



HAL
open science

Analyse de traces d'EIAH pour l'identification de groupes d'apprenants de profil similaire

Fatima Harrak

► **To cite this version:**

Fatima Harrak. Analyse de traces d'EIAH pour l'identification de groupes d'apprenants de profil similaire. 6èmes Rencontres Jeunes Chercheurs en EIAH, RJC-EIAH'2016, Jun 2016, Montpellier, France. hal-01667659

HAL Id: hal-01667659

<https://hal.science/hal-01667659>

Submitted on 19 Dec 2017

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Analyse de traces d'EIAH pour l'identification de groupes d'apprenants de profil similaire

Fatima Harrak

1^{ère} année de doctorat

Sorbonne Universités, UPMC Univ Paris 06, CNRS, LIP6 UMR 7606, 4 place Jussieu, 75005 Paris, France

Université Paris 1 Panthéon-Sorbonne, CRI, 90 rue de Tolbiac, 75013 Paris, France

fatima.harrak@lip6.fr

Résumé

L'objectif de nos travaux est d'analyser des traces d'EIAH pour proposer à l'enseignant des restitutions qu'il puisse exploiter en classe. Il s'agit par exemple de lui proposer des groupes d'élèves qui pourront travailler ensemble dans des ateliers (et non la proposition de parcours individualisés difficiles à mettre en œuvre en présentiel). Nous dressons un état de l'art des techniques existantes dans ce domaine, puis présentons les résultats d'une étude de cas spécifique. Les traces ont été collectées à partir d'une plateforme d'évaluation de compétences mathématiques, proposant aux élèves des questions à réponse ouverte.

Les informations, extraites à partir d'une classe de 23 élèves, portent sur l'exactitude des réponses, le temps nécessaire pour chaque question et le nombre de tentatives. Nous avons appliqué des méthodes de classification non supervisée pour identifier des groupes d'apprenants de profil similaire. Nous avons identifiés deux principaux groupes (les élèves bons et rapides d'une part, les plus mauvais et lents d'autre part) ainsi que quelques profils atypiques. Au-delà de ces résultats prévisibles sur un si petit échantillon, l'objectif de notre thèse est de proposer à l'enseignant une restitution intuitive et automatique des résultats d'analyse, quelle que soit la méthode mise en œuvre (ici, le clustering).

1. Introduction

L'analyse de traces d'EIAH est un domaine qui connaît un développement important, ouvrant des perspectives intéressantes à différents niveaux. Par exemple, un enseignant pourra s'en servir pour personnaliser un parcours d'apprentissage ou guider des interventions auprès de décrocheurs. Un apprenant pourra également visualiser sa trajectoire individuelle au sein d'une formation et son positionnement par rapport aux autres apprenants. Dans le but d'améliorer l'apprentissage, un chercheur pourra exploiter ces traces afin de produire de nouvelles connaissances et proposer des rétroactions

pertinentes ou de diagnostic permettant d'assister l'enseignant lors de ses cours.

Dans cet article, nous nous intéressons aux EIAH utilisés en complément d'un enseignement traditionnel présentiel, (on parle d'apprentissage hybride) essentiellement à des fins d'évaluation.

Notre objectif est d'étudier et d'améliorer la manière dont les évaluations des apprenants sont restituées aux enseignants pour qu'ils les exploitent en classe. Pour ceci, nous avons réalisé une analyse de traces d'une plateforme d'évaluation en mathématiques pour aider l'enseignant à construire des groupes de travail en présentiel. La question des modalités d'évaluation, abordée dans un article antérieur (Le Grand et al. 2015), ne sera pas développée ici.

La suite de cet article est organisée comme suit. Nous décrivons dans la section 2 l'état de l'art sur l'analyse de traces destinée à une restitution à l'enseignant. Nous présentons dans la section 3 la méthodologie de travail que nous avons suivie et les résultats des différentes méthodes de classification utilisées dans cette étude de cas. Nous décrivons ensuite dans la section 4 les caractéristiques des groupes d'étudiants de profil similaire identifiés. Enfin, nous présentons les perspectives de ces travaux pour la poursuite de la thèse.

2. Etat de l'art

2.1. Besoin d'amélioration du suivi des apprenants

La collecte et l'analyse de traces sont de plus en plus répandues dans le contexte du e-learning, comme on peut le voir dans les communautés *Educational Data Mining (EDM)* et *Learning Analytics (LA)*. Les articles de (Siemens et Baker 2012) et de (Romero et Ventura 2013) dressent notamment un panorama des techniques de fouille appliquées au sein de ces deux communautés. La différence principale entre les deux

concerne les cibles de production : pour EDM les algorithmes et outils produits sont principalement utilisés par la machine alors que les outils du LA s'adressent avant tout aux utilisateurs humains. Notre travail se situe dans le champ de LA, puisque le but principal est d'outiller l'enseignant en l'occurrence ici pour qu'il détermine les groupes d'apprenants et non de lui proposer des solutions dans lesquelles le système intervient lui-même auprès des groupes d'apprenants.

Les approches de type fouille de données consistent à manipuler, fouiller ou transformer des traces afin d'en extraire des connaissances pour l'enseignant. Notre objectif est de fournir des résultats directement actionnables par l'enseignant, et non à créer des modèles d'apprenants ou à valider des hypothèses (Iksal 2011).

Les enseignants ont besoin d'outils pour améliorer le suivi des élèves et concevoir des enseignements qui exploitent plus de connaissances que ce que fournissent de simples notes. Nous nous intéressons à la manière dont les résultats d'évaluation peuvent être restitués à l'enseignant, à des fins de diagnostic. Le diagnostic fait partie intégrante de l'activité de l'enseignant : il renseigne sur les connaissances aussi bien que sur les aptitudes ou difficultés des élèves afin d'aider à prendre des décisions relatives à l'adaptation de l'enseignement, à la remédiation ou en matière d'orientation scolaire. Chenevotot et al. (2012) exposent la stratégie d'intégration d'un diagnostic en algèbre élémentaire dans la plateforme LaboMEP de l'association Sésamath, qui est une base d'exercices en ligne largement utilisée par les enseignants de mathématiques de collège. L'étude montre que le diagnostic permet à l'enseignant d'adapter le parcours d'apprentissage en fonction des besoins des élèves. Notre objectif est similaire : nous souhaitons fournir à l'enseignant des informations supplémentaires, par exemple l'aider à construire des groupes de travail collectif en fonction des informations collectées au travers d'une plateforme informatique.

2.2. Extraction de profils individuels

L'utilisation de modèles d'apprenants est l'un des moyens permettant d'adapter l'apprentissage aux spécificités des apprenants ; c'est aussi une façon d'aider l'enseignant ou le tuteur dans sa tâche de suivi (Grandbastien et Labat, 2006). Les techniques de fouille de données et d'apprentissage automatique peuvent être utilisées pour identifier aussi tôt que possible dans le processus d'apprentissage le modèle de l'apprenant (Koedinger et al. 2013, Timms et al. 2015). Long et al. (2015) utilisent des approches cognitives pour découvrir le modèle de l'apprenant et inciter les étudiants à suivre des stratégies pour prendre la bonne décision. D'autres auteurs utilisent plutôt des profils (Carlson et al. 2013) pour caractériser les stratégies d'apprentissage et adapter les instructions à chaque apprenant. Le modèle correspond à la modélisation générique des apprenants, alors que le profil fait référence aux informations concernant un individu donné dans un contexte donné. Le profil d'un apprenant (Jean-Daubias et al. 2009) contient un ensemble

d'informations interprétées, concernant ses connaissances, compétences, son comportement, ou encore des informations d'ordre métacognitif. Dans notre cas, nous nous intéressons plutôt à extraire des profils pour fournir à l'enseignant, à partir des résultats d'évaluation à l'échelle individuelle, des pistes pour la constitution de groupes d'élèves, ainsi que pour l'élaboration du programme à aborder dans chaque groupe, en fonction des profils identifiés.

Les traces peuvent être exploitées pour fournir des recommandations basées sur les expériences passées (Hug et al. 2012) ou des feedbacks adaptatifs en temps réel (Conati et al. 2015). Elles peuvent également permettre de détecter le décrochage dans les MOOCs (Bani 2014) ou en présentiel, comme (Ecar-Analytics 2015) qui décrit l'impact des analyses prédictives sur les processus d'apprentissage.

Dans notre travail, nous ne cherchons pas à prédire les performances des élèves ; nous nous sommes focalisés sur l'identification de groupes d'élèves de profil similaire.

2.3. Identification de groupes d'apprenants

Plusieurs travaux utilisent des techniques de classification pour fournir des restitutions à l'échelle d'un groupe d'apprenants. (Sachan et al. 2012) analysent les motifs d'interaction entre utilisateurs pour identifier des communautés dans les réseaux sociaux. D'autres (Floryan et al. 2015) utilisent des techniques pour automatiser les évaluations des apprenants afin d'identifier les groupes qui nécessitent une intervention de l'enseignant. (Kaser et al. 2013) regroupent les élèves similaires selon leurs trajectoires d'apprentissage afin de prédire leurs performances. Les méthodes de clustering peuvent être utilisées en apprentissage pour améliorer les performances de prédiction dans le système ou simplement pour mieux comprendre le comportement d'un apprenant (Davoodi et al. 2013), en caractérisant ensuite ces clusters (Bouchet et al. 2013).

Dans notre étude de cas, nous cherchons à identifier des groupes d'apprenants à partir des données de la plateforme de révision en mathématiques KWYK¹. Nous avons eu recours à la classification non supervisée pour regrouper les élèves de profil similaire dans des classes (non prédéfinies). En effet, les données disponibles, relatives aux évaluations des élèves, ne contiennent pas d'informations de type label permettant d'effectuer une classification supervisée. De plus, les méthodes de détection de communautés n'ont pas été applicables du fait qu'il ne s'agit pas de graphes.

3. Détermination de clusters

Nous avons utilisé des méthodes de clustering pour créer de petits groupes homogènes et identifier les élèves de profil similaire. L'intérêt des approches de clustering est de fournir des connaissances facilement exploitables par les enseignants, puisqu'elles n'impliquent pas une action auprès de chaque étudiant mais plutôt à l'échelle de quelques groupes. Notre

¹ www.kwyk.fr

objectif est de proposer à l'enseignant une répartition possible des élèves dans des groupes différents. Ces restitutions (retours exploitables par l'enseignant dans le contexte présentiel) prennent en compte non seulement les notes des élèves mais aussi leurs différents rythmes, sans étiqueter les apprenants comme « bons » ou « mauvais » élèves.

3.1. Méthodologie : comparaison de 3 méthodes

Présentation des données

Les résultats présentés ici proviennent de l'analyse de données anonymisées issues de la plateforme KWYK dédiée à la révision des mathématiques. L'enseignant crée un devoir, constitué d'exercices associés à des compétences spécifiques (par exemple le calcul mental, les opérations, les nombres décimaux). Les devoirs proposés par KWYK¹ comportent en grande majorité des questions « ouvertes » : les élèves (de la 6e à la terminale) doivent en effet taper eux-mêmes la réponse, sous forme de valeur ou d'équation par exemple. L'élève peut répondre correctement du premier coup à la question ouverte ou en seconde chance par QCM en cas de mauvaise réponse initiale. Ces devoirs doivent être résolus par les élèves en dehors des heures de classe. L'élève a donc la possibilité de répondre aux questions d'un devoir dans l'ordre qu'il préfère. L'enseignant l'autorise aussi à refaire un devoir autant de fois qu'il souhaite jusqu'à ce qu'il obtienne une bonne note. Un nouveau questionnaire, de difficulté et structure équivalente est généré automatiquement.

Les données collectées proviennent d'une classe particulière de 23 élèves de niveau 6ème (parmi les 160 classes que nous avons à notre disposition, c'est l'une des classes les plus importantes en nombre d'élèves et d'exercices). Le choix d'une seule classe est essentiel pour notre cas parce que nous voulons faire des groupes au sein d'une même classe, et pas parmi des apprenants de classes différentes. Les exercices sont répartis sur deux devoirs, chaque devoir comportant en moyenne 27 exercices couvrant deux compétences (calcul mental et nombre décimaux) et 5 tentatives par élève. Les données analysées consistent en l'ensemble des résultats obtenus par les élèves à ces devoirs qui contiennent des exercices étiquetés par domaine de compétences. Les traces reflètent l'heure d'affichage d'une question et l'heure de sa résolution, ce qui permet par la suite de calculer le temps de réponse de chaque élève, le nombre de tentatives pour réussir un exercice, ainsi que le résultat obtenu par l'élève. Pour construire un profil, nous avons considéré les trois critères suivants : le niveau d'acquisition (note) sur chacune des compétences, le temps moyen pour résoudre des exercices par type de compétence et le nombre de tentatives par devoir (il s'agit d'une réponse à une nouvelle instance de l'exercice).

Le nettoyage des données consiste à éliminer les données aberrantes et manquantes ; dans ce cas nous n'avons pas supprimé d'élèves, mais seulement les réponses qui dépassent les 30 minutes, pour chaque élève. Nous avons ensuite standardisé le reste de

données pour éviter les différences d'échelles. Nous présentons par la suite les trois méthodes de clustering choisies pour cette étude, issues de familles de méthodes différentes : CAH, une méthode hiérarchique très connue, K-Means, une méthode de partition et SOM, une approche plus heuristique.

CAH

Cette méthode consiste à fusionner les deux classes les plus proches dans une même classe. Cette opération est répétée jusqu'à ce qu'il ne reste plus qu'une seule classe. Nous avons choisi la méthode *Ward* pour calculer la dissimilarité entre deux classes et qui consiste à regrouper les classes de façon à ce que l'augmentation de l'inertie interclasse soit maximum. Pour choisir le nombre de clusters, il faut donc couper le dendrogramme où la hauteur des branches est élevée pour que la perte d'inertie interclasse soit la plus faible possible.

K-means

K-means est l'une des méthodes de partitionnement de données les plus simples. Son principe est de choisir aléatoirement un ensemble de centres fixé a priori et de chercher itérativement la partition optimale. La limite principale de cette méthode est dans le choix d'un nombre optimal de clusters. Nous sommes partis des résultats obtenus par CAH, qui propose un nombre optimal de clusters pour maximiser le gain d'inertie et pour comparer plus facilement les résultats obtenus par les deux méthodes.

SOM

Les cartes auto-adaptatives (Self Organizing Map) est un cas particulier de réseau de neurones non-supervisé, qui permet de réduire les dimensions et visualiser les données sous forme d'une carte fixée a priori.

3.2. Résultats

La figure 1 présente le dendrogramme obtenu avec la Classification Ascendante Hiérarchique pour les élèves d'une classe spécifique (de niveau 6ème).




Figure 1 : Dendrogramme de classification ascendante hiérarchique

Ce graphique se lit comme un arbre généalogique : moins on remonte dans l'arbre pour relier deux individus et plus leur degré de « parenté » est élevé. La

hauteur à laquelle se trouvent reliés les individus illustre leur niveau de ressemblance : il s'agit de l'indice de niveau. Plus cet indice est faible (proche de 0), plus les individus sont semblables. Ce diagramme nous suggère un découpage en trois clusters avec un indice élevé (supérieur à 1,5) pour minimiser la perte d'information pendant le regroupement des élèves. L'un des clusters (1) contient un seul élève, et les deux autres 10 et 12.

Le cluster 2 contient 10 élèves qui ont des performances plus faibles (temps de réponse moyen et score faible) que la moyenne en nombres décimaux.

Le cluster 3 est composé de 12 élèves plus forts que la moyenne en nombre décimaux mais uniquement en termes d'exercices réussis et pas en termes de temps de réponse.

L'unique élève du cluster 1 est atypique car il a un score en calcul mental très faible par rapport aux autres. Il a réussi toutes les questions de calcul mental uniquement par QCM.

D'après ces résultats, on constate que le nombre de tentatives n'affecte pas la répartition des élèves dans les trois clusters. Par conséquent, cette variable n'est pas discriminante dans notre étude.

La répartition des élèves dans les trois groupes par K-means se rapproche des résultats obtenus par CAH. En effet, les clusters 2 et 3 de K-means sont presque similaires aux clusters 2 et 3 obtenus par CAH. Le cluster 1 de K-means contient deux élèves (à la place d'un seul pour CAH) qui ont des temps de réponses très élevés en calcul mental par rapport aux autres et des scores moyens (associés au cluster 2 et 3 de CAH). Le tableau 1 propose une comparaison des clusters issus de CAH et k-means.

CAH/K-means	cluster1	cluster2	cluster3
CAH 1	0	0	1
CAH 2	1	0	9
CAH 3	1	11	0

Tableau 1. Comparaison des clusters d'élèves K-means/CAH

On remarque une forte correspondance entre les clusters obtenus par les deux algorithmes. En effet les clusters sont quasiment identiques, à la différence de trois élèves atypiques qui ont été classés différemment par chacun des algorithmes. La différence dans le classement de ces trois élèves vient du fait que la CAH procède à un regroupement hiérarchique, ce qui veut dire que les élèves les plus proches sont associés au même groupe et ne peuvent pas être séparés à l'étape suivante, alors que K-means procède à une réaffectation de chaque élève à chaque nouveau calcul du centre. Dans tous les cas, il est intéressant de remarquer que les deux algorithmes arrivent à identifier la même structure dans les données tout en faisant ressortir les « outliers ».

Nous avons choisi d'adapter la taille de la carte SOM sur 3 clusters afin de comparer facilement les résultats obtenus par les trois méthodes. Le tableau 2 propose une comparaison des clusters issus de K-

means et SOM.

SOM/K-means	cluster1	cluster2	cluster3
SOM 1	0	0	10
SOM 2	1	0	0
SOM 3	1	11	0

Tableau 2. Comparaison des clusters d'élèves K-means/SOM

Les deux clusters (de taille identique) identifiés par SOM sont similaires aux clusters trouvés par K-means et CAH. Le cluster avec un unique élève est caractérisé par un temps de réponse lent pour les deux compétences (calcul mental et nombres décimaux).

3.3. Discussion

Après l'analyse comparative des résultats obtenus par CAH, K-means et SOM, on constate que les trois algorithmes ont classé les trois élèves de profils atypiques différemment. En effet, SOM et CAH ont trouvé la même répartition des élèves au niveau des clusters mais pas au niveau des profils dans chaque groupe. SOM a placé chacun des trois « outliers » séparément dans les trois groupes identifiés selon le critère du temps de réponse considéré pour les deux compétences. Pour CAH, c'est l'élève qui a le score le plus bas en calcul mental et pour K-means les deux élèves qui ont les temps de réponse les plus lents en calcul mental. Il est intéressant de noter la différence établie par chaque algorithme pour la répartition de ces élèves atypiques.

L'étude des profils déduits a posteriori des groupes identifiés par les différents algorithmes de clustering nous mène à identifier deux groupes de profils similaires : un groupe d'élèves, rapides avec un bon score et un autre groupe d'élèves plus lents avec un score mauvais. Les résultats obtenus sont globalement proches et les groupes identifiés sont cohérents tout en faisant ressortir quelques individus « outliers ».

Tableau récapitulatif sur le partitionnement des élèves

Nous avons dressé un tableau pour montrer les limites de chacun des trois algorithmes étudiés.

Algorithme	Temps d'exécution	Limites
K-means	rapide	- obligation de spécifier le nombre de classes a priori
CAH	Lent	-Nécessité de définir une mesure de similarité entre groupes et de bien la choisir. -Sensibilité aux valeurs extrêmes : il suffit de modifier la distance pour que les résultats changent
SOM	Plus rapide que CAH	-Nécessité de définir la taille de la carte

Tableau 3. Comparatif des trois algorithmes

Nous avons obtenu des résultats similaires par les trois méthodes, ce qui signifie que les groupes identifiés sont stables. La CAH présente l'avantage de suggérer le nombre de clusters « optimal ».

4. Caractérisation des clusters

4.1 Présentation

Le tableau 2 présente les caractéristiques des deux groupes stables identifiés par les trois algorithmes de clustering sur 20 élèves. Les trois élèves qui ont été détectés comme des « outliers » ne représentent pas une unique catégorie mais des cas particuliers que nous avons préféré ignorer.

Les exercices avec un bon score représentent les exercices réussis directement en question ouverte et les exercices avec mauvais score sont les exercices non réussis ou réussis en seconde chance par QCM.

Cluster (nombre d'élèves)	Cluster2 (9)	Cluster3 (11)
Nombre moyen d'exercices	127	125
Nombre moyen d'exercices avec bon score	94	112
Nombre moyen d'exercices avec mauvais score	32	13
% moyen d'exercices avec bon score	74 %	90 %
% moyen d'exercices avec mauvais score	26 %	10 %
Temps moyen des bonnes réponses	47s	32s
Temps moyen des mauvaises réponses	77s	83s

Tableau 4. Caractéristiques des groupes similaires

Nous constatons que les deux clusters ne se distinguent pas en nombre moyen d'exercices ; on note également que le temps moyen effectué par les élèves des deux clusters est très élevé en cas de mauvaises réponses. On remarque également que les élèves du cluster 2 (caractérisé comme moins bon et lent) passent plus de temps que les autres pour répondre correctement.

La figure 2 représente la répartition des élèves dans les deux clusters en fonction de bonnes et mauvaises réponses (en rouge celle des exercices réussis, en bleu celle des exercices les moins bien réussis) et le nombre de tentatives. D'après la figure 2, les élèves du cluster 3 effectuent un nombre de tentatives important même s'ils répondent correctement, alors que les élèves du cluster 2 qui possèdent les proportions de mauvaises réponses les plus élevées ne font pas assez de tentatives pour améliorer leur résultat.

Dans cette analyse, nous n'avons pas pris en compte les différentes stratégies des élèves ni l'ordre de traitement des exercices dans chaque devoir.

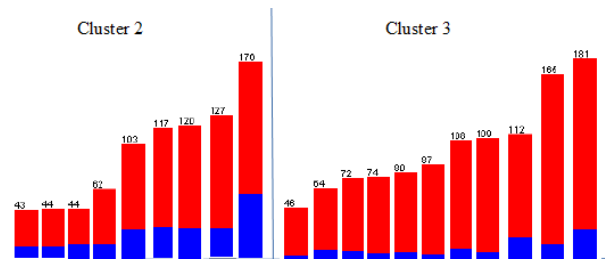


Figure 2. La répartition des élèves dans les deux clusters (ordonnés par ordre croissant de leur tentatives)

4.2. Interprétation

Les élèves du cluster 2 devraient travailler en priorité les exercices de type nombre décimaux et être assistés par l'enseignant. L'enseignant peut donc mettre en binôme un élève du cluster 2 avec un élève du cluster 3 pour qu'ils s'entraident.

Ces résultats (des bons rapides et des mauvais lents) peuvent sembler « évidents » mais ceci lié au faible nombre de dimensions de données. L'objectif de cette étude de cas est d'illustrer notre méthodologie d'analyse et de restitution des résultats à l'enseignant.

Les trois élèves détectés comme « outliers » peuvent avoir un soutien personnalisé par l'enseignant.

5. Conclusion et perspectives

Nous avons discuté de l'intérêt de l'analyse de traces et de leurs différentes formes d'exploitations possibles. Nous nous sommes focalisés sur les méthodes de clustering qui permettent d'extraire et restituer des connaissances exploitables en classe par l'enseignant. Notre objectif est de lui proposer une répartition possible des élèves dans des groupes de profil similaire mais aussi des associations possibles entre des élèves de profils différents (et complémentaires). Pour ceci, nous avons appliqué des méthodes de clustering de familles différentes afin d'obtenir un éventail de résultats sous plusieurs formes visuelles (arbre, graphe, carte). Cette étude nous a amené à constater que même des techniques de clustering simples fournissent des résultats qui peuvent être utiles à des enseignants, et qu'elles nous ont donné ici des résultats comparables mais très proches, avec une préférence pour la CAH. Nous avons soulevé quelques limites de ce travail, liées à la taille de l'échantillon et aux « outliers » qu'il faut exclure au début de l'analyse. Il nous reste également du travail pour rendre ces techniques, pourtant basiques pour des spécialistes de l'analyse de données, accessibles à des non spécialistes et c'est ce à quoi je compte consacrer ma thèse.

Ces travaux ont porté sur l'analyse de traces d'évaluation spécifiques. Dans l'avenir, à partir de données plus riches, nous souhaitons améliorer et diversifier les restitutions aux enseignants. Il faudra également réfléchir à la manière de permettre à l'enseignant de visualiser et comprendre ces résultats, qui ne sont pour l'instant pas encore suffisamment accessibles pour des non spécialistes. A court terme, nous pourrions également appliquer des techniques de

process mining sur des données d'apprentissage et d'évaluation pour étudier le parcours des élèves afin de proposer des parcours personnalisés (et identifier les profils individuels des apprenants). A long terme, nous souhaitons également exploiter les interactions sociales entre les apprenants en utilisant des techniques d'analyse de réseaux sociaux. La conception d'algorithmes combinant des techniques de fouille de données et d'analyse de graphe est aussi envisageable. Ceci nous permettra d'élargir la restitution des analyses aux autres acteurs que les enseignants. En effet, des retours pertinents pourront aussi être adressés aux apprenants pour la personnalisation et la recommandation de leur parcours.

Remerciements. Je tiens à remercier chaleureusement mon encadrante de stage Bénédicte Le Grand pour son soutien et sa disponibilité.

Références

Livre de Plusieurs Auteurs

Grandbastien, M., Labat, J.-M. 2006. Environnements informatiques pour l'apprentissage humain. Traité IC2, série Cognition et traitement de l'information.

Long, Y., Aman, Z., and Alevan, V. 2015. Motivational Design in an Intelligent Tutoring System that Helps Students Make Good Task Selection Decisions. In *Artificial Intelligence in Education*, C. Conati, N. Heffernan, A. Mitrovic, and M.F. Verdejo, eds. Cham: Springer International Publishing, pp. 226–236.

Timms, M., DeVelle, S., Schwantner, U., and Lay, D. 2015. Towards a Model of How Learners Process Feedback. In *Artificial Intelligence in Education*, C. Conati, N. Heffernan, A. Mitrovic, and M.F. Verdejo. Cham: Springer International Publishing, pp. 794–799.

Article de Revue

Bouchet, F., Harley, J. M., Trevors, G. J., & Azevedo, R. 2013. Clustering and Profiling Students According to their Interactions with an Intelligent Tutoring System Fostering Self-Regulated Learning. *Journal of Educational Data Mining*, 5(1), 104-146.

Chenevotot-quentin, F., Grugeon-allys, B., Pillet, J., and Delozanne, E. 2012. De la conception à l'usage d'un diagnostic dans une base d'exercices en ligne. Actes Espace Mathématique Francophone GT6.

ECAR Working Group. 2015. The Predictive Learning Analytics Revolution: Leveraging Learning Data for Student Success. EDUCAUSE.

Jean-Daubias, S., Eyssautier-Bavay, C., and Lefevre, M. 2009. Modèles et outils pour rendre possible la réutilisation informatique de profils d'apprenants hétérogènes. *Revue Sticef* : Volume 16.

Romero, C., and Ventura, S. 2013. Data mining in education, *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery* 3.1 : 12-27.

Actes de Conférences

Carlson, R., Genin, K., Rau, M.A., and Scheines, R.

2013. Student Profiling from Tutoring System Log Data: When do Multiple Graphical Representations Matter?. In *Proceedings Of the 6th International Conference on Educational Data Mining*.

Conati, C., Fratamico, L., Kardan, S., and Roll, I. 2015. Comparing Representations for Learner Models in Interactive Simulations. In *Artificial Intelligence in Education*, C. Conati, N. Heffernan, A. Mitrovic, and M.F. Verdejo, eds. Cham: Springer International Publishing, pp. 74–83.

Davoodi, A., Kardan, S., and Conati, C. 2013. Understanding Users Interaction Behavior with an Intelligent Educational Game: Prime Climb. In *AIED 2013 Workshops Proceedings Volume 2 Scaffolding in Open-Ended Learning Environments*, p. 9.

Floryan, M., Dragon, T., Basit, N., Dragon, S., and Woolf, B. 2015. Who Needs Help? Automating Student Assessment Within Exploratory Learning Environments. In *Artificial Intelligence in Education*, Conati, C., Heffernan, N., Mitrovic, A., Verdejo, M.F. (Eds.), *Lecture Notes in Computer Science*. Springer International Publishing, Cham.

Hug, C., Deneckere, R., and Salinesi, C. 2012. Map-TBS: Map process enactment traces and analysis, In: *International Conference on Research Challenges in Information Science (RCIS)*, Valencia : Espagne.

Käser, T., Busetto, A.G., Solenthaler, B., Kohn, J., von Aster, M., and Gross, M. 2013. Cluster-based prediction of mathematical learning patterns. In *Artificial Intelligence in Education*, (Springer), pp. 389–399.

Koedinger, K.R., Stamper, J.C., McLaughlin, E.A., and Nixon, T. 2013. Using data-driven discovery of better student models to improve student learning. In *Artificial Intelligence in Education* : Springer, pp. 421–430.

Le Grand, B., Le Cor, G., Albano, A., and Harrak, F. 2015. Restitution aux enseignants de l'évaluation des apprentissages dans des EIAH. In *Atelier Évaluation Des Apprentissages et Environnements Informatiques de La Conférence EIAH 2015*.

Sachan, M., Contractor, D., Faruque, T. a., and Subramaniam, L. V. 2012. Using content and interactions for discovering communities in social networks. In *Proceedings of the 21st international conference on World Wide Web*, pp 331-341.

Siemens, G., and d Baker, R.S. 2012. Learning analytics and educational data mining: towards communication and collaboration. In *Proceedings of the 2nd international conference on learning analytics and knowledge*, ACM 252-254.

Mémoire, Thèse ou HDR

Bani, I. 2014. Analyse des traces d'apprentissage et d'interactions inter-apprenants dans un MOOC. Mémoire. Lip6, Université Pierre et Marie Curie.

Iksal, S. 2012. Ingénierie de l'observation basée sur la prescription en EIAH. HdR. LIUM, Université du Maine.