

Profilage comportemental dans les jeux vidéo éducatifs via des réseaux convolutifs graphiques : le cas de GraphoGameFrançais

Emna Ammari¹ Patrice Bellot¹ Ambre Denis-Noël² Johannes C.Ziegler²

(1) Aix Marseille Univ, CNRS, LIS, Marseille, France

(2) Aix Marseille Univ, CNRS, CRPN, Marseille, France

emna.ammari@lis-lab.fr, patrice.bellot@univ-amu.fr,
johannes.ziegler@univ-amu.fr, ambre.denis@univ-amu.fr

RÉSUMÉ

Les données comportementales des jeux vidéo ainsi que les traces de joueurs suscitent un intérêt croissant, tant pour la recherche que pour l'industrie du jeu. Ces données peuvent notamment enrichir l'expérience de jeu et améliorer l'identification automatique des profils des joueurs. Dans cet article, nous nous intéressons principalement aux données du jeu sérieux GraphoGame, un outil innovant d'aide à l'apprentissage de la lecture, offrant un environnement interactif pour les apprenants. Nous cherchons notamment à évaluer l'impact de ce jeu sur la performance des élèves en lecture via le profilage comportemental des joueurs et un apprentissage à base de graphes. Ainsi, deux techniques d'intégration basées sur des réseaux convolutifs, GraphSAGE et ECCConv, sont mises à profit pour classer les graphes d'interactions des joueurs. Les résultats montrent qu'ECCConv surpasse GraphSAGE, mais que leurs prédictions combinées peuvent améliorer la classification, confirmant l'impact éducatif de GraphoGame même chez les élèves les plus avancés.

ABSTRACT

Behavioral profiling in educational video games through graph convolutional networks : GraphoGameFrançais use case.

Recently, behavioral data of computer games and players actions have turned to be a pivotal interest for both researchers and game industry. These data could substantially enhance the gaming experience and machine learning tasks to build more actionable groups of players. In this paper, we're more interested in a serious learning game data GraphoGame, an advanced tool providing learners with a dynamic educational environment. In light of this, the study focuses on revealing the true impact of GraphoGame on students' reading performance through behavior profiling and graph representation learning. Accordingly, two convolutional network-based embedding techniques, GraphSAGE and ECCConv, are leveraged to classify player interactions graphs. The results show that ECCConv can outperform GraphSAGE, yet their combined predictions enhance classification, underlining the educational impact of GraphoGame even among advanced students.

MOTS-CLÉS : Jeux vidéo sérieux – profilage des joueurs – réseaux convolutifs de graphes – intégrations de graphes.

KEYWORDS: Serious video games – players profiling – graph convolutional networks – graph embeddings.

ARTICLE : **Accepté à IA-ÉDU@CORIA-TALN 2025.**

1 Introduction

En quelques décennies, les jeux vidéo se sont imposés comme une source majeure de divertissement et de plaisir au niveau mondial. Devenu une tendance en plein essor, ce domaine attire des joueurs de tous âges et de tous horizons. Certains jeux se distinguent par un objectif « sérieux » et sont appréciés pour leur impact éducatif (Wong *et al.*, 2007). Ces jeux proposent une approche interactive et diversifiée, à même de répondre à des objectifs de formation, de communication ou de sensibilisation plutôt que de simplement divertir. En France, l'industrie du jeu éducatif affiche une progression spectaculaire, entraînant plusieurs startups à cibler en priorité les établissements scolaires et les centres de formation. Selon (Lee & Peng, 2006), les jeux éducatifs s'adressent principalement aux enfants de moins de dix ans et visent à renforcer leurs compétences en lecture ainsi que leur expérience éducative enrichie par des activités ludiques. Ce type de jeux constitue un vecteur privilégié favorisant un apprentissage actif et contextualisé ainsi que l'engagement scolaire des élèves.

Dans le but d'assurer une expérience utilisateur enrichissante, les concepteurs de jeux manifestent un intérêt croissant pour l'analyse en temps réel des interactions des joueurs. Ces observations obtenues durant le *gameplay* améliorent la qualité des jeux et permettent une meilleure compréhension de l'implication des joueurs, tout en maintenant leur intérêt. Par conséquent, les indicateurs de *gameplay*, définis comme les traces numériques laissées par les joueurs (Drachen *et al.*, 2013), constituent des éléments majeurs dans les processus de modélisation comportementale des joueurs.

Ce travail s'inscrit autour du jeu sérieux GraphoGameFrançais relevant d'une dynamique interdisciplinaire, combinant l'informatique, les sciences de l'éducation et la psychologie cognitive. Il est basé sur une version française du jeu finlandais GraphoGame, un outil numérique d'aide à l'apprentissage de la lecture. La version française de GraphoGame (GGF)¹ propose un programme d'entraînement audiovisuel visant à renforcer les compétences fondamentales en lecture chez les enfants d'âge préscolaire et primaire, y compris ceux présentant des troubles spécifiques des apprentissages.

2 Analyse d'impact des jeux sérieux et identification de profils

Bien que de nombreuses recherches antérieures aient mis en lumière l'efficacité des jeux vidéo sérieux à visée éducative (Wong *et al.*, 2007; Smith, 2008; Laamarti *et al.*, 2014), la plupart se limitent à des revues de la littérature ou des analyses conceptuelles. En revanche, les recherches empiriques fondées sur des données issues du *gameplay* réel demeurent rares.

Deux études ciblées (Lassault *et al.*, 2022; Ruiz *et al.*, 2017) ont été menées afin d'évaluer l'efficacité de GGF en comparaison avec un autre outil d'entraînement des compétences mathématiques, FieteMath². Bien que ces travaux aient confirmé l'apport distinct de GGF auprès d'enfants à risque de dyslexie scolarisés, leurs analyses reposaient exclusivement sur des données et des évaluations des activités de lecture en dehors du jeu ou sur quelques indicateurs tels que le pourcentage de bonnes réponses ou le nombre de niveaux complétés. Ainsi, les données séquentielles des traces d'interaction enregistrées durant le *gameplay* ont été exclues de ces analyses.

En outre, les jeux vidéo commerciaux non éducatifs ont fait l'objet de nombreuses analyses, reposant sur divers attributs et méthodes. Des caractéristiques dérivées à l'aide d'outils tels que des caméras

1. <https://graphogame.com/le-jeu/>

2. <https://www.ahoiini.com>

(Kim *et al.*, 2015) ou des capteurs enregistrant les réactions des joueurs (Smerdov *et al.*, 2023) ont été exploitées pour identifier des clusters de comportements distincts, comme le souligne également la revue de Hooshyar *et al.* (2018). D'autres études, en revanche, se sont appuyées sur les fichiers logs de *gameplay* comme source principale de données d'interactions (Sifa *et al.*, 2014; Saas *et al.*, 2016; Menéndez *et al.*, 2014), en recourant à des méthodes non supervisées pour l'analyse des parcours des joueurs. Par ailleurs, plusieurs approches fondées sur des réseaux de neurones, telles que les architectures à mémoire longue à court terme LSTM (Shahzad Farooq *et al.*, 2021), les modèles d'apprentissage par renforcement profond (Gharbi *et al.*, 2024), et, plus récemment, le modèle *Actionable Forecasting Network* (Jagirdar *et al.*, 2024), ont été mobilisées pour l'identification des profils d'utilisateurs. Les représentations vectorielles des interactions des joueurs se sont également révélées pertinentes pour la modélisation des comportements complexes, notamment à travers l'usage de techniques d'intégration de nœuds (*node embedding*) telles que Node2Vec et *Large-scale Information Network Embedding* (Shah & Thue, 2023), ou encore des encodeurs basés sur des réseaux de neurones (Sapienza *et al.*, 2019) et des modèles de langue (Wang *et al.*, 2024). Enfin, les réseaux de neurones graphiques (*Graph Neural Networks*, GNNs) se sont révélés particulièrement efficaces dans l'analyse du *gameplay*. Cependant, l'attention s'est majoritairement portée sur des représentations vectorielles au niveau des nœuds, en association avec d'autres méthodes d'apprentissage automatique ou techniques de partitionnement telles que les k-moyennes (Melo *et al.*, 2020).

En complément de ces études, notre travail s'inscrit dans une direction peu explorée, en mettant l'accent sur les plongements (*embeddings*) au niveau des graphes pour la modélisation des joueurs. L'ensemble du graphe d'interaction est encodé dans un espace latent, permettant un profilage direct, sans avoir recours à des classificateurs supplémentaires. Sur le plan applicatif, cet article a pour objectif de mettre en évidence et de valider l'impact éducatif du GGF sur l'amélioration des compétences en lecture, en exploitant les traces comportementales générées en jeu pour une caractérisation fine de profils d'apprenants à l'aide de techniques d'apprentissage automatique sur graphes.

3 GraphoGame : expérimentation et données

GraphoGame constitue un cadre méthodologique innovant favorisant une intégration effective des technologies numériques au sein des environnements d'apprentissage scolaires. Une expérimentation a été conduite auprès de plusieurs groupes d'élèves de niveau CP³, durant des cours de français durant l'année scolaire 2017–2018. Les sessions d'entraînement sur tablette étaient organisées à raison de quatre par semaine, chacune durant entre 15 et 20 minutes, selon le rythme et le taux d'erreurs de chaque élève. Au total, 451 élèves âgés de 5 à 8 ans ont pris part à l'expérimentation. Ces élèves ont ainsi été engagés, via l'application, dans une variété d'activités ludiques de lecture, conçues pour renforcer leurs compétences en décodage de lettres et de mots ainsi que le développement de la fluidité en lecture. Ces activités s'inscrivent dans une progression pédagogique structurée en 67 unités (séquences), chacune centrée sur un contenu spécifique (Lassault *et al.*, 2022).

À titre d'exemple, la première unité introduit les voyelles orales simples (ex. : 'a', 'i', 'e', 'o'), les consonnes continues (ex. : 'f', 'j', 'l', 'r') et des mots monosyllabiques (ex. : 'ou', 'la', 'sol', 'four'). La quatrième, quant à elle, porte sur les voyelles nasales (ex. : 'an', 'on', 'in', 'un') tandis que la troisième propose des exercices de discrimination visuelle (ex. : 'u' vs 'n'), phonémique (ex. : 't' vs 'd') et combinée (ex. : 'p' vs 'b').

3. CP : Cours préparatoire, première année de l'école élémentaire

Chaque unité pédagogique se compose d'environ 10 niveaux, proposant un exercice ludique distinct. La durée moyenne d'un niveau est de 2 à 3 minutes et comprend généralement entre 10 et 15 essais. Selon l'exercice, l'enfant, muni d'un casque, doit associer un stimulus auditif à l'élément visuel correspondant affiché à l'écran. Si le taux d'erreur dépasse 25 %, le niveau est automatiquement réinitialisé. Après cinq tentatives, l'élève peut néanmoins accéder au niveau suivant. L'application permet également à l'élève de revenir sur les niveaux non réussis ou d'ignorer ceux déjà maîtrisés.

Les interactions des élèves avec GraphoGameFrançais génèrent une séquence horodatée d'événements. Ces données, issues de 1 548 100 actions consignées, constituent la principale source des métriques de *gameplay* analysées dans le cadre de cet article, à partir desquelles quatre indicateurs clés sont sélectionnés (table 1).

Indicateur	Description
accuracy	Indique si la réponse du joueur est correcte (1) ou non (0)
RTclean	Temps de réaction du joueur pour donner des réponses correctes
nRepLevel	Nombre de répétitions d'un niveau donné par un joueur
abortedLevel	Indique si le joueur a quitté le niveau avant de le terminer (1) ou non (0)

TABLE 1 – Indicateurs comportementaux du *gameplay*.

À la suite du prétraitement des données, 440 joueurs ont été retenus pour la modélisation, soit 440 séquences de données détaillant l'intégralité de leurs actions dans le jeu. Les participants ont complété 49 unités pédagogiques, les premières étant les plus fréquemment jouées, comme l'illustre la figure 1. Au total, 579 niveaux ont été explorés. Toutefois, certaines des unités n'ont pas été entièrement parcourues par l'ensemble des élèves. L'unité pédagogique 4.1 représente, pour la majorité d'entre eux, la phase la plus avancée atteinte.




FIGURE 1 – Nombre d'élèves ayant joué à chaque unité pédagogique parmi les 440 joueurs retenus.

Une série d'évaluations a été conduite, avant et après l'entraînement des élèves avec GGF, pour mesurer l'évolution des performances en lecture au fil du temps. Les pré-tests ont été effectués en

novembre 2017, suivis d’une session post-test en juin 2018, durant laquelle les mêmes exercices ont été reproduits afin d’évaluer les progrès réalisés. Les tests d’évaluation se sont principalement axés sur diverses compétences en lecture, telles que détaillées dans (Lassault *et al.*, 2022).

Les évaluations pré- et post-intervention reposent principalement sur trois mesures : le nombre de mots correctement lus dans un texte dénué de sens lors du test de l’Alouette, les performances en décodage de pseudo-mots et de mots familiers issues du test "Lecture une Minute" LUM, ainsi que la capacité d’identification orthographique de mots, évaluée par le test TIME2.

Trois groupes d’élèves ont été identifiés sur la base de leurs performances initiales (lors des pré-tests) et le gain obtenu (post-pre) à la fin de l’année scolaire : ‘les bons répondants’ (cluster C_1), ayant enregistré des progrès supérieurs à la moyenne, ‘les mauvais répondants’ (cluster C_2), dont les performances sont demeurées significativement inférieures avec une progression limitée, et ‘les bons élèves’ (cluster C_0), qui présentaient déjà un niveau initial élevé et ont maintenu une progression continue, similaire à celle ‘des bons répondants’.

L’enjeu applicatif principal de cet article⁴ consiste alors à retrouver les trois groupes préalablement définis, en s’appuyant sur les indicateurs comportementaux du jeu plutôt que sur les résultats aux tests de lecture. L’identification rapide des élèves qui répondent ou pas à une intervention, telle que GGF, est capitale sur le plan pédagogique ou thérapeutique (Ziegler *et al.*, 2020).

4 Méthodologie à base de réseaux neuronaux graphiques

Étant donné que les joueurs ont tendance à suivre des parcours d’apprentissage non linéaires, divers scénarios d’interaction peuvent être détectés et analysés. Ces données non structurées génèrent, pour chaque joueur, une séquence d’horodatages (*timestamps*) de taille variée. Les réseaux de neurones graphiques (GNNs) sont de bons candidats pour le traitement de telles structures de données du fait de leurs représentations sous forme de graphes. Les approches de modélisation associées ne reposent pas uniquement sur la topologie, mais intègrent également les attributs des nœuds.

4.1 Approche GraphSAGE

GraphSAGE (*Graph Sample and Aggregation*) constitue un modèle performant pour l’apprentissage sur les graphes, basé sur une agrégation récursive des informations issues des nœuds voisins (Hamilton *et al.*, 2017). Cette approche permet de générer des représentations vectorielles (*embeddings*) pour des nœuds jamais observés durant l’apprentissage, et par conséquent pour des graphes de traces de joueurs entièrement nouveaux.

L’application d’une approche graphique pour la classification supervisée nécessite le recours à une bibliothèque d’implémentation adaptée. Spektral⁵ en fournit une version robuste, compatible avec les modèles convolutionnels inductifs. Son emploi implique, toutefois, un prétraitement des données, des matrices de caractéristiques des nœuds et des structures d’adjacence. Pour cela, les niveaux joués sont modélisés comme des nœuds du graphe, tandis que les arêtes traduisent les transitions entre ces niveaux. La figure 2 illustre un exemple de parcours d’un joueur, représenté par un sous-ensemble de

4. cette étude s’inscrit dans une démarche de science ouverte.

5. <https://graphneural.network>

niveaux joués, dont certains sont revisités à plusieurs reprises. Ces répétitions sont symbolisées par des boucles de nœuds, accentuées par des liens en gras, soulignant ainsi les aspects non linéaires du parcours.

À partir de cette modélisation, nous avons implémenté un modèle GraphSAGE dont l’architecture repose sur trois couches GraphSageConv suivies d’un GlobalAvgPool, permettant l’apprentissage de représentations vectorielles des graphes à partir des voisinages locaux des nœuds. Les deux premières couches convolutionnelles utilisent des embeddings intermédiaires de dimension 64, tandis que la dernière projette les représentations vers un espace aligné avec le nombre de classes cibles. Une couche dense softmax assure ensuite la prédiction des profils comportementaux à partir de ces représentations.




FIGURE 2 – Exemple des interactions d’un joueur pour certains niveaux joués.

En entrée, l’architecture mobilise une matrice d’adjacence creuse, encodant uniquement les connexions effectives entre les entités, une matrice d’attributs de nœuds dérivée de métriques clés du *gameplay*, décrivant les interactions par niveau, ainsi que des labels de classes définis. Malheureusement, la couche GraphSageConv n’intègre pas les poids des arêtes et repose sur une matrice d’adjacence binaire, indiquant si un lien existe ou non entre les nœuds. Cette limitation réduit la capacité du modèle à refléter des informations structurelles fines, notamment lorsque certains niveaux font l’objet de multiples retours.

4.2 Approche ECCConv

En réponse à cette contrainte, une seconde architecture a été développée reposant sur la couche ECCConv (*Edge-Conditioned Convolution*) (Simonovsky & Komodakis, 2017) de Spektral, permettant d’intégrer la fréquence des transitions entre niveaux en tant que caractéristiques portées par les arêtes. Ces attributs sont ensuite exploités par cette couche pour adapter dynamiquement le filtrage appliqué aux nœuds voisins, offrant ainsi une modélisation plus fine et contextuelle des relations au sein du graphe.

L'architecture adoptée reprend la structure de GraphSAGE, avec trois couches ECCConv successives, suivies d'une opération de *pooling* global moyen. Le modèle ECCConv adopte une structure hiérarchique avec des dimensions croissantes d'embeddings successives (32, 64, puis 128), reflétant l'approche classique d'augmentation progressive de la capacité représentative. En sortie, deux couches denses sont utilisées : la première (ReLU) pour l'apprentissage de représentations profondes et la seconde (Softmax) pour la classification multi-classe. L'entrée du modèle est similaire à l'approche précédente, enrichie des attributs d'arêtes.

5 Résultats

Pour la tâche de classification, consistant à reconnaître à quelle classe appartient un élève parmi C_0 , C_1 et C_2 (voir section 3), la précision obtenue est de 66% pour GraphSAGE et de 68% pour ECCConv. En complément, le F1-score met en évidence la meilleure capacité du second à distinguer les classes minoritaires, tout en maintenant de bonnes performances globales. Cette tendance en faveur d'ECCConv est également observée lors de plusieurs exécutions indépendantes (moyennes de 67,2% vs 64,9%), avec une p -value de 0,089 (test t de *Welch*) suggérant qu'elle mérite d'être confirmée par des analyses complémentaires.

Une stratégie de fusion pondérée (50-50) des prédictions des deux modèles a ensuite été appliquée. Cette combinaison a permis d'accroître la robustesse de la classification, atteignant une précision de 71% et améliorant la détection des profils de joueurs, ce qui renforce l'hypothèse de l'impact éducatif positif de GGF.

Une analyse par classe (cf. table 2) montre que l'approche combinée capte plus finement les spécificités de chaque profil, notamment pour les élèves en difficulté (classe C_2) suggérant un besoin d'accompagnement ciblé et ouvrant la voie à des parcours d'apprentissage plus adaptés. L'identification de la classe C_1 (F1-score = 0,68) confirme que ces élèves ont bénéficié de l'entraînement avec GGF, bien que leur distinction avec la classe C_0 demeure plus subtile, en raison de comportements d'apprentissage similaires.

	GraphSAGE	ECCConv	Approche combinée	
Accuracy	66,25	68,75	71,25	0,65 C_0
				0,71 C_1
				0,77 C_2
F1-score	64,58	68,74	71,20	0,70 C_0
				0,68 C_1
				0,77 C_2

TABLE 2 – Résultats des deux approches GraphSAGE et ECCConv.

Les élèves de la classe C_0 , ayant entamé l'expérimentation avec un bon niveau initial, obtiennent un F1-score de 0,70 indiquant une reconnaissance fiable. Ce résultat souligne que ces profils, bien qu'en minorité, sont correctement identifiés, renforçant l'utilité pédagogique du jeu pour tous les types d'élèves.

GGF permet également une analyse fine de la progression des élèves tout au long de l'expérimentation, comme l'illustre la figure 3. Celle-ci met en évidence l'évolution des traces comportementales des joueurs, segmentés en clusters, au fil du temps et selon divers indicateurs de *gameplay*.




FIGURE 3 – Analyse des parcours de jeu associés aux trois clusters.

Les courbes révèlent une forte similarité de progression entre les clusters C_0 et C_1 , en contraste avec les élèves en difficulté, marqués par un faible taux de bonnes réponses et des répétitions fréquentes de niveaux sans progrès notable. À l'inverse, certains niveaux, impliquant des temps de réponse plus élevés ou des abandons en cours de tâche chez les bons élèves, restent inaccessibles aux élèves en difficulté et partiellement explorés par les bons répondants. Cela suggère que ces niveaux, probablement plus exigeants sur le plan pédagogique, constituent des points de blocage pour les élèves, et justifieraient une attention particulière en classe ou une intégration plus progressive au sein du dispositif d'apprentissage.

6 Conclusion et perspectives

Cette étude visait à évaluer l'impact éducatif de GraphoGameFrançais (GGF) à travers une analyse comportementale fondée sur des représentations graphiques des parcours d'apprenants. En mobilisant deux modèles de réseaux de neurones graphiques, GraphSAGE et ECCConv, nous avons pu classer les profils d'élèves à partir des dynamiques d'apprentissage extraites, mettant ainsi en évidence les bénéfices spécifiques de l'application dans le développement des compétences en lecture.

Au-delà de sa fonction d'entraînement à la lecture, GGF se révèle également être un dispositif de suivi pédagogique efficace, permettant d'identifier les élèves nécessitant un accompagnement éducatif particulier, ainsi que ceux qui tirent pleinement parti de l'entraînement. Ce potentiel de diagnostic

ouvre la voie vers une stratégie d'apprentissage différencié, durant laquelle des interventions et des parcours adaptés pourraient être construits selon les besoins spécifiques des élèves.

Bien que notre étude ait mis en évidence l'effet éducatif de GGF, son usage en parallèle des enseignements scolaires suggère qu'il pourrait constituer un outil complémentaire aux apprentissages en classe, plutôt qu'un vecteur d'acquisition autonome. Pour mieux isoler son impact propre, il serait pertinent de mener des expérimentations dans un cadre non scolaire, auprès de groupes d'élèves aux profils homogènes (notamment en termes d'environnement familial, ou de capacités cognitives) afin de valider de manière plus contrôlée l'efficacité du dispositif.

Une dimension supplémentaire concerne la modélisation des dynamiques d'apprentissage. Elle pourrait être affinée en remplaçant les nœuds actuels (niveaux joués) par des sous-niveaux, tels que les réponses cibles "*targets*" (réponses correctes), afin de mieux exploiter les données. Toutefois, ces éléments se répètent dans différents niveaux, ce qui pourrait diluer l'aspect chronologique. Une alternative consisterait à les concaténer avec d'autres variables contextuelles, comme les options affichées à l'écran, créant ainsi des nœuds de graphes plus détaillés. Cela offrirait une représentation plus fine des parcours et permettrait de mieux capter la progression et les comportements des joueurs.

Un autre enjeu majeur porte sur la présence de variables binaires pour certains attributs. En adoptant un recodage approprié et en réservant une valeur spécifique au padding, il deviendrait possible d'exploiter des architectures séquentielles telles que les LSTM, offrant ainsi une modélisation plus affinée de la dimension temporelle.

7 Financement

Cette étude a été financée par le programme eFRAN (France 2030) soutenu par l'Agence Nationale de la Recherche (ANR-22-FRAN-0004), l'Institut de Convergences sur le Langage, la Communication et le Cerveau (ILCB, ANR-16-CONV-0002) et le Pôle pilote pour la recherche en éducation et la formation des enseignants (AMPIRIC).

Références

- DIAS G., Éd. (2015). *Actes de TALN 2015 (Traitement automatique des langues naturelles)*, Caen. ATALA, HULTECH.
- DRACHEN A., CANOSSA A. & SØRENSEN J. R. M. (2013). Gameplay metrics in game user research : Examples from the trenches. In *Game analytics : Maximizing the value of player data*, p. 285–319. Springer.
- GHARBI H., ELAACHAK L. & FENNAN A. (2024). Replicating video game players' behavior through deep reinforcement learning algorithms. *Journal of Theoretical and Applied Information Technology*, **102**(15).
- HAMILTON W., YING Z. & LESKOVEC J. (2017). Inductive representation learning on large graphs. *Advances in neural information processing systems*, **30**.
- HOOSHYAR D., YOUSEFI M. & LIM H. (2018). Data-driven approaches to game player modeling : a systematic literature review. *ACM Computing Surveys (CSUR)*, **50**(6), 1–19.

- JAGIRDAR H., TALWADKER R., PAREEK A., AGRAWAL P. & MUKHERJEE T. (2024). Explainable and interpretable forecasts on non-smooth multivariate time series for responsible gameplay. In *Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, p. 5126–5137.
- KIM Y. B., KANG S. J., LEE S. H., JUNG J. Y., KAM H. R., LEE J., KIM Y. S., LEE J. & KIM C. H. (2015). Efficiently detecting outlying behavior in video-game players. *PeerJ*, **3**, e1502.
- LAAMARTI F., EID M. & EL SADDIK A. (2014). An overview of serious games. *International Journal of Computer Games Technology*, **2014**(1), 358152.
- LASSAULT J., SPRENGER-CHAROLLES L., ALBRAND J.-P., ALAVOINE E., RICHARDSON U., LYYTINEN H. & ZIEGLER J. C. (2022). Testing the effects of graphogame against a computer-assisted math intervention in primary school. *Scientific Studies of Reading*, **26**(6), 449–468.
- LEE K. M. & PENG W. (2006). What do we know about social and psychological effects of computer games ? a comprehensive review of the current literature. *Playing video games : motives, responses, and consequences*.
- MELO S. A., KOHWALTER T. C., CLUA E., PAES A. & MURTA L. (2020). Player behavior profiling through provenance graphs and representation learning. In *Proceedings of the 15th International Conference on the Foundations of Digital Games*, p. 1–11.
- MENÉNDEZ H. D., VINDEL R. & CAMACHO D. (2014). Combining time series and clustering to extract gamer profile evolution. In *Computational Collective Intelligence. Technologies and Applications : 6th International Conference, ICCCI 2014, Seoul, Korea, September 24-26, 2014. Proceedings 6*, p. 262–271 : Springer.
- RUIZ J.-P., LASSAULT J., SPRENGER-CHAROLLES L., RICHARDSON U., LYYTINEN H. & ZIEGLER J. C. (2017). Graphogame : un outil numérique pour enfants en difficultés d'apprentissage de la lecture. *ANAE Approche neuropsychologique des apprentissages chez l'enfant*.
- SAAS A., GUITART A. & PERIÁNEZ A. (2016). Discovering playing patterns : Time series clustering of free-to-play game data. In *2016 IEEE Conference on Computational Intelligence and Games (CIG)*, p. 1–8 : IEEE.
- SAPIENZA A., GOYAL P. & FERRARA E. (2019). Deep neural networks for optimal team composition. *Frontiers in big Data*, **2**, 14.
- SHAH J. & THUE D. (2023). Representing player behaviour via graph embedding techniques : A case study in dota 2. In *2023 IEEE Conference on Games (CoG)*, p. 1–8 : IEEE.
- SHAHZAD FAROOQ S., FIAZ M., MEHMOOD I., KASHIF BASHIR A., NAWAZ R., KIM K. & KI JUNG S. (2021). Multi-modal data analysis based game player experience modeling using lstm-dnn. *Computers, Materials and Continua*, **68**(3), 4087–4108.
- SIFA R., BAUCKHAGE C. & DRACHEN A. (2014). The playtime principle : Large-scale cross-games interest modeling. In *2014 IEEE conference on computational intelligence and games*, p. 1–8 : IEEE.
- SIMONOVSKY M. & KOMODAKIS N. (2017). Dynamic edge-conditioned filters in convolutional neural networks on graphs. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, p. 3693–3702.
- SMERDOV A., SOMOV A., BURNAEV E. & STEPANOV A. (2023). Ai-enabled prediction of video game player performance using the data from heterogeneous sensors. *Multimedia Tools and Applications*, **82**(7), 11021–11046.
- SMITH P. (2008). Serious games 101. *Rta. Nato. Int*, p. 1–12.

- WANG T., HONARI-JAHROMI M., KATSAROU S., MIKHEEVA O., PANAGIOTAKOPOULOS T., ASADI S. & SMIRNOV O. (2024). player2vec : A language modeling approach to understand player behavior in games. *arXiv preprint arXiv :2404.04234*.
- WONG W. L., SHEN C., NOCERA L., CARRIAZO E., TANG F., BUGGA S., NARAYANAN H., WANG H. & RITTERFELD U. (2007). Serious video game effectiveness. In *Proceedings of the international conference on Advances in computer entertainment technology*, p. 49–55.
- ZIEGLER J. C., PERRY C. & ZORZI M. (2020). Learning to read and dyslexia : From theory to intervention through personalized computational models. *Current Directions in Psychological Science*, **29**(3), 293–300.