



Full Length Research Paper

Contribution de l'Intelligence Artificielle à la discrimination des émotions favorables à la performance des apprenants du secondaire second cycle de l'Enseignement Général

Kouamé Abel Assielou ^{1*}, Denon Arthur Richmond Gono ², Kouakou Daniel Yao ³, Karim Sidibé ⁴

¹Institut National Polytechnique Félix Houphouët-Boigny (INP-HB) – Yamoussoukro, Côte d'Ivoire

²Institut Pédagogique National de l'Enseignement Technique et Professionnel (IPNETP) – Abidjan, Côte d'Ivoire

³Université Jean Lorougnon Guédé (UJLoG) – Abidjan, Côte d'Ivoire

⁴Université Alassane Ouattara – Bouaké, Côte d'Ivoire

Received July 2023 – Accepted October 2023



*Corresponding author. Email : askab.line@gmail.com

Author(s) agree that this article remain permanently open access under the terms of the Creative Commons Attribution License 4.0 International License.

Résumé :

Une récente étude sur l'évaluation de la qualité des systèmes éducatifs en Afrique subsaharienne montre clairement que les apprenants Ivoiriens (Côte d'Ivoire) ne disposent pas des compétences en langue et en mathématiques pour le cycle primaire. Aussi, l'on constate une évolution irrégulière des résultats scolaires avec des variations ponctuées par des hausses et des baisses. Face à ce constat, plusieurs études ont été menées en vue d'améliorer le rendement des apprenants. Cependant, ces études visent en général à revoir les curricula, les contenus d'apprentissage, les méthodes d'évaluation sans prendre en compte l'état émotionnel des apprenants durant les séances de cours et d'évaluation qui constituent également un facteur important dans le processus d'apprentissage. La présente contribution, s'inscrivant dans le champ de l'utilisation de l'Intelligence Artificielle pour l'apprentissage, la formation et l'éducation, vise donc à apporter une solution à ce problème d'amélioration des rendements scolaires en utilisant une approche d'Intelligence Artificielle qui combine une Régression Linéaire Multiple (modélisant l'impact émotionnel) et un modèle de Factorisation Matricielle Multi-Relationnelle Pondérée (WORMF) pour tirer profit tant des facultés cognitives qu'émotionnelles des apprenants. Elle vise à discriminer les émotions favorables au rendement des apprenants du secondaire second cycle de l'Enseignement Général. L'étude menée ici, prend en compte non seulement les relations qui existent entre les apprenants, les tâches et les compétences mais aussi les émotions de ces derniers et s'appuie sur la théorie du contrôle et de la valeur des émotions d'accomplissement de Pekrun. Pour évaluer notre approche et discuter de la discrimination des émotions favorables à la performance des apprenants, nous avons effectué une enquête sur des apprenants du second cycle secondaire de l'enseignement général, inscrits en classe de Terminale, au Lycée Moderne Khalil (Daloa, Côte d'Ivoire). Les données sur les émotions (joie, espoir, fierté, soulagement, colère, anxiété, honte, désespoir) ont été recueillies au moyen du questionnaire AEQ (Achievement Emotions Questionnaire) distribué aux apprenants volontaires à participer à cette recherche. L'échantillon était composé de 250 apprenants. Ces apprenants ont été évalués par ailleurs, lors des examens blancs, dans plusieurs disciplines : Mathématiques, Français, Anglais, Histoire-Géographie, Philosophie et Science de la Vie et de la Terre. Les résultats expérimentaux de cette étude ont montré que les émotions influençaient différemment les réalisations dans les disciplines scolaires. Il ressort aussi de cette étude que les émotions à valences positives sont plus avantageuses dans les différentes réalisations en Lettres qu'en Sciences.

Mots clés: Intelligence Artificielle, Amélioration du rendement des apprenants; Factorisation Matricielle; Impact Emotionnel; Discrimination des émotions, Approche Par Compétences.

Cite this article:

Kouamé Abel Assielou, Denon Arthur Richmond Gono, Kouakou Daniel Yao, Karim Sidibé (2023). Contribution de l'Intelligence Artificielle à la discrimination des émotions favorables à la performance des apprenants du secondaire second cycle de l'Enseignement Général. Revue RAMReS – Sci. Appl. & de l'Ing., Vol. 5(1), pp. 48-56. ISSN 2630-1164.

1. Introduction

Depuis plus d'une décennie, les résultats scolaires en Côte d'Ivoire connaissent une évolution irrégulière avec des variations ponctuées par des hausses et des baisses. Pour remédier à ce problème, plusieurs solutions ont été implémentées. Au nombre de celles-ci figure l'APC (Approche Par Compétences). L'APC est une approche pédagogique qui accorde une place centrale au développement des compétences et des connaissances dans l'activité d'apprentissage. En vigueur dans plusieurs autres pays francophones, cette approche pédagogique vise à mettre le processus d'enseignement et d'apprentissage en adéquation avec celui de l'emploi dans le monde réel. Tout porte cependant à croire que la situation est restée inchangée malgré l'adoption de ce nouveau modèle d'éducation. Les résultats du PASEC (Programme d'Analyse des Systèmes Educatifs de la CONFEMEN) sont la meilleure illustration de cet état de fait. Ces résultats révèlent en effet que la Côte d'Ivoire occupe les derniers rangs dans l'évaluation en Français et en Mathématique [1]. Aussi convient-il d'expérimenter d'autres approches telles que l'Intelligence Artificielle (apprentissage automatique) dans une perspective d'amélioration des rendements scolaires. En effet, l'apprentissage automatique se présente comme une alternative intéressante au regard de son utilisation de plus en plus répandue dans le domaine de la recherche en science cognitive et en éducation. Son avantage est de contribuer à améliorer nos connaissances sur la façon de catégoriser les différents facteurs en corrélation avec la performance des apprenants dans un système éducatif. Cependant, les études menées pour l'amélioration du système éducatif visent en général à revoir les curricula, les contenus d'apprentissage[2], les méthodes d'évaluation sans prendre en compte l'aspect affectif des apprenants durant les séances de cours et d'évaluation qui constituent également un facteur important dans le processus d'apprentissage. L'émotion est définie comme un ensemble de processus coordonnés comprenant des sous-systèmes psychologiques incluant l'affectif, le cognitif, la motivation, l'expression et les processus physiologiques périphériques [3]. Dans le contexte de l'éducation, spécifiquement en science cognitive, elle est perçue comme étant la résultante d'une évaluation cognitive à des situations d'apprentissage[4]. Ainsi, la présente contribution, s'inscrivant dans le champ de l'utilisation de l'Intelligence Artificielle pour l'apprentissage, la formation et l'éducation, vise donc à apporter une solution à ce problème d'amélioration de rendement des apprenants à l'aide d'une approche de Machine Learning qui combine une Régression Linéaire Multiple (modélisant l'impact émotionnel) et un modèle de Factorisation Matricielle Multi-Relationnelle Pondérée afin de tirer profit tant des facultés cognitives qu'émotionnelles des apprenants. Cette étude s'inscrit dans la continuité de nos travaux

menés [5, 6] dans le champ de l'intelligence socio-émotionnelle dans l'éducation et l'apprentissage. L'étude menée ici vise à discriminer les émotions favorables aux différentes réalisations en terme de performances des apprenants dans les disciplines littéraires et scientifiques. Elle s'appuie par ailleurs sur la théorie du contrôle et de la valeur des émotions d'accomplissement proposée par Pekrun [7] et ses collaborateurs.

Cet article est organisé de la manière suivante : la partie 2 présentes les travaux connexes en termes d'approche d'Intelligence Artificielle utilisée, de théorie cognitive adoptée et de méthodologie. La troisième partie expose les différents résultats et les discussions. La dernière partie permet de conclure l'article.

2. Matériels et méthodes

L'étude menée dans cet article s'appuie principalement sur l'approche de Factorisation Matricielle et Emotionnelle (*Emo-WRMF*) proposée par Assielou et al., [5]. Dans ces travaux, les auteurs ont quantifié l'impact des émotions des apprenants sur leurs performances globales à travers un modèle de régression linéaire multiple. Le modèle *Emo-WRMF* est une amélioration successive de la Factorisation Matricielle (MF) [8, 9] puis de la Factorisation Matricielle Multi-Relationnelle (MRMF)[10, 11] et enfin de la Factorisation Matricielle Multi-Relationnelle Pondérée (WRMF)[12-14]. Cette section décrit brièvement les travaux connexes.

2.1. Approche de Factorisation Matricielle Multi-Relationnelle Pondérée (WRMF)

La technique MRMF telle que proposée dans [15] est une technique de recommandation qui exploite plusieurs types de relations ou sources d'informations du domaine telles que les acquis des apprenants, les notes obtenues afin d'affiner les résultats des différentes prédictions. Dans cette approche, toutes les informations prises en compte ont la même valeur de pondération. Cependant, à la différence du modèle MRMF, le modèle WRMF intègre un facteur de pondération θ permettant d'exprimer ou de représenter l'importance des différentes sources d'informations les unes par rapport aux autres.

Le principe de cette technique est le suivant : on considère un environnement d'apprentissage constitué d'un ensemble S d'apprenants, d'un ensemble I de tâches (activités, évaluations ...) et une gamme P de performances possibles. Cette technique vise, après avoir effectué un apprentissage machine sur l'ensemble des données connues, à prédire les performances des apprenants (ensemble des données non connues). Soit R , une matrice de performances dénotant les différentes réalisations des apprenants de l'ensemble S par rapport à aux différentes tâches de l'ensemble

I. Dans le cadre de cette approche, la performance \hat{p}_{si} d'un apprenant s pour une tâche i , est obtenue par la relation suivante :

$$\hat{p}_{si} = \sum_{f=1}^F w_{1_{sf}} w_{2_{if}} = w_{1_s} w_{2_i}^T \quad [\text{Eq. 1}]$$

Dans cette équation, $W_1 \in \mathbb{R}^{S \times F}$ désigne une matrice dans laquelle chaque ligne s est un vecteur contenant les F facteurs latents décrivant l'apprenant s et $W_2 \in \mathbb{R}^{I \times F}$ est une matrice où chaque ligne i est un vecteur contenant les F facteurs latents décrivant la tâche i . Les vecteurs w_{1_s} et w_{2_i} appartiennent respectivement aux matrices W_1 et W_2 tels que leurs éléments sont désignés par $w_{1_{sf}}$ et $w_{2_{if}}$.

W_1 et W_2 sont les paramètres du modèle MF (matrices de facteurs latents) ou encore matrices factorielles. Dans le cadre de la WRMF, ces paramètres sont notés W_1, W_2, \dots, W_n et peuvent être appris en optimisant la fonction objectif (équation 2) à partir d'un critère tel que l'erreur quadratique moyenne (RMSE pour Root Mean Squared Error) en utilisant la méthode de Descente de Gradient Stochastique (SGD).

$$\begin{aligned} \mathcal{O}^{WRMF} = & \sum_{r=1}^M \Theta_r \sum_{(s,i) \in R_r} (R_{si} - w_{r1_s} w_{r2_i}^T)^2 + \\ & \lambda \left(\sum_{n=1}^N \|W_n\|_F^2 \right) \end{aligned} \quad [\text{Eq. 2}]$$

Dans cette équation,

- r désigne un type de relation du domaine, telle que la relation « effectuer » qui lie l'apprenant à la tâche. Si nous considérons M types de relations, on aura alors $r = 1 \dots M$
- $\| \cdot \|_F^2$ est la norme de Frobenius
- λ est un paramètre faisant un compromis entre l'erreur d'approximation au carré et la norme de Frobenius du modèle [11]
- Θ_r est le facteur de pondération et est défini de la manière suite :

$$\Theta_r = \begin{cases} 1, & \text{si } r \text{ est la relation principale} \\ \theta, & \text{si } (0 < \theta < 1) \end{cases} \quad [\text{Eq. 3}]$$

Les équations pour la mise à jour des paramètres sont données par :

$$w'_{r1_{sk}} = w_{r1_{sk}} + \beta (2\Theta_r e_{r_{si}} w_{r2_{ik}} - \lambda w_{r1_{sk}}) \quad [\text{Eq. 4}]$$

$$w'_{r2_{ik}} = w_{r2_{ik}} + \beta (2\Theta_r e_{r_{si}} w_{r1_{sk}} - \lambda w_{r2_{ik}}) \quad [\text{Eq. 5}]$$

Avec $e_{r_{si}}$ désignant l'erreur de prédiction pour un type de relation. Le paramètre β désigne le taux d'apprentissage.

A titre d'exemple, considérons un environnement d'apprentissage dans lequel trois apprenants (numérotés de s_1 à s_3) ont effectué 6 tâches (numérotées de t_1 à t_6). Les différents résultats de performances R sont présentés à travers la figure 1.

	t_1	t_2	t_3	t_4	t_5	t_6
s_1	1	0	1	1	0	1
s_2		1	1		1	0
s_3	1	1	1		0	

Figure 1 : Matrice binaire R des performances de 4 apprenants (s_1, s_2, s_3) pour 6 tâches (t_1, t_2, \dots, t_6)

La valeur $R_{11} = 1$ signifie que l'apprenant s_1 a effectué la tâche t_1 avec un score de 1 tandis que $R_{26} = 0$ stipule que l'apprenant s_2 a effectué la tâche t_6 avec un score de 0. Les valeurs à blanc signifient que les tâches n'ont pas encore été réalisées et donc que ces valeurs peuvent être prédites sur la base de l'apprentissage des paramètres du modèle et en utilisant les deux équations 4 et 5.

2.2. Modélisation de l'impact des émotions \mathcal{E}_{si}

L'approche proposée dans [5] permet de tirer parti des différentes émotions ressenties par un apprenant dans un environnement d'apprentissage et repose sur les hypothèses suivantes :

- La réalisation d'une tâche quelconque par un apprenant s'accompagne toujours d'une ou plusieurs émotions bien données. De ce fait, les performances d'un apprenant dépendent non seulement de ses capacités intrinsèques (capacités cognitives), mais aussi de l'impact de ses émotions ressenties.

- Un apprenant peut ressentir non pas une émotion unique mais plutôt une combinaison de plusieurs émotions liées à l'activité d'apprentissage.

Elle s'appuie en outre sur la Théorie de Contrôle et de la valeur des émotions proposée par Reinhard Pekrun. [7]. Cette théorie fournit un cadre d'intégration pour analyser les antécédents et les effets des émotions vécues dans les réalisations en milieu académique appelées émotions d'accomplissement. La théorie de Pekrun dénote huit échelles d'émotions liées au test (évaluation). Ces émotions sont classées en deux valences : les émotions à valences positives à savoir la joie, l'espoir, la fierté, le soulagement et les émotions à valences négatives que sont la colère, l'anxiété, la honte, le désespoir.

Pour quantifier l'impact de ces émotions, les auteurs dans [5] ont proposé un modèle de régression linéaire multiple noté \mathcal{E}_{si} . Il représente l'impact (positif comme négatif) des émotions sur la performance de

l'apprenant s à la réalisation de la tâche i . Les différentes valeurs prises par \mathcal{E}_{si} sont des réels appartenant à l'intervalle $[-1;1]$ et ses coefficients sont les éléments du vecteur $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_8)$. Les différentes variables sont les éléments de $e = (e_1, e_2, \dots, e_8)$. La formulation mathématique de \mathcal{E} est la suivante :

$$\mathcal{E} = \alpha e + \alpha_0 \quad [\text{Eq. 6}]$$

Les éléments de e représentent respectivement les intensités des huit échelles d'émotions liées au test que sont : le **joie**, l'**espoir**, la **fierté**, le **soulagement**, la **colère**, l'**anxiété**, la **honte** et le **désespoir**.

Les différentes valeurs e_1, e_2, \dots, e_8 peuvent être obtenues à l'aide du questionnaire (AEQ) sur les émotions d'accomplissement[7]. Ce questionnaire est un instrument d'auto-évaluation permettant de mesurer les émotions des apprenants en situation scolaire en général et en situation d'évaluation en particulier. L'instrument, dans sa version finale, se compose de 232 éléments qui mesurent huit émotions différentes liées à l'apprentissage en général parmi lesquels il y a 77 éléments pour les échelles d'émotions liées au test. Les 77 éléments du questionnaire sont classés en trois blocs évaluant les expériences émotionnelles avant, pendant et après le test. Le modèle \mathcal{E} , de ce fait, vise à apporter une source d'information supplémentaire sous forme de matrice d'impact des émotions au modèle WMRMF.

2.3. Méthodologie

Dans le but de discriminer les catégories d'émotions favorables aux disciplines dans un contexte éducatif, nous avons effectué une enquête au Lycée Moderne Khalil, lycée d'enseignement secondaire général de la Direction Régionale de l'Éducation Nationale et de l'Alphabétisation de Daloa (Côte d'Ivoire). Cette enquête a porté sur des élèves inscrits en classe de terminale. L'échantillon était composé de 250 apprenants (80 filles et 170 Garçons) des séries C et D. Les apprenants ont été évalués, en situation réelle lors des examens blancs de la Direction Régionale de l'Éducation Nationale et de l'Alphabétisation de Daloa. Les disciplines prises en compte par l'étude lors de cet examen sont les suivantes : Mathématiques (Maths), Français (Fr), Physique-Chimie (PC), Histoire-Géographie (HG), Philosophie (Philo) et Sciences de la Vie et de la Terre (SVT). Elles sont rangées en deux catégories : 3 matières littéraires et 3 matières scientifiques (voir tableau 1).

Tableau 1 : Catégorisation des matières évaluées lors de l'examen blanc régional

Les matières littéraires	Les matières scientifiques
- Français	- Mathématiques
- Philosophie	- Physique-Chimie
- Histoire-Géographie	- Sciences de la Vie et de la Terre

Les différentes notes obtenues par les apprenants durant cet examen et celles obtenues durant les autres évaluations (interrogation écrites, devoirs surveillés, devoirs de niveau) ont été utilisées pour créer la matrice binaire des performances. Par ailleurs les différents acquis des apprenants (participations au cours) ont aussi été exploitées dans le modèle *Emo-WMRMF* comme source d'informations supplémentaire pour ajuster les résultats de cette étude. En ce qui concerne les émotions, nous les avons obtenus grâce au questionnaire d'auto-évaluation AEQ distribué aux 250 apprenants volontaires à participer à cette recherche. Le questionnaire a été rempli pour chacune des épreuves de l'examen. Les réponses sont données sur une échelle de Likert à cinq (5) points : de « *fortement en désaccord* » (1) à « *fortement en accord* » (5). À chacune des épreuves de l'examen, les 77 questions du questionnaire AEQ ont été répondues de la manière suivante (conformément au manuel d'utilisation) : 25 questions avant le démarrage de l'épreuve, 27 questions lors de l'épreuve et 25 questions juste après l'épreuve. Le tableau 2 illustre un extrait de la production d'un apprenant).

Tableau 2 : Extrait des réponses du questionnaire rempli par un apprenant

PENDANT LE TEST / EXAMEN	Réponse				
	1	2	3	4	5
J'aime bien passer l'examen.	x				
Je me demande si je réussirai l'examen.					x
Au début du test (examen), mon cœur se met à battre.			x		
Je pense que peu importe mes efforts, je ne réussirai pas le test.				x	
...					
J'ai envie d'abandonner.				x	
Mes mains tremblent.					x
Je suis très confiant.		x			

Les différentes valeurs de réponse données par les apprenants sont catégorisées puis sommées pour représenter chacune des huit échelles d'émotions d'accomplissement. La figure 2 présente un exemple de valeurs d'intensités des huit échelles d'émotions et quelques valeurs d'impacts émotionnels calculés en utilisant le modèle \mathcal{E} tel que présenté par l'équation 6.

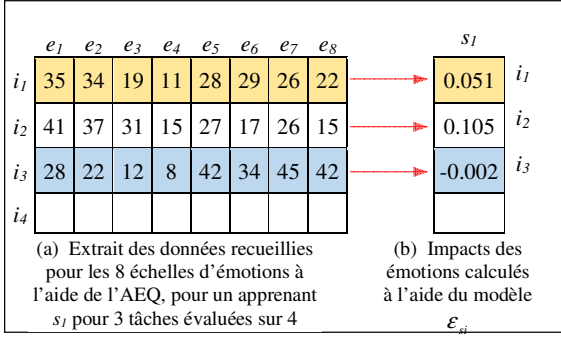


Figure 2 : Exemple de calcul des éléments de \mathcal{E} pour un apprenant s_1 à la réalisation de 3 tâches (i_1, i_2, i_3) à l'aide d'un extrait de données recueillies par le questionnaire AEQ

Dans cet exemple, un apprenant s_1 a réalisé trois (3) tâches i_1, i_2, i_3 sur quatre. La figure 2(a) est un exemple d'intensités des échelles d'émotions recueillies à l'aide du questionnaire AEQ lors de nos enquêtes terrain. Les différents impacts émotionnels pour chacune des tâches sont illustrés à travers la figure 2(b). Ainsi, la valeur d'impact émotionnel à la réalisation de la tâche i_1 est $\mathcal{E}_{11} = 0,051$ tandis que celle de la tâche i_3 est $\mathcal{E}_{13} = -0,002$. La matrice d'impact émotionnel \mathcal{E} est obtenue lorsque cette action est étendue à tous les apprenants, pour toutes les tâches réalisées. Cette matrice est utilisée comme source d'informations supplémentaire pour alimenter l'approche de Factorisation Matricielle *Emo*-WRRMF.

Pour apprendre les paramètres W_1, W_2, \dots, W_n du modèle *Emo*-WRRMF afin de discriminer les émotions favorables aux réalisations scolaires, nous avons utilisé une technique d'apprentissage automatique (Machine Learning) dite supervisée. A cet effet, nous avons utilisé 3/4 des données pour la phase d'apprentissage machine et 1/4 des données pour la phase de test. L'ensemble des données étant constitué des notes, des acquis, des différentes compétences mises en œuvres, des tâches et des émotions des apprenants. L'algorithme d'apprentissage proposé utilise la technique de Descente de Gradient Stochastique (DGS). Elle est l'une des méthodes les plus utilisées pour la minimisation itérative d'une fonction de coût différentiable [16, 17]. Dans l'approche DGS, chaque itération consiste à effectuer l'opération suivante (algorithme 1) pour toutes les évaluations dans un ordre aléatoire[18].

Algorithme 1 : DGS

- Etape 1 :** Initialisation des paramètres W_1, W_2, \dots, W_n
- Etape 2 :** Calcul de l'erreur de prédiction $e_{si} = (R_{si} - w_{r_{1k}} w_{r_{2k}}^T)$
- Etape 3 :** Mise à jour des paramètres pour un type de relation

$$w'_{r_{1k}} = w_{r_{1k}} + \beta(2\Theta_r e_{si} w_{r_{2k}} - \lambda w_{r_{1k}})$$

$$w'_{r_{2k}} = w_{r_{2k}} + \beta(2\Theta_r e_{si} w_{r_{1k}} - \lambda w_{r_{2k}})$$
- Etape 4 :** Affectation des données $(w_{r_{1k}}, w_{r_{2k}}) = (w'_{r_{1k}}, w'_{r_{2k}})$
- Etape 5 :** Répéter les étapes 2, 3 et 4 pour un autre couple (s, i)

Cet algorithme procède d'abord par l'initialisation des paramètres du modèle *Emo*-WRRMF à partir de la distribution normale $N(\mu, \sigma^2)$, en prenant pour espérance $\mu = 0$ et pour écart type $\sigma = 0,01$.

L'environnement de travail utilisé pour les simulations est un ordinateur de système d'exploitation de 64 bit, 8GB de RAM, intel Core i7. Le développement de l'Algorithme 1 s'est fait en langage de programmation Python.

Pour exposer les différents résultats dans la section suivante, nous avons utilisé comme métrique, l'erreur quadratique moyenne *RMSE* (Root Mean Squared Error). Cette métrique est calculée sur la base des données de test D^{test} de la manière suivante :

$$RMSE = \sqrt{\frac{\sum_{(r,s,i) \in D^{test}} (p_{si} - \hat{p}_{si})^2}{|D^{test}|}} \quad [\text{Eq. 7}]$$

L'erreur quadratique moyenne est la racine carrée du rapport du carré de l'écart entre la valeur prédite \hat{p}_{si} et la valeur réelle p_{si} et le nombre d'observations $|D^{test}|$.

Dans le processus d'évaluation du modèle *Emo*-WRRMF, la métrique *RMSE* calcule toutes les valeurs de la racine carrée de la moyenne de la somme quadratique de l'écart des valeurs réelles et des valeurs prédites ; plus la valeur est petite, plus la précision de la prédiction du modèle est élevée. C'est la métrique la plus utilisée pour évaluer l'exactitude des prédictions. La taille de l'ensemble des données pour l'apprentissage machine est de 75 % et nous effectuons une quadruple validation croisée.

3. Résultats

L'étude menée dans cet article vise à discriminer ou catégoriser les émotions en fonction de leurs effets sur le rendement des apprenants dans différentes disciplines scolaires. A la différence des travaux menés dans [5], nous avons étendu le nombre d'émotions prisent en compte de trois à quatre ; ce sont la joie l'espoir, l'anxiété et le désespoir. Ces émotions sont

celles qui ont été les plus discutées dans la littérature en Science Cognitive. Ces quatre émotions sont par ailleurs celles ayant les valeurs d'intensité les plus élevées dans l'ensemble de données utilisées pour l'évaluation. L'équation 6 réduite, pour nos simulations, se présente alors comme suit :

$$\varepsilon_{si} = \alpha_0 + \alpha_1 e_1 + \alpha_2 e_2 + \alpha_6 e_6 + \alpha_8 e_8 \quad [\text{Eq. 8}]$$

Les différents coefficients des échelles d'émotions ont été uniformisés à $\pm 2.10^{-3}$ pour ne pas privilégier les émotions les unes par rapport aux autres. Les paramètres d'optimisation obtenus après l'apprentissage machine sont consignés dans le tableau 3

Tableau 3 : Paramètres d'optimisation du modèle Emo-WMFMF

Paramètres du modèle <i>Emo-WMFMF</i>
$K = 2$; #iter = 320 ; $\beta = 3.10^{-3}$; $\lambda = 15.10^{-4}$;
$\theta \in \{1, 0; 0, 40; 0, 80; 0, 70\}$; $\alpha_0 = 0$
$\alpha_1 = \alpha_2 = 2.10^{-3}$ # Joie et Espoir
$\alpha_6 = \alpha_8 = -2.10^{-3}$ # Anxiété et Désespoir

La figure 3 présente les erreurs de prédiction (au bout de 320 itérations) pour chacune des disciplines utilisées dans l'enquête à savoir les matières littéraires (Français, Philosophie et Histoire-Géographie) et les trois matières scientifiques (Mathématiques, Physique-Chimie et Sciences de la Vie et de la Terre). Ces résultats montrent que l'approche *Emo-WMFMF* peut prédire certes, le rendement global des apprenants (comme l'ont montré Assielou et al., [5]) mais aussi, les rendements spécifiques (par matières). Le meilleur score de prédiction est obtenu en Physique Chimie

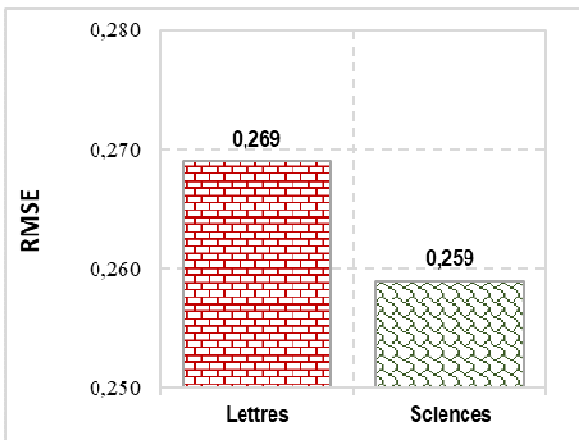


Figure 5 : Résultats RMSE pour les catégories des disciplines (Lettres contre Sciences)

avec une valeur RMSE de 0,196 pour les sciences contre une valeur de 0,212 en Histoire-Géographie pour les lettres. Cependant, le modèle s'avère moins précis dans la prédiction du rendement des apprenants en Français. Ce résultat pourrait se justifier par la sensibilité du rendement des apprenants dans certaines matières ou catégories de matières par rapport à certaines catégories d'émotions.




Figure 3 : Résultats RMSE pour chacune des disciplines étudiées (FR, HG, PHILO, MATH, PC, SVT)

Cet état de fait nous a conduit à établir le lien entre les catégories d'émotions (émotions à valences positives et émotions à valences négatives) et les différentes disciplines. Ainsi, les figures 4 et 5 présentent respectivement le résultat RMSE et son évolution de manière générale dans les matières littéraires et dans les matières scientifiques en fonction du nombre d'itérations utilisé dans l'apprentissage machine ; de même la figure 6 (a et b) illustre l'évolution des résultats RMSE pour chacune des disciplines.

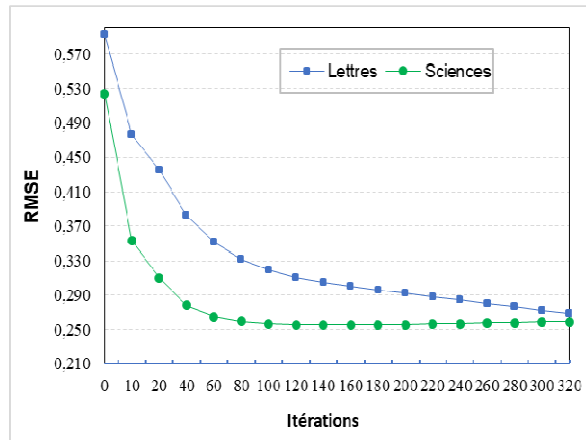
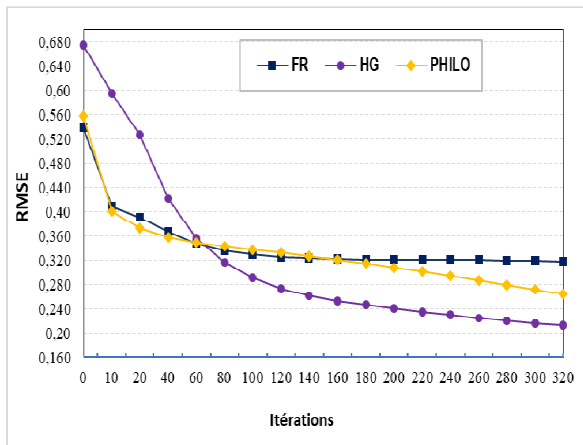
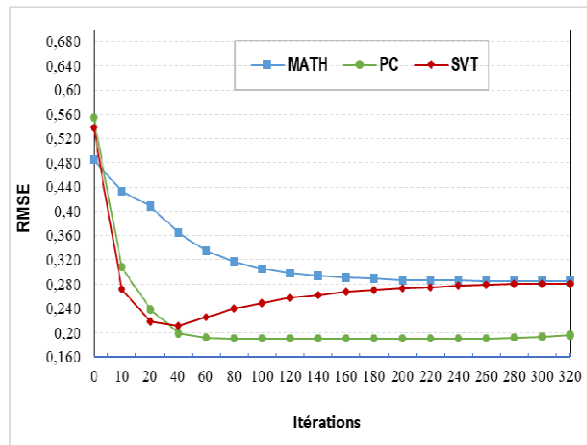


Figure 4 : Evolution des résultats RMSE pour les catégories de disciplines (Lettres contre Sciences)

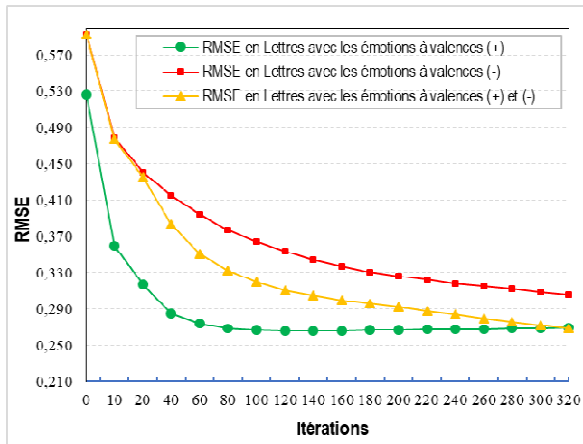


(a) Evolutions des résultats RMSE pour les disciplines littéraires

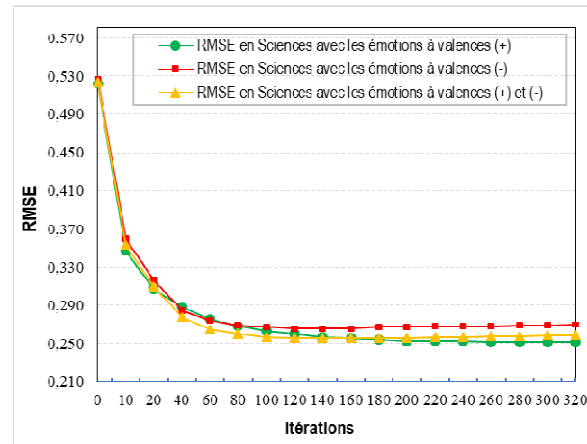


(b) Evolutions des résultats RMSE pour les disciplines scientifiques

Figure 6 : Evolutions des résultats RMSE par catégorie de disciplines et par discipline

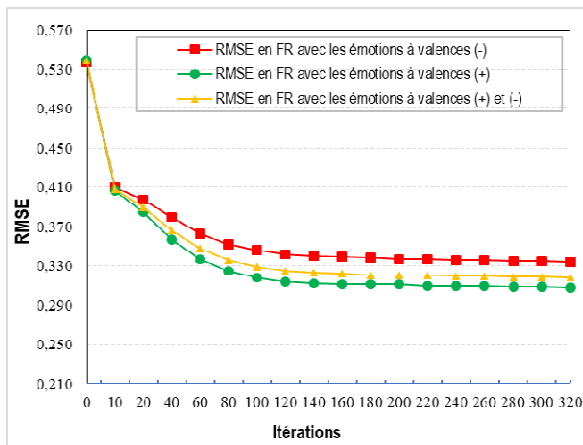


(a) Evolutions des résultats RMSE en lettres par catégories d'émotions

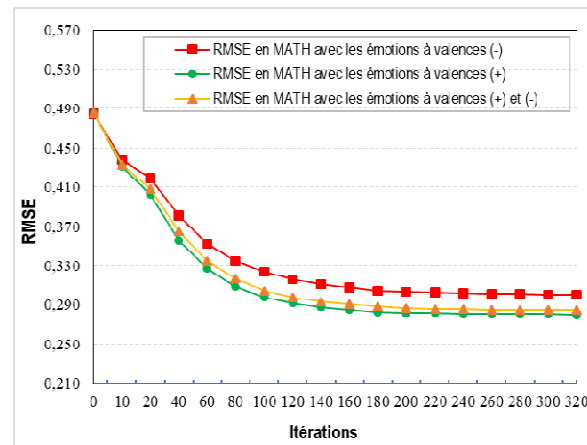


(b) Evolutions des résultats RMSE en sciences par catégories d'émotions

Figure 7 : Evolutions des résultats RMSE par catégorie de disciplines en prenant en compte soit uniquement les émotions à valences négatives, soit uniquement les émotions à valences positives soit les deux catégories d'émotions



(a) Evolutions des résultats RMSE en Français par catégories d'émotions



(b) Evolutions des résultats RMSE en Mathématiques par catégories d'émotions

Figure 8 : Evolutions des résultats RMSE en Français et en Mathématiques en prenant en compte soit uniquement les émotions à valences négatives, soit uniquement les émotions à valences positives soit les deux catégories d'émotions

Les résultats des figures 4 et 5 montrent que le modèle *Emo-WMRMF* est moins précis dans la prédiction du rendement des apprenants, en général, dans les matières littéraires. Cela pourrait s'expliquer par le fait que les activités de production et de compréhension du langage (telles que parler, écrire, lire un texte) peuvent avoir un impact sur l'état émotionnel des individus. De la même façon, la réalisation de ces mêmes activités peut être impactée par des dimensions émotionnelles et affectives propres à l'individu et/ou au contexte [19]. Selon Marion Van Brederode [20], les connaissances scientifiques correspondent souvent à des savoirs objectifs, rigoureux et qui seraient moins concernés par l'arbitraire culturel que les savoirs des disciplines telles que l'art ou la philosophie. Pour Bourdieu et Passeron [21] le succès en sciences semble dépendre moins directement de la possession d'un capital culturel. Ainsi, les rendements des apprenants en science seraient moins liés aux émotions par rapport aux disciplines littéraires. Cette hypothèse est soutenue par les résultats à la figure 7. Cette figure présente l'évolution de l'erreur RMSE par catégorie de disciplines en prenant en compte soit uniquement les émotions à valences négatives, soit uniquement les émotions à valences positives soit les deux catégories d'émotions. Les résultats aux figures 7(a) et 8(a) montrent que les émotions à valences positives valorisent davantage le rendement des apprenants dans les disciplines littéraires tandis que les émotions à valences négatives sont dévalorisantes pour les rendements. En ce qui concerne la pratique des sciences cet aspect est moins perceptif (voir figure 7(b)). Cependant, en ce qui concerne spécifiquement la discipline Mathématiques, l'on observe une influence négative des émotions à valences négatives sur le rendement des apprenants (figure 8(b)) et une légère amélioration du rendement en ce qui concerne les émotions à valences positives.

4. Conclusion

Dans la présente contribution, nous avons effectué une étude permettant de discriminer les émotions favorables au rendement des apprenants du secondaire second cycle de l'Enseignement Général. Cette étude s'est réalisée au Lycée Moderne Khalil, lycée d'enseignement secondaire général de la Direction Régionale de l'Éducation Nationale et de l'Alphabétisation de Daloa (Côte d'Ivoire). Elle a impliqué 250 élèves de terminale des séries C et D et a porté sur différentes réalisations de ces apprenants et sur leurs différentes expériences émotionnelles vécues durant les examens blancs de la Direction Régionale. Les différentes disciplines en jeu sont : Mathématiques, Français, Physique-Chimie, Histoire-Géographie, Philosophie et Sciences de la Vie et de la Terre. La technique utilisée pour les différentes simulations est la Factorisation Matricielle et émotionnelle (*Emo-WMRMF*), méthode d'intelligence artificielle

permettant d'apprendre des données de base afin de prédire les données inconnues du système. Les résultats de cette étude ont montré que les émotions influençaient différemment les réalisations dans les disciplines scolaires. Il ressort aussi de cette étude que les émotions à valences positives sont plus avantageuses dans les différentes réalisations en Lettres qu'en Sciences. Il s'agit alors de susciter, et ce principalement dans les disciplines littéraires, des émotions positives dans l'expérience des élèves. Plus spécifiquement, il importe aux enseignants de s'engager dans une démarche à exploiter les émotions comme amplificateurs d'expérience et de rendement personnelle chez l'apprenant.

REFERENCES

- [1] PASEC, "Synthèse du rapport PASEC2019 – Performances du système éducatif ivoirien : Performances et environnement de l'enseignement-apprentissage au primaire," 2019, Available: <https://pasec.confemen.org/ressource/synthese-du-rapport-pasec2019-performances-du-systeme-educatif-ivoirien-performances-et-environnement-de-l-enseignement-apprentissage-au-primaire/>.
- [2] D. A. R. Gono, B. T. Goore, Y. Tiecoura, and K. A. Assielou, "Multi-relational Matrix Factorization Approach for Educational Items Clustering," *International Journal of Information and Education Technology*, vol. 13, no. 1, pp. 42-47, 2023.
- [3] V. Shuman and K. R. Scherer, "Concepts and structures of emotions," in *International handbook of emotions in education*. (Educational psychology handbook series., New York, NY, US: Routledge/Taylor & Francis Group, 2014, pp. 13-35.
- [4] C. Méndez-Aguado, J. M. Aguilar-Parra, J. F. Álvarez, R. Trigueros, and J. A. Fernández-Archilla, "The Influence of Emotions, Motivation and Habits in the Academic Performance of Primary Education Students in French as a Foreign Language," *Sustainability*, vol. 12, no. 6, 2020.
- [5] K. A. Assielou, C. T. Haba, B. T. Gooré, T. L. Kadjo, and K. D. Yao, "Emotional Impact for Predicting Student Performance in Intelligent Tutoring Systems (ITS)," *International Journal of Advanced Computer Science and Applications*, vol. 11, no. 7, 2020.
- [6] K. A. Assielou, C. T. Haba, T. L. Kadjo, B. T. Goore, and K. D. Yao, "A New Approach to Modelling Students' Socio-Emotional Attributes to Predict Their Performance in Intelligent Tutoring Systems," *Journal of Education and e-Learning Research*, vol. 8, no. 3, pp. 340-348, 2021.
- [7] R. Pekrun, "The Control-Value Theory of Achievement Emotions: Assumptions, Corollaries, and Implications for Educational Research and Practice," *Educational Psychology Review*, vol. 18, no. 4, pp. 315-341, 2006.
- [8] N. Thai-Nghe, L. Drumond, A. Krohn-Grimberghe, and L. Schmidt-Thieme, "Recommender system for predicting student performance," *Procedia Computer Science*, vol. 1, no. 2, pp. 2811-2819, 2010.
- [9] Y. Koren, R. Bell, and C. Volinsky, "Matrix Factorization Techniques for Recommender Systems," *Computer*, vol. 42, no. 8, pp. 30-37, 2009.
- [10] A. Krohn-Grimberghe, L. Drumond, C. Freudenthaler, and L. Schmidt-Thieme, "Multi-relational matrix

- factorization using bayesian personalized ranking for social network data," presented at the Proceedings of the fifth ACM international conference on Web search and data mining, 2012.
- [11] C. Lippert, S.-H. Weber, V. Tresp, M. Schubert, and H.-P. Kriegel, "Relation Prediction in Multi-Relational Domains using Matrix Factorization," presented at the NIPS 2008 Workshop on Structured Input - Structured Output., 2008.
- [12] N. Thai-Nghe and L. Schmidt-Thieme, "Multi-relational Factorization Models for Student Modeling in Intelligent Tutoring Systems," presented at the 2015 Seventh International Conference on Knowledge and Systems Engineering (KSE), 2015.
- [13] N. Thai-Nghe, M. Nhut-Tu, and H.-H. Nguyen, "An Approach for Multi-Relational Data Context in Recommender Systems," in Asian Conference on Intelligent Information and Database Systems, 2017, pp. 709-720.
- [14] K. A. Assielou, C. T. Haba, T. L. Kadjo, K. D. Yao, and B. T. Gooré, "Multi-Relational and Social-Influence Model for Predicting Student Performance in Intelligent Tutoring Systems (ITS)," *International Journal of Engineering and Advanced Technology*, vol. 9, no. 3, pp. 2058-2066, 2020.
- [15] P. Nedungadi and T. K. Smruthy, "Personalized Multi-relational Matrix Factorization Model for Predicting Student Performance," *Advances in Intelligent Systems and Computing*, vol. 384, 2016.
- [16] S. Rendle, "Factorization Machines with libFM," *ACM Transactions on Intelligent Systems and Technology*, vol. 3, no. 3, pp. 1-22, 2012.
- [17] S. Theodoridis, "Stochastic Gradient Descent," in *Machine Learning*, 2015, pp. 161-231.
- [18] N. Satish et al., "Navigating the maze of graph analytics frameworks using massive graph datasets," presented at the Proceedings of the 2014 ACM SIGMOD international conference on Management of data - SIGMOD '14, 2014.
- [19] L. Soulier and P. Largy, "Chapitre 7. Émotions et langage écrit," in *Émotions et apprentissages*, 2021, pp. 205-228.
- [20] M. Van Brederode, "Les textes de savoirs dans les cahiers de SVT des élèves de 6e. Problématisation et inégalités," *Recherches en didactiques*, vol. N° 28, no. 2, pp. 89-100, 2019.
- [21] P. Bourdieu and J.-C. Passeron, É. d. Minit, Ed. *La reproduction : Eléments pour une théorie du système d'enseignement*. 1970, p. 284.