

**THESE DE DOCTORAT DE L'ETABLISSEMENT UNIVERSITE BOURGOGNE
FRANCHE-COMTE**

PREPAREE A L'UNIVERSITE DE FRANCHE-COMTE

Ecole doctorale n° <numéro de l'Ecole doctorale>

<Nom de l'Ecole doctorale>

Doctorat de Informatique

Par

M. SOTO FORERO Daniel

Adaptation en temps réel d'une séance d'entraînement par intelligence artificielle

Thèse présentée et soutenue à Besançon, le <date>

Composition du Jury :

<Civilité><Nom><Prénom>	<Fonction et établissement d'exercice>	Président
<Civilité><Nom><Prénom>	<Fonction et établissement d'exercice>	Rapporteur
<Civilité><Nom><Prénom>	<Fonction et établissement d'exercice>	Rapporteur
<Civilité><Nom><Prénom>	<Fonction et établissement d'exercice>	Examinateur
<Civilité><Nom><Prénom>	<Fonction et établissement d'exercice>	Examinatrice
<Civilité><Nom><Prénom>	<Fonction et établissement d'exercice>	Directeur de thèse
<Civilité><Nom><Prénom>	<Fonction et établissement d'exercice>	Codirecteur de thèse
<Civilité><Nom><Prénom>	<Fonction et établissement d'exercice>	Invité

REMERCIEMENTS

SOMMAIRE

I	Contexte et Problématiques	1
1	Introduction	3
1.1	Contributions Principales	4
1.2	Plan de la thèse	5
2	Contexte	7
2.1	Les stratégies d'apprentissage humain et les environnements informatiques pour l'apprentissage humain (EIAH)	7
2.1.1	Les stratégies d'apprentissage	7
2.1.2	Les EIAH	8
2.1.3	L'exerciseur initial AI-VT	9
2.2	Le contexte technique	10
2.2.1	Le raisonnement à partir de cas (RàPC)	10
2.2.1.1	Retrouver (Rechercher)	12
2.2.1.2	Réutiliser (Adapter)	12
2.2.1.3	Réviser et Réparer	12
2.2.1.4	Retenir (Stocker)	13
2.2.1.5	Conteneurs de Connaissance	14
2.2.2	Les systèmes multi-agents	14
2.2.3	Différents algorithmes et fonctions implémentés dans AI-VT pour la personnalisation et l'adaptation des séances d'entraînement proposées	15
2.2.3.1	Pensée Bayésienne	15
2.2.3.2	Méthode des k plus proches voisins (K-Nearest Neighborhood - KNN)	16
2.2.3.3	K-Moyennes	17
2.2.3.4	Modèle de Mélange Gaussien GMM (<i>Gaussian Mixture Model</i>)	18
2.2.3.5	Fuzzy-C	18
2.2.3.6	Bandit Manchot MAB (<i>Multi-Armed Bandits</i>)	19
2.2.3.7	Échantillonnage de Thompson TS (<i>Thompson Sampling</i>)	19

II	État de l'art	21
3	Environnements Informatiques d'Apprentissage Humain	23
3.1	L'Intelligence Artificielle	23
3.2	Systèmes de recommandation dans les EIAH	24
4	État de l'art (Raisonnement à Partir de Cas)	29
4.1	Raisonnement à partir de cas (RàPC)	29
III	Contributions	37
5	Architecture Globale pour le Système AI-VT	39
5.1	Introduction	39
5.2	Description du système AI-VT	40
5.3	Modèle d'architecture proposé	41
5.3.1	Correction automatique	43
5.3.2	Identification	44
5.3.3	Révision	45
5.3.4	Test	46
5.4	Conclusion	47
6	Système de Recommandation dans AI-VT	49
6.1	Introduction	49
6.2	Modèle Proposé	50
6.3	Résultats	51
6.4	Discussion et Conclusions	57
7	Raisonnement à partir de cas (RàPC) pour Régression	61
7.1	Introduction	61
7.2	Modèle Proposé	62
7.2.1	Rechercher	63
7.2.2	Réutiliser	64
7.2.3	Révision	67
7.2.4	Mémorisation	68
7.3	Résultats	68
7.4	Discussion	70
7.5	Conclusion	71

8	Intégration du Raisonnement à partir de cas (RàPC) et des Systèmes Multi-Agent (SMA)	73
8.1	Introduction	73
8.2	Modèle Proposé	74
8.2.1	Algorithmes	75
8.2.2	Structure des agents	77
8.2.3	Apprentissage des agents	77
8.2.4	Échanges entre les agents	79
8.3	Résultats	79
8.4	Conclusion	81
9	Application du Raisonnement à partir de cas (RàPC) et des Systèmes Multi-Agent (SMA) au système AI-VT	83
9.1	Introduction	83
9.2	Concepts Associés	83
9.3	Modèle Proposé	86
9.4	Résultats et Discussion	88
9.4.1	Régression dans la base de données des apprenants avec ESCBR-SMA	89
9.4.2	Progression des connaissances	90
9.4.3	Comparaison entre TS et BKT	91
9.4.4	Système de recommandation avec ESCBR-SMA	92
9.4.5	Progression des connaissances TS vs TS et ESCBR-SMA	93
9.5	Conclusion	94
10	Application du raisonnement à partir de cas (RàPC), des systèmes multi-agents (SMA) et du processus de Hawkes au système AI-VT	95
10.1	Introduction	95
10.2	Modèle Proposé	96
10.3	Résultats et Discussion	98
10.3.1	Système de recommandation avec une base de données d'étudiants réels (TS avec Hawkes)	98
10.3.2	Base de données simulée (ESCBR, TS avec Hawkes)	99
10.4	Conclusion	101
11	Conclusions et Perspectives	103
11.1	Conclusion générale	103
11.2	Perspectives	103

12 Publications	105
12.1 Publications par rapport au sujet de thèse	105
12.2 Autres publications	106

I

CONTEXTE ET PROBLÉMATIQUES

INTRODUCTION

Ce chapitre introductif vise à expliquer les termes du sujet et à introduire la thématique principale abordée. Il présente la problématique de cette thèse, introduit les différentes contributions proposées et annonce le plan du manuscrit.

Comme l'indique [Nkambou et al., 2010], les environnements informatiques pour l'apprentissage humain (EIAH) sont des outils proposant des services devant permettre aux apprenants d'acquérir des connaissances et de développer des compétences dans un domaine spécifique. Pour fournir des services efficaces, le système doit intégrer une représentation des connaissances du domaine et des mécanismes pour utiliser ces connaissances. Il doit également être en mesure de raisonner et de résoudre des problèmes.

Le système *Artificial Intelligence - Virtual Trainer* (AI-VT) est un EIAH générique développé au département d'informatique des systèmes complexes (DISC) de l'institut de recherche FEMTO-ST. Cet outil informatique propose un ensemble d'exercices aux apprenants dans le cadre de séances d'entraînement. AI-VT intègre le fait qu'une séance d'entraînement se situe dans un cycle de plusieurs séances. Les réponses apportées par l'apprenant à chaque exercice sont évaluées numériquement sur une échelle prédéfinie, ce qui permet d'estimer les progrès de l'apprenant et de déduire les sous-domaines dans lesquels il peut avoir des difficultés. Une séance est générée par un système multi-agents associé à un système de raisonnement à partir de cas (RàPC) [Henriet et al., 2017]. Un apprenant choisit le domaine dans lequel il souhaite s'entraîner et AI-VT lui propose un test préliminaire. Les résultats obtenus permettent de placer l'apprenant dans le niveau de maîtrise adéquate. Le système génère ensuite une séance adaptée veillant à l'équilibre entre l'entraînement, l'apprentissage et la découverte de nouvelles connaissances. L'actualisation du niveau de l'apprenant est effectuée à la fin de chaque séance. De cette façon l'apprenant peut avancer dans l'acquisition des connaissances ou s'entraîner sur des connaissances déjà apprises.

Un certain nombre d'EIAH utilisent des algorithmes d'intelligence artificielle (IA) pour détecter les faiblesses et aussi pour s'adapter à chaque apprenant. Les algorithmes et modèles de certains de ces systèmes seront analysés dans les chapitres 3 et 4. Ces chapitres présenteront leurs propriétés, leurs avantages et leurs limites.

Le système AI-VT initial était capable d'ajuster les paramètres de personnalisation d'une séance à l'autre, mais il ne pouvait pas modifier une séance en cours même si certains exercices de celle-ci étaient trop simples ou trop complexes. Chaque séance était figée et devait être déroulée jusqu'à son terme avant de pouvoir identifier des acquis et des lacunes. Les travaux de cette thèse ont eu pour objectif de pallier ce manque.

La problématique principale de cette thèse est la personnalisation en temps réel du parcours d'apprentissage des apprenants dans le système AI-VT (*Artificial Intelligence - Virtual Trainer*)

Ici *le temps réel* est considéré comme étant le moment où se déroule la séance que l'apprenant est en train de suivre. Par conséquent, l'objectif est de rendre AI-VT plus dynamique pour l'identification des difficultés et l'adaptation du contenu personnalisé en fonction des connaissances démontrées.

La partie suivante présente une liste des principales contributions apportées par cette thèse à la problématique générale énoncée plus haut.

Ce travail de thèse a été effectué au sein l'Université de Franche-Comté (UFC) devenue depuis le 1er janvier 2025 l'Université Marie et Louis Pasteur (UMLP). Ces recherches ont été menées au sein de l'équipe DEODIS du département d'informatique des systèmes complexes de l'institut de recherche FEMTO-ST, unité mixte de recherche (UMR) 6174 du centre national de la recherche scientifique (CNRS).

1.1/ CONTRIBUTIONS PRINCIPALES

La problématique principale de ces travaux de recherche a été déclinée en plusieurs sous-parties. Ces dernières sont présentées ci-dessous sous la forme de questions. Pour chacune d'elles, une ou plusieurs propositions ont été faites. Voici les questions de recherche abordées et les contributions apportées :

1. **Comment permettre au système AI-VT d'évoluer et d'intégrer de multiples outils ?** Pour répondre à cette question, une architecture modulaire autour du moteur initial d'AI-VT a été conçue et implémentée (ce moteur initial étant le système de raisonnement à partir de cas (RàPC) développé avant le démarrage de ces travaux de thèse).
2. **Comment déceler qu'un exercice est plus ou moins adapté aux besoins de l'apprenant ?** Choisir les exercices les plus adaptés nécessite d'associer une valeur liée à son utilité pour cet apprenant. Les modèles de régression permettent d'interpoler une telle valeur. Pour répondre à cette question, nous avons proposé de nouveaux modèles de régression fondés sur le paradigme du raisonnement à partir de cas et celui des systèmes multi-agents.
3. **Quel modèle et quel type d'algorithmes peuvent être utilisés pour recommander un parcours personnalisé aux apprenants ?** Pour apporter une réponse à cette question, un système de recommandation fondé sur l'apprentissage par renforcement a été conçu. L'objectif de ces travaux est de proposer un module permettant de recommander des exercices aux apprenants en fonction des connaissances démontrées et en se fondant sur les réponses apportées aux exercices précédents de la séance en cours. Ce module de révision de la séance en cours du modèle de RàPC est fondé sur un modèle Bayésien.
4. **Comment consolider les acquis de manière automatique ?** Une séance doit non seulement intégrer des exercices de niveaux variés mais également permettre à l'apprenant de renforcer ses connaissances. Dans cette optique, notre modèle Bayésien a été enrichi d'un processus de Hawkes incluant une fonction d'oubli.

1.2/ PLAN DE LA THÈSE

Ce manuscrit est scindé en deux grandes parties. La première partie contient trois chapitres et la seconde en contient quatre. Le premier chapitre de la première partie (chapitre 2) vise à introduire le sujet, les concepts, les algorithmes associés, présenter le contexte général et l'application AI-VT initiale. Le deuxième chapitre de cette partie présente différents travaux emblématiques menés dans le domaine des environnements informatiques pour l'apprentissage humain. Le chapitre suivant conclut cette première partie en présentant le raisonnement à partir de cas.

Dans la seconde partie du manuscrit, le chapitre 5 explicite l'architecture proposée pour intégrer les modules développés autour du système AI-VT initial et élargir ses fonctionnalités. Le chapitre 6 propose deux outils originaux fondés sur le raisonnement à partir de cas et les systèmes multi-agents pour résoudre des problèmes de régression de façon générique. Le chapitre 7 présente l'application de ces nouveaux outils de régression dans un système de recommandation intégré à AI-VT utilisant un modèle Bayésien. Ce chapitre montre de quelle manière il permet de réviser une séance d'entraînement en cours. Le chapitre 8 montre l'utilisation du processus de Hawkes pour renforcer l'apprentissage.

Enfin, une conclusion générale incluant des perspectives de recherche termine ce manuscrit.

CONTEXTE

Dans ce chapitre sont décrits plus en détails le contexte applicatif et le contexte technique de ces travaux de recherche. Il présente les concepts et algorithmes utilisés dans le développement des modules. Ces modules font partie des contributions de cette thèse à l'environnement informatique pour l'apprentissage humain (EIAH) appelé AI-VT (*Artificial Intelligence - Artificial Trainer*).

Ce chapitre commence par une présentation des EIAH suivie d'une présentation sommaire du fonctionnement d'AI-VT. AI-VT étant un système de raisonnement à partir de cas (RàPC) modélisé sous la forme d'un système multi-agents (SMA), cette présentation des EIAH est suivie d'une présentation du RàPC, puis des SMA. Ce chapitre se termine par une présentation de différents algorithmes et notions implémentés dans AI-VT pour la personnalisation et l'adaptation des séances d'entraînement proposées par l'EIAH.

2.1/ LES STRATÉGIES D'APPRENTISSAGE HUMAIN ET LES ENVIRONNEMENTS INFORMATIQUES POUR L'APPRENTISSAGE HUMAIN (EIAH)

2.1.1/ LES STRATÉGIES D'APPRENTISSAGE

Dans [Lalitha and Sreeja, 2020], l'apprentissage est défini comme une fonction du cerveau humain acquise grâce au changement permanent dans l'obtention de connaissances et de compétences par le biais d'un processus de transformation du comportement lié à l'expérience ou à la pratique. L'apprentissage implique réflexion, compréhension, raisonnement et mise en œuvre. Un individu peut utiliser différentes stratégies pour acquérir la connaissance. Comme le montre la figure 2.1, les stratégies peuvent être classées entre mode traditionnel et mode en-ligne.

L'apprentissage traditionnel se réfère à l'apprentissage-type tel qu'il est fait dans une classe. Il est centré sur l'enseignant où la présence physique est l'élément fondamental dans la mesure où elle implique une unité de temps et de lieu. Ici, l'enseignant interagit directement avec l'élève, et les ressources sont généralement des documents imprimés. L'apprentissage et la participation doivent y être actifs, la rétroaction y est instantanée et il existe des interactions sociales. En revanche, les créneaux horaires, les lieux et les contenus sont rigides (décidés par l'enseignant et la structure dans laquelle les enseignements sont dispensés).




FIGURE 2.1 – Stratégies d'apprentissage (Traduit de [Lalitha and Sreeja, 2020])

L'autre stratégie globale est l'apprentissage en-ligne, qui s'appuie sur les ressources et l'information disponible sur le web. Cette stratégie incite les apprenants à être actifs pour acquérir de nouvelles connaissances de manière autonome grâce aux nombreuses ressources disponibles. Les points positifs de cette stratégie sont par exemple la rentabilité, la mise à niveau continue des compétences et des connaissances ou une plus grande opportunité d'accéder au contenu du monde entier. Pour l'apprenant, l'auto-motivation et l'interaction peuvent être des défis à surmonter. Pour l'enseignant, il est parfois difficile d'évaluer l'évolution du processus d'apprentissage de l'individu. L'apprentissage en-ligne fait aussi référence à l'utilisation de dispositifs électroniques pour apprendre (*e-learning*) où les apprenants peuvent être guidés par l'enseignant à travers des liens, du matériel spécifique d'apprentissage, des activités ou exercices.

Il existe également des stratégies hybrides combinant des caractéristiques des deux stratégies fondamentales, comme un cours en-ligne mais avec quelques séances en présentiel pour des activités spécifiques ou des cours traditionnels avec du matériel d'apprentissage complémentaire en-ligne.

2.1.2/ LES EIAH

Les EIAH sont des outils pour aider les apprenants dans le processus d'apprentissage et l'acquisition de la connaissance. Ces outils sont conçus pour fonctionner avec des stratégies d'apprentissage en-ligne et mixtes. Généralement, l'architecture de ces systèmes est divisée en quatre composants comme le montre la figure 2.2. Ces composants sont :

- Le *domaine* (*Domain Model* sur la figure 2.2), qui contient les concepts, les règles et les stratégies pour résoudre des problèmes dans un domaine spécifique. Ce composant peut détecter et corriger les erreurs des apprenants. En général, l'information est divisée en séquences pédagogiques.
- Le composant *apprenant* (*Student Model* sur la figure 2.2), qui est le noyau du




FIGURE 2.2 – L'architecture générale des EIAH, les composantes et leurs interactions (Traduit de [Nkambou et al., 2010])

système car il contient toute l'information utile à l'EIAH concernant l'apprenant (*User-Learner* sur la figure 2.2). Ce composant contient également les informations sur l'évolution de l'acquisition des compétences de l'apprenant. Ce module doit avoir les informations implicites et explicites pour pouvoir créer une représentation des connaissances acquises, non et partiellement acquises et l'évolution de l'apprentissage de l'apprenant. Ces informations doivent permettre de générer un diagnostic de l'état de la connaissance de l'apprenant, à partir duquel le système peut prédire les résultats dans certains domaines et choisir la stratégie optimale pour présenter les nouveaux contenus.

- L'*enseignant* (*Tutoring Model* sur la figure 2.2) est également modélisé sous la forme d'un composant. Il reçoit l'information des modules précédents, information grâce à laquelle il peut prendre des décisions sur le changement de parcours ou sur la stratégie d'apprentissage. Il peut également interagir avec l'apprenant.
- L'*interface* (*Interface* sur la figure 2.2) est le module chargé de la gestion des configurations de l'EIAH et des interactions entre ses composants.

Le développement et la configuration de ce type de systèmes relèvent de multiples disciplines et impliquent plusieurs domaines de recherche parmi lesquels figurent la pédagogie, l'éducation, la psychologie, les sciences cognitives et l'intelligence artificielle.

2.1.3/ L'EXERCISEUR INITIAL AI-VT

Le DISC travaille depuis plusieurs années sur l'utilisation potentielle de l'intelligence artificielle dans le cadre d'un exerciceur couvrant plusieurs domaines d'apprentissage. Cet exerciceur, appelé AI-VT (Artificial Intelligence Virtual Trainer) est fondé sur différents concepts d'intelligence artificielle et ses domaines d'application sont l'apprentissage de l'aïkido, des bases de l'algorithmique et de l'anglais. Un premier réseau de convolution

détermine les lacunes de l'apprenant en analysant les résultats de quelques exercices préliminaires. Puis un système de raisonnement à partir de cas distribué prend le relais et détermine une liste d'exercices à proposer en regard de ses lacunes et en tenant compte des séances qui ont déjà été proposées par le système à cet apprenant.

Dans le système AI-VT, une séance d'entraînement est proposée dans le cadre d'un cycle d'entraînement. Ainsi, un exercice proposé en première séance du cycle peut être reproposé ensuite dans une autre séance, afin de consolider les acquis et de remettre en mémoire certaines connaissances à l'apprenant. Une séance est entièrement consacrée à une seule et même compétence, déclinée en plusieurs sous-compétences. Des exercices dans différentes sous-compétences sont proposés à chaque séance. Les exercices d'une même sous-compétence sont regroupés. Un même exercice pouvant permettre de travailler deux sous-compétences différentes, un mécanisme de règlement des conflits a été implémenté dans AI-VT afin qu'un même exercice ne puisse être proposé plus d'une seule fois dans une même séance d'entraînement. Dans AI-VT, l'énoncé d'un exercice est constitué de deux parties : le contexte et la question. Cette structure modulaire permet d'associer plusieurs questions à un même contexte et inversement. Les réponses apportées par les apprenants à chaque exercice sont notées sur 10 points et le temps mis pour répondre à chaque question est comptabilisée. L'étudiant dispose d'une interface présentant un tableau de bord des exercices, sous-compétences et compétences qu'il ou elle a travaillé.

Pour l'apprentissage de l'Anglais, un robot est chargé d'énoncer les exercices de la séance. Au démarrage de cette thèse, les apprenants ont une liste personnalisée d'exercices proposée par le système AI-VT, mais c'est à l'enseignant de vérifier la validité des algorithmes/solutions proposés par les étudiants et d'identifier leurs difficultés. L'amélioration du système et de la personnalisation du parcours de l'apprenant implique une correction automatique des exercices et cela sans utiliser un entraînement spécifique à chaque exercice, mais cet objectif ne fait pas partie de cette thèse. La définition de profils d'apprenants par le recueil de traces reste également à travailler pour optimiser les aides et séances d'exercices.

Le système AI-VT a été implémenté en se fondant sur deux paradigmes de l'IA : la séance d'entraînement est construite par différents modules suivant la philosophie du raisonnement à partir de cas, et l'architecture logicielle a été modélisée selon un système multi-agents. Une présentation sommaire de ces deux paradigmes de l'IA sont présentés dans cette section, et celles-ci sont suivies de la présentation de différents algorithmes et fonctions implémentés dans l'EIAH AI-VT. Des états de l'art plus complets sur les EIAH et le RàPC sont présentés dans le chapitre suivant. Le système AI-VT, son architecture et les évolutions qui ont été réalisées sur celle-ci sont détaillés dans le chapitre 4.

2.2/ LE CONTEXTE TECHNIQUE

2.2.1/ LE RAISONNEMENT À PARTIR DE CAS (RÀPC)

Le raisonnement à partir de cas est un modèle de raisonnement fondé sur l'hypothèse que les problèmes similaires ont des solutions similaires. Ainsi, les systèmes de RàPC infèrent une solution à un problème posé à partir des solutions mises en œuvre auparavant pour résoudre d'autres problèmes similaires [Roldan Reyes et al., 2015].

Un cas est défini comme étant la représentation d'un problème et la description de sa solution. Les cas résolus sont stockés et permettent au système de RàPC de construire de nouveaux cas à partir de ceux-ci. Formellement, si P est l'espace des problèmes et S l'espace des solutions, alors un problème x et sa solution y appartiennent à ces espaces : $x \in P$ et $y \in S$. Si y est solution de x alors, un cas est représenté par le couple $(x, y) \in P \times S$. Le RàPC a besoin d'une base de N problèmes et de leurs solutions associées. Cette base est appelée base de cas. Ainsi tout cas d'indice $n \in [1, N]$ de cette base de cas est formalisé de la manière suivante : (x^n, y^n) . L'objectif du RàPC est, étant donné un nouveau problème x^z de trouver sa solution y^z en utilisant les cas stockés dans la base de cas [Lepage et al., 2020].




FIGURE 2.3 – Cycle fondamental du raisonnement à partir de cas (Adapté et traduit de [Leikola et al., 2018])

Le processus du RàPC est divisé en quatre étapes formant un cycle comme l'ont proposé Aamont et Plaza [Aamodt and Plaza, 1994]. La figure 2.3 montre le cycle, le flux d'informations ainsi que les relations entre chacune des étapes [Leikola et al., 2018] : re-

trouver (rechercher), réutiliser (adapter), réviser et retenir (stocker). Chacune des étapes est décrite dans [Richter and Weber, 2013] de la manière suivante.

2.2.1.1/ RETROUVER (RECHERCHER)

L'objectif de cette étape est de rechercher dans la base de cas, les cas similaires à un nouveau cas donné. Cette similarité n'est pas un concept général, mais dépend du contexte, de l'objectif et du type de données. La question fondamentale qui se pose dans cette étape est : quel est le cas le plus approprié dans la base de cas qui permet de réutiliser sa solution pour résoudre le nouveau problème donné ?.

Le nouveau cas est comparé à chaque cas de la base afin d'en évaluer la similitude. La comparaison entre les cas est différente selon la structure de la base et la manière dont les problèmes sont décrits dans celle-ci. Généralement, un problème est représenté par un ensemble d'attributs aux valeurs spécifiques. Cette représentation est connue comme la représentation attribut-valeur. La similitude entre deux cas de ce type est calculée suivant l'équation 2.1. La similitude entre deux cas attribut-valeur $c_1 = a_{1,1}, a_{1,1}, \dots, a_{1,n}$ et $c_2 = a_{2,1}, a_{2,1}, \dots, a_{2,n}$ est la somme pondérée des similitudes entre les attributs considérés individuellement. La pondération détermine l'importance de chaque attribut.

$$\sum_{i=1}^n \omega_i \text{sim}(a_{1,i}, a_{2,i}) \quad (2.1)$$

Dans cette étape, il est possible de sélectionner k différents cas similaires au nouveau cas donné.

2.2.1.2/ RÉUTILISER (ADAPTER)

L'idée du RàPC est d'utiliser l'expérience pour essayer de résoudre de nouveaux cas (problèmes). La figure 2.4 montre le principe de réutilisation d'un cas (problème) résolu (appelé *cas source*) auparavant pour le proposer en solution d'un nouveau cas (dénommé *cas cible*) après adaptation.

Si certains cas cibles sont très similaires au cas source le plus proche, il est cependant souvent nécessaire d'adapter la solution du cas source le plus similaire afin d'arriver à une solution satisfaisante pour le cas cible. De la même manière que pour la phase de recherche du cas le plus similaire, il existe de nombreuses stratégies d'adaptation. Celles-ci dépendent de la représentation des cas, du contexte dans lequel le RàPC est mis en œuvre et des algorithmes utilisés pour l'adaptation. L'une des stratégies les plus utilisées est la définition d'un ensemble de règles transformant la ou les solutions des cas sources les plus similaires au cas cible. L'objectif ici est d'inférer une nouvelle solution y^z du cas x^z à partir des k cas sources retrouvés dans la première étape.

2.2.1.3/ RÉVISER ET RÉPARER

La solution adaptée proposée doit ensuite être évaluée et révisée afin de satisfaire certains critères de validation. L'étape de révision est chargée d'évaluer l'applicabilité de la



FIGURE 2.4 – Principe de réutilisation dans le RàPC (Traduit de [Richter and Weber, 2013])

solution cible obtenue suite à l'étape 'adaptation'. Cette évaluation peut être réalisée dans le monde réel ou dans une simulation.

L'objectif de cette phase de révision est la validation du couple (x^z, y^z) . Autrement dit, le but est ici de vérifier si la solution trouvée y^z résout le problème x^z et satisfait les règles de validité et d'applicabilité. Si la solution n'est pas correcte, l'expert mettant en œuvre la solution doit ajuster ou modifier la solution cible proposée.

Le processus d'évaluation, de révision et de réparation peut être mis en œuvre via un processus d'apprentissage permettant d'améliorer la détection et la correction des failles des futures solutions générées. Dans les travaux de cette thèse, nous avons envisagé la possibilité d'utiliser différents outils d'apprentissage pour évaluer et réviser les solutions cibles dans certains cas particuliers.

L'évaluation peut être faite :

- par un expert humain capable d'évaluer la solution et sa pertinence dans le contexte applicatif,
- par un système fonctionnant en production et renvoyant le résultat de l'application de la solution,
- par un modèle statistique ou un système de test.

La correction des solutions peut être automatique, mais elle dépend du domaine et de l'information disponible. Un ensemble de règles peut aider à identifier les solutions non valides.

2.2.1.4/ RETENIR (STOCKER)

Si le cas cible résolu est jugé pertinent, alors celui-ci peut être stocké dans la base de cas pour aider ensuite à la résolution de futurs cas cible. La décision de stocker ou non un nouveau cas dans la base de cas doit tenir compte de la capacité de cette nouvelle base de cas à proposer de futures solutions pertinentes, évaluer et corriger les solutions

cibles générées d'une part, et maintenir une base de cas d'une taille ne gaspillant pas inutilement des ressources de stockage et de calculs du système de RàPC d'autre part.

2.2.1.5/ CONTENEURS DE CONNAISSANCE

Pour pouvoir exécuter le cycle complet, le RàPC dépend de quatre sources différentes d'information. Ces sources sont appelées les conteneurs de connaissances par [Richter, 2009]. Cet article définit les conteneurs suivants dans les systèmes de RàPC : le conteneur de cas, le conteneur d'adaptation, le conteneur du vocabulaire et le conteneur de similarité :

- Le conteneur de cas contient les expériences passées que le système peut utiliser pour résoudre les nouveaux problèmes. L'information est structurée sous la forme d'un couple (p, s) , où p est la description d'un problème et s est la description de sa solution.
- Le conteneur d'adaptation stocke la ou les stratégies d'adaptation ainsi que les règles et paramètres nécessaires pour les exécuter.
- Le conteneur du vocabulaire contient l'information, sa signification et sa terminologie. Les éléments comme les entités, les attributs, les fonctions ou les relations entre les entités peuvent y être décrits.
- Le conteneur de similarité contient l'ensemble des connaissances liées et nécessaires au calcul de la similarité entre deux cas : les fonctions de calcul de similarité et les paramètres de mesure de similarité $sim(p_1, p_2)$ entre les cas p_1 et p_2 .

La figure 2.5 montre les flux d'informations entre les étapes du RàPC et les conteneurs. Les flèches continues de la figure 2.5 décrivent l'ordre dans lequel les phases du cycle du RàPC sont exécutées. Les flèches avec des lignes discontinues matérialisent les flux d'information, c'est-à-dire les liens entre les étapes du cycle et les conteneurs de connaissance.

2.2.2/ LES SYSTÈMES MULTI-AGENTS

Les systèmes multi-agents sont des systèmes conçus pour résoudre des problèmes en combinant l'intelligence artificielle et le calcul distribué. Ces systèmes sont composés de multiples entités autonomes appelées agents, qui ont la capacité de communiquer entre elles et également de coordonner leurs comportements [Hajduk et al., 2019].

Les agents ont les propriétés suivantes :

- Autonomie : les agents fonctionnent sans intervention externe des êtres humains ou d'autres entités, ils ont un mécanisme interne qui leur permet de contrôler leurs états.
- Réactivité : les agents ont la capacité de percevoir l'environnement dans lequel ils sont et peuvent réagir aux changements qui se produisent.
- Pro-activité : les agents peuvent effectuer des changements, réagir à différents stimuli provenant de leur environnement et s'engager dans un processus cognitif interne.
- Coopération : les agents peuvent communiquer les uns avec les autres, échanger des informations afin de se coordonner et résoudre un même problème.
- Apprentissage : il est nécessaire qu'un agent soit capable de réagir dans un en-



FIGURE 2.5 – Cycle du RàPC, les étapes, les conteneurs et leurs flux de données

environnement dynamique et inconnu, il doit donc avoir la capacité d'apprendre de ses interactions et ainsi améliorer la qualité de ses réactions et comportements.

Il existe quatre types d'agent en fonction des capacités et des approches :

- Réactif : c'est l'agent qui perçoit constamment l'environnement et agit en fonction de ses objectifs.
- Basé sur les réflexes : c'est l'agent qui considère les options pour atteindre ses objectifs et développe un plan à suivre.
- Hybride : il combine les deux modèles antérieurs en utilisant chacun d'eux en fonction de la situation et de l'objectif.
- Basé sur le comportement : l'agent a à sa disposition un ensemble de modèles de comportement pour réaliser certaines tâches spécifiques. Chaque comportement se déclenche selon des règles prédéfinies ou des conditions d'activation. Le comportement de l'agent peut être modélisé avec différentes stratégies cognitives de pensée ou de raisonnement.

2.2.3/ DIFFÉRENTS ALGORITHMES ET FONCTIONS IMPLÉMENTÉS DANS AI-VT POUR LA PERSONNALISATION ET L'ADAPTATION DES SÉANCES D'ENTRAÎNEMENT PROPOSÉES

2.2.3.1/ PENSÉE BAYESIENNE

D'après les travaux de certains mathématiciens et neuroscientifiques, toute forme de cognition peut être modélisée dans le cadre de la formule de Bayes (équation 2.2), car elle permet de tester différentes hypothèses et donner plus de crédibilité à celle qui est confirmée par les observations. Étant donné que ce type de modèle cognitif permet l'apprentissage optimal, la prédiction sur les événements passés, l'échantillonnage représentatif

et l'inférence d'information manquante ; il est appliqué dans quelques algorithmes de machine learning et d'intelligence artificielle [Hoang, 2018].

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (2.2)$$

La formule de Bayes calcule la probabilité a posteriori $P(A|B)$ de la plausibilité de la théorie A compte tenu des données B , et requiert trois termes : (1) une probabilité a priori $P(A)$ de la plausibilité de l'hypothèse A , (2) le terme $P(B|A)$ qui mesure la capacité de l'hypothèse A à expliquer les données observées B et (3) la fonction de partition $P(B)$ qui met en compétition toutes les hypothèses qui ont pu générer les données observées B . À chaque nouvelle évaluation de la formule, la valeur du terme a priori $P(A)$ est actualisée par la valeur du terme a posteriori $P(A|B)$. Ainsi, à chaque évaluation, le degré de plausibilité de chaque hypothèse est ajusté [Hoang, 2018].

Par la suite, nous explicitons quelques algorithmes, intégrés généralement dans l'étape "Rechercher" du RàPC, pour la recherche des cas les plus proches d'un nouveau cas.

2.2.3.2/ MÉTHODE DES K PLUS PROCHES VOISINS (K-NEAREST NEIGHBORHOOD - KNN)

Comme est défini dans [Cunningham and Delany, 2021], la méthode des 'k' plus proches voisins est une méthode pour classer des données dans des classes spécifiques. Pour faire cela, il est nécessaire de disposer d'une base de données avec des exemples déjà identifiés. Pour classer de nouveaux exemples, la méthode attribue la même classe que celle de leurs voisins les plus proches. Généralement, l'algorithme compare les caractéristiques d'une entité avec plusieurs possibles voisins pour essayer d'obtenir des résultats plus précis. 'k' représente le nombre de voisins, sachant que l'algorithme peut être exécuté à chaque fois avec un nombre différent de voisins.

Étant donné un jeu de données D constitué de $(x_i)_{i \in [1,n]}$ données (où $n = |D|$). Chacune des données est décrite par F caractéristiques qui sont des valeurs numériques normalisées $[0, 1]$, et par une classe de labellisation $y_j \in Y$. Le but est de classer une donnée inconnue q . Pour chaque $x_i \in D$, il est possible de calculer la distance entre q et x_i selon l'équation 2.3.

$$d(q, x_i) = \sum_{f \in F} w_f \delta(q_f, x_{if}) \quad (2.3)$$

La distance entre q et x_i est la somme pondérée de toutes les distances élémentaires *delta* calculées pour chaque caractéristique. La fonction de distance δ peut être une métrique générique. Pour des valeurs numériques discrètes il est possible d'utiliser la définition 2.4,

$$\delta(q_f, x_{if}) = \begin{cases} 0 & q_f = x_{if} \\ 1 & q_f \neq x_{if} \end{cases} \quad (2.4)$$

et si les valeurs sont continues l'équation 2.5.

$$\delta(q_f, x_{if}) = |q_f - x_{if}| \quad (2.5)$$

Un poids plus important est généralement attribué aux voisins les plus proches. Le vote pondéré en fonction de la distance est une technique couramment utilisée (équation 2.6).

$$N(a, b) = \begin{cases} 1 & a = b \\ 0 & a \neq b \end{cases} \quad (2.6)$$

Le vote est couramment calculé selon l'équation 2.7.

$$vote(y_i) = \sum_{c=1}^k \frac{1}{d(q, x_c)^p} N(y_j, y_c) \quad (2.7)$$

une autre alternative est basée sur le travail de Shepard, équation 2.8.

$$vote(y_i) = \sum_{c=1}^k e^{d(q, x_c)} N(y_j, y_c) \quad (2.8)$$

La fonction de distance peut être n'importe quelle mesure d'affinité entre deux objets, mais cette fonction doit répondre à quatre critères (équations 2.9).

$$\begin{aligned} d(x, y) &\geq 0 \\ d(x, y) &= 0, \text{ seulement si } x = y \\ d(x, y) &= d(y, x) \\ d(x, z) &\geq d(x, y) + d(y, z) \end{aligned} \quad (2.9)$$

2.2.3.3/ K-MOYENNES

Selon [Sinaga and Yang, 2020], K-Moyennes est un algorithme d'apprentissage utilisé pour partitionner et grouper des données. Considérons $X = \{x_1, \dots, x_n\}$ un ensemble de vecteurs dans un espace Euclidien $\mathbb{R}^d$, et $A = \{a_1, \dots, a_c\}$ où c est le nombre de groupes. Considérons également $z = [z_{ik}]_{n \times c}$, où z_{ik} est une variable binaire (i.e. $z_{ik} \in \{0, 1\}$) qui indique si une donnée x_i appartient au k -ème groupe, $k = 1, \dots, c$. La fonction bijective k-moyenne est définie selon l'équation 2.10.

$$J(z, A) = \sum_{i=1}^n \sum_{k=1}^c z_{ik} \|x_i - a_k\|^2 \quad (2.10)$$

Cet algorithme minimise la fonction objectif des k moyennes $J(z, A)$: à chaque itération, les termes a_k et z_{ik} sont calculés selon les équations 2.11 et 2.12.

$$a_k = \frac{\sum_{i=1}^n z_{ik} x_{ij}}{\sum_{i=1}^n z_{ik}} \quad (2.11)$$

$$z_{ik} = \begin{cases} 1 & \text{if } \|x_i - a_k\|^2 = \min_{1 \leq k \leq c} \|x_i - a_k\|^2 \\ 0, & \text{otherwise} \end{cases} \quad (2.12)$$

2.2.3.4/ MODÈLE DE MÉLANGE GAUSSIEN GMM (*Gaussian Mixture Model*)

Le modèle de mélange gaussien (GMM) est un modèle probabiliste composé de plusieurs modèles gaussiens simples. Ce modèle est décrit dans [Wang et al., 2021]. En considérant une variable d'entrée multidimensionnelle $x = \{x_1, x_2, \dots, x_d\}$, GMM multivarié est défini selon dans l'équation 2.13.

$$p(x|\theta) = \sum_{k=1}^K \alpha_k g(x|\theta_k) \quad (2.13)$$

Dans cette équation, K est le nombre de modèles gaussiens uniques dans GMM, également appelés composants ; α_k est la probabilité de mélange de la k -ème composante respectant la condition $\sum_{k=1}^K \alpha_k = 1$.

θ_k représente la valeur moyenne et la matrice de covariance de chaque modèle gaussien unique : $\theta_k = \{\mu_k, \Sigma_k\}$. Pour un seul modèle gaussien multivarié, nous avons la fonction de densité de probabilité $g(x)$ (équation 2.14).

$$g(x; \mu, \Sigma) = \frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}} \exp\left(-\frac{1}{2}(x - \mu)^T \Sigma^{-1} (x - \mu)\right) \quad (2.14)$$

La tâche principale est d'obtenir les paramètres α_k, θ_k pour tout k défini dans GMM en utilisant un ensemble de données avec N échantillons d'entraînement. Une solution classique pour l'estimation des paramètres requis utilise l'algorithme de maximisation des attentes (Expectation-Maximization EM), qui vise à maximiser la vraisemblance de l'ensemble de données. Il s'agit d'un algorithme itératif durant lequel les paramètres sont continuellement mis à jour jusqu'à ce que la valeur delta log-vraisemblance entre deux itérations soit inférieure à un seuil donné.

2.2.3.5/ FUZZY-C

Fuzzy C-Means Clustering (FCM) est un algorithme de clustering flou non supervisé largement utilisé [Xu et al., 2021]. Le FCM utilise comme mesure de distance la mesure euclidienne. Supposons d'abord que l'ensemble d'échantillons à regrouper est $X = \{x_1, x_2, \dots, x_n\}$, où $x_j \in R^d (1 \leq j \leq n)$ dans un espace Euclidien à d dimensions, et c le nombre de clusters. L'équation 2.15 montre la fonction objectif de FCM.

$$J(U, V) = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m (x_j - v_i)^T A (x_j - v_i) \quad (2.15)$$

où A est la matrice métrique, m est un nombre quelconque ($m > 1$) qui dénote le degré de flou, u_{ij} est le degré d'appartenance du j -ème échantillon x_j qui appartient au i -ème cluster, dont le centre est v_i . $U = (u_{ij})$, $V = [v_1, v_2, \dots, v_c]$, $1 \leq i \leq c, 1 \leq j \leq n, 2 \leq c < n$ satisfaisant les conditions de l'équation 2.16.

$$\sum_{i=1}^c u_{ij} = 1, u_{ij} \geq 0 \quad (2.16)$$

Pour compléter le modèle, les équations de mise à jour pour le centre du cluster v_i (équation 2.17) et des degrés d'appartenance u_{ij} (équation 2.18) sont définies.

$$v_i = \frac{\sum_{j=1}^n u_{ij}^m x_j}{\sum_{j=1}^n u_{ij}^m} \quad (2.17)$$

$$u_{ij} = \frac{((x_j - v_i)^T A (x_j - v_i))^{\frac{2}{m-1}}}{\left(\sum_{h=1}^c (x_j - v_h)^T A (x_j - v_h) \right)^{\frac{2}{m-1}}} \quad (2.18)$$

Les algorithmes qui se trouvent dans la suite de cette section sont des algorithmes qui font partie de l'intelligence artificielle et sont utilisés dans certains EIAH pour améliorer les recommandations, essayer de corriger et de détecter les faiblesses des apprenants de façon automatique.

2.2.3.6/ BANDIT MANCHOT MAB (*Multi-Armed Bandits*)

Dans [Gupta et al., 2021] MAB est décrit comme un problème qui appartient au domaine de l'apprentissage par renforcement. Celui-ci représente un processus de prise de décision séquentielle dans des instants t de temps, où un utilisateur doit sélectionner une action $k_t \in K$ à réaliser dans un ensemble K fini d'actions possibles et donnant une récompense inconnue de l'utilisateur. L'objectif est de maximiser la récompense cumulée globale dans le temps. La clé pour trouver une solution au problème est de trouver l'équilibre optimal entre l'exploration (exécuter des actions inconnues pour collecter de l'information complémentaire) et l'exploitation (continuer à exécuter les actions déjà connues pour cumuler plus de gains). L'un des algorithmes utilisés pour résoudre ce problème c'est l'échantillonnage de Thompson.

2.2.3.7/ ÉCHANTILLONNAGE DE THOMPSON TS (*Thompson Sampling*)

Comme indiqué dans [Lin, 2022], l'algorithme d'échantillonnage de Thompson est un algorithme de type probabiliste utilisé généralement pour résoudre le problème MAB. Il s'appuie sur un modèle Bayésien dans lequel une distribution de probabilités *Beta* est initialisée. Cette distribution de probabilités est ensuite affinée de manière à optimiser la valeur résultat à estimer. Les valeurs initiales des probabilités de Beta sont définies sur l'intervalle $[0, 1]$. Elle est définie à l'aide de deux paramètres α et β .

L'échantillonnage de Thompson peut être appliqué à la résolution du problème du Bandit Manchot(MAB). Dans ce cas, les actions définies dans le MAB ont chacune une incidence sur la distribution de probabilités Beta de l'échantillonnage de Thompson. Pour chaque action de MAB, les paramètres de Beta sont initialisés à 1. Ces valeurs changent et sont calculées à partir de récompenses obtenues : si au moment d'exécuter une action spécifique le résultat est un succès, alors la valeur du paramètre α de sa distribution Beta augmente mais si le résultat est un échec alors c'est la valeur du paramètre β de sa distribution Beta qui augmente. De cette façon, la distribution pour chacune des actions possibles est ajustée en privilégiant les actions qui génèrent le plus de récompenses.

L'échantillonnage de Thompson est un cas particulier de la loi de Dirichlet comme le montre la figure 2.6. L'équation 6.1 décrit formellement la famille des courbes générées

par la distribution Beta.



FIGURE 2.6 – Comportement de la distribution Beta avec différentes valeurs de paramètres α et β

$$B(x, \alpha, \beta) = \begin{cases} \frac{x^{\alpha-1}(1-x)^{\beta-1}}{\int_0^1 u^{\alpha-1}(1-u)^{\beta-1} du} & \text{pour } x \in [0, 1] \\ 0 & \text{sinon} \end{cases} \quad (2.19)$$

La section suivante présente un état de l'art plus détaillé des EIAH et des systèmes de RàPC dédiés aux EIAH.



ÉTAT DE L'ART

ENVIRONNEMENTS INFORMATIQUES D'APPRENTISSAGE HUMAIN

Ce chapitre présente les travaux sur les EIAH en lien avec le travail de cette thèse. Les EIAH référencés dans cet état de l'art sont classés selon le thème principal abordé.

3.1/ L'INTELLIGENCE ARTIFICIELLE

L'intelligence artificielle a été appliquée avec succès au domaine de l'éducation dans plusieurs écoles de différents pays et pour l'apprentissage de l'informatique, les langues étrangères et les sciences. [Zhang. and Aslan, 2021] référence un grand nombre de travaux sur la période de 1993-2020. Cet article montre que les besoins et contraintes des EIAH ne sont pas différentes selon l'âge, le niveau culturel, ou le niveau éducatif des apprenants. Cet article montre également qu'il est possible d'adapter la stratégie d'apprentissage pour n'importe qui et maximiser le rendement et acquisition des connaissances grâce à différentes techniques d'intelligence artificielle.

[Chiu et al., 2023] présente une révision des travaux d'intelligence artificielle appliquée à l'éducation extraits des bases de données bibliographiques ERIC, WOS et Scopus sur la période 2012-2021. Ce travail est focalisé sur les tendances et les outils employés pour aider le processus d'apprentissage. Une classification des contributions de l'IA est faite, fondée sur 92 travaux scientifiques. Les contributions et l'utilité des outils d'IA implémentés dans les EIAH évalués dans cet article sont évaluées dans les quatre domaines suivants : l'apprentissage, l'enseignement, l'évaluation et l'administration. Pour l'apprentissage, l'IA est généralement utilisée pour attribuer des tâches en fonction des compétences individuelles, fournir des conversations homme-machine, analyser le travail des étudiants pour obtenir des commentaires et accroître l'adaptabilité et l'interactivité dans les environnements numériques. Pour l'enseignement, des stratégies d'enseignement adaptatives peuvent être appliquées pour améliorer la capacité des enseignants à enseigner et soutenir le développement professionnel des enseignants. Dans le domaine de l'évaluation, l'IA peut fournir une notation automatique et prédire les performances des élèves. Enfin, dans le domaine de l'administration, l'IA contribue à améliorer la performance des plateformes de gestion, à soutenir la prise de décision pédagogique et à fournir des services personnalisés. Cet article met également en lumière les lacunes suivantes de l'IA :

- Les ressources recommandées par les plateformes d'apprentissage personnal-

- sées sont trop homogènes,
- les données nécessaires pour les modèles d'IA sont très spécifiques,
- le lien entre les technologies et l'enseignement n'est pas bien clair. En effet, la plupart des travaux sont conçus pour un domaine ou un objectif très spécifique difficilement généralisable,
- l'inégalité éducative car les technologies ne motivent pas tous les types d'élèves et parfois il y a des attitudes négatives envers l'IA parfois difficile à maîtriser et à intégrer dans les cours.

Les techniques d'IA peuvent aussi aider à prendre des décisions stratégiques visant des objectifs à longue échéance comme le montre le travail de [Robertson and Watson, 2014]. Les jeux de stratégie présentent en effet plusieurs particularités singulières. Ils contiennent plusieurs règles et des environnements contraints. Ils nécessitent de mettre en œuvre des actions et réactions en temps réel. Ils intègrent des aléas et des informations cachées. Les techniques principales identifiées et implémentées dans ces jeux de stratégie sont l'apprentissage par renforcement, les modèles bayésiens, la recherche dans une arborescence, le raisonnement à partir de cas, les réseaux de neurones et les algorithmes évolutifs. Il est également important de noter que la combinaison de ces techniques permet dans certains cas d'améliorer le comportement global des algorithmes et d'obtenir de meilleures réponses.

3.2/ SYSTÈMES DE RECOMMANDATION DANS LES EIAH

Des systèmes de recommandation sont régulièrement intégrés aux EIAH. Ils permettent en effet de tenir compte des exigences, des besoins, du profile, des talents, des intérêts et de l'évolution de l'apprenant pour s'adapter et recommander des ressources ou des exercices dans le but d'améliorer l'acquisition et la maîtrise de concepts et des connaissances en général. L'adaptation de ces systèmes peut être de deux types [Muangprathub et al., 2020] :

- l'adaptation de la présentation qui montre aux apprenants les ressources en concordance avec leurs faiblesses et
- l'adaptation de la navigation qui change la structure du cours en fonction du niveau et style d'apprentissage de chaque apprenant.

Ces systèmes montrent des effets positifs pour les apprenants comme le révèle le travail de [Huang et al., 2023] qui utilise l'IA pour personnaliser des recommandations de ressources en vidéo et ainsi aider et motiver les apprenants. L'évolution des résultats entre les tests préliminaires et ceux réalisés après la finalisation du cours des groupes ayant suivi les cours avec et sans système de recommandation démontrent cet effet positif. La figure 3.1 montre l'architecture du système où l'intelligence artificielle est utilisée dans différents étapes du processus avec les données de l'apprenant sous la supervision et contrôle du professeur.

Le travail de [Seznec et al., 2020] propose un modèle générique de recommandation qui peut être utilisé dans les systèmes de recommandation de produits ou les systèmes d'apprentissage. Ce modèle est fondé sur l'algorithme par renforcement UCB (*Upper Confidence Bound*) qui permet de trouver une solution approchée à une variante du problème *Bandit manchot* non stationnaire (MAB, présenté dans la section ?? de ce manuscrit), où les récompenses de chaque action diminuent progressivement après chaque utilisation. Pour valider le modèle, une comparaison avec trois autres algorithmes a été menée en




FIGURE 3.1 – Traduction de l'architecture du système de recommandation proposé dans [Huang et al., 2023]

considérant une base de données réelle. La performance du système a été démontrée en se fondant sur la moyenne accumulée du regret et la moyenne de la récompense accumulée.

Aussi [Ingkavara et al., 2022] met en évidence que les technologies et les systèmes de recommandation peuvent s'adapter à différents besoins et aspirations et qu'ils peuvent également favoriser l'apprentissage auto-régulé. Ce type d'apprentissage aide les apprenants à acquérir les habilités pour diminuer les délais de réponse et devenir plus performants. Ce type d'apprentissage permet de définir des objectifs variables dans un environnement structuré, également d'adapter le temps nécessaire à l'acquisition et la maîtrise de connaissances et de compétences. De plus, avec les systèmes de recommandation est possible d'avoir accès à des ressources et ainsi constituer un excellent outil pour le renforcement des connaissances acquises.

L'IA est utilisée pour l'apprentissage adaptatif afin de suggérer des ressources d'étude dans le travail de [Lalitha and Sreeja, 2020]. Le système proposé par ces auteurs intègre un module de personnalisation qui collecte l'information de l'apprenant et ses exigences, un module de classification qui compare l'information avec d'autres profils en utilisant l'algorithme KNN et un module de recommandation chargé d'identifier les ressources communes entre les profils afin d'en extraire des informations complémentaires provenant d'Internet. Ce système inclut également un algorithme *Random Forest* pour améliorer le processus d'apprentissage du nouvel apprenant. Les techniques et les stratégies sont très variées mais l'objectif est de s'adapter aux apprenants et à leurs besoins. Dans [Zhao et al., 2023] les données des apprenants sont collectées et classées dans des groupes présentant des caractéristiques similaires. Ensuite, la méthode d'analyse par enveloppement des données (DEA) permet d'identifier les besoins spécifiques de chaque groupe et ainsi proposer un parcours d'apprentissage personnalisé.

La représentation des données des enseignants, des apprenants et l'environnement sont des aspects particulièrement importants à considérer dans l'implémentation de ces systèmes de recommandation. Ces aspects influencent en effet les performances globales des EIAH dans lesquels ils sont intégrés. La proposition de [Su et al., 2022] consiste à stocker les données des apprenants dans deux graphes évolutifs qui contiennent les relations entre les questions et les réponses correctes ainsi que les réponses données par les apprenants. Ces informations et relations permettent de construire un graphe global propre à chaque apprenant et donnant une information sur son état cognitif et ainsi de personnaliser son parcours. Dans [Muangprathub et al., 2020] définit dans son EIAH trois ensembles de concepts :

- les objets (G),
- les attributs (M) et
- les relations entre G et M.

L'originalité de ce travail consiste à analyser ces concepts en via l'approche FCA (*Formal Context Analysis*). Ce type de représentation permet de mettre en relation les ressources d'étude, les questions et les sujets. En conséquence, si un apprenant étudie un sujet S_1 et si une règle relie S_1 au sujet S_4 ou la question $Q_{3,4}$, alors le système peut suggérer l'étude des ressources d'étude associés au sujet S_4 ou aux questions reliées par les règles. Par ailleurs, cet algorithme se fonde sur une structure du cours prédéfinie pour recommander un parcours exhaustif d'apprentissage.

[Zhou and Wang, 2021] propose un système de recommandation pour personnaliser des exercices pour l'apprentissage de l'anglais. Le système décrit contient un module principal qui représente les apprenants comme des vecteurs selon le modèle DINA où sont stockés les points de connaissance acquise. Le vecteur de connaissances K est de dimension n ($K = \{k_1, k_2, \dots, k_n\}$) où chaque dimension correspond à un point de connaissance. Ainsi, $k_i = 1$ signifie que l'apprenant maîtrise le point de connaissance k_i . A contrario, $k_i = 0$ signifie que l'apprenant doit étudier le point de connaissance k_i car non acquise. La recommandation des questions proposées par le système se sert par ailleurs d'une librairie de ressources associées à chacune des questions possibles et permettant à l'apprenant de renforcer son apprentissage et d'avancer dans le programme du cours.

Certains travaux de recommandation et de personnalisation considèrent des variables complémentaires aux notes. C'est le cas de l'EIAH proposé par [Ezaldeen et al., 2022], qui lie l'analyse du comportement de l'apprenant à une analyse sémantique de son propre profil. La première étape consiste à collecter les données nécessaires pour créer un profil de l'apprenant. Fort de ce profil complet, des associations sont faites entre l'apprenant et un groupe de catégories d'apprentissages prédéfinies. Les apprentissages sont regroupés selon ses préférences et les données historiques. Puis les concepts associés pour les catégories sont recherchés et permettent ainsi de générer un guide pour obtenir des ressources internet qu'il est possible de recommander. Le système est divisé en quatre niveaux représentés sur la figure 3.2 où chacun des niveaux est chargé d'une tâche spécifique. Les résultats d'un niveau sont envoyés au niveau suivant jusqu'à arriver aux recommandations personnalisées pour l'apprenant.

Le tableau 3.1 présente un récapitulatif des articles analysés dans l'état de l'art des EIAH. Les articles apparaissent dans le même ordre qui ont été cités dans le chapitre. Les limites décrites correspondent au temps de calcul, quantité de données d'entraînement, complexité de définitions ou des règles ainsi comme la quantité de variables subjectives.




FIGURE 3.2 – Traduction des niveaux du système de recommandation dans [Ezaldeen et al., 2022]

Une limitation générale qui présente les algorithmes d'IA dans les EIAH est que ce type d'algorithmes ne permettent pas d'oublier l'information avec laquelle ils ont été entraînés, une propriété nécessaire pour les EIAH dans certaines situations où peut se produire un dysfonctionnement du système, la réévaluation d'un apprenant ou la restructuration d'un cours. Par ailleurs, les représentations et algorithmes peuvent changer et évoluer. Aujourd'hui il y a encore beaucoup de potentiel pour développer encore les capacités de calcul et d'adaptation.

Référence	Limites
[Zhang. and Aslan, 2021]	Niveau global d'application de EIAH. Analyse des effets de l'IA
[Chiu et al., 2023]	Aspects non cognitifs en IA. Motivation des apprenants
[Robertson and Watson, 2014]	Peu de test. Pas de standard d'évaluation
[Huang et al., 2023]	Recommandation en fonction de la motivation seulement. N'est pas général pour tous les apprenants
[Seznec et al., 2020]	Le modèle n'a pas été testé avec données d'étudiants. UCB prends beaucoup de temps pour explorer les alternatives
[Ingkavara et al., 2022]	Modèle très complexe. Définition de constantes subjectif et beaucoup de variables.
[Lalitha and Sreeja, 2020]	A besoin de beaucoup de données pour entraînement. Ne marche pas dans le cas 'cold-start', n'est pas totalement automatisé
[Su et al., 2022]	Estimation de la connaissance de façon subjective. Il est nécessaire une étape d'entraînement
[Muangprathub et al., 2020]	Structure des règles complexe. Définition de la connaissance de base complexe
[Zhou and Wang, 2021]	Utilisation d'un filtre collaboratif sans stratification. Utilisation d'une seule métrique de distance
[Ezaldeen et al., 2022]	Il n y a pas de comparaison avec d'autres modèles différents de CNN. Beaucoup de variables à valeurs subjectives

TABLE 3.1 – Tableau de synthèse des articles analysés dans l'état de l'art des EIAH

ÉTAT DE L'ART (RAISONNEMENT À PARTIR DE CAS)

4.1/ RAISONNEMENT À PARTIR DE CAS (RÀPC)

Le raisonnement à partir de cas est une approche fondée sur la connaissance. Il s'agit d'une technique d'intelligence artificielle dont l'idée est de résoudre un nouveau problème grâce aux connaissances déjà acquises par le système et en tenant un raisonnement fondé sur l'analogie. Le RàPC est apparu comme une alternative pour améliorer les systèmes experts. Shank et Abelson [Schank and Abelson, 1977] ont initialement mené des travaux sur l'organisation hiérarchique de la mémoire pour imiter le raisonnement humain. Ceux-ci ont servi de fondement aux travaux de Janet Kolodner [Kolodner, 1983] et ont abouti à l'implémentation un système fondé sur ces principes en 1983. Le terme *raisonnement à partir de cas* est utilisé pour la première fois en 1989 par Riesbeck et Shank [C.K. and R.C., 1989].

Comme vu dans le chapitre du contexte, le raisonnement à partir de cas utilise quatre conteneurs de connaissance pour représenter la connaissance complète du système, chaque conteneur stocke l'information associée à une fonction spécifique et tout est fondé sur le carré d'analogie, c'est-à-dire des solutions ayant permis de résoudre un problème ancien sont réutilisées afin de résoudre un problème nouveau similaire. La plupart des systèmes de RàPC utilisent pour son fonctionnement comme base un cycle composé de quatre étapes (retrouver, réutiliser, réviser et retenir).

Les travaux ici cités sont des travaux représentatifs parce que ils ont permis de trouver certaines points d'amélioration du RàPC, ont donné des pistes d'intégration avec d'autres techniques ou ont donné des idées de modification pour obtenir bons résultats en gagnant de la performance.

Plusieurs travaux combinent le RàPC avec les réseaux de neurones (Deep Learning) avec l'objectif d'améliorer les réponses générées et optimiser les performances de chaque algorithme. C'est une idée qui marche dans certains cas, mais qui n'est pas très récente comme par exemple dans [Jung et al., 2009] les auteurs développent un système fondé sur l'hybridation du RàPC avec des réseaux de neurones pour concevoir des produits. Le système se focalise uniquement dans les phases "rechercher" et "réutiliser" du RàPC dans lesquelles sont exécutés les algorithmes implémentés. Le système détermine de façon automatique les valeurs pour les paramètres nécessaires à la conception d'un produit particulier en suivant le cycle traditionnel du RàPC. Avec l'algorithme de

k-moyennes, est extrait un cas représentatif de la base de cas et l'adaptation des solutions des voisins trouvées est faite avec le réseau de neurones RBFN (Radial Basis Function Network). L'évaluation du système est faite en utilisant une base de données contenant 830 tests, les résultats démontrent que les produits conçus s'ajustent avec un grand pourcentage aux normes définies.

Dans [Butdee and Tichkiewitch, 2011] un réseau de neurones classique est implémenté pour définir la géométrie d'une matrice pour l'extrusion de l'aluminium. En effet, actuellement c'est un processus qui se fait manuellement et par essai et erreur. Le RàPC est alors utilisé pour aider à déterminer les valeurs optimales des paramètres du réseau, en utilisant l'information des matrices d'extrusion déjà testées.

Aussi le travail de [Petrovic et al., 2016] où les auteurs proposent un système de raisonnement à partir de cas pour calculer la dose optimale de radiation pour le traitement du cancer. Dans ce domaine particulier de la radiothérapie, administrer une dose nécessite de connaître avec précision le nombre de faisceaux et l'angle de chacun d'eux. L'algorithme proposé tente de trouver la combinaison de valeurs optimales pour ces deux paramètres en utilisant les réseaux de neurones. L'utilisation des réseaux de neurones intervient lors de l'adaptation des cas connus : ils modifient le nombre et les angles des faisceaux. La validation de l'algorithme est évaluée avec une base de 80 cas réels de cancer du cerveau extraits de l'hôpital de Nottingham City. Le nombre de neurones et de couches ont été définis de façon empirique. Les résultats montrent que l'utilisation des cas historiques et la construction des solutions à partir des solutions déjà connues permet une amélioration de 12% concernant la décision du nombre de faisceaux et de 29% concernant la décision liée à leur angle.

Plus récemment se trouvent travaux comme [Wolf et al., 2024] où le RàPC est employée comme technique pour expliquer les résultats générés par un réseau qui classe les images en fonction de certains attributs et zones dans les images, les résultats permettent conclure que les explications trouvées avec RàPC sont très fidèles aux images testées. Aussi [Parejas-Llanovarcet et al., 2024] utilisent le RàPC et ses avantages pour le coupler à un réseau profond (Deep Learning) pour sélectionner la meilleure explication au résultat donné par le classificateur d'images dans ce cas, la base de connaissance sont certaines images avec des étiquettes qui contiennent l'information associée à l'image, la comparaison réalisée avec les algorithmes représentatifs de l'état de l'art suggèrent que la combinaison Deep Learning marche bien dans ce type de problèmes.

Certains travaux ont appliqué le raisonnement à partir de cas à un problème spécifique en modifiant les représentations des cas et des solutions, d'autres ont modifié le cycle conceptuel comme le montre la figure 4.1 avec l'objectif d'obtenir des réponses dynamiques et plus aptes à problèmes complexes. Dans [Grace et al., 2016] est proposé un cycle complémentaire incluant un outil d'apprentissage profond (*Deep Learning*) pour améliorer le résultat du processus du RàPC. Dans [Butdee and Tichkiewitch, 2011], la phase de stockage est modifiée en retenant les cas dont les résultats n'ont pas eu de succès, pour guider le processus dans la fabrications de nouvelles pièces. Enfin, dans [Robertson and Watson, 2014], les auteurs proposent d'ajouter à chaque cas une valeur d'utilité espérée selon chaque action possible. Cet ajout s'accompagne d'une prédiction probabiliste des actions que l'application engendrera en réponse. Cette prédiction probabiliste dépend bien entendu de l'état initial du système avant mise en oeuvre de l'action.

Plusieurs travaux appliquent le RàPC avec succès en proposant des modifications dans chacune des phases ou en combinant différents algorithmes. Certains systèmes de




FIGURE 4.1 – Ajout d'un cycle complémentaire avec *Deep Learning* au RàPC (Traduit de [Grace et al., 2016])

RàPC appliqués au domaine de la conception de produits sont remarquables à ce titre. Dans [Roldan Reyes et al., 2015] les auteurs proposent, comme le montre la figure 4.2, un algorithme pour produire le propylène glycol dans un réacteur chimique. Dans ce cas, la phase de réutilisation du RàPC est couplée à la recherche des états qui satisfassent le nouveau problème (*Constraint satisfaction problems CSP*) en utilisant l'information des cas de base déjà résolus. Les solutions trouvées sont évaluées selon le nombre de changements réalisés sur les solutions déjà connues (parcimonie), le nombre de solutions possibles trouvées (précision), l'évaluation de commentaires faits par des experts et la complexité des transformations réalisées.

Dans [Grace et al., 2016], les auteurs ajoutent un nouveau cycle au cycle traditionnel du RàPC. Le premier cycle génère des descriptions abstraites du problème avec un réseau de neurones et des algorithmes génétiques ; le second cycle prend les descriptions abstraites comme des nouveaux cas, cherche les cas similaires et adapte les solutions rencontrées. L'exécution des deux cycles prend en compte certains critères prédéfinis par l'utilisateur. En comparant le même problème avec le cycle traditionnel du RàPC, les auteurs mesurent une amélioration de la qualité des recettes proposées et montrent que celles-ci sont plus en accord avec les critères définis.

[Maher and Grace, 2017] s'intéressent quant à eux à la génération de recettes de cuisine originales. Les auteurs modifient le cycle traditionnel du RàPC et créent deux cycles, combinant l'apprentissage profond et la récupération de cas basée sur la similarité, le premier cycle génère des descriptions abstraites de la conception avec des algorithmes génétiques et un réseau neuronal profond, le second cycle utilise les descriptions abstraites pour récupérer et adapter des objets, cette structure donne lieu à un prototype appelé Q-chef qui génère une recette basée sur la base de données d'ingrédients et les demandes de l'utilisateur. Ce travail ne montre pas de métriques standard génériques mais utilise deux nombres indicatifs (plausibilité et surprise) pour démontrer la génération efficace de nouvelles recettes selon les critères de l'utilisateur en comparant le RàPC à deux cycles avec le RàPC à un cycle, démontrant plus de plausibilité et de surprise dans




FIGURE 4.2 – Cycle du RàPC modifié. (Traduit de [Roldan Reyes et al., 2015])

les recettes générées.

Par rapport à l'intégration du RàPC avec d'autres algorithmes nous pouvons citer [Uysal and Sonmez, 2023] qui mettent en œuvre un RàPC avec une méthode d'agrégation bootstrap (bagging) pour améliorer la précision du RàPC lorsque il n'y a pas suffisamment de cas et réduire la variance. Le problème qu'ils essaient de résoudre est l'estimation des coûts conceptuels dans les décisions de faisabilité d'un projet, lorsque l'on ne dispose pas de suffisamment d'informations sur la conception détaillée et les exigences du projet. Les résultats ont révélé que la performance de prédiction de la méthode RàPC agrégée bootstrap est meilleure que la performance de prédiction de la méthode RàPC traditionnelle.

Un modèle d'ensemble fondé sur le raisonnement à partir de cas est proposé par [Yu and Li, 2023] appliqué à la prédiction financière et au remplissage des données manquantes. Dans ce cas, pour retrouver les plus proches voisins, le modèle utilise trois mesures de distance différentes et une étape de vote pour l'intégration. Le modèle a été testé avec une base de données comportant onze dimensions d'informations financières provenant de 249 entreprises. La comparaison est faite avec deux objectifs. Premièrement, le remplissage des données manquantes avec d'autres algorithmes tels que KNN ou RandomForest, et deuxièmement, la comparaison de la prédiction avec des algorithmes uniques utilisant une métrique de distance spécifique. En effet, les résultats montrent une meilleure performance dans le remplissage des données manquantes et les meilleurs résultats dans la prédiction.

La représentation des cas peut permettre également d'améliorer les résultats d'un système de RàPC. La performance d'un système de RàPC dépend de la quantité d'in-

formations stockées, mais également des algorithmes implémentés. C'est le cas dans [Müller and Bergmann, 2015] où les recettes de cuisine sont codées comme un processus de transformation et mélangent des ingrédients en suivant une suite d'étapes ordonnées. Pour créer des recettes innovantes, une mesure de distance est utilisée entre les ingrédients. Cette mesure permet de trouver une recette en substituant certains ingrédients par d'autres, similaires ou aux qualités et/ou caractéristiques similaires. De la même manière, il est possible de créer des recettes plus proches des exigences des utilisateurs. Les étapes de transformation appelées aussi opérateurs sont stockées et catégorisées grâce à une métrique permettant de les échanger afin d'obtenir une nouvelle recette.

La génération, analyse et correction de texte constitue également un domaine d'application intéressant du RàPC. Pour la réalisation de ces tâches il est parfois nécessaire de transformer le texte en représentation numérique ou de mesurer la proximité sémantique de mots. Le travail de [Ontañón et al., 2015] utilise le RàPC pour générer des histoires en utilisant le texte d'autres histoires. Le système décrit explore les transformations possibles afin que la nouvelle histoire ne soit pas très similaire aux histoires déjà connues mais que elle soit cohérente. Le travail est plus focalisé sur la phase de révision, car les résultats de celle-ci déterminent si l'histoire générée correspond aux critères spécifiés ou si le cycle d'adaptation doit recommencer ; l'adaptation se fait en recherchant les personnages, les contextes, les objets dans la base de cas, et en les unifiant avec des actions ; la plupart des histoires générées sont cohérentes mais elles sont constituées de paragraphes très courts.

Dans [Lepage et al., 2020] les phrases écrites en langue française sont corrigées. Ce travail n'utilise ni la transformation numérique des phrases, ni de connaissances linguistiques, mais retrouve les phrases similaires en utilisant l'algorithme LCS (*Longest Common Subsequence*) et en calculant une mesure de distance avec les phrases correctes et incorrectes de la base de connaissances. Si les phrases similaires sont incorrectes, le système peut proposer une correction en changeant certains mots selon le contexte et recalculer les distances afin de mesurer la cohérence et pertinence de la phrase proposée.

Une étape très importante dans le RàPC est l'adaptation. Dans [Malburg et al., 2024] l'objectif est changer la représentation de la connaissance pour évaluer s'il y a un impact positif en les solutions générées, ce changement permet aussi d'établir règles de adaptation, les résultats permettent de dire que choisir une représentation adéquate et des règles correctes en fonction du problème étudié peut améliorer la qualité des solutions pour résoudre des problèmes complexes.

Étant donné la versatilité du RàPC dans la littérature se trouvent des travaux qui l'utilisent comme un outil de prédiction, car en connaissant l'information historique généralement est possible d'inférer la structure ou le comportement des données et avec le RàPC les résultats sont assez bons.

L'objectif du travail de [Smyth and Cunningham, 2018] est la prédiction du temps de course pour un athlète. L'algorithme KNN est utilisé pour rechercher les cas similaires. Le système interpole un temps final grâce au calcul d'une moyenne pondérée des meilleurs temps des cas similaires retrouvés dans la première étape du RàPC.

Dans [Smyth and Willemsen, 2020], les auteurs essaient de prédire le meilleur temps d'un patineur par analogie avec ceux des patineurs ayant des caractéristiques et une histoire de course similaires. Cependant parfois, calculer une moyenne des temps similaires trouvés ne suffit pas. Certaines caractéristiques liées au contexte, à l'environnement et à

la nature de la course (le type de course, le type de piste, la distance à parcourir, etc.), peuvent en effet influencer de manière importante la performance du patineur. L'algorithme a été testé avec une base de données contenant les informations de 21 courses de 500m, 700m, 1000m, 1500m, 3km, 5km and 10km réalisées entre Septembre 2015 et Janvier 2020.

Un système multi-fonctionnel est décrit dans [Feely et al., 2020]. Celui-ci permet d'obtenir une prédiction du temps de course, de suggérer un plan du rythme de la course et il recommande également un plan d'entraînement pour une course donnée. Les trois fonctionnalités sont implémentées en utilisant le RàPC. Les calculs de la similarité sont fondés sur un historique et des caractéristiques physiques des coureurs. Les plans d'entraînement sont génériques et sont proposés sur les 16 semaines précédant le début du marathon ciblé (selon les auteurs, c'est en effet le temps usuel pour une préparation à ce type d'épreuve). Le système a été évalué avec une base de données constituée de caractéristiques de 21000 coureurs des marathons de Dublin, Londres ou New-York pour la période de 2014 à 2017.

Dans [Yu et al., 2024] est proposé un algorithme en deux stages pour prédire avec précision et robustesse la détresse financière, les deux stages utilisent le RàPC. Le premier stage permet de compléter les valeurs manquantes de la base de données choisie afin de obtenir une meilleure performance fiable et stable, après est exécutée une version du RàPC combinée avec un LVQ (Learning Vector Quantization) algorithme pour faire la prédiction de classification. Les résultats démontrent compétitive solutions pour compléter les valeurs manquantes et classification.

[Sadeghi Moghadam et al., 2024] présentent un nouvel algorithme pour la prévision de la demande de matériel de secours utilisant le RàPC avec la méthode du meilleur-pire (Best-Worst Method - BWM) et les modèles de Markov cachés (Hidden Markov Model - HMM). Le HMM est entraîné avec des données historiques de demande de matériel, une fois l'algorithme détecte une situation de catastrophe, le RàPC cherche les cas similaires pour proposer le matériel nécessaire. D'après les résultats, l'indice d'erreur de prévision est inférieur à 10%, par conséquent, le CBR-BWM-HMM proposé est un algorithme solide et robuste.

Les systèmes de recommandation et le RàPC peuvent aussi être combinés comme dans le système proposé par [Supic, 2018] montre les bénéfices de l'utilisation du RàPC dans les environnements informatiques pour l'apprentissage humain (EIAH). Le modèle proposé suit le cycle traditionnel du RàPC en combinant les modèles d'apprentissages traditionnels et numériques. Les principales contributions sont la représentation des cas et la recommandation des parcours d'apprentissage personnalisés selon les informations issues des autres apprenants. Une base de cas initiaux a été créée pour mesurer l'efficacité du modèle. Celle-ci stocke la recommandation du parcours de 120 apprenants. Des examens sont réalisés avant et après avoir suivi le parcours recommandé par le système permettent de mesurer l'efficacité de la recommandation proposée.

[Obeid et al., 2022]. Le système décrit dans cette étude présente la particularité d'être capable d'analyser des données hétérogènes et multidimensionnelles. Dans ce travail, un parcours de carrière et les universités/collèges est recommandé aux élèves du secondaire en fonction de leurs intérêts. Ce travail montre également une taxonomie des techniques algorithmiques généralement utilisées dans les systèmes de recommandation pour les EIAH (figure 4.3).

En fonction de certains paramètres comme type d'école, nombre d'étudiants, nombre

d'étudiants admis, nombre d'étudiants non-admis, total nombre de classes, etc. [Skittou et al., 2024] développent un modèle hybride entre RàPC et le raisonnement à partir de règles pour recommander des actions de planification de l'éducation en réponse à des cas éducatifs des écoles primaires. Le modèle a été testé des bases de données réelles et a donné de bons résultats avec une grande précision.




FIGURE 4.3 – Taxonomie des techniques algorithmiques employées pour des modules de recommandation dans les EIAH (Traduit de [Obeid et al., 2022])

Le tableau 4.1 montre un récapitulatif des articles analysés dans cet état de l'art du RàPC, où on montre chacun d'eux en ordre d'apparition dans le chapitre et les limitations trouvées par rapport aux données, flexibilité, généralité de l'algorithme proposé, validité des solutions proposées, automatisation du processus et complexité du modèle proposée. À part les limites identifiées dans le tableau, nous avons trouvé deux problèmes très communs des systèmes de recommandation de façon générale : (1) le *cold-start* qui se produit au début d'une recommandation lorsque il n'y a pas suffisamment de données pour calculer ou inférer une recommandation appropriée [Hu et al., 2025]. Et (2) le *gray-sheep* qui se produit lorsqu'un utilisateur présente un comportement très différent de ceux qui sont stockés dans la base de données. Le système ne peut donc pas générer des recommandations en se basant sur l'information disponible [Alabdulrahman and Viktor, 2021].

Ref	Limites
[Jung et al., 2009]	Le modèle d'adaptation proposé fonctionne seulement avec des cas très proches. L'apprentissage dans le RàCP se limite à stocker les nouveaux cas.
[Butdee and Tichkiewitch, 2011]	Le RàPC n'est pas modifié ou amélioré. La révision dans le RàPC n'est pas automatique
[Petrovic et al., 2016]	Grande quantité de données pour que l'algorithme fonctionne correctement. Recommandation limitée à un problème très spécifique.
[Wolf et al., 2024]	Le modèle n'est actuellement appliqué qu'à la classification d'images à un seul label
[Parejas-Llanovarcad et al., 2024]	La base de données de test a été construite avec des évaluations subjectives. Le modèle ne considère pas les incertitudes.
[Roldan Reyes et al., 2015]	Une seule méthode d'adaptation est utilisée. Le modèle n'exploite pas les cas qui présentent une erreur.
[Grace et al., 2016]	Beaucoup de données sont nécessaires pour entraîner le modèle de 'Deep Learning'. Les solutions générées n'ont pas été validées.
[Maher and Grace, 2017]	L'évaluation des solutions générées n'est pas automatique. Les solutions sont produites avec un seul point de vue.
[Uysal and Sonmez, 2023]	La fonction d'unification des solutions est une moyenne des solutions générées avec la division des données et un seul approche
[Yu and Li, 2023]	Une base de données déséquilibrée peut affecter négativement la performance du modèle proposé
[Müller and Bergmann, 2015]	Une seule approche pour adapter les cas dans le RàPC. La révision dans le RàPC n'est pas automatique.
[Ontañón et al., 2015]	Les solutions générées peuvent présenter des incohérences. Il n'y a pas une métrique objective pour mesurer la qualité des réponses.
[Lepage et al., 2020]	Les résultats ne sont pas très bons. Le modèle n'a pas de connaissances linguistiques.
[Malburg et al., 2024]	Les règles d'adaptation définies sont fixes et peuvent être limitées pour certaines situations
[Smyth and Cunningham, 2018]	Les prédictions n'ont pas été testées dans le monde réel. Les données sont très spécifiques et peu variées.
[Smyth and Willemsen, 2020]	Les prédictions sont pour des cas limités. Le modèle est entraîné pour un type d'utilisateur spécifique.
[Feely et al., 2020]	Seulement une technique de sélection de solutions. Les données nécessaires pour le modèle sont complexes.
[Yu et al., 2024]	Il n'y a pas de révision des cas dans la méthode d'imputation ni dans le modèle de classification fondé sur RàPC. Cela peut accroître le biais d'imputation et introduire des échantillons avec bruit
[Sadeghi Moghadam et al., 2024]	Le temps de calcul peut être très grand en fonction de la quantité de données associées, du a l'étape d'entraînement du modèle HMM
[Supic, 2018]	Le modèle a été validé avec peu de données. Les recommandations se basent seulement sur l'information des autres apprenants.
[Obeid et al., 2022]	L'ontologie peut être limitée pour évaluer plusieurs cas inconnus ou imprévus. Il est nécessaire d'avoir une forte connaissance du domaine.
[Skittou et al., 2024]	Les règles de décision établies sont fixes et avec l'hybridation peut avoir de l'incertitude et l'imprécision

TABLE 4.1 – Tableau de synthèse des articles analysés dans l'état de l'art du RàPC



CONTRIBUTIONS

ARCHITECTURE GLOBALE POUR LE SYSTÈME AI-VT

5.1/ INTRODUCTION

L'architecture logicielle est essentielle pour définir un système entier avant sa mise en œuvre et est importante car elle aide à décrire et à comprendre des systèmes logiciels complexes. L'architecture montre les composants, les couches, les fonctionnalités et les interactions. Ce chapitre présente l'architecture modulaire proposée pour le système AI-VT. Les modules intègrent des paradigmes, des modèles et des algorithmes d'intelligence artificielle pour améliorer le fonctionnement global. Les objectifs de l'architecture proposée sont de rendre le logiciel AI-VT (Artificial Intelligence Virtual Trainer) stable, évolutif, performant, maintenable, facile à modifier, facile à surveiller et testable. L'architecture proposée se compose de quatre couches indépendantes chacune avec une fonctionnalité spécifique : correction automatique, identification, révision et test. Le contenu de ce chapitre est partiellement extrait du travail de Soto *et al.* [Soto-Forero et al., 2024b].

Les deux principaux types d'architecture logicielle sont l'architecture monolithique et l'architecture modulaire. Dans l'architecture monolithique, le système logiciel est considéré comme une unité unique avec une seule source de code, une seule base de données et un seul déploiement pour l'ensemble du système ; ce type de système est simple à développer et à tester mais n'est pas adapté à la mise à jour et à l'évolution en raison de sa rigidité. Une architecture modulaire divise le système en modules indépendants qui peuvent communiquer entre eux, chaque module contenant alors tout ce qui est nécessaire pour fonctionner. En fait, de nombreux systèmes logiciels ont été conçus avec une architecture modulaire en raison des multiples avantages qu'elle présente [Auer et al., 2021] [Zuluaga et al., 2022].

Le système AI-VT est un outil pédagogique générique qui vise à accompagner les apprenants dans leur apprentissage en leur proposant des fiches d'exercices appelées sessions. À l'intérieur de chaque session, les capacités attendues sont divisées en compétences, elles-mêmes divisées en sous-compétences. L'apprenant choisit une compétence à travailler et le système génère une session composée d'exercices associés à plusieurs sous-compétences de la compétence choisie. Le système propose une liste d'exercices au début d'une session en utilisant le paradigme du raisonnement par cas avec une base de données de questions.

5.2/ DESCRIPTION DU SYSTÈME AI-VT

Le système AI-VT est un EIAH générique dont la structure globale est présentée dans la figure 5.1. Il existe une base de données de questions, chacune des questions est associée à un contexte, au texte de la question considérée et à un niveau de complexité. Les questions appartiennent à un niveau de sous-compétences et les sous-compétences à un niveau de compétences. Les principaux acteurs du système sont l'enseignant et l'apprenant, l'enseignant a la capacité de configurer l'ensemble du système, le nombre de compétences, les sous-compétences d'une compétence, le nombre de questions, la complexité de chacune d'entre elles, le nombre de niveaux de complexité et le temps par session. Et l'apprenant, qui peut commencer l'entraînement d'une compétence spécifique, accéder à des ressources de soutien complémentaires et répondre aux questions de test dans les sessions proposées par le système. Le tableau 5.1 montre les caractéristiques du système AI-VT selon la définition des 20 dimensions du profil de l'apprenant décrites dans [Jean-Daubias, 2011].




FIGURE 5.1 – Structure du système AI-VT

En s'appuyant sur la philosophie CBR, le système global AI-TV part du principe que certains apprenants ont des performances, des besoins et des capacités d'apprentissage similaires, et qu'il est donc possible de les regrouper et d'améliorer ainsi le processus d'apprentissage général pour tous. L'algorithme dans AI-VT tente de proposer une liste d'exercices en fonction de la compétence ou de la sous-compétence sélectionnée.

L'algorithme d'AI-VT tente de proposer une liste d'exercices en fonction de la compétence ou de la sous-compétence sélectionnée et en tenant compte de l'équilibre entre répétitivité et variété, le nombre d'exercices par session change en fonction du domaine, du niveau et de la compétence de chaque apprenant. La liste d'exercices est générée au début de chaque séance et ne modifie donc pas le cours de la séance en fonction des réponses fournies par l'apprenant, les listes d'exercices sont statiques pendant la séance [Henriet and Greffier, 2018].

Type	Definition	Système AI-VT
Subject	Acteur humain concerné par le profil	Apprentissage seul et en groupe
Collaboration	Le rôle de la collaboration dans les activités du profil	Individuel, Collaboratif
Distance	Le rôle de la distance dans les activités du profil	Presentiel, Distanciel
Discipline	Discipline des informations contenues dans le profil	Generic
Niveau	Le niveau scolaire de la matière concernée par le profil	Generic
Initiateur	L'acteur humain à l'origine de la décision de créer le profil de création	Professeur, Administrateur
Créateur	L'acteur humain ou logiciel qui compose le profil	Professeur, Administrateur
Destinataire	Acteur humain ou logiciel exploitant le profil	Apprenant
Temps	Période du profil	Asynchrone
Évolution	L'évolutivité du profil	Profil évolutif
Type	Le type d'informations contenues dans le profil	Profil de l'apprenant
Nature	La nature des informations contenues dans le profil	Connaissances et compétences
Évaluation	La forme sous laquelle l'information est évaluée	Rating, Taux de maîtrise
Représentation interne	Représentation interne utilisée par le système informatique pour manipuler les profils	Tables
Représentation externe	Représentation utilisée pour stocker le profil	Liste de valeurs
Visualisation	Représentation utilisée pour présenter le profil à ses destinataires	Représentation textuel et graphique standard
Norme	Norme ou standard éducatif	-
Format	Format de stockage du profil	Base de données relationnelle
Plate-forme	plate-forme informatique compatible	Web
Dispositifs	le type de dispositif d'affichage du profil	Ordinateur ou appareils connectés

TABLE 5.1 – Un tableau décrivant les caractéristiques du système AI-VT

5.3/ MODÈLE D'ARCHITECTURE PROPOSÉ

L'idée de l'architecture proposée est que le système préserve sa fonctionnalité d'origine et qu'il peut également utiliser des fonctions complémentaires en activant simplement le module correspondant en envoyant et en recevant les informations nécessaires à son fonctionnement, ce qui étend la fonctionnalité globale d'origine du système et facilite l'in-

tégration avec les modules conçus et même avec de nouveaux modules. La conception modulaire facilite également la maintenance du code, le développement et l'intégration de nouvelles extensions, ainsi que la configuration et l'adaptation du système à différents scénarios, tout en réduisant les risques et les coûts. La modularité permet également d'exécuter les fonctionnalités de chaque module de manière asynchrone, en parallèle ou en mode distribué si nécessaire.

L'architecture se compose de deux éléments principaux : le système central (AI-VT System) et les modules fonctionnels. Le système central gère l'ensemble du processus d'apprentissage ; il génère et démarre les séances ; il stocke les données relatives aux compétences, aux questions, aux ressources, aux apprenants et aux réponses ; il contient les commandes et l'interface générale ; il gère le flux d'informations et active les modules nécessaires. Les modules sont un ensemble de fonctionnalités indépendantes mises en œuvre avec des algorithmes d'intelligence artificielle qui reçoivent et envoient des données depuis le composant central, chaque module fonctionne selon des critères spécifiques liés à son propre objectif. Les modules sont regroupés en couches selon leur fonctionnalité : correction automatique, identification, adaptation, révision et test. L'enseignant et l'apprenant n'utilisent pas les modules directement, les modules sont utilisés par le système pour compléter certaines fonctionnalités.

La couche de correction automatique (LC) correspond aux modules chargés de recevoir les réponses des apprenants et, conformément aux algorithmes et critères définis, d'établir une note cohérente avec une réponse de référence à une question spécifique. Dans cette couche, le module routeur (LC0) est chargé d'identifier le type de correction nécessaire et d'instancier le module approprié pour l'exécution de la tâche spécifique.

La couche d'identification (LD) contient les modules qui identifient les faiblesses ou les variables externes des apprenants lors de l'exécution des exercices proposés par le système ou après l'analyse des résultats. Ces modules aident à personnaliser le processus des apprenants en fonction des résultats obtenus par les analyses.

La couche de révision (LR) comprend les modules qui prennent les données des résultats obtenus dans la couche LC et les résultats de l'analyse de la couche LD pour modifier le parcours de l'apprenant en essayant de renforcer l'apprentissage dans les faiblesses détectées. Ici se trouvent également les modules qui obtiennent des informations de la part des apprenants et tentent de prédire leurs résultats en fonction des différentes compétences et des différents niveaux de complexité.

Pour évaluer les modules dans différents scénarios, il est nécessaire de produire des données selon différents critères et complexités, c'est pourquoi la couche de test (LT) a été définie, dans laquelle se trouvent les modules qui permettent de générer des données synthétiques selon des critères variables, de cette manière il est possible d'obtenir des résultats numériques des modules et d'appliquer des métriques. La couche de test (LT) permet d'évaluer les modules selon différents critères et complexités.

Le schéma complet de l'architecture est illustré à la figure 5.2, où les lignes pleines représentent un flux d'informations bidirectionnel, les lignes pleines avec une flèche représentent le flux unidirectionnel et les lignes en pointillé représentent la dépendance de l'information entre les modules, les dispositifs externes qui peuvent être utilisés par les modules pour exécuter leurs fonctionnalités et les étiquettes qui indiquent quel type d'information le module envoie au système central sont également représentés, ainsi que certains des algorithmes d'intelligence artificielle mis en œuvre dans chaque module et le stade de développement dans lequel chacun d'eux se trouve. Certains dispositifs sont

nécessaires à l'exécution des modules qui requièrent l'obtention de données à partir de sources externes, dans le schéma d'architecture sont représentés le robot NAO, des capteurs, une caméra vidéo et un microphone.




FIGURE 5.2 – Schème de l'architecture proposée

5.3.1/ CORRECTION AUTOMATIQUE

Dans cette couche, les modules ont la capacité de recevoir et d'évaluer différents types de réponses données par les apprenants en fonction du contexte et de la question que le système a proposée. Les modules représentés ont la capacité d'évaluer une réponse donnée par l'apprenant, les modules dans lesquels des progrès ont déjà été réalisés correspondent à l'analyse de vidéo, de texte audio (langage naturel), de code source (Java, Python). D'autres modules permettent également d'analyser des images, des expressions mathématiques, des valeurs générées par des capteurs physiques et des variables définies par des activités sportives.

Le module routeur (LC0) a pour fonction d'identifier le type de réponse et de la redi-

ger vers le module d'analyse correspondant ; une fois la réponse générée, ce module la redirige vers le système AI-VT principal.

Le module vidéo (LC1) permet de capturer un flux d'images à partir d'un dispositif externe (caméra vidéo ou robot NAO) et de les analyser pour déterminer si une réponse donnée est correcte, actuellement le module est utilisé pour évaluer la réponse à la question : montrer n nombre de doigts. L'algorithme implémenté détecte les doigts qui apparaissent sur la caméra, les compte et détermine s'il s'agit de la bonne réponse à la question donnée.

Le module audio (LC2) analyse une piste audio et tente de convertir son contenu en texte. Une fois le texte généré, il peut être comparé à une réponse attendue à la question posée à l'aide de techniques NLP mises en œuvre dans le module GC5, et un score d'approximation estimé peut être généré. Le module audio (LC2) analyse une piste audio et tente de convertir son contenu en texte.

Le module d'analyse du code (LC3) génère le score après l'exécution de plusieurs étapes, d'abord il détermine s'il y a des faiblesses dans certaines compétences prédéfinies, ensuite il transforme la représentation du code en un vecteur numérique à comparer avec une réponse de référence, le résultat de la pondération entre les faiblesses détectées et le pourcentage de comparaison est le score généré. Le module d'analyse du code (LC3) génère le score après l'exécution de plusieurs étapes.

Le module d'analyse de texte (LC5) transforme essentiellement le texte envoyé par l'apprenant en un vecteur numérique qui peut être comparé au vecteur numérique d'une réponse attendue. Dans ce cas, la réponse donnée ne doit pas nécessairement être exactement la même que la réponse attendue, puisque la représentation vectorielle permet d'établir des similitudes dans l'espace, même si les termes utilisés et la longueur du texte diffèrent.

Les modules LC6, LC7, LC8 et LC9 ont été définis comme des modules capables d'analyser différents types de réponses potentielles, qui ne sont pas encore gérées par le système AI-VT.

5.3.2/ IDENTIFICATION

Les modules de la couche d'identification visent à extraire des informations complémentaires à la note de l'étudiant pour chacune des réponses envoyées au système, principalement pour obtenir des informations sur les expressions et les faiblesses qui peuvent se manifester dans chaque sous-compétence et niveau de complexité, afin d'obtenir une meilleure estimation de l'état de l'apprentissage, pour guider plus précisément le parcours de l'apprenant.

Les modules d'identification LD1, LD2 et LD4 tentent de détecter les comportements, les émotions et les sentiments à l'aide de dispositifs externes tels que la caméra vidéo et le microphone. Dans le cas de l'analyse vidéo, des réseaux neuronaux d'apprentissage profond sont utilisés pour capturer et analyser les images statiques obtenues à partir du flux de la caméra vidéo, les émotions qui peuvent être détectées ont été prédéfinies et le modèle d'IA a été entraîné à les identifier. Le module audio vise à détecter le même type d'émotions, mais à partir de l'analyse des signaux obtenus à partir d'un microphone, il utilise également l'apprentissage profond formé avec des signaux qui présentent les émotions prédéfinies. Le module capteur est conçu de manière plus générique, mais il

peut être subdivisé en modules spécifiques en fonction du type de capteur et du signal à analyser, mais l'idée de la détection est la même avec les émotions prédéfinies.

Le module Analyse des données (LD3) est différent car, en plus d'être générique, il tente d'identifier les faiblesses dans des compétences spécifiques en fonction du type d'évaluation, ce module peut contenir différents modèles entraînés pour chaque type de cas. Pour les exercices linguistiques, les faiblesses doivent être identifiées dans : la conjugaison des verbes, l'utilisation des temps, le vocabulaire, la correspondance des genres de mots, etc. ; si l'exercice est de type programmation : la syntaxe, la déclaration de variables, l'appel de fonctions, la construction de structures, etc. En interne, ce module contient des modèles d'apprentissage profond et des modèles collaboratifs tels que le raisonnement à partir de cas.

5.3.3/ RÉVISION

Dans la couche de révision, les modules utilisent les informations générées par les modules des couches de correction automatique et d'identification ainsi que les informations complémentaires de l'apprenant stockées dans la base de données du système, ces modules valident que la recommandation générée est optimale pour l'apprenant. Toutes les informations récoltées permettent d'établir la meilleure façon de guider l'apprenant vers une meilleure compréhension en surmontant les faiblesses et les lacunes qui ont été identifiées.

Les ressources recommandées par le module LR1 proviennent d'une base de données déjà établie que le module consulte et suggère à l'étudiant en fonction du résultat de la comparaison de l'état d'apprentissage, du niveau et des caractéristiques et spécifications de chacune des ressources.

Le module LR2 a deux variantes, l'une déterministe et l'autre stochastique, les deux variantes étant basées sur les valeurs générées par l'apprenant. Le modèle déterministe utilise un tableau prédéterminé de rangs sur lequel l'apprenant est positionné pour générer la suggestion d'adaptation. Le modèle stochastique utilise des distributions de probabilités dynamiques qui changent en fonction des résultats de l'apprenant à chaque niveau de complexité de la même sous-compétence.

Il y a d'autres modules, où une prédiction est faite avec les mêmes données que celles qui ont été utilisées pour la génération de l'adaptation et de cette façon est déterminée quelle sera la performance de l'apprenant et si effectivement l'adaptation proposée permet d'acquérir les compétences nécessaires et d'améliorer les notes obtenues.

Le module LR3 obtient dynamiquement des structures variables à partir des informations extraites du système AI-VT central. Ce module peut également effectuer des transformations dans la structure, le contenu et la représentation des données des apprenants.

Le module LR4 utilise les informations produites par l'apprenant et les informations collaboratives pour tenter de prédire les performances futures de l'apprenant, en particulier avec la recommandation générée par les modules de la couche adaptative, la prédiction est utilisée pour valider l'adaptation recommandée et l'ajuster si nécessaire.

5.3.4/ TEST

La couche de test est externe au flux du fonctionnement global du système et à l'intégration avec des outils d'intelligence artificielle, mais elle a été développée parce qu'elle permet d'évaluer chacun des modules indépendamment et de générer des données spécifiques pour divers scénarios de test qui peuvent être pris en compte lors de la validation d'un module.

Les couches définies de l'architecture peuvent communiquer entre elles, car pour que certains de leurs modules internes fonctionnent, elles ont besoin des informations générées par les modules des autres couches. La figure 5.3 montre les interactions qui peuvent se produire dans le fonctionnement du système. La couche de test (LT) a besoin des informations générées par les modules de toutes les autres couches pour évaluer leurs performances individuelles. La couche d'identification (LD) doit obtenir les données relatives au profil des apprenants ; ces informations sont générées par le module de profil qui se trouve dans la couche de révision (LR), pour certains modules qui ont la capacité de modifier une solution, cette couche doit connaître les résultats obtenus par l'apprenant dans chacun des tests ou exercices proposés par le système, ces résultats sont attribués par la couche de correction automatique (LC). De plus, il est possible d'obtenir une estimation du résultat de la révision proposée avant qu'elle ne soit envoyée à l'apprenant, pour cela il faut invoquer les modules spécifiques de prédiction qui appartiennent à la couche de révision (LR).




FIGURE 5.3 – Relation entre les couches définies de l'architecture.

Le flux complet d'informations est représenté dans la figure 5.4. La première étape consiste à envoyer le test généré par le système AI-VT à l'apprenant ; à cette étape, le module d'identification correspondant à l'analyse à effectuer est également lancé. Lorsque l'étudiant envoie la réponse à une question, le module d'identification envoie à l'apprenant l'analyse effectuée sur cette même réponse. Grâce à ces informations, le système active les modules de correction automatique pour attribuer une note à la réponse envoyée, en tenant compte également des résultats du module d'identification. À l'étape 6, la note générée est envoyée au système, puis pour effectuer l'adaptation, le système obtient les informations spécifiques de l'apprenant et lance les modules d'adaptation, en envoyant les informations obtenues dans les étapes précédentes. Les algorithmes d'adaptation évaluent les variables et déterminent le parcours optimal pour l'apprenant, mais avant de le renvoyer au système principal, l'étape 9 évalue sa pertinence à l'aide du module de prédiction. Si la prédiction détermine que le chemin suggéré est acceptable, il est envoyé au système principal qui décide, à l'étape 11, de le présenter à l'apprenant comme une

alternative au chemin sélectionné à l'origine.




FIGURE 5.4 – Étapes du flux de l'information pour la fonctionnalité de recommandation globale.

5.4/ CONCLUSION

L'architecture proposée est basée sur des concepts et des modèles couramment utilisés pour concevoir des systèmes complexes qui utilisent d'une manière ou d'une autre des algorithmes et des outils d'intelligence artificielle. Ce type de conception permet la mise en œuvre d'un système fonctionnel doté d'une capacité d'adaptation, nécessaire à l'exécution de l'une des principales exigences des systèmes d'apprentissage intelligents. En outre, comme l'indiquent les travaux cités en référence, l'architecture modulaire permet une mise en œuvre plus souple et donne au système la possibilité d'évoluer rapidement et même d'ajouter des fonctionnalités complémentaires sans affecter le système et les données qui y sont stockées.

BIBLIOGRAPHIE

- [Aamodt and Plaza, 1994] Aamodt, A. and Plaza, E. (1994). Case-based reasoning : Foundational issues, methodological variations, and system approaches. *AI Communications*, 7(1) :39–59.
- [Abel et al., 2023] Abel, D., Barreto, A., Van Roy, B., Precup, D., van Hasselt, H. P., and Singh, S. (2023). A definition of continual reinforcement learning. In Oh, A., Naumann, T., Globerson, A., Saenko, K., Hardt, M., and Levine, S., editors, *Advances in Neural Information Processing Systems*, volume 36, pages 50377–50407. Curran Associates, Inc.
- [Alabdulrahman and Viktor, 2021] Alabdulrahman, R. and Viktor, H. (2021). Catering for unique tastes : Targeting grey-sheep users recommender systems through one-class machine learning. *Expert Systems with Applications*, 166 :114061.
- [Arthurs et al., 2019] Arthurs, N., Stenhaug, B., Karayev, S., and Piech, C. (2019). Grades are not normal : Improving exam score models using the logit-normal distribution. In *International Conference on Educational Data Mining (EDM)*, page 6.
- [Auer et al., 2021] Auer, F., Lenarduzzi, V., Felderer, M., and Taibi, D. (2021). From monolithic systems to microservices : An assessment framework. *Information and Software Technology*, 137 :106600.
- [Badier et al., 2023] Badier, A., Lefort, M., and Lefevre, M. (2023). Comprendre les usages et effets d'un système de recommandations pédagogiques en contexte d'apprentissage non-formel. In *EIAH'23*, Brest, France.
- [Bakurov et al., 2021] Bakurov, I., Castelli, M., Gau, O., Fontanella, F., and Vanneschi, L. (2021). Genetic programming for stacked generalization. *Swarm and Evolutionary Computation*, 65 :100913.
- [Butdee and Tichkiewitch, 2011] Butdee, S. and Tichkiewitch, S. (2011). Case-based reasoning for adaptive aluminum extrusion die design together with parameters by neural networks. In Bernard, A., editor, *Global Product Development*, pages 491–496, Berlin, Heidelberg. Springer Berlin Heidelberg.
- [Chiu et al., 2023] Chiu, T. K., Xia, Q., Zhou, X., Chai, C. S., and Cheng, M. (2023). Systematic literature review on opportunities, challenges, and future research recommendations of artificial intelligence in education. *Computers and Education : Artificial Intelligence*, 4 :100118.
- [Choi et al., 2023] Choi, J., Suh, D., and Otto, M.-O. (2023). Boosted stacking ensemble machine learning method for wafer map pattern classification. *Computers, Materials & Continua*, 74(2) :2945–2966.
- [C.K. and R.C., 1989] C.K., R. and R.C., S. (1989). *Inside Case-Based Reasoning*. Psychology Press.
- [Cunningham and Delany, 2021] Cunningham, P. and Delany, S. J. (2021). K-nearest neighbour classifiers - a tutorial. *ACM Comput. Surv.*, 54(6).

- [**Didden et al., 2023**] Didden, J. B., Dang, Q.-V., and Adan, I. J. (2023). Decentralized learning multi-agent system for online machine shop scheduling problem. *Journal of Manufacturing Systems*, 67 :338–360.
- [**Ezaldeen et al., 2022**] Ezaldeen, H., Misra, R., Bisoy, S. K., Alatrash, R., and Priyadarshini, R. (2022). A hybrid e-learning recommendation integrating adaptive profiling and sentiment analysis. *Journal of Web Semantics*, 72 :100700.
- [**Feely et al., 2020**] Feely, C., Caulfield, B., Lawlor, A., and Smyth, B. (2020). Using case-based reasoning to predict marathon performance and recommend tailored training plans. In Watson, I. and Weber, R., editors, *Case-Based Reasoning Research and Development*, pages 67–81, Cham. Springer International Publishing.
- [**Grace et al., 2016**] Grace, K., Maher, M. L., Wilson, D. C., and Najjar, N. A. (2016). Combining cbr and deep learning to generate surprising recipe designs. In Goel, A., Díaz-Agudo, M. B., and Roth-Berghofer, T., editors, *Case-Based Reasoning Research and Development*, pages 154–169, Cham. Springer International Publishing.
- [**Gupta et al., 2021**] Gupta, S., Chaudhari, S., Joshi, G., and Yağan, O. (2021). Multi-armed bandits with correlated arms. *IEEE Transactions on Information Theory*, 67(10) :6711–6732.
- [**Hajduk et al., 2019**] Hajduk, M., Sukop, M., and Haun, M. (2019). *Cognitive Multi-agent Systems : Structures, Strategies and Applications to Mobile Robotics and Robosoccer*. Studies in Systems, Decision and Control. Springer International Publishing.
- [**Henriet et al., 2017**] Henriet, J., Christophe, L., and Laurent, P. (2017). Artificial intelligence-virtual trainer : An educative system based on artificial intelligence and designed to produce varied and consistent training lessons. *Proceedings of the Institution of Mechanical Engineers, Part P : Journal of Sports Engineering and Technology*, 231(2) :110–124.
- [**Henriet and Greffier, 2018**] Henriet, J. and Greffier, F. (2018). Ai-vt : An example of cbr that generates a variety of solutions to the same problem. In Cox, M. T., Funk, P., and Begum, S., editors, *Case-Based Reasoning Research and Development*, pages 124–139, Cham. Springer International Publishing.
- [**Hipólito and Kirchhoff, 2023**] Hipólito, I. and Kirchhoff, M. (2023). Breaking boundaries : The bayesian brain hypothesis for perception and prediction. *Consciousness and Cognition*, 111 :103510.
- [**Hoang, 2018**] Hoang, L. (2018). *La formule du savoir. Une philosophie unifiée du savoir fondée sur le théorème de Bayes*. EDP Sciences.
- [**Hu et al., 2025**] Hu, B., Ma, Y., Liu, Z., and Wang, H. (2025). A social importance and category enhanced cold-start user recommendation system. *Expert Systems with Applications*, 277 :127130.
- [**Huang et al., 2023**] Huang, A. Y., Lu, O. H., and Yang, S. J. (2023). Effects of artificial intelligence-enabled personalized recommendations on learners' learning engagement, motivation, and outcomes in a flipped classroom. *Computers and Education*, 194 :104684.
- [**Ingvavara et al., 2022**] Ingvavara, T., Panjaburee, P., Srisawasdi, N., and Sajjapanroj, S. (2022). The use of a personalized learning approach to implementing self-regulated online learning. *Computers and Education : Artificial Intelligence*, 3 :100086.
- [**Jean-Daubias, 2011**] Jean-Daubias, S. (2011). Ingénierie des profils d'apprenants.
- [**Jung et al., 2009**] Jung, S., Lim, T., and Kim, D. (2009). Integrating radial basis function networks with case-based reasoning for product design. *Expert Systems with Applications*, 36(3, Part 1) :5695–5701.

- [Kamali et al., 2023] Kamali, S. R., Banirostan, T., Motameni, H., and Teshnehlab, M. (2023). An immune inspired multi-agent system for dynamic multi-objective optimization. *Knowledge-Based Systems*, 262 :110242.
- [Kim, 2024] Kim, W. (2024). A random focusing method with jensen–shannon divergence for improving deep neural network performance ensuring architecture consistency. *Neural Processing Letters*, 56(4) :199.
- [Kolodner, 1983] Kolodner, J. L. (1983). Reconstructive memory : A computer model. *Cognitive Science*, 7(4) :281–328.
- [Lalitha and Sreeja, 2020] Lalitha, T. B. and Sreeja, P. S. (2020). Personalised self-directed learning recommendation system. *Procedia Computer Science*, 171 :583–592. Third International Conference on Computing and Network Communications (Co-CoNet'19).
- [Lei, 2024] Lei, Z. (2024). Analysis of simpson's paradox and its applications. *Highlights in Science, Engineering and Technology*, 88 :357–362.
- [Leikola et al., 2018] Leikola, M., Sauer, C., Rintala, L., Aromaa, J., and Lundström, M. (2018). Assessing the similarity of cyanide-free gold leaching processes : A case-based reasoning application. *Minerals*, 8(10).
- [Lepage et al., 2020] Lepage, Y., Lieber, J., Mornard, I., Nauer, E., Romary, J., and Sies, R. (2020). The french correction : When retrieval is harder to specify than adaptation. In Watson, I. and Weber, R., editors, *Case-Based Reasoning Research and Development*, pages 309–324, Cham. Springer International Publishing.
- [Li et al., 2024] Li, Z., Ding, Z., Yu, Y., and Zhang, P. (2024). The kullback–leibler divergence and the convergence rate of fast covariance matrix estimators in galaxy clustering analysis. *The Astrophysical Journal*, 965(2) :125.
- [Liang et al., 2021] Liang, M., Chang, T., An, B., Duan, X., Du, L., Wang, X., Miao, J., Xu, L., Gao, X., Zhang, L., Li, J., and Gao, H. (2021). A stacking ensemble learning framework for genomic prediction. *Frontiers in Genetics*, 12.
- [Lin, 2022] Lin, B. (2022). Evolutionary multi-armed bandits with genetic thompson sampling. In *2022 IEEE Congress on Evolutionary Computation (CEC)*, pages 1–8.
- [Liu and Yu, 2023] Liu, M. and Yu, D. (2023). Towards intelligent e-learning systems. *Education and Information Technologies*, 28(7) :7845–7876.
- [Louvros et al., 2023] Louvros, P., Stefanidis, F., Boulougouris, E., Komianos, A., and Vassalos, D. (2023). Machine learning and case-based reasoning for real-time onboard prediction of the survivability of ships. *Journal of Marine Science and Engineering*, 11(5).
- [Maher and Grace, 2017] Maher, M. L. and Grace, K. (2017). Encouraging curiosity in case-based reasoning and recommender systems. In Aha, D. W. and Lieber, J., editors, *Case-Based Reasoning Research and Development*, pages 3–15, Cham. Springer International Publishing.
- [Malburg et al., 2024] Malburg, L., Hotz, M., and Bergmann, R. (2024). Improving complex adaptations in process-oriented case-based reasoning by applying rule-based adaptation. In Recio-Garcia, J. A., Orozco-del Castillo, M. G., and Bridge, D., editors, *Case-Based Reasoning Research and Development*, pages 50–66, Cham. Springer Nature Switzerland.
- [Mang et al., 2021] Mang, L., Tianpeng, C., Bingxing, A., Xinghai, D., Lili, D., Xiaoqiao, W., Jian, M., Lingyang, X., Xue, G., Lupei, Z., Junya, L., and Huijiang, G. (2021). A stacking ensemble learning framework for genomic prediction. *Frontiers in Genetics*.

- [Minsker and Strawn, 2024] Minsker, S. and Strawn, N. (2024). The geometric median and applications to robust mean estimation. *SIAM Journal on Mathematics of Data Science*, 6(2) :504–533.
- [Muangprathub et al., 2020] Muangprathub, J., Boonjing, V., and Chamnongthai, K. (2020). Learning recommendation with formal concept analysis for intelligent tutoring system. *Heliyon*, 6(10) :e05227.
- [Müller and Bergmann, 2015] Müller, G. and Bergmann, R. (2015). Cookingcake : A framework for the adaptation of cooking recipes represented as workflows. In *International Conference on Case-Based Reasoning*.
- [Nguyen, 2024] Nguyen, A. (2024). Dynamic metaheuristic selection via thompson sampling for online optimization. *Applied Soft Computing*, 158 :111566.
- [Nkambou et al., 2010] Nkambou, R., Bourdeau, J., and Mizoguchi, R. (2010). *Advances in Intelligent Tutoring Systems*. Springer Berlin, Heidelberg, 1 edition.
- [Obeid et al., 2022] Obeid, C., Lahoud, C., Khoury, H. E., and Champin, P. (2022). A novel hybrid recommender system approach for student academic advising named cohrrs, supported by case-based reasoning and ontology. *Computer Science and Information Systems*, 19(2) :979–1005.
- [Ontañón et al., 2015] Ontañón, S., Plaza, E., and Zhu, J. (2015). Argument-based case revision in cbr for story generation. In Hüllermeier, E. and Minor, M., editors, *Case-Based Reasoning Research and Development*, pages 290–305, Cham. Springer International Publishing.
- [Ou et al., 2024] Ou, T., Cummings, R., and Avella Medina, M. (2024). Thompson sampling itself is differentially private. In Dasgupta, S., Mandt, S., and Li, Y., editors, *Proceedings of The 27th International Conference on Artificial Intelligence and Statistics*, volume 238 of *Proceedings of Machine Learning Research*, pages 1576–1584. PMLR.
- [Parejas-Llanovarcad et al., 2024] Parejas-Llanovarcad, H., Caro-Martínez, M., del Castillo, M. G. O., and Recio-García, J. A. (2024). Case-based selection of explanation methods for neural network image classifiers. *Knowledge-Based Systems*, 288 :111469.
- [Petrovic et al., 2016] Petrovic, S., Khussainova, G., and Jagannathan, R. (2016). Knowledge-light adaptation approaches in case-based reasoning for radiotherapy treatment planning. *Artificial Intelligence in Medicine*, 68 :17–28.
- [Richter and Weber, 2013] Richter, M. and Weber, R. (2013). *Case-Based Reasoning (A Textbook)*. Springer-Verlag GmbH.
- [Richter, 2009] Richter, M. M. (2009). The search for knowledge, contexts, and case-based reasoning. *Engineering Applications of Artificial Intelligence*, 22(1) :3–9.
- [Robertson and Watson, 2014] Robertson, G. and Watson, I. D. (2014). A review of real-time strategy game ai. *AI Mag.*, 35 :75–104.
- [Roldan Reyes et al., 2015] Roldan Reyes, E., Negny, S., Cortes Robles, G., and Le Lann, J. (2015). Improvement of online adaptation knowledge acquisition and reuse in case-based reasoning : Application to process engineering design. *Engineering Applications of Artificial Intelligence*, 41 :1–16.
- [Sadeghi Moghadam et al., 2024] Sadeghi Moghadam, M. R., Jafarnejad, A., Heidary Dahooie, J., and Ghasemian Sahebi, I. (2024). A hidden markov model based extended case-based reasoning algorithm for relief materials demand forecasting. *Mathematics Interdisciplinary Research*, 9(1) :89–109.
- [Schank and Abelson, 1977] Schank, R. C. and Abelson, R. P. (1977). *Scripts, Plans, Goals and Understanding : an Inquiry into Human Knowledge Structures*. L. Erlbaum, Hillsdale, NJ.

- [Seznec et al., 2020] Seznec, J., Menard, P., Lazaric, A., and Valko, M. (2020). A single algorithm for both restless and rested rotating bandits. In Chiappa, S. and Calandra, R., editors, *Proceedings of the Twenty Third International Conference on Artificial Intelligence and Statistics*, volume 108 of *Proceedings of Machine Learning Research*, pages 3784–3794. PMLR.
- [Sinaga and Yang, 2020] Sinaga, K. P. and Yang, M.-S. (2020). Unsupervised k-means clustering algorithm. *IEEE Access*, 8 :80716–80727.
- [Skittou et al., 2024] Skittou, M., Merrouchi, M., and Gadi, T. (2024). A recommender system for educational planning. *Cybernetics and Information Technologies*, 24(2) :67–85.
- [Smyth and Cunningham, 2018] Smyth, B. and Cunningham, P. (2018). An analysis of case representations for marathon race prediction and planning. In Cox, M. T., Funk, P., and Begum, S., editors, *Case-Based Reasoning Research and Development*, pages 369–384, Cham. Springer International Publishing.
- [Smyth and Willemssen, 2020] Smyth, B. and Willemssen, M. C. (2020). Predicting the personal-best times of speed skaters using case-based reasoning. In Watson, I. and Weber, R., editors, *Case-Based Reasoning Research and Development*, pages 112–126, Cham. Springer International Publishing.
- [Soto-Forero et al., 2024a] Soto-Forero, D., Ackermann, S., Betbeder, M.-L., and Henriët, J. (2024a). Automatic real-time adaptation of training session difficulty using rules and reinforcement learning in the ai-vt its. *International Journal of Modern Education and Computer Science(IJMECS)*, 16 :56–71.
- [Soto-Forero et al., 2024b] Soto-Forero, D., Ackermann, S., Betbeder, M.-L., and Henriët, J. (2024b). The intelligent tutoring system ai-vt with case-based reasoning and real time recommender models. In Recio-Garcia, J. A., Orozco-del Castillo, M. G., and Bridge, D., editors, *Case-Based Reasoning Research and Development*, pages 191–205, Cham. Springer Nature Switzerland.
- [Soto-Forero et al., 2024c] Soto-Forero, D., Betbeder, M.-L., and Henriët, J. (2024c). Ensemble stacking case-based reasoning for regression. In Recio-Garcia, J. A., Orozco-del Castillo, M. G., and Bridge, D., editors, *Case-Based Reasoning Research and Development*, pages 159–174, Cham. Springer Nature Switzerland.
- [Su et al., 2022] Su, Y., Cheng, Z., Wu, J., Dong, Y., Huang, Z., Wu, L., Chen, E., Wang, S., and Xie, F. (2022). Graph-based cognitive diagnosis for intelligent tutoring systems. *Knowledge-Based Systems*, 253 :109547.
- [Supic, 2018] Supic, H. (2018). Case-based reasoning model for personalized learning path recommendation in example-based learning activities. In *2018 IEEE 27th International Conference on Enabling Technologies : Infrastructure for Collaborative Enterprises (WETICE)*, pages 175–178.
- [Uguina et al., 2024] Uguina, A. R., Gomez, J. F., Panadero, J., Martínez-Gavara, A., and Juan, A. A. (2024). A learnheuristic algorithm based on thompson sampling for the heterogeneous and dynamic team orienteering problem. *Mathematics*, 12(11).
- [Uysal and Sonmez, 2023] Uysal, F. and Sonmez, R. (2023). Bootstrap aggregated case-based reasoning method for conceptual cost estimation. *Buildings*, 13(3).
- [Wang et al., 2021] Wang, F., Liao, F., Li, Y., and Wang, H. (2021). A new prediction strategy for dynamic multi-objective optimization using gaussian mixture model. *Information Sciences*, 580 :331–351.
- [Wolf et al., 2024] Wolf, T. N., Bongratz, F., Rickmann, A.-M., Pölsterl, S., and Wachinger, C. (2024). Keep the faith : Faithful explanations in convolutional neural networks

- for case-based reasoning. In *Proceedings of the AAAI Conference on Artificial Intelligence*, volume 38, pages 5921–5929.
- [Xu et al., 2021]** Xu, S., Cai, W., Xia, H., Liu, B., and Xu, J. (2021). Dynamic metric accelerated method for fuzzy clustering. *IEEE Access*, 9 :166838–166854.
- [Xu et al., 2023]** Xu, S., Ge, Y., Li, Y., Fu, Z., Chen, X., and Zhang, Y. (2023). Causal collaborative filtering. In *Proceedings of the 2023 ACM SIGIR International Conference on Theory of Information Retrieval*, ICTIR '23, page 235–245, New York, NY, USA. Association for Computing Machinery.
- [Yu and Li, 2023]** Yu, L. and Li, M. (2023). A case-based reasoning driven ensemble learning paradigm for financial distress prediction with missing data. *Applied Soft Computing*, 137 :110163.
- [Yu et al., 2024]** Yu, L., Li, M., and Liu, X. (2024). A two-stage case-based reasoning driven classification paradigm for financial distress prediction with missing and imbalanced data. *Expert Systems with Applications*, 249 :123745.
- [Zhang. and Aslan, 2021]** Zhang., K. and Aslan, A. B. (2021). Ai technologies for education : Recent research and future directions. *Computers and Education : Artificial Intelligence*, 2 :100025.
- [Zhang and Yao, 2018]** Zhang, K. and Yao, Y. (2018). A three learning states bayesian knowledge tracing model. *Knowledge-Based Systems*, 148 :189–201.
- [Zhang et al., 2023]** Zhang, P., Wang, L., Fei, Z., Wei, L., Fei, M., and Menhas, M. I. (2023). A novel human learning optimization algorithm with bayesian inference learning. *Knowledge-Based Systems*, 271 :110564.
- [Zhao et al., 2023]** Zhao, L.-T., Wang, D.-S., Liang, F.-Y., and Chen, J. (2023). A recommendation system for effective learning strategies : An integrated approach using context-dependent dea. *Expert Systems with Applications*, 211 :118535.
- [Zhou and Wang, 2021]** Zhou, L. and Wang, C. (2021). Research on recommendation of personalized exercises in english learning based on data mining. *Scientific Programming*, 2021 :5042286.
- [Zuluaga et al., 2022]** Zuluaga, C. A., Aristizábal, L. M., Rúa, S., Franco, D. A., Osorio, D. A., and Vásquez, R. E. (2022). Development of a modular software architecture for underwater vehicles using systems engineering. *Journal of Marine Science and Engineering*, 10(4).

Résumé :

L'objectif de ce travail de thèse est la prise en compte en temps réel du travail d'un apprenant pour une meilleure personnalisation d'AI-VT (Artificial Intelligence Virtual Trainer).

Mots-clés : Mot-clé 1, Mot-clé 2

Abstract:

This is the abstract in English.

Keywords: Keyword 1, Keyword 2



■ École doctorale SPIM 16 route de Gray F - 25030 Besançon cedex
■ tél. +33 (0)3 81 66 66 02 ■ ed-spim@univ-fcomte.fr ■ www.ed-spim.univ-fcomte.fr

