

Application d'une approche inspirée des colonies de fourmis pour la recommandation des chemins d'apprentissage dans un cours en ligne : modèle et expérience

Recherche scientifique avec données empiriques

Résumé

Dans cet article, nous présentons la mise en œuvre, l'expérimentation et l'évaluation d'une approche pour la recommandation des chemins d'apprentissage dans un cours en ligne. Le processus de recommandation est inspiré de l'intelligence en essaim et plus particulièrement de l'optimisation par colonies de fourmis (OCF) (*ant colony optimization* [ACO]). Dans ce contexte, nous avons considéré une différenciation des chemins d'apprentissage en fonction de l'activité explorée pour l'apprentissage d'un cours.

Dans l'objectif de recommander des chemins d'apprentissage considérés optimaux et d'évaluer ainsi leur impact sur l'apprentissage d'un cours en ligne, l'approche proposée est basée à la fois sur la recommandation de chemins pertinents par l'enseignant et sur les résultats stockés au fur et à mesure par les apprenants sur les chemins empruntés. Notre approche a été validée expérimentalement et les résultats obtenus ont montré l'émergence d'un

chemin d'apprentissage favorisant la réussite d'un nombre d'apprenants relativement considérable.

Mots clés

Intelligence en essaim, optimisation par colonies de fourmis, activité pédagogique

Abstract

In this article, we present the implementation, the experimentation and the evaluation of an approach for the recommendation of learning paths in an online course. The recommendation process is inspired by swarm intelligence and especially the ant colony optimization (ACO). In this context, we considered a differentiation of the learning paths based on the explored educational activity for learning a lesson.

With the aim to recommend learning paths considered optimal and thus assess their impact on the learning of an online course, the proposed approach is based both on the recommendation of relevant paths

Aziz **DAHBI**

Professeur en sciences et technologies de l'information et de la communication
Université Chouaib Doukkali, Maroc
dahbi_aziz@yahoo.fr

Najib **EL KAMOUN**

Professeur en sciences et technologies de l'information et de la communication
Université Chouaib Doukkali, Maroc
elkamoun@ucd.ac.ma

Abdelhak **AQQAL**

Professeur en sciences et technologies de l'information et de la communication
Université Chouaib Doukkali, Maroc
aqqal_abdelhak@yahoo.fr

Asmaa **EL HANNANI**

Professeur en informatique
Université Chouaib Doukkali, Maroc
elhannani.a@ucd.ac.ma



©Auteur(s). Cette œuvre, disponible à http://ritpu.ca/IMG/pdf/RITPU_v11_n02_6.pdf, est mise à disposition selon les termes de la licence Creative Commons Attribution - Pas de Modification 2.5 Canada : <http://creativecommons.org/licenses/by-nd/2.5/ca/deed.fr>

by the teacher and the result stored progressively by learners on the paths taken. Our approach was validated experimentally and the results showed the emergence of a learning path promoting the success of a relatively considerable number of learners.

Keywords

Swarm intelligence, ant colony optimization, educational activity

Introduction

Pour optimiser l'apprentissage en ligne, on peut distinguer principalement trois approches de navigation qui ont été utilisées pour guider efficacement les apprenants. La première approche consiste à proposer des parcours stéréotypes définis à l'avance par le concepteur selon les classes d'apprenants. La deuxième approche consiste à personnaliser la navigation selon deux degrés d'adaptation : i) les parcours adaptables générés en début de session d'apprentissage en fonction des informations introduites par l'apprenant; ii) les parcours adaptatifs générés dynamiquement en fonction du modèle de l'apprenant et de ses interactions lors de l'apprentissage (Tattersall *et al.*, 2006). La troisième approche est issue du contexte social de l'apprentissage. En effet, d'après Brookfield (1985) : « *successful self-directed learners [...] place their learning within a social setting in which the advice, information, and skill modelling provided by other learners are crucial conditions for successful learning* ». Cette observation trouve des échos dans la littérature où le concept de navigation sociale (Höök et Benyon, 2003) a été utilisé pour décrire les recherches indiquant que la navigation est un processus social et collaboratif s'appuyant sur les interactions humaines et la recommandation (Dieberger, Höök, Svensson et Lönnqvist, 2001). En particulier, la navigation sociale indirecte en tant que style exploite les traces d'interactions laissées par d'autres comme base d'un système de recommandation (Farzan et Brusilovsky, 2005; Niemczyk, 2000; Shipman, Furuta, Brenner, Chung et Hsieh, 2000).

Notre recherche s'inscrit dans le cadre de la navigation sociale indirecte par la mise en œuvre, l'expérimentation et l'évaluation d'une approche inspirée de l'intelligence en essaim (*swarm intelligence*) (Bonabeau, Dorigo et Theraulaz, 1999; Engelbrecht, 2007). Il s'agit plus particulièrement de l'optimisation par colonies de fourmis (OCF) (*ant colony optimization* [ACO]) (Dorigo, Maniezzo et Colomi, 1996) qui s'inspire des comportements collectifs observés dans les colonies de fourmis pour faire émerger un chemin optimal vers les sources de nourriture en combinant un comportement d'exploration aléatoire et un suivi des traces chimiques (phéromones) laissées par leurs consœurs.

La motivation que suscite l'OCF est issue, d'une part, de son adaptation intrinsèque à un cours hypertexte qui peut être modélisé par un graphe dont les nœuds représentent les activités pédagogiques et les arcs correspondent aux liens reliant ces activités. D'autre part, les apprenants peuvent être assimilés à des fourmis virtuelles qui déposent des traces sur les arcs visités. Ces traces peuvent être exploitées de manière à faire émerger au fil du temps un chemin d'apprentissage optimal.

Dans la première section de cet article, nous présenterons un état de l'art des travaux qui ont utilisé l'OCF dans le cadre de l'apprentissage en ligne. La deuxième section sera consacrée à la mise en œuvre de notre approche. La troisième section décrira son expérimentation dans le cadre d'un cours d'initiation à Microsoft Excel.

1. État de l'art

Dans le cadre de l'apprentissage en ligne, nous citons quelques travaux qui ont utilisé l'OCF :

- Gutierrez, Valigiani, Jamont, Collet et Kloos (2007) ont développé une approche qui guide l'apprenant vers le choix du prochain nœud en lui présentant le nombre de visites, de réussites et d'échecs des apprenants précédents.

- Van den Berg *et al.* (2005) ont développé un algorithme qui recommande le prochain nœud en fonction du nombre de réussites des apprenants précédents.
- Semet, Lutton et Collet (2003) ont développé une approche qui recommande le prochain nœud en fonction d'un facteur de l'enseignant, un facteur du collectif (performances) et un facteur individuel.
- Wang, Wang et Huang (2008) ont développé un système (*style-based ant colony system* [SACS]) qui recommande le prochain nœud en fonction du nombre de transitions des apprenants précédents ayant un style similaire à celui de l'apprenant en cours.
- Wong et Looi (2009) ont développé un système (*dynamic learning path advisor* [DYLPAL]) qui recommande le prochain nœud en fonction des performances des apprenants précédents ayant des attributs similaires à ceux de l'apprenant en cours.

En guise de conclusion, ces travaux de recherche ont avancé des approches et des modèles sans les expérimenter suffisamment dans un contexte réel. En effet, nous pouvons citer une seule expérimentation effectuée par Janssen *et al.* (2007) dans le cadre de l'approche développée par Van den Berg *et al.* (2005). Les résultats issus de cette étude ont montré une amélioration des scores des apprenants.

En raison de ce manque d'études expérimentales dans le cadre de l'apprentissage en ligne, nous allons tenter par la présente étude de répondre à un besoin clairement défini, à savoir évaluer par les performances l'apport de notre approche de recommandation basée sur l'OCF.

2. Mise en œuvre de notre approche

L'OCF a été largement utilisée dans des champs d'application variés (Blum, 2005; Monirul, Shahjahan et Kazuyuki, 2013). D'une manière générale, l'OCF se présente en résumé de la façon suivante : le problème à résoudre est modélisé par un graphe et chaque solution au problème est alors définie en tant que parcours dans ce graphe. La recherche d'un parcours optimal consiste à faire déplacer un ensemble de fourmis virtuelles sur le graphe puis à mettre à jour les quantités de phéromones. Ainsi, le meilleur parcours sera celui où se concentre la plus grande quantité de phéromones. La mise en œuvre de notre approche basée sur l'OCF pour la recommandation des chemins d'apprentissage renvoie à :

- **Phase 1** – La représentation de la structure hypermédia par un graphe de chemins possibles;
- **Phase 2** – L'exploration des chemins par les apprenants et le dépôt de phéromones;
- **Phase 3** – L'évaluation de la pertinence des chemins empruntés par les apprenants;
- **Phase 4** – La recommandation d'un chemin selon une sélection probabiliste.

2.1. Représentation de la structure hypermédia par un graphe de chemins possibles

Dans le cadre de notre approche, chaque étape du cours peut être enseignée au moyen d'une activité (A), d'une illustration (I), d'une théorie (T) ou d'un exercice (E) (figure 1). Les chemins d'apprentissage sont alors différenciés par l'activité pédagogique explorée.

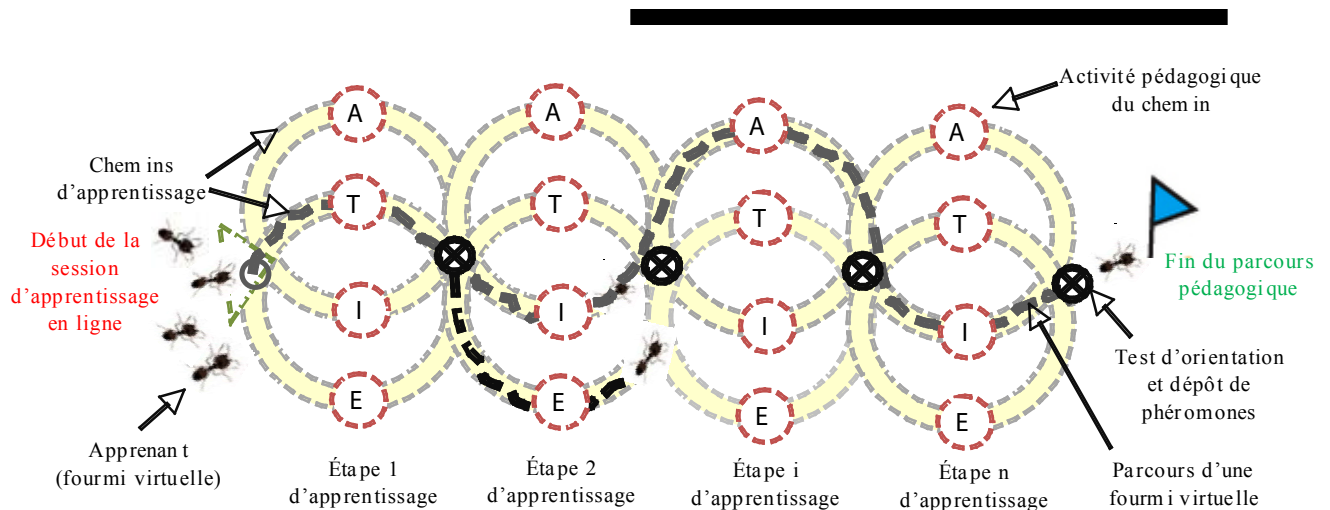


Figure 1. Structure de l'hypermédia

- Une activité **A** permet l'acquisition des connaissances par l'expérimentation, l'étude de cas et des recherches approfondies.
- Une illustration **I**, composée essentiellement d'animations audiovisuelles et des simulations didactiques, favorise la réflexion, l'observation et l'accumulation des connaissances.
- Une théorie **T** aide à l'organisation des connaissances, à l'analyse et à la synthèse à travers des présentations et des définitions théoriques.
- Un exercice **E** est constitué d'un travail pratique et de manipulations permettant à l'apprenant l'application des connaissances et la réalisation concrète des tâches.

2.2. Exploration des chemins par les apprenants et dépôt de phéromones

Dans notre cas, chaque étape peut être réalisée par le choix d'un chemin parmi quatre possibles. Les chemins sont disposés physiquement sous forme de pages hypermédiées qui seront explorées au fur et à mesure par les apprenants lors de leur navigation à travers les pages. À l'issue d'une étape, l'appre-

nant (assimilé à une fourmi virtuelle) effectue un test d'évaluation dont le résultat peut être considéré comme une phéromone. Les chemins sont alors associés à des pistes de phéromones décrivant l'état du système à la suite d'une navigation des apprenants (navigation sociale indirecte). En effet, nous nous sommes inspirés d'une analogie avec l'algorithme *ant-density* (Dorigo *et al.*, 1996) qui consiste à renforcer chaque trajet traversé par une fourmi virtuelle d'une quantité de phéromones. Ainsi, nous considérons que chaque chemin **C** est caractérisé par deux facteurs : S_c (phéromone de réussite) et F_c (phéromone d'échec) initialisés au départ à la valeur nulle. À la suite d'une réussite à la fin d'une étape, S_c est incrémenté par une valeur de renforcement Q ($S_c = S_{c-1} + Q$) et l'apprenant passera alors à l'étape suivante. Par contre, en cas d'échec, c'est le facteur F_c qui se voit renforcé par la même valeur Q ($F_c = F_{c-1} + Q$) et l'apprenant est forcé de refaire la même étape suivant un autre chemin qui lui sera recommandé par le système.

À l'état initial, le système ne dispose pas de données provenant de l'exploration collective pour initialiser le processus de recommandation (Wong et Looi, 2009). En ce qui nous concerne, nous avons jugé utile en un premier temps d'initialiser le système par un facteur supplémentaire **W** attribué par

l'enseignant à chaque chemin. La pertinence de cette recommandation sera ajustée ultérieurement par l'auto-organisation collective.

2.3. Évaluation de la pertinence des chemins empruntés par les apprenants

Nous considérons qu'un chemin d'apprentissage C est pertinent s'il est plus encouragé par l'enseignant (W_c est élevé) et plus marqué par la réussite (S_c est élevé et F_c est faible). Nous avons alors proposé une fonction **EVAL** , décrite par les expressions [1] et [2] ci-dessous, qui exprime cette pertinence en pondérant W_c et (S_c, F_c) . Cette fonction admet aussi une limite inférieure et supérieure pour empêcher un chemin d'être trop renforcé ou trop pénalisé et laisser la possibilité à d'autres chemins d'apprentissage d'être également explorés (Dahbi, El Kamoun et Berraissoul, 2007).

$$\text{EVAL}(C) = W_c + K * G(S_c, F_c) \quad [1]$$

Avec :

$$\begin{aligned} G(S_c, F_c) &= \ln(1 + (S_c - F_c)) \text{ si } S_c \geq F_c; \\ G(S_c, F_c) &= -\ln(1 - (S_c - F_c)) \text{ si } S_c < F_c \end{aligned} \quad [2]$$




Figure 2. Représentation de la fonction EVAL(C)

2.4. Recommandation d'un chemin selon une sélection probabiliste

Afin de préserver l'exploration aléatoire de tous les chemins tout en recommandant le plus pertinent (analogie avec l'OCF) et mettre sous évaluation tous les chemins existants, nous avons utilisé une procédure de sélection probabiliste décrite par l'expression [3] ci-dessous qui indique qu'un chemin est plus probable d'autant qu'il est pertinent (Dahbi, El Kamoun et Berraissoul, 2009). Donc, la probabilité que le système recommande un chemin C est proportionnelle à la valeur retournée par sa fonction d'évaluation EVAL(C).

$$P(C) = [\text{EVAL}(C) / \sum \text{EVAL}(M)]_{\text{Étape } i} \quad [3]$$

M désigne les différents chemins menant à une étape du cours

2.5. Architecture du système

La mise en œuvre de notre système prototype repose sur une architecture Web à trois niveaux (figure 3) :

- Le premier niveau gère l'interface avec l'utilisateur et permet d'interagir avec le système.
- Le second niveau s'appuie sur un serveur d'applications qui assure les fonctions suivantes : 1) exécuter les traitements demandés lors d'une requête de l'utilisateur; 2) invoquer le processus de recommandation pour le calcul et la sélection du chemin d'apprentissage; 3) invoquer le générateur de QCM (questions à choix multiple) pour générer aléatoirement la page de test. Cela permettra d'évaluer le

niveau de connaissances d'un apprenant tout en évitant qu'il repasse le même test en cas d'échec dans une étape. Notons que le QCM et les activités pédagogiques ont été créés par un environnement de production collaborative des contenus pédagogiques appelé Moulinette (Aqqal, Haidine, Dahbi et Labouidya, 2014).

- Le troisième niveau est un serveur de base de données qui assure la gestion des données relatives aux facteurs collectifs, aux QCM, aux activités pédagogiques, aux apprenants et aux chemins d'apprentissage.

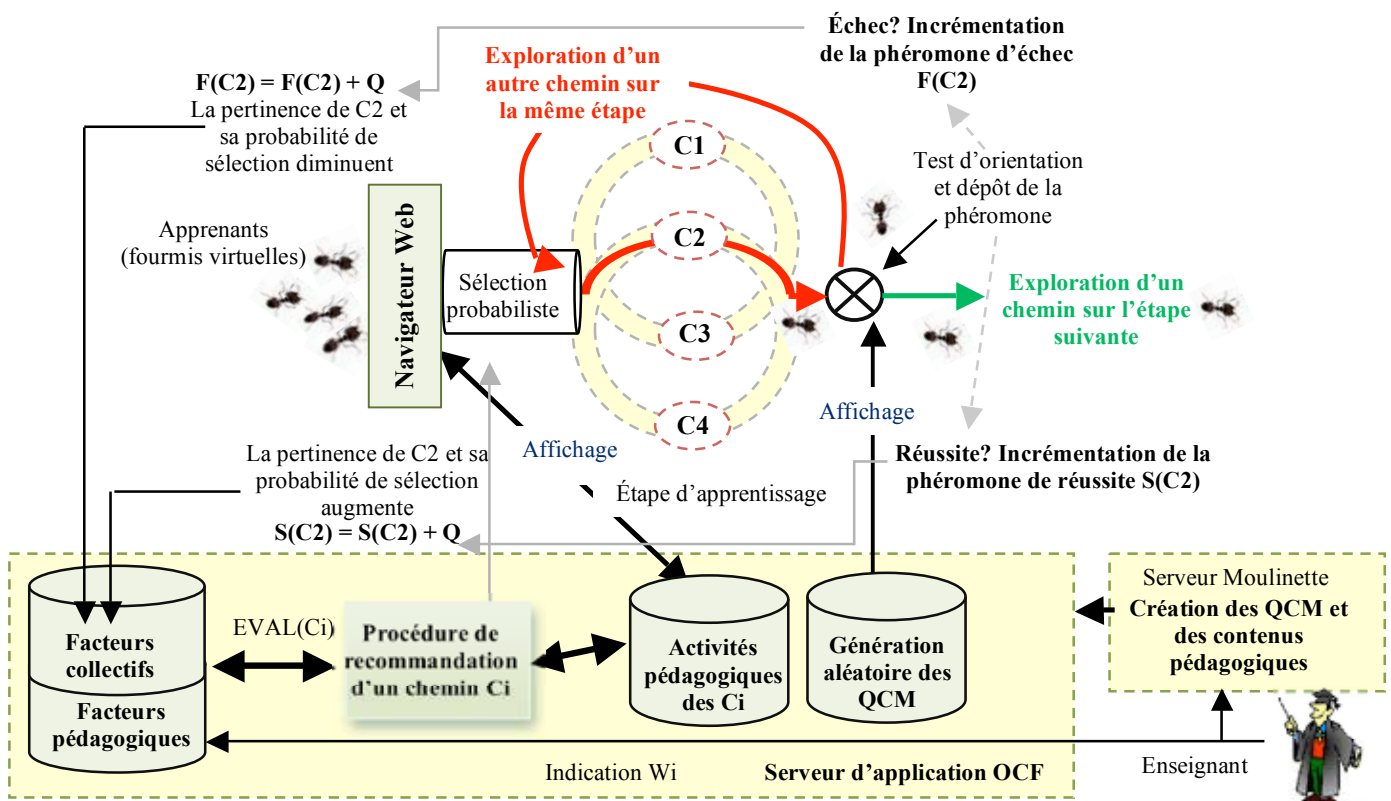


Figure 3. Architecture du système

3. Expérimentation

3.1. Contexte de l'expérimentation

En expérimentant notre système, nous souhaitons évaluer par les performances l'apport de la recommandation des chemins d'apprentissage basée sur l'OCF dans un contexte réel. Nous nous situons dans le cadre d'une approche de développement incrémental, où l'usage de l'expérimentation permet d'affiner le modèle et d'ajuster les paramètres. Les apprenants ont reçu une formation d'initiation à Microsoft Excel constituée de quatre étapes : 1) **Étape 1** : les notions de base sur Excel; 2) **Étape 2** : la gestion des formules; 3) **Étape 3** : les fonctions Excel; 4) **Étape 4** : la création de graphiques.

Notre première expérimentation s'est déroulée auprès d'une population de 100 apprenants sélectionnés parmi 160 à l'aide d'un questionnaire permettant de déduire leur niveau de connaissances et leurs préférences pour les activités pédagogiques préconisées (figure 4).

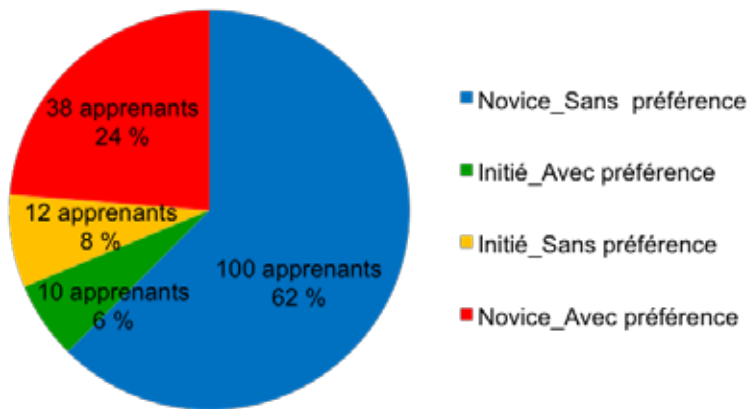


Figure 4. Répartition des apprenants de l'expérimentation

La répartition des apprenants de l'expérimentation a constitué quatre groupes selon leur niveau de connaissances (novices ou initiés) et leurs préférences par rapport aux activités de la formation (avec ou sans préférence). Nous n'avons retenu pour cette expérimentation que les apprenants

novices sans préférence pour avoir une population homogène. En effet, nous supposons que l'implication des apprenants avec les prérequis et/ou les préférences est susceptible d'influencer les résultats.

3.2. Paramètres de la première expérimentation

Nous avons mené la première expérimentation suivant les paramètres indiqués au tableau I ci-dessous :

Tableau I. Paramètres de la première expérimentation

Paramètres	Commentaires et justifications
Nombre d'apprenants inscrits = 100 apprenants novices et sans préférence	Ne pas influencer la neutralité des résultats
La valeur de renforcement des facteurs collectifs S et F : Q = 1	Éviter le renforcement ou la pénalisation trop rapide des chemins d'apprentissage
Initialisation des facteurs S et F des différents chemins à 0 (S = 0 et F = 0)	Exprimer le fait que Lors du lancement de la formation, l'exploration des chemins n'est pas encore entamée
Seuil de réussite dans le test de chaque étape du cours fixé à la note 12/20	Favoriser le contraste entre réussite et échec lors de l'évaluation
Coefficient pondérateur entre le facteur pédagogique W et les facteurs (S, F) des différents chemins K = 1	Équilibrer l'importance relative de W par rapport à S et F
Facteur W ayant la même valeur pour les différents chemins	Neutraliser le facteur pédagogique vis-à-vis des facteurs collectifs
<ul style="list-style-type: none"> - Choix de la valeur W = 5 - $G_{\max}(S, F) = K * \ln(1 + (S - F)) = 4,61$ (cas particulier où tous les apprenants réussissent sur un même chemin : S = 100 et F = 0) - $G_{\min}(S, F) = -K * \ln(1 - (S - F)) = -4,61$ (cas particulier où tous les apprenants échouent sur un même chemin : S = 0 et F = 100) 	<ul style="list-style-type: none"> - Éviter que W domine G(S, F) et préserver l'apport des facteurs collectifs - Permettre la sélection probabiliste (expression [3]) lorsque G(S, F) est extrêmement négatif ($G_{\min}(S, F)$)

3.3. Analyse des résultats et premier bilan

Pour effectuer les évaluations et les interprétations, nous nous sommes placés dans une approche empirique fondée sur l'analyse des résultats à partir des données recueillies (Senach, 1990). Nous nous sommes focalisés sur :

1. L'analyse des résultats liés aux chemins d'apprentissage;
2. L'analyse des résultats liés aux apprenants;
3. L'analyse des parcours d'apprentissage explorés.

3.3.1. Analyse des résultats liés aux chemins d'apprentissage

a. Corrélation entre les performances des apprenants et la sélection des chemins

À la figure 5 ci-dessous, nous avons présenté pour chaque étape de cours le pourcentage de sélection, de réussite et d'échec observé sur les chemins d'apprentissage explorés par tous les apprenants confondus. Il y a lieu de signaler que parmi 100 apprenants qui ont été retenus pour l'expérimentation, uniquement 60 ont utilisé effectivement le système pour l'apprentissage des quatre étapes de cours. La contribution des apprenants qui ont abandonné la formation n'a pas été prise en considération dès le moment où ils n'ont pas effectué de test d'évaluation (dépôt de phéromones). Nous désignons par A, I, T et E les chemins centrés respectivement sur l'activité, l'illustration, la théorie et l'exercice.




Figure 5. Pourcentage de sélection, de réussite et d'échec enregistré sur les chemins d'apprentissage

Dans toutes les étapes du cours, le chemin d'apprentissage de l'exercice (E) est celui qui a enregistré plus de réussites que d'échecs lorsqu'il a été sélectionné avec un écart très positif ($E_{(E, \text{étape 1})} = 56\%$, $E_{(E, \text{étape 2})} = 36\%$, $E_{(E, \text{étape 3})} = 32\%$ et $E_{(E, \text{étape 4})} = 38\%$). Cela a entraîné le renforcement de son facteur collectif G(S, F) et favorisé par conséquent sa sélection par rapport aux autres chemins d'apprentissage. Par contre, nous constatons que le chemin de la théorie (T) a enregistré plus d'échecs que de réussites lorsqu'il a été sélectionné avec un écart très négatif ($E_{(T, \text{étape 1})} = -30\%$, $E_{(T, \text{étape 2})} = -16\%$, $E_{(T, \text{étape 3})} = -18\%$ et $E_{(T, \text{étape 4})} = -28\%$), ce qui a entraîné la diminution de son facteur G(S, F) en défavorisant sa sélection par la suite. Ce constat est confirmé également par la figure 6 ci-dessous

qui illustre une corrélation entre le taux de sélection d'un chemin en fonction de son taux de réussite par rapport aux autres chemins, d'où la capacité de notre système à recommander les chemins d'apprentissage en corrélation avec le nombre de réussites enregistrées sur ces derniers, favorisant ainsi l'émergence du chemin le plus optimal (s'il y a lieu). Nous soulignons que le taux de sélection de chaque chemin est resté presque invariable au long des étapes, ce qui est dû à notre avis au fait que les étapes de cours sont de même nature.




Figure 6. Corrélation entre le taux de sélection d'un chemin (S) et son pourcentage de réussite (R) par rapport aux autres chemins

b. Rendement des apprenants enregistré sur les chemins d'apprentissage

Dans le but d'évaluer le rendement (score) des apprenants sur les chemins d'apprentissage, nous avons présenté au tableau II ci-dessous la moyenne sur vingt (/20) des notes obtenues par tous les apprenants sur les chemins d'apprentissage empruntés.

Tableau II. Moyenne des notes obtenues sur les chemins empruntés

	A	I	T	E
Étape 1	11,59	10,70	10,12	12,11
Étape 2	11,64	10,68	10,42	12,29
Étape 3	11,50	10,71	10,41	12,11
Étape 4	10,86	10,54	9,07	12
Toutes les étapes confondues	11,39	10,65	10	12,12

Malgré l'écart peu significatif entre le rendement des chemins d'apprentissage, ces résultats indiquent que le chemin de l'exercice a enregistré constamment un rendement moyen supérieur au seuil exigé (12/20) et relativement meilleur que les autres chemins. Par contre, le chemin de la théorie a enregistré le plus faible rendement de tous les chemins. En ce sens, choisir judicieusement un seuil de validation nous paraît un paramètre très déterminant et qui affecte implicitement la réussite ou l'échec sur un chemin donné. Cela nous amène à critiquer notre choix de départ concernant le renforcement « binaire » des chemins selon le seuil de validation (marquer le chemin soit par la réussite soit par l'échec). En fait, le renforcement doit prendre en considération les nuances des résultats de l'exploration lors de la sélection probabiliste en pondérant le facteur collectif par le rendement des apprenants. Ainsi, on pourra différencier un échec relatif avec 11,99/20 (respectivement une réussite relative avec 12/20) d'un échec absolu avec 0/20 (respectivement une réussite absolue avec 20/20). Le dépôt des phéromones deviendra alors minutieusement régulé en fonction du rendement et permettra par la même occasion de remédier au problème d'un choix subjectif du seuil de validation.

3.3.2. Analyse des résultats liés aux apprenants

À partir du tableau III ci-dessous, le nombre total de réussites dans chaque étape converge progressivement vers la valeur 60 (nombre effectif d'apprenants), car les apprenants qui échouent sur un chemin d'apprentissage arrivaient finalement à réussir sur un autre chemin après de 2 à 4 tentatives avant de passer à l'étape suivante du cours.

Tableau III. Nombre de réussites et d'échecs dans tous les chemins confondus à la suite des tentatives d'exploration

	Étape 1		Étape 2		Étape 3		Étape 4	
	R	E	R	E	R	E	R	E
1 ^{re} tentative	34	26	36	24	33	27	32	28
2 ^e tentative	14	12	14	10	15	12	16	12
3 ^e tentative	7	5	7	3	9	3	9	3
4 ^e tentative	5	0	3	0	3	0	3	0
Total	60	0	60	0	60	0	60	0

Dans ce cadre, nous nous sommes intéressés à la notion d'effet mémoire des apprenants et à son influence éventuelle sur le choix de tel ou tel chemin lors d'une deuxième tentative. En effet, un apprenant qui n'a pas réussi dès la première tentative pourrait exploiter les connaissances mémorisées sur le premier chemin dans la deuxième tentative sur un autre chemin. Cette hypothèse a été mise en doute en raison de trois facteurs :

1. Les tests d'évaluation pour chaque tentative n'étaient pas similaires et générés aléatoirement;
2. Le seuil de validation 12/20 nécessite une maîtrise de l'étape en question;
3. Presque la moitié des apprenants n'ont pas pu valider la deuxième tentative (46 % (12/26) à l'étape 1, 42 % (10/24) à l'étape 2, 44 % (12/27) à l'étape 3 et 43 % (12/28) à l'étape 4).

3.3.3. Analyse des parcours d'apprentissage explorés

Un parcours d'apprentissage correspond à la suite des chemins poursuivis avec succès par un même apprenant depuis l'étape initiale jusqu'à l'étape finale. Nous considérons qu'un parcours est optimal s'il se démarque par la réussite d'un grand nombre d'apprenants par rapport aux autres parcours. Nous avons présenté au tableau IV ci-dessous les différents parcours d'apprentissage poursuivis par les apprenants avec leur nombre d'occurrences.

Tableau IV. Les différents parcours d'apprentissage poursuivis par les apprenants

Parcours poursuivis	Nombre d'occurrences
E-E-E-E	15 fois (42 %)
A-A-A-A, A-I-I-A	3 fois (8 %)
I-E-E-I, E-A-A-I, I-A-I-T, T-I-I-A, I-E-E-E, E-E-T-A	2 fois (6 %)
E-E-T-I, E-I-E-E, A-E-T-I, A-A-T-A, E-A-I-I, I-A-A-A, A-A-I-A, E-T-A-A, A-I-E-I, E-I-I-A, A-E-E-I, E-T-E-E, I-A-A-I, T-A-I-E, I-I-A-T, E-I-A-I, I-T-A-I, T-T-A-E, A-E-E-E, T-I-A-T, I-I-A-A, A-T-T-A, A-A-A-T, E-A-T-E, A-A-A-I, E-I-I-E, T-E-E-E	1 fois (3 %)
Les autres combinaisons possibles (256 - 36 = 220 parcours)	0 fois (0 %)

Nous constatons d'après le tableau IV que parmi les 256 (4⁴) parcours possibles, seulement 14 % (36/256) ont été poursuivis par les apprenants. Parmi ces 36 parcours poursuivis, celui de l'exercice désigné par (E-E-E-E) figure 15 fois et représente à lui seul 42 %. Ceci confirme que notre approche est très intéressante dans la mesure où elle a pu faire émerger un parcours optimal (E-E-E-E en l'occurrence) qui a permis à lui seul la réussite de 25 % des apprenants par suite du renforcement progressif des chemins d'apprentissage à chaque étape. Cette émergence est logiquement cohérente avec la na-

ture du cours qui a un aspect pratique et plus propice à l'apprentissage par une réalisation concrète et pratique des tâches plutôt que par la théorie. Ce constat est extrêmement utile puisqu'il sera exploité lors des sessions futures dans le cadre d'une formation similaire. En ce sens, une piste est offerte par l'étude de la possibilité d'ajuster (voire remplacer) le facteur pédagogique de l'enseignant (W) par des facteurs collectifs G(S, F) enregistrés lors des sessions antérieures. Enfin, le démarquage très distinctif du parcours (E-E-E-E) par rapport aux autres parcours démontre que le fait d'augmenter le nombre d'apprenants n'a pas trop influencé nos résultats sur le plan qualitatif. Toutefois, l'abandon de 40 apprenants du processus d'apprentissage en ligne nous incite à nous poser des questions sur la nécessité de prendre en considération les préférences individuelles des apprenants dans notre approche.

Conclusions

Après avoir situé nos travaux de recherche par rapport à ceux qui existent dans ce domaine et établi un état de l'art des principaux travaux qui ont utilisé l'OCF dans le cadre de l'apprentissage en ligne, nous avons présenté dans cet article notre contribution sur le plan conceptuel, technologique et expérimental. Nous avons décrit conceptuellement les différentes phases pour la mise en œuvre d'une approche de recommandation des chemins d'apprentissage basée sur l'OCF, à savoir la définition des facteurs collectifs, le facteur pédagogique, la fonction d'évaluation des chemins et le choix de la procédure de sélection. Inscrite dans une démarche empirique, notre approche a été évaluée à l'aide d'un prototype informatique par une première expérimentation dans un cadre de formation en ligne portant sur un cours d'initiation à Microsoft Excel. L'analyse des résultats issus de cette évaluation a montré une émergence relative du parcours d'apprentissage (E-E-E-E) et cette émergence a confirmé que le cours proposé a été plus adapté à l'apprentissage par l'activité pédagogique de type exercice que par les autres activités proposées. Globalement, les résultats obtenus sont satisfaisants et

montrent l'intérêt scientifique de notre approche pour la recommandation d'un parcours optimal à l'aide de la navigation sociale indirecte et pour aider l'enseignant à mieux affiner la conception pédagogique de son cours en ligne. Toutefois, nous sommes conscients qu'il faut expérimenter notre système dans d'autres contextes pédagogiques afin d'obtenir une évaluation et de tirer des analyses qui soient plus significatives et génériques tout en essayant de consolider nos propositions sur la base de nos résultats et interprétations.

Références

- Aqal, A., Haidine, A., Dahbi, A. et Labouidya, O. (2014, octobre). *On supporting nature-inspired modeling to optimize production of WBTs via a human mind mapping*. Communication présentée à l'International Conference on Metaheuristics and Nature Inspired Computing (Meta2014), Marrakech, Maroc. [Récupéré du site de la conférence : http://meta2014.sciencesconf.org](http://meta2014.sciencesconf.org)
- Blum, C. (2005). Ant colony optimization: Introduction and recent trends. *Physics of Life Reviews*, 2(4), 353-373. [doi:10.1016/j.plrev.2005.10.001](https://doi.org/10.1016/j.plrev.2005.10.001)
- Bonabeau, E., Dorigo, M. et Theraulaz, G. (1999). *Swarm intelligence: From natural to artificial systems*. New York, NY : Oxford University Press.
- Brookfield, S. (1985). Self-directed learning: A critical review of research. Dans S. Brookfield (dir.), *Self-directed learning: From theory to practice. New directions for continuing education series* (Vol. 25). San Francisco, CA : Jossey-Bass.
- Dahbi, A., El Kamoun, N. et Berraissoul, A. (2007). Adaptation and optimisation of pedagogical paths by ants's algorithm. Dans *Proceedings of the 8th International Conference on Information Technology Based Higher Education and Training* (p. 156-161). Kumamoto, Japon.
- Dahbi, A., El Kamoun, N. et Berraissoul, A. (2009). Conception d'un système hypermédia d'enseignement adaptatif centré sur les styles d'apprentissage : modèle et expérience. *Revue internationale des technologies en pédagogie universitaire*, 6(1), 55-71. [Récupéré de http://ritpu.org](http://ritpu.org)
- Dieberger, A., Höök, K., Svensson, M. et Lönnqvist, P. (2001). *Social navigation research agenda*. Dans *CHI'01 Extended Abstracts on Human Factors in Computing Systems* (p. 107-108). New York, NY : ACM.
- Dorigo, M., Maniezzo, V. et Coloni, A. (1996). Ant system: Optimization by a colony of cooperating agents. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 26(1), 29-41. [doi:10.1109/3477.484436](https://doi.org/10.1109/3477.484436)
- Engelbrecht, A. P. (2007). *Computational intelligence: An introduction* (2^e éd.). Hoboken, NJ : John Wiley & Sons.
- Farzan, R. et Brusilovsky, P. (2005). Social navigation support in e-learning: What are the real footprints? Dans B. Mobasher et S. S. Anand (dir.), *Proceedings of the Third International Workshop on Intelligent Techniques for Web Personalization* (p. 49-56). Édimbourg, R.-U.
- Gutierrez, S., Valigiani, G., Jamont, Y., Collet, P. et Kloos, C. D. (2007). A swarm approach for automatic auditing of pedagogical planning. Dans J. M. Spector et al. (dir.), *Proceedings of the Seventh IEEE International Conference on Advanced Learning Technologies* (p. 136-138). New York, NY : IEEE Computer Society.
- Höök, K. et Benyon, D. (2003). *Designing information spaces: The social navigation approach*. Londres, R.-U. : Springer.
- Janssen, J., Tattersall, C., Waterink, W., Van den Berg, B., Van Es, R., Bolman, C. et Koper, R. (2007). Self-organizing navigational support in lifelong learning: How predecessors can lead the way. *Computers & Education*, 49(3), 781-793. [doi:10.1016/j.compedu.2005.11.022](https://doi.org/10.1016/j.compedu.2005.11.022)

- Monirul, K., Shahjahan, M. et Kazuyuki, M. (2013). Ant colony optimization toward feature selection. Dans H. Barbosa (dir.), *Ant colony optimization – Techniques and applications*. Rijeka, Croatie : InTech. [Récupéré](#) du site de l'éditeur : <http://www.intechopen.com>
- Niemczyk, S. (2000). *On pedagogical-aware navigation of educational media through virtual tutors* (document interne). Cambridge, MA : Massachusetts Institute of Technology, Department of Civil and Environmental Engineering.
- Semet, Y., Lutton, E. et Collet, P. (2003). Ant colony optimization for e-learning: Observing the emergence of pedagogic suggestions. Dans *Proceedings of IEEE Swarm Intelligence Symposium* (p. 46-52). New York, NY : IEEE Computer Society.
- Senach, B. (1990). *Évaluation ergonomique des interfaces homme-machine : une revue de la littérature* (rapport technique n° 383). [Récupéré](#) de l'archive ouverte HAL-Inria : <http://hal.inria.fr>
- Shipman, F., Furuta, R., Brenner, D., Chung, C. et Hsieh, H. (2000). Guided paths through web-based collections: Design, experiences, and adaptations. *Journal of the American Society for Information Sciences*, 51(3), 260-272. [doi:10.1002/\(SICI\)1097-4571\(2000\)51:3<260::AID-ASI5>3.0.CO;2-J](https://doi.org/10.1002/(SICI)1097-4571(2000)51:3<260::AID-ASI5>3.0.CO;2-J)
- Tattersall, C., Manderveld, J., Van den Berg, B., Van Es, R., Janssen, J. et Koper, R. (2006). *Swarm-based wayfinding support in open and distance learning*. Dans E. Alkhalifa (dir.), *Cognitively informed systems: Utilizing practical approaches to enrich information presentation and transfer* (p. 167-184). Hershey, PA : IDEA.
- Van den Berg, B., Van Es, R., Tattersall, C., Janssen, J., Manderveld, J., Brouns, F., ... Koper, R. (2005). Swarm-based sequencing recommendations in e-learning. Dans *Proceedings of the 5th International International Conference on Intelligence Systems Design and Applications* (p. 488-493). New York, NY : IEEE Computer Society.
- Wang, T.-I., Wang, K.-T. et Huang, Y.-M. (2008). Using a style-based ant colony system for adaptive learning. *Expert Systems with Applications*, 34(4), 2449-2464. [doi:10.1016/j.eswa.2007.04.014](https://doi.org/10.1016/j.eswa.2007.04.014)
- Wong L. H. et Looi, C. K. (2009). Adaptable learning pathway generation with ant colony optimization. *Educational Technology & Society*, 12(3), 309-326. [Récupéré](#) de <http://www.ifets.info>