



HAL
open science

La prise en compte de l'incertitude dans le processus de diagnostic des compétences de l'apprenant

Nesrine Rahmouni, Domitile Lourdeaux, Azzeddine Benabbou, Taher Bensebaa

► To cite this version:

Nesrine Rahmouni, Domitile Lourdeaux, Azzeddine Benabbou, Taher Bensebaa. La prise en compte de l'incertitude dans le processus de diagnostic des compétences de l'apprenant. 10e Conférence sur les Environnements Informatiques pour l'Apprentissage Humain (EIAH 2021), ATIEF : Association des Technologies de l'Information pour l'Éducation et la Formation, Jun 2021, Fribourg (Virtual), Suisse. pp.202-213. <hal-03292886>

HAL Id: hal-03292886

<https://hal.science/hal-03292886v1>

Submitted on 23 Jul 2021

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.



HAL Authorization

La prise en compte de l'incertitude dans le processus de diagnostic des compétences de l'apprenant

Nesrine Rahmouni¹, Domitile Lourdeaux², Azzeddine Benabbou³, Taher Bensebaa¹

¹ Université de Badji Mokhtar Annaba – Algérie

nesrinerahmouni.pro@gmail.com

t.g-bensebaa@gmail.com

² Alliance Sorbonne Université, Université de technologie de Compiègne, CNRS, Heudiasyc
UMR 7253

domitile.lourdeaux@hds.utc.fr

³ Université de Toulouse 3 - Institut de Recherche en Informatique de Toulouse

azzeddine.benabbou@irit.fr

Résumé. Nos travaux portent sur le processus de diagnostic dans les environnements informatiques pour l'apprentissage humain (EIAH). Dans cet article, nous proposons un module basé sur la théorie des fonctions de croyances pour le diagnostic des compétences de l'apprenant dans un EIAH. Ce module permet de prendre en compte l'imprécision, l'incertitude et la contradiction des informations récoltées sur l'apprenant. Nous visons par ce module la détermination de l'état des compétences évaluées, ainsi que la prédiction de l'état des compétences non évaluées de l'apprenant. Notre postulat principal est que ces résultats pourront servir d'appui à la rétroaction et à la remédiation rendues à l'apprenant, en lui offrant ainsi une meilleure personnalisation.

Mots-clés : diagnostic, compétences, apprenant, incertitude, fonction de croyances.

Abstract. Our work is related to the diagnosis process in intelligent tutoring systems (ITS). In this paper, we propose a diagnosis based on the theory of belief functions to take into account uncertainties in this process. The objective of our work is twofold: first, a dynamic diagnosis of the evaluated skills, then, the prediction of the state of the non-evaluated one. Our main premise is that these results will serve as a support to the feedbacks and to the remediation given to the learner, by providing her/him a proper personalization.

Keywords: diagnosis, skills, learner, uncertainty, belief functions.

1 Introduction

L'un des principaux atouts des environnements informatiques pour l'apprentissage humain (EIAH) est leur capacité à fournir un apprentissage sur mesure à chaque apprenant [1]. La personnalisation des apprentissages est en effet l'un des verrous majeurs des EIAH. Pour ce faire, il est indispensable de disposer d'une représentation informatique

de l'apprenant dans ces environnements [2]. C'est dans ce cadre de recherche que s'inscrit notre travail. Nous souhaitons proposer un module informatique pour le diagnostic des compétences de l'apprenant dans un EIAH dédié à l'apprentissage de l'algorithmique. Nous visons par ce module à la fois l'identification de l'état des compétences évaluées de l'apprenant et la prédiction de l'état des compétences non évaluées. Néanmoins, le diagnostic des compétences dans les EIAH est souvent un processus complexe [3] car il repose sur des évaluations souvent imparfaites tachées d'incertitudes, d'imprécisions et parfois de contradictions. Le problème que nous traitons ici est comment prendre en compte ces imperfections dans le processus de diagnostic afin d'améliorer la personnalisation des apprentissages ?

Nous faisons l'hypothèse que la théorie des fonctions de croyances permet de prendre en compte les imperfections du diagnostic et donc de l'améliorer. Dans la suite de cet article, nous présentons dans la section 2 quelques travaux connexes. Dans la section 3, nous détaillons l'architecture générale dans laquelle s'intègre notre module de diagnostic que nous décrivons dans les sections 4 et 5. Enfin, dans la section 6, nous exposons l'expérimentation réalisée afin d'évaluer le module de diagnostic.

2 État de l'art

Le Bayesian Knowledge Tracing (BKT)[4] représente l'une des techniques d'intelligence artificielle les plus utilisées pour le diagnostic des connaissances [3]. Le BKT s'appuie sur quatre paramètres : $p_0(x)$ la probabilité que l'apprenant maîtrise la compétence a priori, $p(guess)$ la probabilité que l'apprenant applique correctement la compétence par chance, $p(slip)$ la probabilité que l'apprenant applique incorrectement la compétence sans avoir une défaillance dans cette compétence, et $p(T)$ la probabilité de transition d'une compétence de l'état « non acquise » à « acquise » [4]. Ce modèle suppose que la réalisation de la compétence observée est binaire : correcte ou incorrecte [5]. Cependant, dans notre contexte, le processus de diagnostic de compétences est basé sur des évaluations numériques non binaires. De plus, le modèle BKT considère les concepts du domaine comme des éléments indépendants les uns des autres. Cela implique une perte d'informations utiles qui pourrait enrichir le processus de diagnostic. Les réseaux bayésiens, utilisés par exemple dans [6][7][8], permettent d'exploiter les interactions entre les concepts du domaine. En général, dans le cadre d'un ITS, les nœuds du réseau représentent les connaissances ou les compétences, et sont connectés par des relations probabilistes. Toutefois, les réseaux bayésiens ont l'inconvénient majeur de devoir être paramétrés [9]. Or, ce paramétrage est difficile si l'expert ne dispose pas d'une quantité de données suffisante. D'autres travaux de la littérature utilisent la logique floue pour la modélisation de l'apprenant [10][11]. Cette technique permet l'exploitation de variables linguistiques et la conception de modèles à la fois intelligibles et exploitables par des systèmes informatiques. À l'instar de [12], nous proposons un modèle de diagnostic reposant sur la théorie des fonctions de croyances. Une des originalités de cette proposition porte sur la possibilité de quantifier le potentiel conflit qui pourrait survenir des contradictions entre les différentes sources d'informations (ex. évaluations, croyances propagées). Cette proposition permet également, contrairement

aux approches probabilistes classiques, une meilleure représentation de l'état d'ignorance en le distinguant du cas où les hypothèses seraient effectivement équiprobables. Par ailleurs, contrairement à [12], ce modèle exploite les relations entre les compétences du domaine afin d'inférer l'état de celles qui n'ont pas encore été évaluées.

3 Architecture générale

Nous nous intéressons particulièrement au diagnostic des compétences de l'apprenant dans un EIAH dédié à l'apprentissage de l'algorithmique. Le module de diagnostic que nous proposons, s'intègre dans le cadre d'une architecture plus générale qui met en jeu différents modules à savoir : le module d'évaluation et le module de scénarisation. Les modules de cette architecture reposent sur une représentation ontologique du domaine qui permet de spécifier les différents concepts ainsi que les relations qu'ils ont les uns avec les autres. Dans cette section, nous présentons le modèle du domaine ainsi que les différents modules de l'architecture.

3.1 Le modèle du domaine

Dans le cadre de nos travaux, le domaine est modélisé grâce à l'ontologie Algoskills [13] qui apporte aux experts une meilleure visualisation et indexation des différents concepts de l'algorithmique. Cette ontologie est organisée autour de trois classes : la classe Topics, la classe Skills et la classe Ressources. La classe Topics représente la hiérarchie des notions de cours en algorithmique. La classe Skills représente quant à elle l'ensemble des compétences en algorithmique. Elle comporte deux types de compétences : les compétences disciplinaires et les compétences transversales. La classe Topic est reliée aux compétences disciplinaires par la relation sémantique « is-useful-to ». Par exemple, le Topic « Récursivité » is-useful-to « Identifier la structure récursive d'un problème ». Finalement, la classe Ressources regroupe l'ensemble des exercices utilisés pour évaluer les compétences. Cette classe est reliée à la classe Skills par la relation sémantique « has-for-objective ».

Afin de faciliter le processus de prédiction de l'état des compétences non évaluées de l'apprenant, nous étendons cette ontologie en ajoutant à la relation hiérarchique existante entre les compétences « is-a », une relation de précédence explicite « is-prerequisite ». Par exemple une compétence C_i est un prérequis de la compétence C_j , si l'acquisition de la compétence C_i précède forcément l'acquisition de la compétence C_j .

3.2 Module d'évaluation

Le module d'évaluation est en charge d'évaluer les productions de l'apprenant. Ce module, reçoit en entrée les productions de l'apprenant et les compare avec les productions attendues par l'expert du domaine. L'interprétation de cette comparaison s'exprime sous la forme de résultats numériques (notes d'évaluations) attribués aux compétences de l'apprenant. Ces notes d'évaluation sont transmises par la suite au module de diagnostic que nous présentons dans la section suivante.

3.3 Module de diagnostic

Dans cette architecture, le module de diagnostic reçoit les résultats retournés par le module d'évaluation. A partir de ces résultats, il génère des croyances sur l'état des compétences de l'apprenant. Une compétence peut être acquise, non acquise, probablement acquise, probablement non acquise ou indéterminé dans le cas où le système ignore l'état de la compétence. Une fois les croyances générées, elles sont transmises par la suite au module de scénarisation qui se charge de générer les décisions adaptées. Le module de diagnostic constitue la contribution majeure de cet article. Nous la détaillons dans les sections 4 et 5.

3.4 Module de scénarisation

Ce module est chargé de la scénarisation des sessions d'apprentissage pour chaque apprenant. Il reçoit les croyances sur l'état des compétences de l'apprenant établies par le module de diagnostic. A partir de ces croyances, il génère les scénarios d'apprentissage (exercices, cours) adéquats. Par exemple si l'état de la compétence A est « Probablement acquis », le module de scénarisation propose des exercices pour consolider cette compétence. En revanche, si l'état de la compétence est « Acquis » le module scénarisation peut proposer des exercices pour lesquels la compétence A est considérée comme prérequis

4 Le module de diagnostic

Les notes d'évaluation sont issues d'interprétations parfois subjectives d'un expert, ou d'un processus automatique d'évaluation. De ce fait, les données fournies sont entachées d'un certain nombre de défauts tels que :

- L'incertitude : un apprenant peut donner une réponse correcte sans pour autant maîtriser les compétences qui lui sont associées. A l'inverse, un apprenant peut donner une réponse erronée sans que cela ne soit nécessairement lié à une défaillance dans les compétences.
- L'imprécision : la note d'évaluation attribuée à la compétence peut ne pas être précise. Par exemple, un processus d'évaluation automatique pourrait estimer que la note d'évaluation attribuée à une compétence est comprise entre 15 et 20.
- La contradiction : les notes d'évaluations peuvent être déterminées à partir de différentes sources. Par conséquent, ces évaluations peuvent être contradictoires.

S'ajoute à ces défauts, l'ignorance de l'état des compétences qui n'ont pas encore été évaluées. Pour faire face à ces défauts, le module de diagnostic doit prendre en compte toutes ces imperfections. Par ailleurs, il doit être capable de fusionner des informations issues de sources hétérogènes tout en représentant l'éventuel conflit existant. Pour cela, nous avons considéré plusieurs cadres formels : la théorie des ensembles, la théorie des probabilités, la théorie des ensembles flous, la théorie des possibilités et la théorie des fonctions de croyances. Le cadre formel des fonctions de

croyances nous paraît le plus pertinent pour le diagnostic des compétences de l'apprenant. En effet, il généralise toutes les théories précédentes, et répond à tous nos besoins à savoir la représentation de l'incertitude, l'ignorance et la contradiction. Par ailleurs, cette théorie permet de fusionner et représenter des informations issues de sources hétérogènes. Plus précisément, nous utilisons le modèle des croyances transférables [14].

Dans le cadre des fonctions de croyances, l'état du système prend des valeurs discrètes w_n appelées hypothèses. L'ensemble de ces hypothèses $\Omega = \{w_1, w_2, \dots, w_n\}$ est appelé cadre de discernement. Une fonction de croyances peut être représentée de différentes manières. Nous utilisons la représentation par une distribution de masse de croyances notée m définie de 2^Ω dans $[0,1]$, et qui vérifie :

$$\sum_{A \subseteq \Omega} m(A) = 1 \quad (1)$$

Chaque sous-ensemble $A \subseteq \Omega$, tel $m(A) > 0$, est appelé élément focal de m . La masse $m(A)$ représente le degré de croyance attribué à la proposition A et qui, compte tenu de la connaissance, ne peut être affectée à un sous ensemble plus spécifique que A .

Dans notre contexte, une compétence peut être soit acquise soit non acquise. Par conséquent, l'application de ce cadre formel se fait tel que pour chaque compétence C , le cadre de discernement est $\Omega(C) = \{Acquise(C), \neg Acquise(C)\}$. Par ailleurs, pour chaque compétence C , nous définissons les masses et notations suivantes :

- $m(a) = m(\{Acquise(C)\})$ la masse de croyance attribuée au fait que la compétence soit acquise par l'apprenant ;
- $m(\neg a) = m(\{\neg Acquise(C)\})$ la masse de croyance attribuée au fait que la compétence soit non acquise par l'apprenant ;
- $m(i) = m(\Omega)$ la masse de croyance attribuée à l'ignorance qu'a le système quant à l'acquisition ou la non-acquisition de la compétence par l'apprenant ;
- $m(c) = m(\emptyset)$ la masse de croyance attribuée au conflit résultant de la contradiction entre les observations pour la même compétence.

Avec la contrainte : $m(a) + m(\neg a) + m(i) + m(c) = 1$ (2)

5 Processus de diagnostic :

Notre processus de diagnostic s'appuie sur quatre fonctions essentielles (cf. figure 2) :

- **La transformation** des notes d'évaluation en masses de croyances,
- **La révision** des masses de croyance à l'arrivée de nouvelles informations,
- **La propagation** des croyances aux compétences voisines,
- **La fusion des masses** des croyances attribuées à la même compétence.

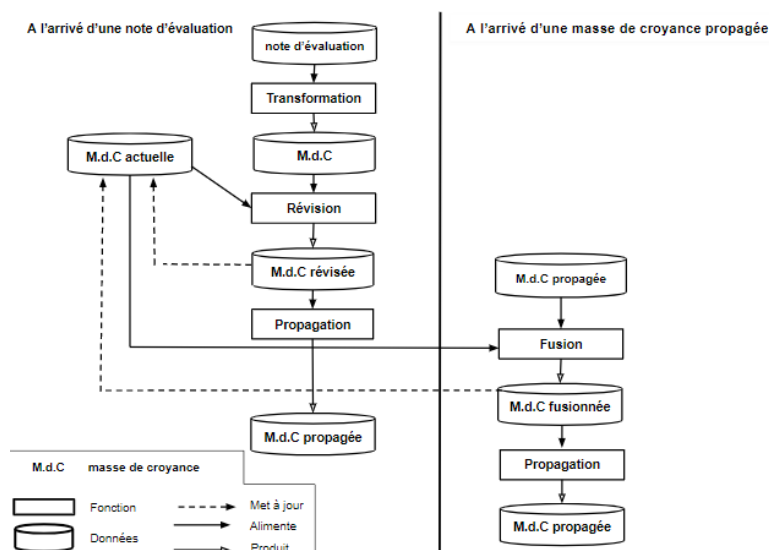


Fig. 1. Processus de diagnostic

Nous décrivons chaque fonction en détail dans les sous-sections suivantes.

5.1 La fonction de transformation

Le module d'évaluation retourne des notes numériques pour chaque compétence. Ces notes ne sont pas directement exploitables par le module de diagnostic. Ce dernier utilise les masses de croyances pour déterminer l'état des compétences évaluées et prédire l'état des compétences non évaluées de l'apprenant. Par conséquent, il est nécessaire de transformer les évaluations numériques en croyances. Pour ce faire, nous définissons une fonction de transformation qui permet de définir l'opération permettant d'obtenir l'état de la compétence à partir d'une note d'évaluation. Cette fonction prend en entrée une valeur $ne \in [0, n]$, où 0 et n représentent respectivement la note minimale et maximale que l'apprenant peut avoir dans une évaluation. Elle prend également en entrée une valeur E qui correspond à la note minimale nécessaire afin de valider l'évaluation, et une valeur ϵ qui représente une marge de doute autour de E .




Fig. 2. Distribution de masses de croyance en fonction de la note d'évaluation

Nous pouvons distinguer 4 zones dans la figure :

- La zone 1 où $ne \in [0, E - \varepsilon[$. La distribution de masse est telle que : $m(a)=0$, $m(\neg a) = 1$, $m(i)=0$, $m(c)=0$. (3)

Nous considérons dans ce cas que la compétence est non acquise.

- La zone 2 où $ne \in [E - \varepsilon, E [$. La distribution de masse est telle que : $m(a) = 0$, $m(\neg a) = \frac{-ne}{\varepsilon} + \frac{E}{\varepsilon}$, $m(i) = \frac{ne}{\varepsilon} + 1 - \frac{E}{\varepsilon}$, $m(c) = 0$. (4)

Nous considérons dans ce cas que la compétence est probablement non acquise.

- La zone 3 où $ne \in] E, E + \varepsilon]$. Dans cette zone, la distribution de masse est telle que: $m(a) = \frac{ne}{\varepsilon} - \frac{E}{\varepsilon}$, $m(\neg a) = 0$, $m(i) = -\frac{ne}{\varepsilon} + 1 + \frac{E}{\varepsilon}$, $m(c) = 0$. (5)

Nous considérons dans ce cas que la compétence est probablement acquise.

- La zone 4 où $ne \in [E + \varepsilon, n [$. Dans cette zone, la distribution de masse est telle que : $m(a) = 1$, $m(\neg a) = 0$, $m(i) = 0$, $m(c) = 0$ (6)

Nous considérons dans ce cas que la compétence est acquise.

En plus de ces quatre zones, il existe le cas particulier où $ne = E$. Dans ce cas, la distribution est telle que : $m(a)=0$, $m(\neg a) = 0$, $m(i) = 1$, $m(c) = 0$. (7)

Nous considérons dans ce cas que nous ignorons l'état de la compétence.

Prenons l'exemple d'un exercice sur 10 points ciblant une compétence particulière. L'enseignant considère que pour valider cet exercice, l'apprenant doit avoir au minimum la note de 5, avec une marge de doute de 2 points. On veut déterminer la croyance sur l'état de la compétence d'un apprenant qui a eu la note de 6 dans cette évaluation. La fonction de transformation indiquera dans ce cas la distribution de masse suivante :

$$m(a) = \frac{6}{2} + \frac{-5}{2} = \frac{1}{2}, m(\neg a) = 0, m(i) = -\frac{6}{2} + 1 + \frac{5}{2} = \frac{1}{2}, m(c) = 0$$

Nous considérons dans ce cas que la compétence est probablement acquise.

5.2 Fonction de révision

L'intérêt de cette fonction est de mettre à jour automatiquement l'état d'une compétence à l'arrivée d'une nouvelle information. Elle consiste à prendre en compte les nouvelles évaluations renvoyées par le module d'évaluation et qui viennent soit pour confirmer l'état de la compétence antérieure – donc l'apprenant a conservé son niveau – ou au contraire l'infirmier – le niveau de l'apprenant a évolué. On dit que l'apprenant a conservé son niveau si le nouvel état de la compétence est similaire à l'état actuel de cette compétence. A l'inverse, on dit que l'état de la compétence de l'apprenant a évolué si le nouvel état de la compétence est différent de son état actuel. De ce fait, la fonction de révision s'appuie sur deux mécanismes pour la révision des croyances que nous détaillons dans la suite.

Révision par une croyance similaire. Cela concerne le cas où la croyance actuelle est révisée par une croyance similaire. Dans ce cas, nous cherchons à maximiser la prise en compte de la nouvelle information tout en minimisant la perte de l'ancienne. Pour cela, nous utilisons la règle de révision interne [15]. Soit m_I et m_A deux distributions de masses distinctes pour la compétence C_p définies sur le même cadre de discernement

Ω avec m_I la distribution de masse de croyance initialement affectée à la compétence C_p , et m_A la distribution de masse de croyance affectée à la compétence C_p à partir de la nouvelle note d'évaluation, et \otimes l'opérateur de révision de la règle interne qui révisé m_I par m_A :

$$\begin{aligned} m_R(C_p) &= m_I(C_p) \otimes m_A(C_p) \\ &= \sum_{A \subseteq B} \sigma_A(A, B) * m_A(B) \\ \sigma_A(A, B) &= \begin{cases} \frac{m_I}{Bel(B)} & \text{pour } Bel(B) > 0 \\ 0 & \text{pour } Bel(B) > 0 \text{ et } A \neq B \\ 1 & \text{pour } Bel(B) = 0 \text{ et } A = B \end{cases} \end{aligned} \quad (8)$$

Où $Bel(B)$ est la part de croyance spécifiquement allouée à B , avec $Bel(B) = \sum_{C \subseteq B, C \neq \emptyset} m(C)$.

L'application de cette règle permet de déterminer la distribution de masse de croyance révisée m_R :

$$m_R(a) = \frac{m_I(a)}{m_I(a) + m_I(\neg a) + m_I(i)} * m_A(i) + m_A(a) \quad (9)$$

$$m_R(\neg a) = \frac{m_I(\neg a)}{m_I(a) + m_I(\neg a) + m_I(i)} * m_A(i) + m_A(\neg a)$$

$$m_R(i) = m_I(i) * m_A(i)$$

$$m_R(c) = 1 - m_R(a) - m_R(\neg a) - m_R(i)$$

Révision par une croyance différente. Cela concerne le cas où la croyance actuelle est révisée par une nouvelle croyance différente. Dans ce cas, nous proposons d'accorder la même importance à la nouvelle et l'ancienne masse de croyance. De ce fait, l'utilisation de la moyenne non associative nous paraît pertinente. Soit m_I et m_A deux distributions de masses distinctes pour la compétence C_p définies sur le même cadre de discernement Ω avec m_I est la distribution de masse de croyance initialement affectée à la compétence C_p , et m_A est la distribution de masse de croyance affectée à la compétence C_p à partir de la nouvelle note d'évaluation, et σ l'opérateur de révision de la moyenne non associative qui révisé m_I par m_A .

$$\begin{aligned} m_R(C_p) &= m_I(C_p) \sigma m_A(C_p) \\ &= \frac{1}{2}(m_I(C_p) + m_A(C_p)) \end{aligned} \quad (10)$$

L'application de cette règle permet de déterminer la distribution de masse de croyance révisée m_R :

$$\begin{aligned} m_R(a) &= \frac{m_I(a) + m_A(a)}{2} \\ m_R(\neg a) &= \frac{m_I(\neg a) + m_A(\neg a)}{2} \\ m_R(c) &= \frac{m_I(c) + m_A(c)}{2} \\ m_R(i) &= 1 - m_R(a) - m_R(\neg a) - m_R(c) \end{aligned} \quad (11)$$

5.3 La fonction de propagation de croyance :

L'objectif ultime du modèle de diagnostic est d'établir un diagnostic global des compétences de l'apprenant. Il ne s'agit pas seulement de diagnostiquer les compétences

directement évaluées, mais également de prédire l'état des compétences n'ayant pas été évaluées. Nous proposons alors une fonction de propagation des croyances entre les compétences du domaine. Nous avons évoqué dans la section précédente les relations de prérequis entre les compétences. Nous émettons l'hypothèse que la propagation des croyances entre ces compétences implique une perte d'informations sur la distribution de masses de croyances $m(a)$, $m(\neg a)$, $m(i)$ et $m(c)$ selon la distance qui les sépare. Afin de quantifier cette perte d'information, nous utilisons la règle d'affaiblissement de [16] :

$$\begin{aligned} m^\alpha(A) &= (1-\alpha) * m(A), \quad \forall A \subset \Omega \\ m^\alpha(\Omega) &= (1-\alpha) * m(\Omega) + \alpha \end{aligned} \quad (12)$$

Avec : $0 < \alpha < 1$

α Correspond au degré d'affaiblissement.

$1-\alpha$ Correspond au degré de fiabilité.

Nous définissons la fonction de propagation \mathcal{F} qui prend en paramètres la compétence source et la compétence ciblée par la propagation. Cette fonction retourne une distribution de masse de croyance affaiblie. Nous proposons que l'affaiblissement soit calculé en fonction de la distance qui sépare les compétences. Ainsi, nous définissons la fonction comme suit :

$$\begin{aligned} m_2(a) &= (1-\alpha)^d \times m_1(a) \\ m_2(\neg a) &= (1-\alpha)^d \times m_1(\neg a) \\ m_2(i) &= (1-\alpha)^d \times m_1(i) \\ m_2(c) &= (1-\alpha)^d \times m_1(c) \end{aligned} \quad (13)$$

5.4 La fonction de fusion

Lorsqu'une propagation de croyances a lieu, les compétences concernées reçoivent en entrée une croyance propagée qui vient compléter la masse de croyance locale. Par conséquent, pour déterminer le nouvel état de ces compétences, il est nécessaire de fusionner ces masses de croyances. La fusion de ces croyances permet d'enrichir le modèle de diagnostic, et donc d'affiner la scénarisation. Par exemple, si la croyance propagée montre que cette compétence est acquise et si la croyance locale déterminée à partir d'une évaluation directe montre totalement le contraire, cela signifie qu'il existe une incohérence dans l'état de la compétence pour cet apprenant. Par conséquent, une évaluation supplémentaire serait souhaitable pour lever cette incohérence. Afin de réaliser cette fusion, nous utilisons la règle de combinaison conjonctive de Shafer [16], qui permet de fusionner les informations en maximisant la concordance entre les sources d'information.

Soit m_l et m_p deux croyances distinctes pour une compétence donnée définies sur le cadre de discernement Ω . \oplus est l'opérateur de fusion de la règle de combinaison conjonctive [16] :

$$\begin{aligned} m_f(A) &= m_l(A) \oplus m_p(A) \\ m_f(A) &= \sum_{B \cap C = A} m_l(B) * m_p(C) \end{aligned} \quad (14)$$

Nous définissons la fonction de fusion F qui prend en paramètre les différentes masses de croyances associées à une compétence (propagée ou locale) et retourne une masse de croyance fusionnée m_f Où :

$$m_f(a) = m_l(a) * m_p(a) + m_l(i) * m_p(a) + m_p(i) * m_l(a)$$

$$\begin{aligned}
m_f(\neg a) &= m_i(\neg a) * m_p(\neg a) + m_i(i) * m_p(\neg a) + m_p(i) * m_i(\neg a) \\
m_f(i) &= m_i(i) * m_p(i) \\
m_f(c) &= 1 - m_f(a) - m_f(\neg a) - m_f(i)
\end{aligned}
\tag{15}$$

Cet opérateur de fusion est commutatif, l'ordre dans lequel on fusionne les informations n'est pas important, il génère du conflit en donnant l'information sur la quantité de la contradiction entre les sources d'informations.

6 L'expérimentation

L'objectif de notre expérimentation est d'évaluer la pertinence des diagnostics réalisés par le module de diagnostic en les comparant avec les diagnostics réalisés par un expert du domaine. Cette expérimentation a été réalisée à l'Université de Technologie de Compiègne avec des étudiants en première année de préparation intégrée. Elle a rassemblé 28 étudiants guidés par un enseignant qui assure le cours d'algorithmique depuis 15 ans. Dans cette expérimentation, nous avons proposé des exercices afin d'évaluer séparément chacune des compétences suivantes : Rechercher un élément dans un tableau ; Parcourir un tableau ; Maîtriser la boucle For ; Maîtriser la boucle while ; Maîtriser la boucle do-while. Ces compétences sont reliées entre elles avec les relations de précédence telles qu'illustrées dans la figure 3. La compétence « Parcourir un tableau » est un prérequis de la compétence « Rechercher un élément dans un tableau ». Les compétences « maîtriser les boucles {for, while, do-while} » sont des prérequis de la compétence « parcourir un tableau ».

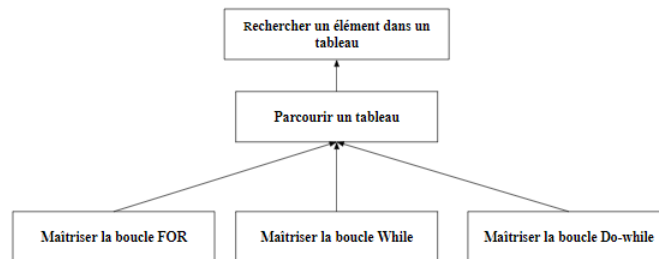


Fig. 3. Hiérarchie des compétences

Nous avons proposé de comparer la prédiction du module de diagnostic pour la compétence « Rechercher un élément dans un tableau » avec le diagnostic direct de cette compétence par l'expert du domaine. Pour ce faire, nous avons proposé aux étudiants deux séries d'exercices afin d'évaluer ces compétences. Le module de diagnostic reçoit les évaluations de chacune des compétences suivantes: « Parcourir un tableau », « Maîtriser la boucle For », « Maîtriser la boucle While », « Maîtriser la boucle Do-while », et à partir de ces évaluations et par sa fonction de propagation, il génère des prédictions sur l'état de la compétence « Rechercher un élément dans un tableau ». Ensuite nous faisons une comparaison entre ces prédictions et l'évaluation directe de l'expert. Pour effectuer cette comparaison, nous proposons la mesure de précision suivante:

$$\text{Mesure de précision} = \frac{\text{Nombre de prédictions pertinentes}}{\text{Nombre total de prédictions}}$$

Avec *Nombre de prédictions pertinentes* est le nombre des prédictions réalisées par le module de diagnostic pour la compétence « Rechercher un élément dans un tableau » similaires aux diagnostics de l'expert pour cette compétence.

Le Tableau 1 récapitule les résultats obtenus.

Table 1. Résultats de l'expérimentation

Nombre total de prédictions	Prédictions pertinente	Mesure de précision
28	23	0,82

6.1 Discussion :

Comme nous pouvons le voir dans le tableau ci-dessus, l'expérimentation révèle que pour un nombre total de 28 prédictions établies par notre module de diagnostic, 23 d'entre elles sont similaires à celles de l'expert. En revanche, 5 prédictions de le sont pas. En effet, les notes d'évaluations attribuées par l'expert, transformées par le module de diagnostic, montrent que la compétence « Rechercher un élément dans un tableau » n'est pas acquise pour ces cinq étudiants. Tandis que le module de diagnostic montre que cette compétence est probablement acquise. Selon notre expert, ces étudiants ont bien utilisé des boucles. Cependant ils ne les ont pas bien exploités pour résoudre l'exercice associé à la compétence « Rechercher un élément dans le tableau ».

Cette différence entre le diagnostic de l'expert et le module pourrait s'expliquer, entre autres, par les valeurs de la distance et/ou du taux d'affaiblissement sur lesquelles repose le module pour établir les prédictions.

7 Conclusion et perspectives :

Dans cet article, nous avons présenté notre proposition pour un module de diagnostic des compétences de l'apprenant dans un EIAH dédié à l'apprentissage de l'algorithmique. Ce module s'appuie sur la théorie des fonctions de croyances, pour quantifier l'incertitude, l'imprécision et la contradiction dans le processus de diagnostic. Ce processus repose sur quatre fonctions essentielles qui permettent à l'arrivée d'une nouvelle information, de mettre à jour, fusionner et propager les croyances sur l'état des compétences. Notre module a fait l'objet d'une première expérimentation auprès d'étudiants en première année d'études postbac, et les résultats sont encourageants. Une de perspectives de ce travail serait d'alléger encore plus la tâche de l'expert en calculant automatiquement les paramètres nécessaires à la fonction de propagation.

Références

1. M. Lefevre, J. Broisin, V. Butoianu, P. Daubias, L. Daubigney, et al. : Personnalisation de l'apprentissage : comparaison des besoins et approches à travers l'étude de quelques dispositifs. STICEF, ATIEF, 19, pp.353-387, (2012).
2. T. Carron and J.-C. Marty. : User Modelling in Learning Games BeIng Project View project Creating a Learning Lab View project. Proc. of the 3rd European Conference on Games Based Learning, Graz, Austria, pp. 86–94, (Oct. 2009).
3. A. Abyaa, M. Khalidi Idrissi, et S. Bennan. : Learner modelling: systematic review of the literature from the last 5 years. vol. 67, no. 5. Springer US,(2019).
4. A. T. Corbett and J. R. Anderson, Knowledge Tracing, User modeling and user-adapted interaction. vol. 4, no. 4. pp. 253–278,(1995).
5. M. V. Yudelson, K. R. Koedinger, and G. J. Gordon. : Individualized bayesian knowledge tracing models. Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics), vol. 7926 LNAI, pp. 171–180, (2013).
6. C. J. Butz, S. Hua, and R. B. Maguire. : A web-based bayesian intelligent tutoring system for computer programming.. Web Intell. Agent Syst., vol. 4, no. 1, pp. 61–81, (2006).
7. G. Gogwadze, S. Sosnovsky, S. Isotani, and B. M. McLaren. : Towards a Bayesian student model for detecting decimal misconceptions. Proc. 19th Int. Conf. Comput. Educ. ICCE 2011, no. January, pp. 34–41,(2011).
8. C. Y. Ting and S. Phon-Amnuaisuk. : Properties of Bayesian student model for INQPRO. Appl. Intell., vol. 36, no. 2, pp. 391–406, (2012).
9. A. Jameson. : Numerical uncertainty management in user and student modeling: An overview of systems and issues.. User Model. User-Adapted Interact. J. Pers. Res., vol. 5, no. 3, pp. 193–251, (1995).
10. D. Xu, H. Wang, and K. Su. : Intelligent student profiling with fuzzy models. In Proc. Annu. Hawaii Int. Conf. Syst. Sci., vol. 2002-Janua, no. February,(2002).
11. G. Tsaganou, M. Grigoriadou, T. Cavoura, and D. Koutra. : Evaluating an intelligent diagnosis system of historical text comprehension..Expert Systems with Applications, , pp. 493-502.(2003)
12. K. Carpentier. : Scénarisation personnalisée dynamique dans les environnements virtuels pour la formation., p. 271, (2015).
13. Belhaoues T.E., Bensebaa T., Abdessemed M., Bey A. : AlgoSkills: An ontology of Algorithmic Skills for exercises description and organization. Journal of e-Learning and Knowledge Society, v.12, (2012).
14. P. Smets and R. Kennes. : The transferable belief model. Artif. Intell., vol. 66, no. 2, pp. 191–234, (1994).
15. J. Ma, W. Liu, D. Dubois, and H. Prade. : Revision rules in the theory of evidence. Proc. - Int. Conf. Tools with Artif. Intell. ICTAI, vol. 1, pp. 295–302, (2010).
16. G. Shafer. : A Mathematical Theory of Evidence. Princeton, New Jersey, USA: Princeton Univ. Press, (1976).