires en termes de goût, d'activités d'apprentissage et d'objectifs. La description de notre approche proposée est divisée en deux sections principales : La première contient la description de l'algorithme du FC qui garantit une multi-affectation de l'apprenant actuel aux différents clusters, et la prédiction des scores des items. La deuxième partie, contient l'algorithme de recommandation adapté au domaine de l'apprentissage amélioré par la technologie, en incorporant la performance de l'apprenant.

4.1. Description de l'environnement

Nous introduisons d'abord quelques notations, supposons que nous traitons des relations entre deux types d'entités u et c , que nous appelons «utilisateur» et «item», ou «apprenant» et «cours», respectivement, et pour certains u et c nous observons un score (évaluation) relationnel(le) $r_{u,c}$ que nous appelons «évaluation (rating)». Nous envisageons un monde avec :

- Un ensemble d'apprenants $U = \{u1, u2, \dots, uN\}$;
- Un ensemble de cours $C = \{c1, c2, \dots, cM\}$.
- Chaque item est décrit par un ensemble de descripteurs $D(t) = \{d1, d2, \dots, dn\}$ tel que $|D(t)| \geq 1$. Un descripteur taxonomique d est une séquence ordonnée de sujets (ou thèmes) p dénotée par $d = \{p0, p1, \dots, pq\}$ où $d \in D(c)$, $c \in C$. Les thèmes d'un descripteur sont séquencés de sorte que les anciens thèmes soient des super-thèmes des derniers sujets, où le super-thème couvre le terme général du domaine et le sous-thème couvre un terme plus spécifique.
- $r_{u,c}$ L'évaluation du cours c faite par l'apprenant u . Toutes les évaluations faites par l'apprenant forment un vecteur r_u , qui représente son profil. La matrice d'évaluation est R .
- $Z_{(u, k)}$ La probabilité que l'apprenant u appartient au groupe k ; $Z = (Z_{(u, k)})$ est la matrice de probabilité $U \times K$, où U, K sont le

nombre d'apprenants et de groupes, respectivement.

- $uc_{(k, c)}$ La moyenne des évaluations faites par les membres du groupe k à l'item c , et $UC = (m(k, c))$ est la matrice des centroïdes $K \times C$, où C est le nombre d'items (cours).

4.2. Algorithme du Filtrage Collaboratif basé flou

Comme mentionné ci-dessus, cette partie est consacrée à la description de notre nouvel algorithme du FC. A partir de l'étude de la littérature sur les algorithmes du FC, nous avons mis les principales étapes de notre algorithme :

- Tout d'abord, la construction automatique des clusters dans le système à partir de la matrice d'évaluation en utilisant la méthode de Factorisation Matricielle Non Négative (FMNN). La raison derrière le choix d'utilisation de cette méthode est la réduction du problème d'évolutivité de données, qui survient lors de l'ajout d'un nouvel utilisateur ou d'un nouvel item. De plus, la matrice de probabilité qui en résulte peut être utilisée pour traiter les données afin de résoudre plus efficacement les problèmes du FC à grande échelle.
- Ensuite, pour la sélection du voisinage, nous proposons de ne considérer que les K -plus proches voisins appartenant aux C -plus proches clusters suivant le principe de [20-9] mais en utilisant l'extension floue de l'algorithme.
- Et enfin, La prédiction des préférences de l'apprenant.

4.2.1. Algorithme de clustering des utilisateurs : FCM modifié en FMNN (MFCMtoNNMF)

Dans cette étape, nous allons factoriser la matrice d'évaluation R en deux matrices Z et UC . où Z est la matrice de probabilité et UC est la matrice des centres de clusters.

Nous utiliserons une version modifiée de FCM en FMNN suivant le même principe de WU et LI [13], en ajoutant la contrainte de non-négativité sur les éléments de la matrice UC . Puisque UC est la matrice des centres de cluster où chaque élément est la moyenne des évaluations faites par les membres d'un cluster c à un cours donné c , donc ses composants doivent être ≥ 0 . Le problème à résoudre avec la nouvelle contrainte est :

$$H(Z, UC) = \frac{1}{2} \sum_{(u,c) \in P} (r_{uc} - \frac{1}{\sum_{k=1}^K e^{z_{uk}} \sum_{k=1}^K e^{z_{uk}} uc_{k,c}})^2 + \lambda_c \|uc_c\|_2^2 + \lambda_z \|z_u\|_2^2 \quad (1)$$

$$\text{St. } Z_1 = 1; Z \geq 0; UC \geq 0.$$

Où, $r_{u,c}$ est l'évaluation faite par

l'utilisateur u à l'item c , et $e^{z_{uk}}$ est la probabilité que cet utilisateur appartienne au cluster k , ayant comme centre $uc_{k,c}$ qui est la moyenne des évaluations faites par les membres de ce groupe à ce cours, avec k un nombre positive.

$0 \leq \lambda_c, \lambda_z \leq 1$ sont des petits paramètres de régularisation définis à travers les expérimentations. Sachant que nous avons utilisé une formule de normalisation de la matrice de probabilité Z pour mettre la somme des éléments de chaque ligne égale à 1.

Pour résoudre ce problème, nous avons utilisé l'algorithme des moindres carrés contraints alternatif (ACLS Alternate Constrained Least Squares Algorithm) proposé dans [21].

Et pour initialiser l'algorithme ACLS, nous avons proposé une version modifiée de la méthode d'initialisation aléatoire Acol citée en [21] en initialisant chaque ligne de la matrice C en faisant la moyenne de p lignes aléatoires de la matrice d'évaluation R . Nous appelons cette méthode, méthode d'initialisation Rows aléatoires.

4.2.2. Pré-sélection et sélection des voisins.

Une étape importante dans l'algorithme du FC est la recherche de voisins de l'apprenant actuel. Les méthodes traditionnelles ont généralement besoin de rechercher toute la base de données, qui souffre certainement du problème d'évolutivité. Nous avons proposé une version ajustée de l'algorithme de voisinage flou suivant le même principe que dans [9-20] comme suit :

- Calculer la similarité entre l'apprenant actif et tous les clusters pour sélectionner les C -Plus Proches Clusters Flous (CPPCF) [22]. Nous n'avons considéré que le CPPCF car il n'est pas intéressant d'affecter l'apprenant à des groupes dissimilaires.
- Calculer la similarité entre l'apprenant actif et les membres des CPPCF afin de sélectionner les K -Plus Proches Voisins Flous (FKNN) [22] en utilisant les degrés d'appartenance de l'apprenant aux clusters afin de minimiser les calculs.

Pour calculer la similarité entre apprenants, nous avons proposé d'utiliser la différence entre les degrés d'appartenance au même cluster comme mesure de similarité entre l'apprenant actif et les membres des CPPCF. Où, la similarité entre deux apprenants augmente lorsque la différence entre leurs degrés d'appartenance tend vers 0.

4.3. La prédiction basée FC des préférences de l'apprenant

Similaire à l'idée présentée dans [9-20], nous proposons un cadre qui peut effectivement améliorer les performances, en combinant linéairement les résultats de prédiction de l'algorithme de *clustering*, et des algorithmes, basé utilisateur et basé item, respectivement, comme la prédiction basée FC

$$CFB_{pred(u,c)} = \delta \hat{m}_{u,c} + \alpha(1-\delta)\hat{u}_{u,c} + (1-\alpha)(1-\delta)\hat{i}_{u,c} \quad (2)$$

Où $\hat{m}_{u,c}$, $\hat{u}_{u,c}$ et $\hat{i}_{u,c}$ sont les prédictions basées modèle, sur l'utilisateur et sur les items, respectivement. $0 \leq \lambda, \delta \leq 1$ sont des coefficients de fusion pour contrôler le poids entre les différentes prédictions, que nous allons définir expérimentalement

Après l'application des méthodes de prédiction basées sur le FC, les valeurs dans les cellules de la matrice apprenant-cours sont mises à jour. Ainsi, l'éparpillement de la matrice est donc réduit. Cependant, il peut toujours y avoir des cellules vides en raison du nombre insuffisant des plus proches voisins pour cet apprenant. Pour cette raison, il est nécessaire d'utiliser les informations de contenu pour faire des prédictions pour chaque paire apprenant-cours. Puis, fusionner les deux types de prédictions pour avoir une matrice d'évaluation complète.

4.4. Filtrage basé sur le contenu

Pour prédire les évaluations inconnues en se basant sur le contenu, nous devons avoir un ensemble de caractéristiques pour décrire le contenu des items afin de corréliser les items similaires. Dans notre système, les items sont des cours et les caractéristiques sont les thèmes ou sujets (informations utilisées pour décrire le contenu des cours).

Nous proposons de calculer la fréquence d'occurrence de chaque thème (sujet) dans tous les items évalués par l'apprenant actif u_a . Ensuite, nous attribuerons une note à chaque thème afin de promouvoir les cours en fonction de l'apparence des sujets et des évaluations faites par les apprenants à chaque cours. La raison est que deux sujets $p1$ et $p2$ appartiennent à deux cours $c1$ et $c2$, respectivement, peuvent avoir la même fréquence d'occurrence dans l'ensemble des items évalués par u_a , mais le cours $c1$ a eu une meilleure évaluation par rapport au cours $c2$. Par conséquent, les préférences de l'apprenant devraient promouvoir $p1 \in c1$ sur $p2 \in c2$ à travers leurs scores dans le vecteur des préférences. Ainsi, le score attribué au sujet pn

dans le vecteur des préférences de l'apprenant u_a est calculé comme suit

$$score(p_n, \vec{V}_{u_a}) = \frac{\sum_{p_n \in c(u_a)} (rating(u_a, c) \cdot Occur(p_n))}{|c(u_a)|} \quad (3)$$

Tels que $|c(u_a)|$ est le nombre d'articles évalués par u_a . $rating(u_a, c)$ est l'évaluation effectuée par u_a au cours c contenant le sujet pn , et $Occur(p_n)$ représente la fréquence d'occurrence du sujet pn dans l'ensemble des items évalués par u_a .

Après avoir donné un score pour chaque sujet, nous calculons la similarité entre le cours de test et l'ensemble des cours évalués par l'apprenant actif pour sélectionner les cours les plus proches du cours de test. Nous proposons d'utiliser la mesure de similarité cosinus pour calculer la similarité entre deux vecteurs de cours.

4.4.1. Prédiction basée sur le contenu

Enfin, nous faisons la prédiction basée sur le contenu des valeurs inconnues. La prédiction d'évaluation pour un cours non vu est formulée comme suit :

$$CB_{pred}(u_a, c) = \frac{\sum_{m \in TNI(c)} rating(u_a, m) \cdot sim(c, m)}{\sum_{m \in TNI(c)} sim(c, m)} \quad (4)$$

Où $rating(u_a, m)$ représente l'évaluation faite par l'apprenant u_a au cours $m \in TNI(c)$ et $sim(c, m)$ est la similarité calculée dans la section précédente.

Ce type de prédiction utilise des sujets pour prédire les évaluations inconnues. Ainsi, il a besoin de sujets prédictifs pour réaliser une bonne prédiction qui limite l'efficacité de l'utilisation de cette prédiction seule. Pour répondre aux limitations des prédictions fondées sur le FC et sur le contenu, nous procédons à une hybridation entre elles.

4.5. Prédiction hybride

Dans cette section, nous présenterons notre modèle de prédiction hybride qui combine la prédiction basée sur le FC et la prédiction basée sur le contenu afin d'obtenir une matrice apprenant-cours complète. Notre schème de prédiction hybride proposé est défini comme suit :

$$Final_pred = \alpha \times CFB_pr(u_a, c) + (1-\alpha) \times CB_pred(u_a, c) \quad (5)$$

Où α est utilisé pour contrôler le poids entre les deux prédictions.

4.6. La Recommandation Top-K

Après avoir appliqué l'algorithme du FC cité ci-dessus, nous obtenons des prédictions des items non vus par l'apprenant actif. Ensuite, nous appliquons la procédure de génération de la recommandation.

La première étape consiste à calculer les scores des items en fonction des préférences des clusters et de la prédiction des préférences de l'apprenant, afin de sélectionner les Top-N items dans chaque groupe. Ensuite, une liste des Top-K items est sélectionnée parmi les Top-N items.

Les items (cours) préférés sont déterminés par le nombre d'apprenants les plus proches ayant évalué le cours (popularité), et la moyennes de leurs évaluations explicites par:

$$C_pref(uc, c) = \beta * moy(uc, c) + (1 - \beta) * pop(uc, c) \quad (6)$$

Où, $moy(uc, c)$ est la moyenne des évaluations explicites faites par les membres du cluster uc pour le cours c , et elle est obtenue à partir de la matrice des centres de clusters UC , et $pop(c, t)$ est la popularité du cours c dans le cluster uc , calculée comme le nombre d'utilisateurs appartenant au cluster uc qui ont évalués le cours c . β est une variable utilisée pour ajuster le poids entre la moyenne des évaluations des items et la popularité de l'item.

Cette formule est basée uniquement sur les évaluations explicites. Pour appliquer cette formule dans le domaine de l'apprentissage amélioré par la technologie TEL, nous introduisons l'importance de la connaissance proposée dans [16]. Ainsi, la moyenne sera remplacée par une estimation de l'évaluation d'un cours en tenant compte de l'importance de la connaissance des apprenants qui ont évalué le cours;

$$e(uc, c) = \frac{1}{\mu} \sum_{u=1}^{FKNN} \bar{c}_u r_{u,c} \quad (7)$$

Où $\mu = \sum_{u=1}^{FKNN} \bar{c}_u$ est la somme des notes moyennes des tests, tel que $\bar{c}_u$ est calculé comme

$$\bar{c}_u = \frac{1}{S} \sum_{s=1}^S c_{u,s} \quad (8)$$

Où $c_{u,s}$ est la note obtenue par l'apprenant u dans le test s . $r_{u,c}$ est l'évaluation explicite de l'apprenant dans le cours c . Ainsi, la formule C_pref devient comme suit :

$$C_pref(uc, c) = \beta * e(uc, c) + (1 - \beta) * pop(uc, c) \quad (9)$$

Ensuite, un score est attribué à chaque item (cours), afin de classer les items en fonction des préférences du cluster et des préférences prédites de l'apprenant, avec la formule

$$Rank_{u,t} = \theta C_pref(uc, c) + (1 - \theta) \hat{r}(u, c) \quad (10)$$

Avec, $0 \leq \theta \leq 1$ est un facteur pour ajuster le poids.

La liste de recommandation à générer dans le cluster uc est choisie en sélectionnant les TOP-N items ayant les scores les plus élevés. Ensuite, les TOP-K items seront définis comme suit

$$K = z_{u,uc} * N \quad (11)$$


Où N est le nombre d'items sélectionnés dans le cluster uc et $z_{u,uc}$ est le degré d'appartenance de l'apprenant u à uc . La recommandation finale est formellement représentée comme suit :

$$\sum_{uc \in C-FNP(u)} TOP-K(uc, i) \quad (12)$$

5. Application: Expérience et Résultats

5.1. Moodle Dataset

Moodle¹ est une plateforme de logiciel d'apprentissage en ligne gratuite. En raison de l'absence d'ensembles de données accessibles au public pour l'apprentissage formel et non formel, nous avons utilisé une base de données très connue dans les SR, *BX-Book-Rating*² et nous considérons que chaque livre est une ressource d'apprentissage ou un cours. Nous avons limité notre validation à un sous-ensemble de cette base en sélectionnant seulement 21 apprenants, 20 cours et nous avons ajouté des informations sur le niveau de connaissance de l'apprenant, qui sont ses notes dans les tests, et nous l'avons intégré à notre technique dans la plateforme Moodle. Comme montré dans (Fig. 1).



¹ www.moodle.org

² www.informatik.uni-freiburg.de/~chiegler/BX/

Fig. 1 : Plateforme Moodle avec notre ensemble de données

5.2. Erreur absolue moyenne (MAE)

Nous choisissons l'erreur absolue moyenne (MAE) comme mesure d'évaluation pour calculer la performance de notre algorithme du FC.

$$MAE = \frac{\sum_{u \in U} |r_{u,c} - \hat{r}_{u,c}|}{|N|} \quad (13)$$

Comme nous sommes dans le domaine TEL, nous avons appliquée la métrique MAE adaptée au domaine de l'e-learning proposée par [16], afin de prendre en compte l'importance de la connaissance de l'apprenant (ses différentes notes de test). La nouvelle métrique est la suivante

$$MAE = \frac{1}{|k|} \sum_{k=1}^{|k|} r_{u,c} - [(1 - \alpha)]e_c + \alpha r_{u,c}; \quad 0 < \alpha < 1 \quad (14)$$

5.3. F1 métrique

Pour évaluer la performance de la recommandation Top-K, nous avons utilisé la métrique F_1

$$F_1 = \frac{2PR}{P+R} \quad (15)$$


Où P et R sont la précision et le rappel, respectivement et ils sont calculés comme

$$P = \frac{N_t}{N} , R = \frac{N_t}{N_p} \quad (16)$$

N: Le nombre total d'items; N_t : Nombre d'items pertinents trouvés et N_p : Nombre total d'items pertinents

5.4. Évaluation de la performance de la nouvelle technique du FC flou

Comme l'échantillon de données sur lequel nous avons appliqué notre algorithme est plus petit que celui utilisé par [16], nous ne pouvons donc pas les comparer. Comme Bobadilla dans [16], a utilisé quatre groupes de taille variant entre 15 et 90, et nous avons utilisé seulement trois groupes de taille comprise entre 5 et 10. Nous évaluons la performance en utilisant la nouvelle métrique MAE adaptée au domaine de l'e-learning. Les résultats sont montrés sur Fig. 2.


**Fig. 2 :** Performance MAE, petites valeurs signifie une meilleure performance

De la Figure (Fig. 2), Nous observons que l'erreur MAE a une relation inverse avec la taille des clusters K, et les différentes valeurs de α [0.3 - 0.8], respectivement, c.à.d. plus K et α sont grands; plus la valeur de MAE est faible. On a remarqué que dans presque tous les cas la nouvelle MAE est plus petite que l'erreur MAE traditionnelle, ce qui est dû à la soustraction des deux produits des valeurs sur l'axe des ordonnées.

Donc, la précision du système est meilleure quand la nouvelle métrique est appliquée, et cela est dû à la pondération favorable de la connaissance des utilisateurs.

5.5. Évaluation de la performance de la recommandation Top-K

La Figure (Fig. 3), ci-dessous montre l'évolution de la métrique F1 avec le nombre de cours recommandés.

**Fig. 3 :** Métrique F1

Nous observons sur la Figure 3 que la métrique F1 augmente jusqu'à 15 cours évalués. Les valeurs F1 varient en fonction du nombre d'items pertinents. On peut dire aussi à partir de la figure que la performance du système de recommandation est bonne.

6. Conclusion et Perspectives

Les systèmes de recommandation sont largement utilisés récemment dans le domaine de l'apprentissage amélioré par la technologie, ce qui crée le besoin de faire adapter ces systèmes à l'apprentissage en ligne. Pour cela, nous avons proposé dans cet article, une

nouvelle approche qui utilise un système de recommandation adapté au domaine de l'apprentissage amélioré par la technologie, surtout s'il s'agit d'une recommandation d'objets d'apprentissage appartenant à différents contextes. Les résultats expérimentaux ont montré que l'approche proposée et qui est adaptée au domaine de l'apprentissage amélioré par la technologie a amélioré la précision de la recommandation et a donné des résultats acceptables vu le nombre restreint des échantillons de test.

Comme perspective, nous envisageons l'utilisation d'un ensemble d'échantillons plus grand afin de tester encore mieux la faisabilité et l'efficacité du système.

Référence :

- [1] Burke R. (2002). Hybrid recommender systems: Survey and experiments, *User Modeling and User Adapted Interaction*, vol. 12, 4: 331-370.
- [2] Li-Tung Weng, Yue Xu Yuefeng Li, R. Nayak. 2008. Exploiting Item Taxonomy for Solving Cold-Start Problem in Recommendation Making. *Tools with Artificial Intelligence, ICTAI'08*, 20th IEEE International Conference, 2: 113-120.
- [3] S. Rendle, C. Freudenthaler, L. Schmidt-Thieme, (2010). Factorizing personalized Markov chains for next-basket recommendation, in *Proc. of the 19th IC on WWW*, ACM, 811-820.
- [4] Y. Koren, R. Bell, C. Volinsky, (2009). Matrix Factorization Techniques for Recommender Systems. *IEEE Computer Society Press* 42, 8: 30-37, ISSN 0018-9162
- [5] N. Manouselis, H. Drachsler, R. Vuorikari, H. Hummel, R. Koper, (2010): *Recommender Systems in Technology Enhanced Learning*, in the 1st RSs Handbook, Springer-Berlin,.
- [6] N. Manouselis and Hendrick, (2009). How Recommender Systems in Technology-Enhanced Learning depend on Context, In the 1st International Workshop on Context-Aware Middleware and Services, CAMS'.
- [7] Benmachiche, A., Bouhadada, T., Laskri M, T., Zendi, A. (2016). A dynamic navigation for autonomous mobiles robots, *iospress: Intelligent Decision Technologies*, ISSN 1875-8843 (E), Volume 10, Issue 1,
- [8] Belkin N.J., Croft W.B. (1992). Information filtering and information retrieval: two sides of the same coin?, *Communication of the ACM*, vol. 35, 12: 29-38,
- [9] Chen G., Wang F., Zhang C. (2009). Collaborative Filtering Using Orthogonal Nonnegative Matrix Tri-factorization. *Journal of Information Processing and Management*, Volume 45,
- [10] Makhoulf A. Lazli L. Bensaker B. (2016). Structure evolution of Hidden Markov Models FOR Audiovisual Arabic Speech recognition, *Inter. Journal of signal and Imaging Systems Engineering, IJSISE*, 9(1): 55-66.
- [11] Maâtallah M. and Seridi H. (2010) "A Fuzzy Hybrid Recommender System, the 1st International Conference on Machine and Web Intelligence, ICMWI'10.
- [12] C. Bezdek. (1973). Fuzzy mathematics in pattern classification. ph.D. dissertation. Cornell Univ.. Ithaca, NY,
- [13] Wu J. and Li T. (2008). A modified fuzzy C-means algorithm for collaborative filtering. *Proc. of the 2nd KDD Workshop on Large-Scale RSs and the NPC*, ACM New York,.
- [14] H. Drachsler, H. G. K. Hummel, R. Koper. (2010). Identifying the Goal, User model and Conditions of Recommender Systems for Formal and Informal Learning, *Journal of DI* 10.
- [15] E.Garcia, C.Romero, S.Ventura, C.D.Castro, (2009). An architecture for making recommendations to courseware authors using association rule mining and collaborative filtering, *User Modeling and User-Adapted Interaction*, Vol 19(1-2),
- [16] J. Bobadilla, F. Serradilla, A. Hernando, (2009). Collaborative filtering adapted to recommender systems of e-learning, *Knowledge-Based Systems*, *Journal of KBS*, vol 22 (4).
- [17] N. Soonthornphisaj, E. Rojsattarat, S. Yim-ngam, (2006). Smart E-Learning Using Recommender System, *International Conference on Intelligent Computing*, 518-523,
- [18] L. Ge, W. Kong, J. Luo, (2006). Courseware Recommendation in E-Learning System, *International Conference on Web-based Learning (ICWL' 06)*, 10-24,
- [19] Nguyen Thai-Nghe, Lucas Drumond, Artus Krohn-Grimberghe, Lars Schmidt-ThiemeThay. 2010. Recommender System for Predicting Student Performance, 1st Workshop on RSs for TEL, *Procedia Computer Science*, Elsevier,
- [20] G.-R. Xue, C. Lin, Q. Yang, W. Xi, H.-J. Zeng, Y. Yu, and Z. Chen. 2005. Scalable collaborative filtering using cluster-based smoothing. In *Proc. of SIGIR*,
- [21] Amy Langville, Carl Meyer, Russell Albright, James Cox and David Duling, 2006. Algorithms, Initializations, and Convergence for the Nonnegative Matrix Factorization, *KDD*
- [22] James M.Keller, Michael R.Gray, James A.Givens, JR, 1985. A Fuzzy Nearest Neighbor Algorithm, *IEEE Transaction on Systems,Man and Cybernetics*,VOL.SMC-15.
- [23] J. Wang, A. P. de Vries, and M. J. T. Reinders. 2006. Unifying user-based and item-based collaborative filtering approaches by similarity fusion. In *Proc. of SIGIR*,