

Modèle de recommandation stochastique et de raisonnement à partir de cas appliqué à l'EIAH AI-VT

Daniel Soto-Forero¹[0000-0003-0753-4673], Marie-Laure
Betbeder¹[0000-0002-8103-4098], and Julien Henriet¹[0000-0002-7671-4574]

DISC, Université Marie et Louis Pasteur, CNRS, Institut FEMTO-ST 16 Route de
Gray, 25000, Besançon, France

Résumé Cet article présente l'intégration d'un modèle de recommandation fondé sur l'échantillonnage de Thompson (ET) à un modèle multi-agent associé au raisonnement à partir de cas (ESCBR-SMA). Le modèle intégré est utilisé pour améliorer l'adaptation en temps réel d'un environnement informatique pour l'apprentissage humain (EIAH) appelé AI-VT. Il a été évalué à partir de deux bases de données d'apprenants afin de prédire les notes d'exercices de différents niveaux de complexité selon trois scénarios prédéfinis. Nous avons comparé l'algorithme de recommandation et l'intégration de l'algorithme de recommandation avec l'algorithme de prédiction en évaluant l'évolution de l'acquisition des connaissances de chaque apprenant. Les mesures effectuées permettent de déterminer la précision de la prédiction pour chaque apprenant et chaque niveau de complexité. Les résultats montrent que l'intégration de l'adaptation stochastique et de la prédiction avec le paradigme du raisonnement à partir de cas permet d'obtenir une meilleure identification des faiblesses des apprenants et donc une meilleure recommandation de parcours personnalisé pour l'apprenant.

Keywords: Environnement Informatique d'Apprentissage Humain · Raisonnement à Partir de Cas · Stacking · Régression · Recommandation Stochastique

Abstract. This paper presents the integration of a recommendation model based on Thompson sampling (TS) with a multi-agent model associated with case-based reasoning (ESCBR-SMA). The integrated model is used to improve the real-time adaptation of an intelligent tutoring system (ITS) called AI-VT. It was evaluated on two learner databases to predict scores for exercises of different levels of complexity under three predefined scenarios. We compared the recommendation algorithm and the integration of the recommendation algorithm with the prediction algorithm by evaluating the evolution of each learner's knowledge acquisition. The measurements carried out allow us to determine the accuracy of the prediction for each learner and each level of complexity. The results show that integrating stochastic adaptation and prediction with the

case-based reasoning paradigm results in better identification of learner weaknesses, and therefore in better personalized path recommendations for the learner.

Keywords: Intelligent Tutoring System · Case-Based Reasoning · Stacking · Regression · Stochastic Recommender

1 Introduction

Le système AI-VT (Artificial Intelligence - Virtual Trainer) est un environnement informatique pour l'apprentissage humain (EIAH) créé pour aider les apprenants à comprendre et à acquérir des connaissances dans divers domaines [10,9].

Certains EIAH intègrent un module de recommandation permettant de personnaliser les contenus et les exercices en fonction des besoins et des résultats des apprenants. L'efficacité du système dans l'acquisition des connaissances et l'adaptation aux différents types d'apprentissage dépend de ce module [6].

Les contributions de cet article sont les suivantes :

- proposition d'un modèle de recommandation (échantillonnage de Thompson - ET) intégré à un système de raisonnement à partir de cas (RàPC) couplé à un système multi-agents (ESCBR-SMA),
- évaluation du modèle intégré pour l'amélioration de la personnalisation du parcours de l'apprenant utilisant l'EIAH AI-VT.

La section 2 de cet article présente les travaux connexes aux EIAH, le RàPC, les techniques d'apprentissage d'ensemble (*Ensemble Stacking*), ET et la régression. Le modèle proposé est expliqué dans la section 3. La section 4 décrit le protocole expérimental utilisé, présente et discute les résultats. Enfin, les conclusions et les travaux futurs sont abordés dans la section 5.

2 Travaux Connexes

Pour améliorer l'expérience de l'apprenant, certains EIAH adaptent le contenu aux besoins et aux connaissances des apprenants afin de leur permettre de progresser dans l'acquisition de connaissances [1] [11].

Mao *et al.* [7] proposent un système de recommandation bilatéral fondé sur l'apprentissage par renforcement (RTR) pour personnaliser des quiz en choisissant des questions adaptées au niveau des apprenants.

Les informations historiques et les connaissances acquises par l'application complètent l'utilisation des algorithmes d'intelligence artificielle en améliorant l'adaptation du système, comme l'illustre la méthode de recommandation de Li *et al.* [5]. Testée sur les bases de données *Assistment 2009-201 et Eedi 2020*, cette méthode peut améliorer les performances des apprenants en recommandant des exercices appropriés. Le travail de Clemente *et al.* [3] infère le progrès des

apprenants grâce à une ontologie dynamique pour détecter, corriger les faiblesses et adapter le système de recommandation.

Clément *et al.* [2] font une analogie entre les EIAH et le problème du *Bandit Manchot* en se fondant sur le fait que dans les deux cas, il est nécessaire de trouver l'ensemble d'actions maximisant le gain. Cela se résume à ce que l'on appelle le compromis "*exploration/exploitation*" dans l'apprentissage automatique. Le modèle proposé permet à l'enseignant de définir le parcours du cours en fonction des réponses des élèves.

Le travail de Soto *et al.* [8], utilise un algorithme fondé sur l'ET, la recommandation dans les EIAH étant en effet à la fois différente pour chaque apprenant et dynamique dans le temps.

3 Modèle Proposé

Le modèle proposé est une intégration d'un modèle de recommandation fondé sur l'échantillonnage de Thompson (ET) à un modèle multi-agent associé au raisonnement à partir de cas (ESCBR-SMA). Le modèle de recommandation produit une adaptation en fonction des notes de l'apprenant et l'ESCBR-SMA effectue une prédiction pour valider l'adaptation générée.

Une fonction de pondération unifie les résultats du modèle. La recommandation finale est celle qui optimise l'expression 3.

Ce modèle adapte grâce à l'ET, puis l'ECBR-SMA propose une prédiction et enfin le processus se termina par la prise de décision envoyée à l'apprenant. Le tableau 1 présente les variables et les paramètres du modèle proposé ainsi que les mesures employées.

TABLE 1. Paramètres (p), variables (v) et fonctions (f) du modèle proposé

ID	Type	Description	Domain
α	p	Paramètre de la distribution BETA	$[1, \infty] \in \mathbb{R}$
β	p	Paramètre de la distribution BETA	$[1, \infty] \in \mathbb{R}$
t	p	Temps défini des itérations	\mathbb{N}
c	p	Niveau de complexité	\mathbb{N}
$k_{t,c}$	v	Évolution de la connaissance dans le temps t pour le niveau de complexité c	$[0, 1] \in \mathbb{R}$
$vk_{t,c}$	v	Évolution de la connaissance pour chaque niveau de complexité c	\mathbb{R}
TS_c	v	Récompense de l'ET pour un niveau de complexité c	$[0, 1] \in \mathbb{R}$
TSN_c	v	Normalisation de TS_c avec d'autres niveaux de complexité	$[0, 1] \in \mathbb{R}$
$ESCBR_c$	v	Prédiction de la note pour un niveau de complexité c	\mathbb{R}_+
D_{JS}	f	Divergence de Jensen-Shannon	$[0, 1] \in \mathbb{R}$

L'intégration se fait en trois étapes. Tout d'abord, il est nécessaire d'avoir des valeurs aléatoires pour chaque niveau de complexité c en utilisant les distribu-

tions de probabilités générées avec le modèle ET (équation 1). La normalisation de toutes ces valeurs est calculée selon l'équation 2. Ces valeurs servent de paramètres de priorité pour les prédictions effectuées par le modèle ESCBR-SMA dans l'équation 3.

$$TS_c = rand(Beta(\alpha_c, \beta_c)) \quad (1)$$

$$TSN_c = \frac{TS_c}{\sum_{i=0}^4 TS_i} \quad (2)$$

$$n_c = max(TSN_c * ESCBR_c) \quad (3)$$

Après avoir calculé les valeurs finales pour chaque niveau de complexité, le système propose le niveau de complexité ayant la valeur la plus élevée (équation 3).

4 Résultats et Discussion

Deux bases de données ont été utilisées pour tester le modèle, la première a été générée [8] et la seconde est un ensemble de données réelles d'étudiants [4].

La première série de tests est définie sous la forme de différents scénarios. Dans le scénario E1, la note d'un apprenant au premier niveau de complexité est interpolée après 3 questions. Dans le scénario E2, la note de la 9ème question dans le même niveau de complexité est interpolée. Le scénario E3 interpole les deux notes dans un niveau de complexité supérieur.

Le modèle a été comparé à neuf algorithmes de régression présentés dans le tableau 2.

TABLE 2. Liste des algorithmes évalués

ID	Algorithme	ID	Algorithme
A1	Linear Regression	A6	Polinomial Regression
A2	K-Nearest Neighbor	A7	Ridge Regression
A3	Decision Tree	A8	Lasso Regression
A4	Random Forest (Ensemble)	A9	Gradient Boosting (Ensemble)
A5	Multi Layer Perceptron	A10	Proposed ET-ESCBRSMA

Les algorithmes ont été évalués à l'aide de trois mesures (Root Mean Squared Error - RMSE, Median Absolute Error - MedAE, Mean Absolute Error - MAE). Les résultats figurent dans le tableau 3. L'algorithme proposé obtient de meilleurs résultats que les autres algorithmes avec lesquels il a été comparé dans quatre des neuf scénarios. Il se place en deuxième position dans les cinq autres scénarios.

La progression dans le temps avec ET est évaluée avec la divergence de Jensen-Shannon (équations 4 et 5) et la famille de distribution Beta en t et $t - 1$ comme second test.

TABLE 3. Résultats de régression avec 100 exécutions

Scenario (Métrique)	Algorithmes									
	A1	A2	A3	A4	A5	A6	A7	A8	A9	A10
E1 (RMSE)	0.625	0.565	0.741	0.56	0.606	0.626	0.626	0.681	0.541	0.54
E1 (MedAE)	0.387	0.35	0.46	0.338	0.384	0.387	0.387	0.453	0.327	0.347
E1 (MAE)	0.485	0.436	0.572	0.429	0.47	0.485	0.485	0.544	0.414	0.417
E2 (RMSE)	0.562	0.588	0.78	0.571	0.61	0.562	0.562	0.622	0.557	0.556
E2 (MedAE)	0.351	0.357	0.464	0.344	0.398	0.351	0.351	0.415	0.334	0.346
E2 (MAE)	0.433	0.448	0.591	0.437	0.478	0.433	0.433	0.495	0.422	0.429
E3 (RMSE)	0.591	0.589	0.785	0.568	0.613	0.591	0.591	0.644	0.554	0.549
E3 (MedAE)	0.367	0.362	0.465	0.57	0.375	0.367	0.367	0.433	0.336	0.343
E3 (MAE)	0.453	0.45	0.598	0.438	0.466	0.453	0.453	0.512	0.426	0.417

$$vk_{t,c} = \begin{cases} D_{JS}(Beta(\alpha_{t,c}, \beta_{t,c}), Beta(\alpha_{t+1,c}, \beta_{t+1,c})), & \frac{\alpha_{t,c}}{\alpha_{t,c} + \beta_{t,c}} < \frac{\alpha_{t+1,c}}{\alpha_{t+1,c} + \beta_{t+1,c}} \\ -D_{JS}(Beta(\alpha_{t,c}, \beta_{t,c}), Beta(\alpha_{t+1,c}, \beta_{t+1,c})), & Sinon \end{cases} \quad (4)$$

$$k_t = \sum_{c=4}^{c=0 \vee k_t \neq 0} \begin{cases} \alpha_{c-1} vk_{t,c-1}; & vk_{t,c} > 0 \\ 0; & Sinon \end{cases} \quad (5)$$

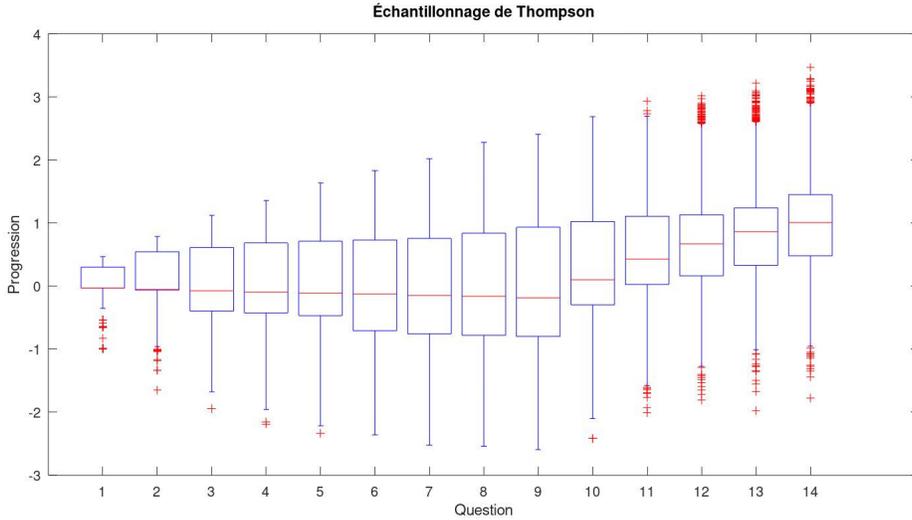


FIGURE 1. Progression des connaissances avec l'ET selon la divergence de Jensen-Shannon

La figure 1 montre la progression cumulative des connaissances sur quinze questions d'une seule session. Entre la première et la dernière question, tous les apprenants ont statistiquement augmenté leur niveau de connaissance puisque la moyenne a augmenté. La variabilité augmente à partir de la première question jusqu'à la question 9, où le système a acquis plus d'informations sur les apprenants. À ce stade, la variance diminue et la médiane augmente.

Pour le troisième test, la figure 2 montre qu'après 100 exécutions et malgré la stochasticité, l'algorithme est stable : la variance globale dans tous les niveaux de complexité est faible par rapport au nombre total de recommandations.

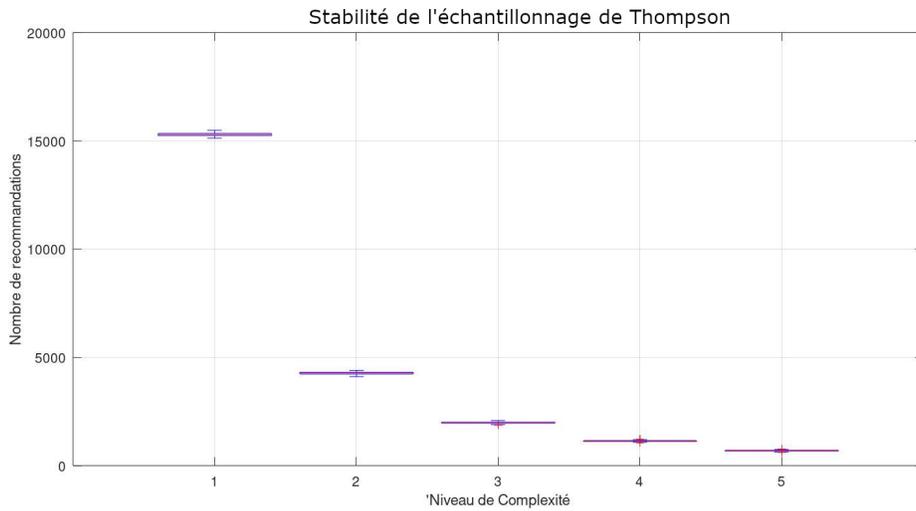


FIGURE 2. Nombre de recommandations par niveau de complexité

5 Conclusion

Cet article présente l'intégration d'un système de recommandation fondé sur l'échantillonnage de Thompson et un modèle de régression d'ensemble ESCBR-SMA. Le modèle proposé permet de générer des recommandations pour chaque apprenant. Par ailleurs, l'intégration de plusieurs perspectives de solution sur une même problématique, selon le principe du paradoxe de Stein, permet de limiter le risque d'être confronté au paradoxe de Simpson. Pour finir, les deux modèles se complètent mutuellement en améliorant les résultats finaux.

Il est maintenant envisagé d'associer d'autres algorithmes d'intelligence artificielle complémentaires pour bénéficier de plus de données pour l'adaptation.

Références

1. Esmael Ahmed. Student performance prediction using machine learning algorithms. *Applied Computational Intelligence and Soft Computing*, 2024(1) :4067721, 2024.
2. Benjamin Clement, Didier Roy, Pierre-Yves Oudeyer, and Manuel Lopes. Multi-armed bandits for intelligent tutoring systems, 2015.
3. Julia Clemente, Héctor Yago, Javier de Pedro-Carracedo, and Javier Bueno. A proposal for an adaptive recommender system based on competences and ontologies. *Expert Systems with Applications*, 208 :118171, 2022.
4. Jakub Kuzilek, Martin Hlosta, and Zdenek Zdrahal. Open university learning analytics dataset. *Scientific Data*, 4(1) :170171, Nov 2017.
5. Linqing Li and Zhifeng Wang. Knowledge graph-enhanced intelligent tutoring system based on exercise representativeness and informativeness. *International Journal of Intelligent Systems*, 2023(1) :2578286, 2023.
6. Mengchi Liu and Dongmei Yu. Towards intelligent e-learning systems. *Education and Information Technologies*, 28(7) :7845–7876, Jul 2023.
7. Kejie Mao, Qiwen Dong, Ye Wang, and Daocheng Hong. An exploratory approach to intelligent quiz question recommendation. *Procedia Computer Science*, 207 :4065–4074, 2022. Knowledge-Based and Intelligent Information and Engineering Systems : Proceedings of the 26th International Conference KES2022.
8. Daniel Soto-Forero, Simha Ackermann, Marie-Laure Betbeder, and Julien Henriët. Automatic real-time adaptation of training session difficulty using rules and reinforcement learning in the ai-vt its. *International Journal of Modern Education and Computer Science(IJMECS)*, 16 :56–71, 2024.
9. Daniel Soto Forero, Simha Ackermann, Marie-Laure Betbeder, and Julien Henriët. The intelligent tutoring system ai-vt with case-based reasoning and real time recommender models. In *32nd International conference on Case-based reasoning (ICCBR 2024)*, pages 191 – 205, Mérida, Mexico, jul 2024.
10. Daniel Soto Forero, Marie-Laure Betbeder, and Julien Henriët. Ensemble stacking case-based reasoning for regression. In *32nd International conference on Case-based reasoning (ICCBR 2024)*, pages 159 – 174, Mérida, Mexico, jul 2024.
11. Raaa Subha, Naaa Gayathri, Saaa Sasireka, Raaa Sathiyabanu, Baaa Santhiyaa, and Baaa Varshini. Intelligent tutoring systems using long short-term memory networks and bayesian knowledge tracing. In *2024 5th International Conference on Mobile Computing and Sustainable Informatics (ICMCSI)*, volume 0, pages 24–29, 2024.