

# Comprendre les usages et effets d'un système de recommandations pédagogiques en contexte d'apprentissage non-formel

Anaëlle Badier, Mathieu Lefort, Marie Lefevre

Univ Lyon, UCBL, CNRS, INSA Lyon, LIRIS, UMR5205,  
F-69622 Villeurbanne, France  
`prenom.nom@liris.cnrs.fr`

**Résumé.** Nos travaux se situent dans un contexte d'apprentissage non-formel sur application mobile où nous avons proposé un moteur de recommandation de ressources pédagogiques. Les apprenants concernés ont des objectifs et modalités de travail très variés. Dans cet article, après avoir rappelé le fonctionnement de notre moteur de recommandations, nous analysons les traces d'utilisation de plus de 10 000 apprenants sur 4 mois, montrons que les recommandations répondent à des objectifs et des usages différents, et que leur suivi influe positivement sur l'expérience d'apprentissage.

**Mots-clés :** Recommandations pédagogiques , Analyse de Traces , Analyse d'usages et de pratiques , Apprentissage auto-régulé

**Abstract.** Our work takes place in a non-formal learning context on a mobile application in which we propose an educational recommendation system. Our learners have very different objectives and learning behaviours. In this article, after having briefly explained the recommendation system, we analyze the learning traces of more than 10,000 learners over 4 months, show that the recommendations meet different objectives and uses, and that following them has a positive impact on the learning experience.

**Keywords:** Pedagogical Recommendations , Traces Analysis , Usage and Practice Analysis , Self-Regulated Learning

Le nombre croissant des applications et plateformes de e-learning depuis plusieurs décennies a conduit à de nouvelles formes d'apprentissage. Les apprenants sont de plus en plus amenés à travailler par eux-mêmes en recherchant des contenus d'apprentissage hors de la classe. Dans ce contexte, nous travaillons avec une application mobile parascolaire qui propose des contenus de révision pour tous les niveaux scolaires et toutes les disciplines, y compris les enseignements professionnels ou de spécialités. Au sein de cette application, la navigation est libre et l'utilisation n'est pas encadrée. De ce fait, les apprenants l'utilisent comme

un outil de micro-apprentissage, avec un travail occasionnel, non régulier et des sessions de travail très courtes.

Nous pensons que la mise en place d'un système de navigation guidée personnalisée au sein de l'application peut améliorer l'expérience utilisateur. Pour ce faire, nous avons implémenté un système de recommandations pour les Mathématiques du Collège au Lycée, pédagogiquement validé par des experts et utilisé par les apprenants [1]. Dans cet article, nous nous intéressons à l'expérience utilisateur avec ce système au travers des questions de recherche suivantes :

**Q1- Quels facteurs influencent le suivi des recommandations par les apprenants dans un contexte parascolaire ?**

**Q2 - Quels usages des recommandations pouvons-nous observer dans une application parascolaire ?**

Après avoir brièvement rappelé le fonctionnement du système de recommandation présenté dans l'application et l'avoir positionné au regard des travaux du domaine (section 1), nous présentons le cadre d'expérimentation et de recueil des données d'utilisation (section 2). Dans cette étude exploratoire, nous analysons ensuite selon plusieurs critères les recommandations suivies par les apprenants parmi celles proposées (section 3) et finissons notre étude sur les modifications observées dans l'expérience d'apprentissage (section 4). Les résultats présentés sont discutés dans la section 5.

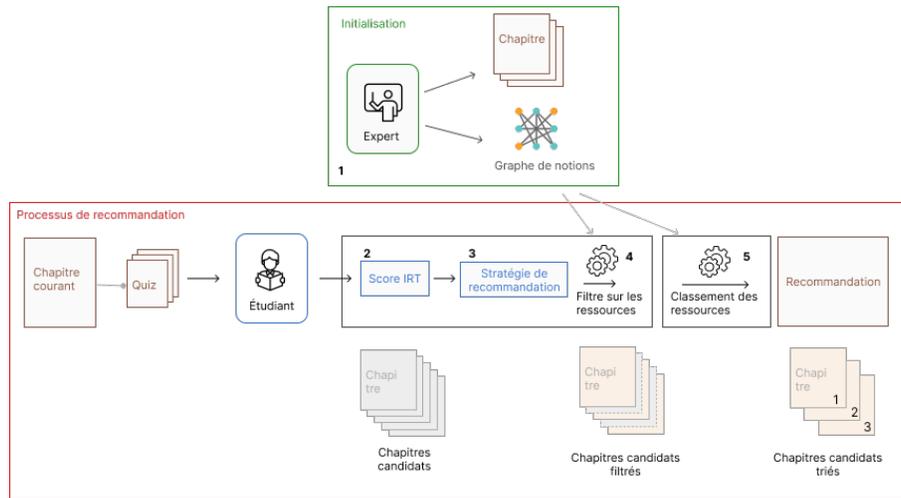
## 1 Recommander en contexte d'apprentissage non-formel

L'application mobile avec laquelle nous travaillons organise les ressources pédagogiques au sein de disciplines (Mathématiques, Français, Anglais...), elles-même subdivisées en chapitres (Arithmétique, Droites du plan, Fonctions de références...). Au sein de chaque chapitre, l'élève a à disposition des mini-cours (1 à 5), des fiches de révision et 4 quiz de 5 questions au format QCM. Nous proposons un moteur de recommandations pour accompagner l'élève de chapitres en chapitres. Considérant un étudiant qui travaille sur un chapitre donné (*Chapitre d'entrée*), nous recommandons une petite liste de chapitres (*Chapitres recommandés*) parmi les chapitres disponibles dans l'application. Selon la classification de Brusilovsky [5], il s'agit d'un système de support de navigation adaptatif. Le fonctionnement général du système est présenté sur la figure 1. Pour proposer des recommandations et accompagner l'apprenant dans son utilisation de l'application, le système est basé sur 3 modules : un **Module Pédagogique**, un **Module Historique** et un **Module Nouveauté**.

### 1.1 Sélection et classement pédagogiques des ressources

Le **Module Pédagogique** décrit dans [1] sélectionne une stratégie de recommandation (3 sur la figure 1), filtre les *Chapitres Candidats* selon cette stratégie d'apprentissage (4) et calcule un score de pertinence pédagogique pour classer les chapitres et recommander les meilleurs (5).

## Usages de recommandations en contexte non-formel



**FIG. 1.** Fonctionnement global du système de recommandations. Les étapes numérotées sont référencées et expliquées ci-dessous.

Les chapitres disponibles dans l'application sont organisés dans un graphe de notions (1). D'autres travaux organisent leurs ressources avec des approches axées compétences comme dans le projet ComPer [16] ou utilisent des ontologies [9]. Dans notre cas, nous ne recommandons que les ressources internes à l'application, qui sont étiquetées avec des notions clés par les professeurs concepteurs de ces ressources. Nous appelons *notion* une composante de savoir abordée dans un chapitre. Une notion est étiquetée comme *prérequise* au chapitre si l'apprenant doit avoir déjà rencontré cette notion précédemment pour aborder le chapitre en question. Une notion est attendue si le chapitre permet de découvrir cette notion ou d'aller plus loin dans sa maîtrise. Avec ce système de notions clés, les chapitres sont liés les uns aux autres. Un chapitre est d'autant plus proche d'un autre qu'il partage des notions spécifiques en commun.

Nous définissons 3 stratégies de recommandations : révision, continuité et approfondissement. Ces stratégies sont assignées à l'apprenant à la fin de l'étude de chaque chapitre selon sa maîtrise du chapitre terminé. Plusieurs systèmes de recommandation se basent sur le concept de Zone Proximale de Développement (ZPD) [20] pour attribuer des ressources à des apprenants basées sur le niveau de difficulté de la ressource et le niveau de compétence estimé de l'apprenant [3]. D'autres approches utilisent les Modèles de Traçage de Connaissances (*Knowledge Tracing Models, KTM*) pour modéliser le niveau de connaissance d'un apprenant et lui recommander du contenu adapté. Parmi ces *KTM*, on peut citer le *Bayesian Knowledge Tracing, BKT* de Corbett et Anderson [8] ou d'autres systèmes *KTM* comme ceux de Vie et Kashima pour prédire la performance des apprenants dans le cadre des MOOCs [18]. Dans notre cas, nous estimons le niveau de maîtrise d'un chapitre à partir des quiz effectués par l'élève

dans ce chapitre. En utilisant le modèle de la théorie de réponse à un item (*Item Response Theory, IRT*) développé par Baker [2], nous calculons un score  $\theta$  qui représente le niveau de maîtrise des quiz, et par extension du chapitre (2). Nous définissons 3 groupes de niveaux selon le score  $\theta$  et attribuons les stratégies de recommandation selon ces groupes (3). Les stratégies étant ainsi définies, et recalculées pour chaque élève à chaque nouveau chapitre, nous filtrons les chapitres éligibles à la recommandation (4). Nous calculons ensuite un score de pertinence pédagogique (cf. équation 1) pour chaque chapitre éligible, basé sur les notions en commun ( $score_{similarite}$ ) et la distance ( $penalite_{distance}$ ) au niveau scolaire du chapitre courant, ce qui permet de classer les chapitres éligibles (5). Les détails du filtrage et du calcul du score pédagogique sont présentés dans l'article [1]. Les recommandations fournies par ce système ont été validées par les experts pédagogiques et sont utilisées par les apprenants.

$$score_{pedagogique} = score_{similarite} * (1 - penalite_{distance}) \quad (1)$$

**Prendre en compte l'historique de l'apprenant.** Le système de recommandation étant limité à l'application parascolaire, les seules données *a priori* sur les connaissances des étudiants sont les items explorés au sein de l'application, particulièrement les quiz faits et les résultats obtenus. Nous n'avons aucune information sur les chapitres étudiés en classe. Pour maintenir une variété dans l'activité au sein de l'application, nous ne souhaitons pas recommander des chapitres déjà récemment étudiés et maîtrisés par l'apprenant. Pour cette raison, le **Module Historique** est basé sur deux composantes : la complétion des chapitres candidats et la note obtenue sur ces chapitres. Le module historique évolue avec le temps. En effet, la dimension temporelle est un facteur important dans de nombreux systèmes de recommandation : Choffin *et al.* ont étudié l'effet de la répétition sur l'apprentissage et l'oubli [6], et Jiang *et al.* utilisent un modèle de réseau de neurones LSTM pour inclure un paramètre d'oubli [12]. La distribution de la rétention mémorielle au cours du temps, décrite par Ebbinghaus [10] a été utilisée dans de nombreux travaux depuis [19]. Nous introduisons dans notre module historique un facteur de rétention  $w_t$ , calculé à partir de l'allure de la courbe d'oubli d'Ebbinghaus, mais adaptée pour notre contexte d'usage non régulier : dans notre cas, la courbe d'oubli estime une rétention de 70% après 7 jours, diminuée à 12% après 30 jours. Le score du module historique est calculé avec l'équation 2.

$$score_{historique} = 1 - [w_t * score_{completion} * score_{note}] \quad (2)$$

avec  $w_t \in [0, 1]$  le facteur de rétention,  $score_{completion} \in [0, 1]$  le ratio de quiz terminés dans le chapitre candidat et  $score_{note} \in [0, 1]$  la note moyenne sur les quiz terminés dans le chapitre candidat.

Avec ce module, nous prenons en compte les ressources déjà étudiées sur l'application. Nous nous autorisons toutefois à recommander du contenu non terminé ou non maîtrisé, ou étudié longtemps avant la recommandation, en supposant qu'un rappel de ces chapitres peut être bénéfique. Ce module intervient dans la partie classement des ressources (5 sur la figure 1).

**Encourager la curiosité en variant les recommandations.** Notre système de recommandation est appliqué à un contexte d'apprentissage non formel. Pour permettre un renouvellement de l'offre de recommandations et palier un effet de lassitude, nous introduisons un **Module Nouveauté**. Oudeyer *et.al* ont démontré que la curiosité et la nouveauté sont importants pour améliorer l'apprentissage et la rétention de l'information [14]. La sérendipité est également un critère notable pour rendre les recommandations attractives [23]. Comme pour le module historique, nous conservons un facteur temporel pour nous permettre de recommander des ressources déjà proposées longtemps auparavant. Pour limiter le nombre de paramètres dans le modèle dans un premier temps, et sans études approfondies sur l'évolution de la rétention mémorielle dans un contexte de navigation sur application mobile, nous posons que le facteur temporel  $w_t$  est identique à celui utilisé dans le module historique. Le score de nouveauté est calculé avec l'équation 3. Ainsi, une ressource déjà fortement recommandée se retrouve pénalisée dans son score de nouveauté. Ce module intervient dans la partie classement des ressources (5 sur la figure 1).

$$score_{nouveaute} = 1 - [w_t * \frac{1}{n} \sum_{i=1}^n \frac{3 - k_i}{3}] \quad (3)$$

avec  $n$  le nombre de fois où le chapitre a été recommandé,  $t$  la dernière fois que le chapitre a été recommandé et  $k_i \in [0, 3[$  le rang de la ressource dans le top-3 des recommandations proposées (0 étant le meilleur) la  $i^e$  fois.

Pour paramétrer notre modèle de recommandations et faire le classement (5), nous décidons de donner plus d'importance au module pédagogique, puis au module historique et enfin au module nouveauté. Cette initialisation manuelle des poids initiaux de l'équation 4, semblable a ce qui a pu être fait par Zhao *et.al* [22], est discuté dans la section 5.

$$score_{reco} = 0.5 * score_{pedagogique} + 0.4 * score_{historique} + 0.1 * score_{nouveaute} \quad (4)$$

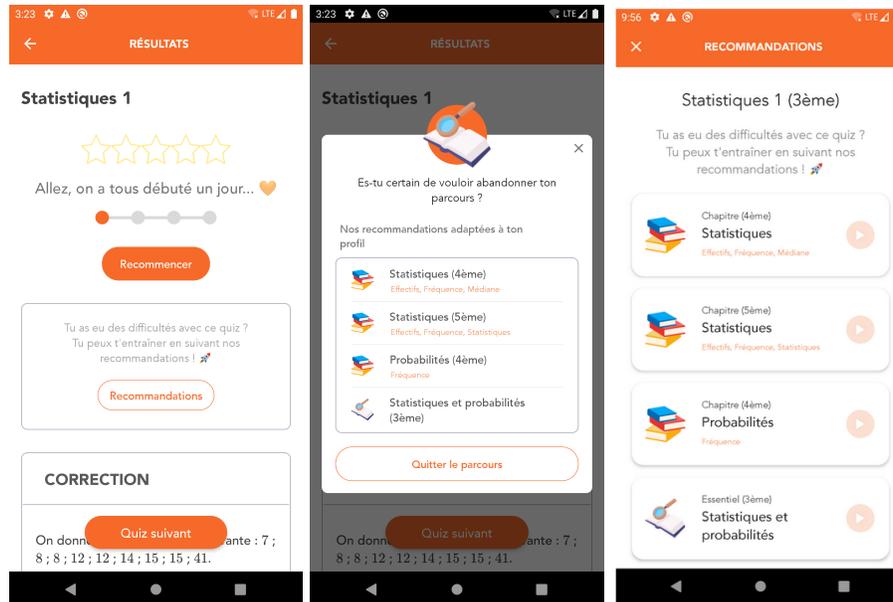
## 2 Protocole d'évaluation

De nombreux systèmes de recommandation sont utilisés et évalués en classe [15,17,21], ou avec des étudiants simulés virtuellement [7] pour disposer d'une quantité de données suffisante pour entraîner les modèles d'apprentissage, ce qui n'est pas notre cas. En raison de notre contexte et pour comprendre les besoins et comportements de nos apprenants, nous évaluons directement le système dans les conditions réelles d'utilisation. Le principal inconvénient de ce système de validation "en vie réelle" est la difficulté de collecte de données comme souligné par Erdt *et. al* [11]. Cette difficulté est accentuée dans les contextes d'apprentissage auto-régulés, puisque les apprenants peuvent quitter à tout moment la plateforme d'apprentissage.

Le moteur de recommandation a été implémenté pour la discipline Mathématiques, pour les niveaux scolaires de la 6<sup>e</sup> à la Terminale générale. Il a été mis à la disposition de tous les nouveaux apprenants pour une durée de 1 mois à

partir de leur date d'inscription sur l'application. Les recommandations ont été proposées *via* 3 points d'entrée :

- *Quiz échoué*. Si l'apprenant échoue totalement à l'un des quiz de 5 questions du chapitre, un bouton lui propose d'accéder directement à des recommandations de révision.
- *Parcours interrompu*. Les apprenants sont incités à travailler avec 4 quiz de 5 questions. Si un apprenant interrompt son parcours, une fenêtre propose de continuer à travailler avec des recommandations dont la stratégie a été attribuée selon les réponses déjà données.
- *Fin du parcours*. Les recommandations sont affichées sur la page de résultat à la fin du parcours de 4 quiz et dépendent des notes obtenues sur ces 4 quiz.



**FIG. 2.** Interface de recommandations pour le chapitre *Statistiques* de niveau 3ème pour la stratégie révision. À gauche, par le point d'entrée quiz échoué, au milieu le cas d'un parcours interrompu et à droite l'interface de fin du parcours. Le niveau scolaire des chapitres recommandés est affiché entre parenthèses. Les notions en commun avec le chapitre actuel sont indiquées en orange. Le contenu "Essentiel" ne fait pas partie du système de recommandation présenté dans le cadre de cet article.

L'interface de présentation des recommandations est présenté sur la figure 2. Pour analyser l'utilisation faite par les apprenants des recommandations proposées, nous mettons en place un mécanisme de collecte des traces d'apprentissage spécifique. Semblable au système xAPI utilisé dans plusieurs travaux [13,4], chaque action de l'utilisateur est identifiée et stockée en base. Nous pou-

vons ainsi identifier les actions de *Vue de l'interface de recommandations*, *Clic sur une recommandation de l'interface*, *Quitter l'interface de recommandations* mais également des événements plus génériques comme *Connexion à l'application*, *Quiz commencé*, *Mini-cours consulté*, ... avec les informations de contexte associées : niveau scolaire de l'apprenant, discipline de la ressource, identifiant de la session de travail correspondante, heure de la consultation de la ressource, etc. Les apprenants sont anonymisés et leur identité n'est pas stockée dans les bases de données d'analyse de traces pour des raisons de protection des données. Nous présentons dans les sections suivantes les résultats observés pendant la période du 07 septembre 2022 au 07 janvier 2023.

### 3 Choix des recommandations par les apprenants

Nous avons collecté les traces d'utilisations de 11 962 apprenants ayant été confrontés au moins une fois à une recommandation, ce qui représente 39 420 traces de recommandation vues, dont 5 609 recommandations suivies par 3 448 apprenants. Pour répondre à notre première question de recherche sur les facteurs influençant le suivi des recommandations, nous avons analysé les données selon plusieurs critères.

**TABLE 1.** Influence de la source de la recommandation sur la décision de suivi (test du Chi-2 de Pearson.  $\chi^2 = 2714.6$ ,  $df=2$ ,  $V = 0.3$ ,  $p_{value} < 2.2e - 16$ ).

Point d'entrée	Recommandation <i>effectifs observés (résidus)</i>	
	Choisie	Rejetée
Quiz échoué	904 (+34.9)	1202 (-14.2)
Parcours interrompu	1724 (-26.6)	21041 (+10.8)
Fin du parcours	2981 (+20.0)	11568 (-8.2)

Le premier critère étudié est le point d'entrée de l'affichage des recommandations. Les résultats présentés sur le tableau 1 montrent que les recommandations sont plus suivies dans un contexte de quiz échoué (résidus +34.9) ou de parcours terminé (résidus +20). Les recommandations issues de parcours interrompus sont plus rejetées que les autres (résidus -26.6).

Le second critère est l'influence de la stratégie de recommandation appliquée sur le choix de suivre ou non une recommandation. Les résultats sont présentés tableau 2. Nous constatons que les recommandations associées à la stratégie de révision ont tendance à être plus suivies (résidus +10.9) que les stratégies de continuité ou d'approfondissement.

Ces premières analyses montrent que le suivi des recommandations dépend du moment où elles sont proposées (quiz échoué, fin du parcours) et qu'elles sont davantage adoptées lorsqu'elles proposent des contenus de révision.

**TABLE 2.** Influence de la stratégie de recommandation sur la décision de suivi (test du Chi-2 de Pearson,  $\chi^2 = 207.19$ ,  $df=2$ ,  $V = 0.1$ ,  $p_{value} < 2.2e - 16$ ).

Stratégie	Recommandation <i>effectifs observés (résidus)</i>	
	Choisie	Rejetée
Révision	1682 (+10.9)	7384 (-4.4)
Continuité	1815 (-7.6)	13431 (+3.1)
Approfondissement	2112 (-0.8)	12996 (+0.3)

#### 4 Effets des recommandations sur l'expérience d'apprentissage

Après avoir identifié certains critères de sélection des recommandations, et afin de traiter notre deuxième question de recherche adressant les usages observés des recommandations, nous étudions les activités réalisées au sein des chapitres recommandés suivis. Pour cela, nous reprenons les 5 609 traces des 3 448 étudiants ayant suivi au moins une fois une recommandation et observons les activités effectuées au sein du chapitre qu'ils ont choisi. Les résultats sont présentés dans le tableau 3.

**TABLE 3.** Activités réalisées au sein des chapitres pour les ressources recommandées et suivies. Une recommandation suivie peut à la fois mener à une activité de quiz commencé, quiz terminé et cours consulté (total > 100%).

Activité dans le chapitre suivi	Nombre de recommandations concernées N=5609
Aucune activité	1813 (32.3%)
Au moins 1 cours consulté	1668 (29.7%)
Au moins 1 quiz commencé	3061 (54.6%)
Au moins 1 quiz commencé et terminé	2027 (36.1%)

Au sein de chaque chapitre, l'apprenant peut étudier 2 ressources différentes : les quiz et les cours. Nous constatons que 32.3% des recommandations suivies n'ont débouché sur aucune activité dans le chapitre suivi : soit parce que la recommandation n'a pas correspondu aux attentes des apprenants, ou parce qu'ils ont suivi les recommandations uniquement par curiosité. On pourrait qualifier les recommandations suivies sans activité consécutive dans le chapitre consulté de *suivi consultatif*. Dans la majorité des cas, la recommandation suivie a mené à une réelle activité : les apprenants ont commencé au moins 1 un quiz ou consulté au moins 1 cours (*suivi partiel*) et dans 29.7% ils ont terminé au moins un quiz du chapitre suivi (*suivi approfondi*).

Au-delà de l'activité au sein d'une recommandation suivie, nous nous interrogeons sur l'impact du suivi des recommandations dans l'expérience d'apprentissage. Dans notre contexte d'utilisation volontaire et parascolaire, nous ne cherchons pas à obtenir des gains d'apprentissage mais plutôt des évolutions de comportements de travail avec l'application. Pour qualifier l'expérience d'apprentissage, nous utilisons les indicateurs de *nombre de sessions de travail*, *durée des sessions de travail*, *nombre de quiz commencés*, *nombre de quiz terminés*, *nombre de cours consultés*, *temps moyen de lecture des cours*. Une *session de travail* est définie comme l'ensemble des activités enregistrées dans l'application entre l'ouverture et la fermeture de cette dernière. Un apprenant peut avoir plusieurs sessions de travail dans une même journée.

Nous avons récolté les données de sessions complètes de 1126 apprenants ayant suivi au moins une fois des recommandations, et ayant commencé au moins un quiz de mathématiques, pour comparer l'expérience d'apprentissage entre des sessions avec suivi et sans suivi des recommandations. À l'aide d'un test de Student apparié sur chacun des indicateurs, nous étudions l'impact du suivi des recommandations sur l'expérience d'apprentissage au sein de l'application. Les résultats sont présentés sur le tableau 4.

**TABLE 4.** Comparaison par test de Student des indicateurs d'apprentissage entre des sessions avec ou sans suivi des recommandations. (\*\**pvalue* < 0.001, \**pvalue* < 0.05)

Indicateurs par membre	Sessions avec suivi N=1471	Sessions sans suivi N=6222	pvalue
Nombre de sessions	1.31	5.53 ***	<2.2e-16
Temps moyen de session (min)	11.06 ***	6.72	<2.2e-16
Nombre moyen de quiz commencés par session	3.97 ***	2.28	<2.2e-16
Nombre moyen de quiz terminés par session	3.27 ***	1.85	<2.2e-16
Nombre moyen de cours consultés par session	3.01 ***	1.67	<2.2e-16
Temps moyen de lecture des cours par session (sec)	49.4 *	37.9	0.02

Nous constatons que les sessions avec suivi d'une ou plusieurs recommandations sont des sessions de travail plus actives. Les apprenants travaillent presque deux fois plus longtemps, même si nous restons dans un contexte de micro-learning. Ils font également plus de quiz, et lisent plus de cours. La conclusion de cette analyse peut être de deux natures : les recommandations encouragent l'apprenant à travailler plus, ou bien lorsque l'apprenant décide de consacrer un temps d'étude plus approfondi avec l'application, il aura tendance à suivre davantage les recommandations proposées. Dans les deux cas, notre système a

un impact positif en proposant une nouvelle expérience d'apprentissage dans l'application.

## 5 Discussion

**Construction du système.** Nous avons fait le choix de paramétrer le système en construisant le score de recommandation (équation 4) avec de premières valeurs arbitraires en priorisant le score pédagogique (0.5), puis historique (0.4) et d'accorder peu de poids au score de nouveauté (0.1). Des *ablation studies* auraient été nécessaires pour évaluer précisément l'impact de chacun des modules dans le classement des ressources et le choix des apprenants. De même, le choix de la modélisation du temps avec le paramètre  $w_t$  peut être discuté. Des études plus poussées pourraient faire varier ce paramètre pour étudier sa pertinence dans un contexte d'apprentissage sur application mobile. Dans un contexte d'apprentissage parascolaire avec très peu de régularité d'utilisation, nous avons choisi de mener en premier lieu une démarche exploratoire afin d'étudier l'adéquation d'un tel système à notre contexte. Le système a donc été préalablement initialisé pour collecter rapidement de premières données d'utilisation et comprendre les comportements des apprenants.

**Influence du suivi sur l'expérience d'apprentissage.** Dans un contexte d'utilisation parascolaire et non formel du système de recommandation, il est difficile de comprendre les motivations qui poussent les apprenants à utiliser l'application et nos recommandations d'une certaine manière. Les recommandations semblent être adoptées par les apprenants dans certains contextes (quiz échoué, stratégie de révision) mais moins dans d'autres (parcours interrompu, stratégie d'approfondissement). Quand on s'intéresse à l'influence du suivi des recommandations sur l'expérience d'apprentissage, le tableau 4 montre que le nombre de cours consultés est supérieur pour les sessions avec suivi de recommandations, mais que le temps de lecture n'est que très légèrement supérieur. Nous pouvons poser l'hypothèse que l'apprenant survole les recommandations en passant rapidement sur le contenu recommandé mais sans s'y attarder. En effet, les temps de sessions très courts témoignent bien du caractère très accessoire de l'application qui est utilisée comme un outil support et non comme la première source d'apprentissage. Ce comportement "exploratoire" dans le suivi des recommandations est illustré par le tableau 3 avec des recommandations suivies mais dont les activités pédagogiques relatives ne sont pas systématiquement exploitées. Nous avons choisi d'analyser le comportement des apprenants par le prisme de certains critères et indicateurs, de par le contexte totalement libre de cette forme d'apprentissage, plusieurs autres critères auraient pu être pertinents pour poursuivre l'analyse.

## 6 Conclusion et Perspectives

Dans cet article nous avons étudié la mise en place d'un moteur de recommandation adapté à un contexte d'apprentissage non formel sur application mobile.

Les recommandations, construites à partir de trois modules (Pédagogique, Historique et Nouveauté), sont présentées aux apprenants à différents moments de leur parcours de travail, et s'articulent autour de 3 stratégies : révision, continuité et approfondissement. Nous avons analysé les traces d'apprentissage et montré que les apprenants utilisent principalement les recommandations du système dans la stratégie de révision, prioritairement lorsqu'ils ont échoué à un quiz ou terminé l'étude du chapitre en cours. Nous avons également mis en évidence différentes modalités de suivi des recommandations (consultatif, partiel ou approfondi) et avons montré que les sessions de travail avec suivi des recommandations étaient plus riches que celles sans suivi. En effet, le temps de session ainsi que le nombre de quiz commencés, terminés et la consultation des cours sont significativement supérieurs dans les sessions avec suivi que dans celles sans suivi des recommandations.

Cette première étude donnant des résultats prometteurs, nous allons poursuivre les analyses du moteur de recommandation appliqué à d'autres disciplines, pour lequel le système est déjà implémenté mais pas encore rendu accessible aux apprenants.

Notre première question de recherche s'intéressait à la sélection des recommandations proposées par les apprenants. Nous allons approfondir l'analyse avec d'autres indicateurs pouvant influencer cette sélection, par exemple l'affichage ou non du niveau scolaire dans les recommandations. En lien avec la première étude publiée dans [1], nous allons examiner si ces critères de sélection sont communs à tous les apprenants, ou varient en fonction des publics.

Notre seconde question de recherche posait la question de l'influence du suivi des recommandations sur l'expérience d'apprentissage. Ayant observé différents niveaux de suivi, dans la suite de nos travaux, nous chercherons à comprendre le comportement de deux publics cibles : ceux qui ne consultent jamais les recommandations proposées et ceux qui ne restent qu'en suivi consultatif. Cette meilleure compréhension permettrait peut-être de leur proposer des recommandations plus pertinentes.

## Références

1. Badier, A., Lefort, M., Lefevre, M. : Recommendation model for an after-school e-learning mobile application. In : Proceedings of CSEDU 15th (2023)
2. Baker, F.B. : The Basics of Item Response Theory. ERIC Clearinghouse on Assessment and Evaluation (2001)
3. Baker, R., Ma, W., Zhao, Y., Wang, S., Ma, Z. : The results of implementing zone of proximal development on learning outcomes. In : The 13th International Conference on Educational Data Mining (2020)
4. Branthôme, M. : Pyrates : A Serious Game Designed to Support the Transition from Block-Based to Text-Based Programming. In : EC-TEL. vol. 13450, pp. 31–44 (2022)
5. Brusilovsky, P., Peylo, C. : Adaptive and Intelligent Web-based Educational Systems. International Journal of Artificial Intelligence in Education (2003)

6. Choffin, B., Popineau, F., Bourda, Y., Vie, J.J. : DAS3H : Modeling Student Learning and Forgetting for Optimally Scheduling Distributed Practice of Skills. In : Junior Conference on Data Science and Engineering (2019)
7. Clément, B., Roy, D., Oudeyer, P.Y., Lopes, M. : Multi-Armed Bandits for Intelligent Tutoring Systems. *Journal of Educational Data Mining* pp. 20–48 (2015)
8. Corbett, A.T., Anderson, J.R. : Knowledge tracing : Modeling the acquisition of procedural knowledge. In : *Proceedings of UMUAI*. pp. 253–278 (1994)
9. De Maio, C., Fenza, G., Gaeta, M., Loia, V., Orciuoli, F., Senatore, S. : RSS-based e-learning recommendations exploiting fuzzy FCA for Knowledge Modeling. *Applied Soft Computing* pp. 113–124 (2012)
10. Ebbinghaus (1885), H. : Memory : A Contribution to Experimental Psychology. *Annals of Neurosciences* pp. 155–156 (2013)
11. Erdt, M., Fernandez, A., Rensing, C. : Evaluating Recommender Systems for Technology Enhanced Learning : A Quantitative Survey. *IEEE Transactions on Learning Technologies* pp. 326–344 (2015)
12. Jiang, W., Pardos, Z.A., Wei, Q. : Goal-based Course Recommendation. In : *LAK 9th*. pp. 36–45 (2019)
13. Nikolayeva, I., Martin, B., Yessad, A., Chenevotot, F., Pilet, J., Prévité, D., Grugeon-Allys, B., Luengo, V. : How to Help Teachers Adapt to Learners? Teachers' Perspective on a Competency and Error-Type Centered Dashboard. In : *13th EC-TEL*. pp. 596–599 (2018)
14. Oudeyer, P.Y., Gottlieb, J., Lopes, M. : Intrinsic motivation, curiosity, and learning. In : *Progress in Brain Research*, vol. 229, pp. 257–284. Elsevier (2016)
15. Sablayrolles, L., Lefevre, M., Guin, N., Broisin, J. : Design and Evaluation of a Competency-based Recommendation Process. In : *Proceedings of ITS* (2022)
16. Venant, R., Teyssie, C., Marquié, D., Vidal, P., Broisin, J. : A Competency-Based Model to Bridge the Gap between Academic Trainings and Industrial Trades. In : *15th International Conference on Advanced Learning Technologies* (2015)
17. Venant, R., Sharma, K., Dillenbourg, P., Vidal, P., Broisin, J. : A Study of Learners' Behaviors in Hands-On Learning Situations and Their Correlation with Academic Performance. In : *AIED*. vol. 10331 (2017)
18. Vie, J.J., Kashima, H. : Knowledge Tracing Machines : Factorization Machines for Knowledge Tracing. In : *Proceedings of the AAAI Conference on AI* (2019)
19. Vlach, H.A., Sandhofer, C.M. : Distributing Learning Over Time : The Spacing Effect in Children's Acquisition and Generalization of Science Concepts. *Child Development* pp. 1137–1144 (2012)
20. Vygotskiï, L.S., Cole, M. : *Mind in Society : The Development of Higher Psychological Processes*. Harvard University Press (1978)
21. Yanes, N., Mohamed Mostafa, A., Ezz, M., Naif Almuayqil, S. : A Machine Learning-Based Recommender System for Improving Students Learning Experiences. *IEEE Access* **8**, 201218–201235 (2020)
22. Zhao, Z., Hong, L., Wei, L., Chen, J., Nath, A., Andrews, S., Kumthekar, A., Sathiamoorthy, M., Yi, X., Chi, E. : Recommending what video to watch next : A multitask ranking system. In : *Proceedings of the 13th ACM Conference on Recommender Systems*. pp. 43–51 (2019)
23. Ziarani, R.J., Ravanmehr, R. : Serendipity in Recommender Systems : A Systematic Literature Review. *Journal of Computer Science and Technology* (2021)