

3

Personnalisation de l'apprentissage : Vers une forme hybride des technologies d'apprentissage combinant l'humain et l'IA

Inge Molenaar

Faculté des sciences sociales, Université de Radbout, Pays-Bas

Ce chapitre présente l'état de la recherche et du développement en matière d'apprentissage personnalisé dans les laboratoires et instituts de recherche des pays de l'OCDE. Il décrit les dernières avancées dans le domaine de l'apprentissage personnalisé en s'appuyant sur un modèle d'automatisation à six niveaux qui structure les rôles de l'IA, des enseignants et des apprenants. Ce modèle montre dans quelle mesure les solutions mixtes combinent les forces de l'humain et de l'intelligence artificielle pour produire un apprentissage personnalisé. Les technologies d'apprentissage actuelles s'attachent surtout à diagnostiquer l'état des connaissances des élèves et à adapter les commentaires, les tâches et/ou les programmes de cours. Les frontières du développement sont délimitées par la prise en compte d'un éventail plus large de caractéristiques propres à l'apprenant comme l'autorégulation, la motivation et l'émotion.

Introduction

L'intelligence artificielle (IA) peut améliorer l'enseignement et l'apprentissage dans de nombreuses situations. L'instauration d'un dialogue entre chercheurs, entrepreneurs, décideurs politiques et professionnels de l'éducation pourrait offrir au secteur de l'éducation des solutions hybrides très prometteuses combinant IA et intervention humaine. Ce chapitre examine comment ces solutions s'appliquent à la personnalisation de l'apprentissage. L'apprentissage personnalisé à l'aide de la technologie est une tendance qui vise de plus en plus à adapter l'enseignement aux besoins individuels des apprenants (Aleven et al., 2016^[1]). À l'origine, on suppose qu'il est possible d'optimiser le talent de chaque apprenant grâce à un environnement d'apprentissage adapté à ses besoins (Corno, 2008^[2]). En général, tous les élèves d'une même classe suivent le même programme de cours, reçoivent la même instruction, accomplissent les mêmes tâches et reçoivent en grande partie des commentaires similaires. Ce modèle « industriel » d'enseignement étant largement critiqué (Robinson, 2010^[3]), des propositions émergent pour développer des technologies permettant la transition vers une meilleure personnalisation. Pourtant, même s'il existe une grande variété de technologies d'apprentissage adaptables aux besoins de l'apprenant, telles que l'enseignement assisté par ordinateur (EAO), les technologies d'apprentissage adaptatifs (TAA), les systèmes de tutorat intelligents (STI) et les jeux éducatifs, leur mise en œuvre dans les établissements scolaires s'est faite lentement (Tondeur et al., 2013^[4]).

Toutefois, au cours des cinq dernières années, trois avancées ont amené les systèmes éducatifs à s'intéresser davantage à l'apprentissage personnalisé. Tout d'abord, les élèves disposent fréquemment d'un ordinateur chacun, ce qui facilite aujourd'hui l'utilisation régulière du numérique dans les salles de classe et l'intégration croissante des technologies dans les pratiques pédagogiques quotidiennes. Ensuite, l'exploitation des données visant à faciliter l'apprentissage s'est grandement améliorée dans le domaine en expansion de l'analyse des données d'apprentissage. Ceci montre que les données sont non seulement utiles dans les technologies d'apprentissage, mais sont aussi précieuses lorsqu'elles sont transmises directement aux enseignants et apprenants. Enfin, les technologies d'apprentissage qui font appel à l'analyse de l'apprentissage et à l'intelligence artificielle (IA) commencent à se répandre largement dans les établissements scolaires.

La génération actuelle de technologies pédagogiques personnalisées s'adapte le plus souvent aux élèves en fonction de prédictions sur les connaissances de l'apprenant dans la matière enseignée (Aleven et al., 2016_[11]). Généralement, ces technologies adaptent les thèmes à étudier, les problèmes à résoudre ou les commentaires en fonction des réponses données (Vanlehn, 2006_[5]). Cependant, outre la personnalisation en fonction des prédictions relatives aux connaissances des apprenants, un certain nombre d'autres caractéristiques de l'apprenant, comme l'émotion, la motivation, la métacognition et l'autorégulation, sont très utiles pour répondre aux besoins individuels des apprenants (Winne et Baker, 2013_[6]) (D'Mello, 2021_[7]).

En vue d'étoffer la réflexion sur le potentiel de l'analyse de l'apprentissage et de l'IA dans la personnalisation et l'enrichissement de l'enseignement, ce chapitre s'appuie sur un modèle à six niveaux d'automatisation défini par l'industrie automobile afin de l'appliquer au domaine de l'éducation. Dans ce modèle, le passage du contrôle entre l'enseignant et la technologie s'organise en tirant parti de la force combinée de l'intelligence humaine et artificielle et s'inscrit dans la logique de l'intelligence hybride qui met l'accent sur l'interaction de l'homme et de l'IA (Kamar, 2016_[8]). Le modèle présente les dernières avancées en matière de personnalisation de l'apprentissage et étaye la discussion sur les scénarios futurs combinant IA et éducation. C'est un exercice essentiel pour pouvoir envisager les futures évolutions et articuler les différents niveaux de personnalisation de l'apprentissage autour des rôles que joueront l'IA, les enseignants et les apprenants.

Le chapitre débute par un aperçu des niveaux d'automatisation de l'apprentissage personnalisé. En nous appuyant sur ce modèle, nous examinerons les dernières avancées en matière de personnalisation de l'apprentissage dans les laboratoires de recherche des pays de l'OCDE. Par la suite, nous brosserons un tableau de l'utilisation concrète des technologies d'apprentissage dans les établissements scolaires à l'aide d'exemples appliqués à grande échelle dans les établissements. Nous aborderons finalement les limites de la personnalisation de l'apprentissage. En particulier, les applications utilisant des flux de données multiples offrent de nouveaux moyens de détecter et de diagnostiquer cette vaste gamme de caractéristiques propres à l'apprenant qui permettent une personnalisation poussée de l'apprentissage. Malgré la mise en place rapide et à grande échelle des technologies éducatives, les technologies de pointe en matière de personnalisation de l'apprentissage ne sont pas assez largement répandues dans les établissements scolaires. Ces derniers mettent davantage en œuvre les technologies qui s'insèrent dans leurs modèles d'organisation traditionnels et qui respectent la capacité d'agir des enseignants. Le chapitre se termine sur trois recommandations à l'intention des décideurs politiques concernant la mise en œuvre à grande échelle des technologies de pointe : i) encadrer l'éthique dès la conception, notamment en matière de transparence et d'utilisation des données ; ii) améliorer les technologies d'apprentissage grâce à des partenariats public-privé ; et iii) faire en sorte que les enseignants et les professionnels de l'éducation soient parties prenantes de ces transformations.

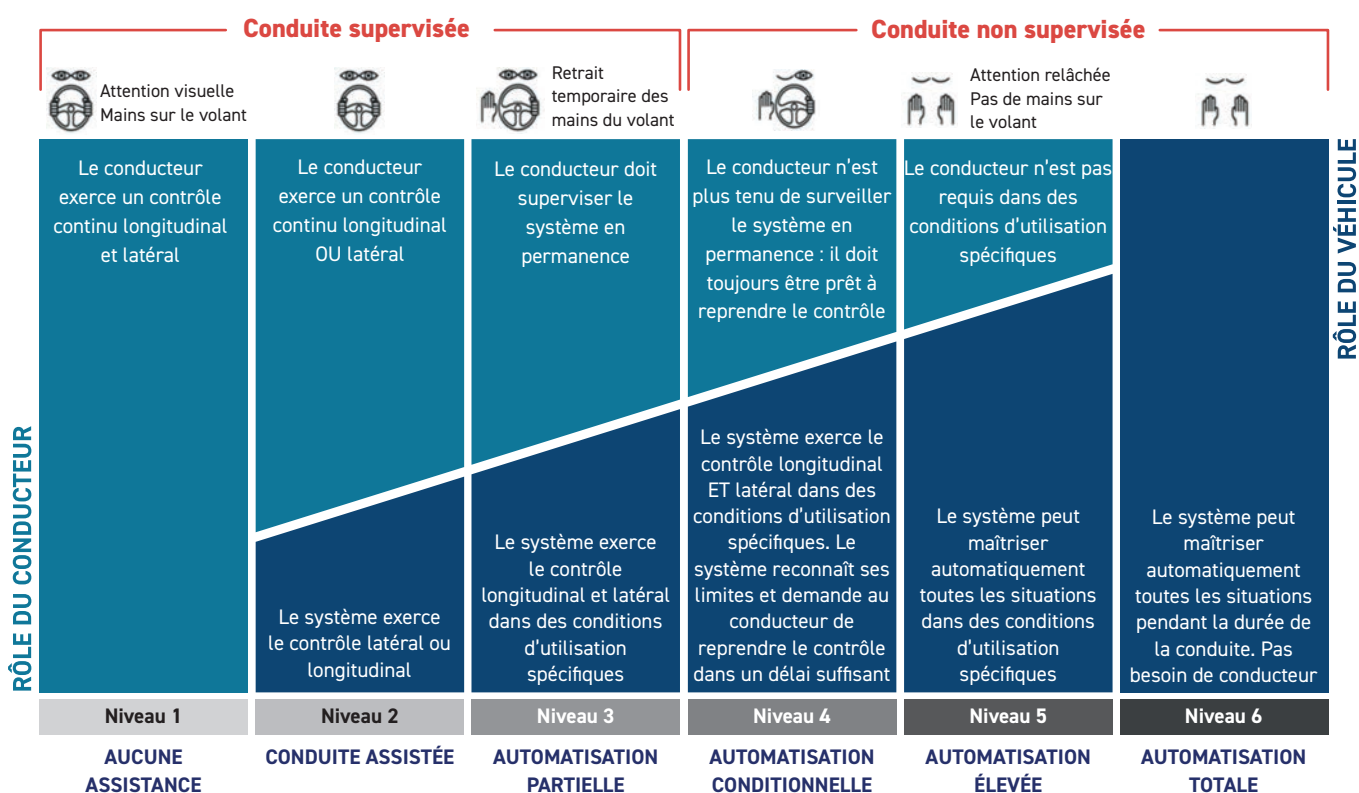
Les systèmes hybrides humains-IA : le rôle des enseignants et de la technologie

En engrangeant davantage de données et en devenant sans cesse plus intelligentes, les technologies ouvrent une nouvelle ère d'interaction entre l'homme et l'IA (Kamar, 2016_[8]). L'apprentissage s'adaptera davantage aux caractéristiques individuelles de l'apprenant. Beaucoup s'attendent à ce que la tendance vers la personnalisation de l'apprentissage se poursuive (Holmes et al., 2018_[9]). En même temps, l'humain et l'intelligence artificielle (IA) fusionneront dans des systèmes hybrides humains-IA dans divers domaines (Harari, 2018_[10]). Par exemple, bien que les voitures autonomes soient destinées à remplacer un jour les conducteurs humains, elles ne sont aujourd'hui qu'une aide à la conduite (Awad et al., 2018_[11]). De même, les systèmes experts d'IA dans le domaine médical aident les médecins à prendre des décisions, mais ne les remplacent pas (Topol, 2019_[12]). L'une des

caractéristiques déterminantes d'un système hybride est que les frontières entre l'IA et la prise de décision de l'humain fluctuent. Dans les voitures autonomes, la conduite repose sur l'IA, mais lorsque la situation devient trop complexe, le contrôle revient à l'humain.

Afin de différencier les capacités de conduite autonome nécessaires aux voitures pour qu'elles soient totalement automatisées, la société des ingénieurs automobiles (SAE) (2016) a établi six niveaux d'automatisation (Graphique 3.1). Ces niveaux s'appuient sur des travaux antérieurs qui examinaient les différents degrés d'automatisation et les conséquences qui en découlent pour les humains dans différents contextes (Parasuraman, Sheridan et Wickens, 2000_[13]). Ces six niveaux d'automatisation marquent différentes étapes du développement d'un véhicule autonome. À chaque étape, le contrôle passe un peu plus des mains du conducteur humain à la technologie de conduite autonome. Plus les niveaux s'élèvent, plus le contrôle humain diminue, tandis que celui de la technologie de conduite autonome augmente pour atteindre une conduite totalement autonome dans toutes les situations. Il faut souligner cependant que l'automatisation totale ne sera probablement jamais souhaitable dans des domaines spécifiques comme ceux de l'éducation ou de la médecine.

Graphique 3.1 Six niveaux d'automatisation pour un véhicule autonome

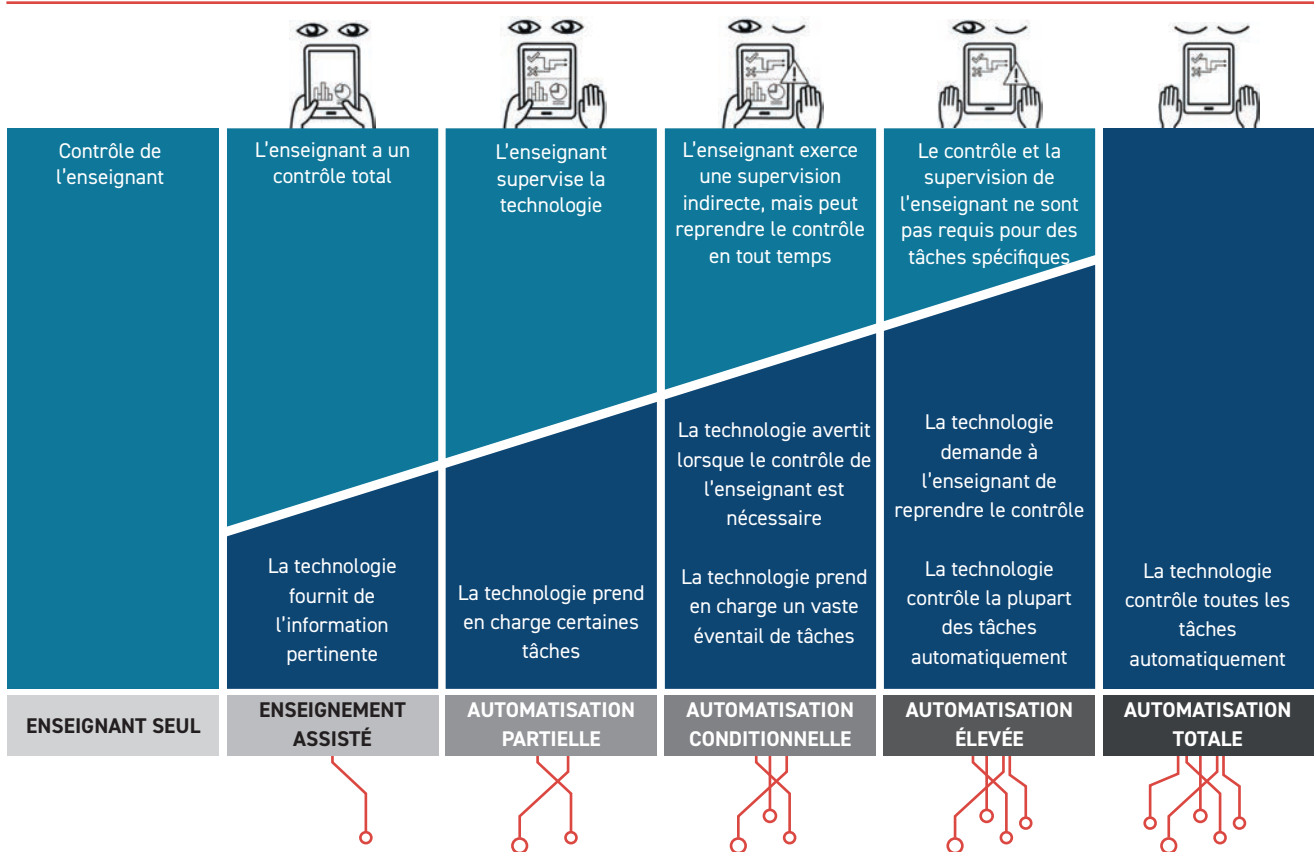


Source: Illustration - Mike Lemanski / ZF TRW, The Society of Automotive Engineers (<https://www.sae.org/>).

Dans les trois premiers niveaux, le conducteur contrôle le véhicule, tandis que dans les trois derniers le contrôle du véhicule bascule du côté de la technologie de conduite autonome. Dans la conduite assistée (niveau 1), la technologie de conduite autonome fournit des informations pertinentes au conducteur. Dans une conduite autonome partielle (niveau 2), la technologie contrôle la conduite dans des situations bien précises, par exemple sur une autoroute dans de bonnes conditions météorologiques, mais le conducteur gère la technologie en tout temps. En revanche, dans l'automatisation conditionnelle (niveau 3), c'est la technologie de conduite autonome qui prend le contrôle, mais le conducteur doit être prêt à reprendre le véhicule en main à tout moment. À l'heure actuelle, les voitures à conduite autonome se situent entre automatisation partielle et automatisation conditionnelle. Dans le domaine médical, on estime être entre les niveaux d'automatisation assistée et d'automatisation partielle (Topol, 2019_[12]). Dans ce domaine, l'IA facilite souvent la prise de décisions médicales, les systèmes experts, par exemple, détectent les tumeurs dans les radiographies, mais les médecins continuent de poser le diagnostic final du patient et de choisir le traitement qui convient le mieux.

À notre connaissance, les niveaux d'automatisation n'ont pas encore été transposés au domaine de l'éducation. Grâce à ce modèle, on peut situer les plus récentes technologies d'apprentissage et voir comment elles sont appliquées dans les établissements. Il peut nous aider à mieux comprendre l'écart existant entre les plus récentes avancées de ces technologies et l'utilisation qui en est faite au quotidien dans les établissements sous l'angle d'un pilotage humain.

Graphique 3.2 Six niveaux d'automatisation de l'apprentissage personnalisé



Anne Horvers et Inge Molenaar, Adaptive Learning Lab

Source: Illustration - Anne Horvers et Inge Molenaar, Adaptive Learning Lab
<https://www.ru.nl/bsi/research/group-pages/adaptive-learning-lab-all/>

Le Graphique 3.2 illustre les six niveaux d'automatisation appliqués au domaine des technologies pédagogiques. Les lignes tout en bas du modèle reflètent l'idée que des flux grandissants de données seront utilisés dans la transition vers l'automatisation complète. Ces flux peuvent permettre de détecter et de poser un diagnostic plus précis sur les apprenants et leur environnement. En haut du modèle, on peut visualiser l'évolution du contrôle humain à travers les différents niveaux. Les mains sur la tablette symbolisent le niveau de contrôle de l'enseignant. Les deux mains sur la tablette symbolisent le contrôle total de l'enseignant, une seule main ou pas de main symbolisant le contrôle partiel, c'est-à-dire un contrôle secondaire ou aucun contrôle de sa part. Les yeux représentent le niveau requis de suivi de l'enseignant, à savoir un suivi complet, partiel, ponctuel ou aucun. Le triangle d'avertissement indique que l'IA peut demander à l'enseignant de reprendre le contrôle à des moments critiques. Dans la prochaine section, nous verrons comment l'IA utilise différents types de données pour effectuer ses opérations.

Au niveau 0, l'enseignant a une maîtrise complète de l'environnement d'apprentissage et la technologie pédagogique n'a aucune fonction d'organisation. C'était la norme, il y a environ une quinzaine d'années, dans l'enseignement dans la plupart des pays de l'OCDE.

Au niveau 1, l'enseignement assisté, les enseignants ont un contrôle total, la technologie ne leur fournissant qu'une aide supplémentaire dans l'organisation de l'environnement d'apprentissage. La technologie procure un accès au matériel pédagogique et à des informations complémentaires sur les activités de l'apprenant, mais elle ne contrôle aucun élément de l'environnement d'apprentissage. Ainsi, les environnements d'apprentissage électroniques et les systèmes de gestion de l'apprentissage qui dispensent le matériel pédagogique représentent des formes d'aide à l'enseignement. Il en est de même pour les tableaux de bord des enseignants qui fournissent des informations simultanées sur les activités, les progrès et la réussite des élèves (Dillenbourg, 2021_[14]). Grâce à ces informations, les enseignants peuvent prendre des décisions pédagogiques avant et pendant les cours (Bodily et al., 2018_[15]). Le tableau de bord offre, par exemple, une vue d'ensemble des progrès des élèves et permet à l'enseignant d'adapter son prochain cours. En ayant un aperçu des bonnes et mauvaises réponses des élèves, l'enseignant peut détecter les élèves ayant besoin de commentaires supplémentaires ou d'un enseignement plus approfondi (Molenaar et Knoop-van Campen, 2019_[16]). Il existe également des systèmes grâce auxquels les enseignants peuvent suivre les comportements des élèves, ce qui leur permet d'estimer si ceux-ci ont besoin d'un rattrapage proactif (Miller et al., 2015_[17]). En résumé, les fonctions des technologies d'apprentissage au niveau de l'enseignement assisté ont pour but d'aider les enseignants, ainsi que de décrire et refléter le comportement des apprenants. L'enseignant contrôle et supervise. Cette pratique est la norme dans les pays de l'OCDE où les systèmes informatiques se répandent plus largement dans les classes.

Dans l'automatisation partielle (niveau 2), l'enseignant laisse la technologie prendre en charge l'accomplissement de tâches d'organisation spécifiques. Ainsi, le système Snappet (voir Encadré 3.1) choisit des exercices adaptés aux besoins de chaque élève ou fournit des commentaires sur la solution apportée par l'élève à un exercice de maths. En laissant la technologie se charger de ces tâches, l'enseignant peut consacrer du temps à d'autres activités qui ne sont pas à la portée de la technologie, telles que donner des commentaires détaillés aux élèves ou aider ceux qui ont besoin d'explications supplémentaires. Dans le cadre de l'automatisation partielle, les fonctions de la technologie d'apprentissage sont catégorisées comme suit : *décrire*, *diagnostiquer*, *conseiller* et dans certains cas précis, *prendre des mesures*. À ce niveau, les enseignants contrôlent la plupart des tâches d'organisation de l'environnement d'apprentissage, à quelques exceptions près où c'est la technologie qui prend le relais. Les enseignants sont encore totalement maîtres du fonctionnement de la technologie dans laquelle leurs tableaux de bord ont souvent un rôle essentiel.

Au niveau 3 de l'automatisation conditionnelle, la technologie prend en charge une plus large part des tâches relatives à l'organisation de l'environnement d'apprentissage. Les enseignants occupent encore une position centrale dans l'organisation de l'environnement d'apprentissage et ils supervisent le fonctionnement des technologies. Par exemple, le système Cognitives Tutor (voir l'Encadré 3.2) choisit les exercices et donne un retour d'information à chaque étape de la résolution de problèmes en fonction des progrès des élèves (Koedinger et Corbett, 2006_[18]). La technologie s'occupe à la fois de la sélection des exercices et des retours d'information. À ce niveau, il est essentiel que la technologie sache déceler dans quelles conditions elle fonctionne efficacement et quand l'enseignant doit reprendre le contrôle. Dans ces moments décisifs, la technologie avertit l'enseignant qu'il doit agir. Par exemple, lorsqu'un élève ne progresse pas au rythme prévu, le système en informe l'enseignant pour qu'il intervienne (Holstein, McLaren et Aleven, 2017_[19]). L'enseignant peut alors rechercher les raisons de ce retard et prendre des mesures correctives. Les fonctions de la technologie d'apprentissage dans l'automatisation conditionnelle sont : intervenir beaucoup plus largement dans l'environnement d'apprentissage ; avertir et conseiller lorsque l'intervention humaine est nécessaire.

Dans l'automatisation élevée (niveau 4), la technologie contrôle totalement l'organisation de l'environnement d'apprentissage dans un domaine précis. Elle réagit efficacement dans la plupart des situations anticipées dans le domaine et tient compte de la diversité des apprenants. Les enseignants n'ont pas besoin de se tenir prêts à reprendre le contrôle et leur supervision n'est pas nécessaire. Dans certaines situations plus pointues, la technologie redonne le contrôle ou la supervision aux enseignants. Les systèmes d'apprentissage autonomes conçus pour aider individuellement les apprenants dans des matières comme les maths, les sciences et les langues peuvent atteindre ce niveau. Par exemple, le système MathSpring est un système de tutorat intelligent qui guide l'apprenant dans le choix de ses objectifs d'apprentissage, lui fournit un enseignement personnalisé, des possibilités de s'exercer et des commentaires afin d'atteindre les objectifs fixés (Arroyo et al., 2014_[20]). En ce qui concerne la technologie, l'enseignant n'effectue aucune tâche de contrôle ou de supervision. À ce jour, ce type

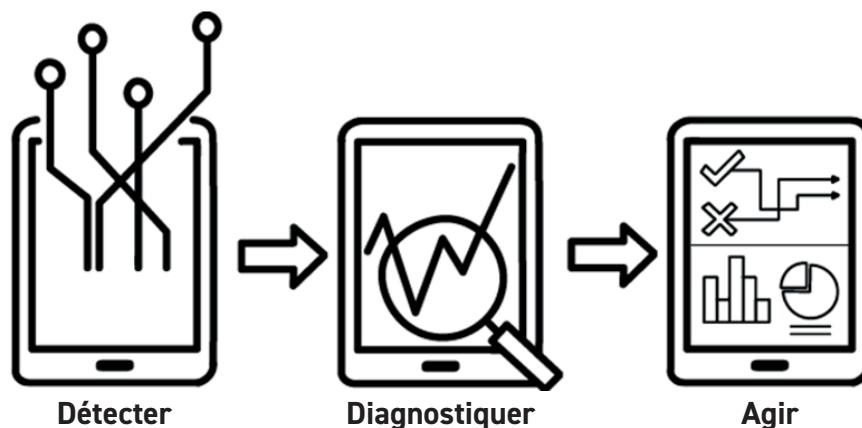
de technologie d'apprentissage hautement autonome reste rare et n'intervient que de manière très limitée dans le programme d'enseignement. Les fonctions de la technologie d'apprentissage dans ce niveau d'automatisation élevée sont : *piloter* les apprenants et, dans des circonstances exceptionnelles, *avertir* les autres humains qu'ils doivent prendre des mesures.

Au niveau 5 de l'autonomie complète, la technologie assume automatiquement l'apprentissage dans tous les domaines et toutes les situations. Elle se substitue totalement à l'enseignant. Ainsi, la technologie de l'apprentissage des langues Alelo¹, employée dans l'apprentissage d'une deuxième langue, pourrait bien évoluer en ce sens. Elle utilise déjà le programme de traitement du langage naturel qui analyse l'usage de la langue chez les élèves, fournit des commentaires, choisit les nouveaux objectifs d'apprentissage et adapte le cours et la pratique en vue d'améliorer le niveau de langue des élèves. Ces caractéristiques pourraient constituer les premières étapes vers un apprentissage complètement automatisé. Dans le contexte d'un contrôle total, la technologie piloterait l'apprentissage de l'apprenant de A à Z. Ce niveau représente le paradigme de nombreuses solutions d'apprentissage développées pour le marché de l'apprentissage informel dans un cadre extrascolaire, de l'apprentissage des langues à l'enseignement de la musique ou à la préparation d'un examen sur le code de la route. Il est primordial de se demander dans quelle mesure l'application de ces technologies serait viable dans le contexte des établissements scolaires et ce qu'elle impliquerait en matière de responsabilité des enseignants et de justification de leur rôle.

Réflexion prospective : le rôle ultime de l'IA

En plus de définir le rôle des enseignants et de l'IA, les six niveaux d'automatisation nous aident à réfléchir sur les attentes à l'égard du rôle ultime de l'IA. En ce qui concerne les voitures autonomes, il est communément admis qu'on n'atteindra pas l'automatisation totale sur toutes les routes et dans toutes les situations (Shladover, 2018_[21]). Trois niveaux de contraintes l'en empêchent : i) la détection de l'environnement grâce à des capteurs, ii) le diagnostic précis des risques, iii) la détermination des actions adéquates. En ce qui concerne plus particulièrement le dernier aspect, la recherche a démontré qu'il était compliqué de déterminer une action dans des conditions difficiles (Awad et al., 2018_[11]). De même, dans le cas du rôle de l'IA dans la prise de décisions médicales, il est peu probable qu'il dépasse un jour le niveau de l'automatisation conditionnelle (Topol, 2019_[12]). Pourtant, la capacité de traiter de vastes ensembles de données de manière rapide, précise et peu coûteuse, ainsi que la capacité de détecter et de diagnostiquer beaucoup mieux que l'humain sont présentées comme les fondements de la médecine ultra performante.

Graphique 3.3 Vers une éducation performante avec l'IA : trois défis à relever




Source: Illustration - Anne Horvers et Inge Molenaar, Source: Adaptive Learning Lab, <https://www.ru.nl/bsi/research/group-pages/adaptive-learning-lab-all>.

Pour les mêmes raisons, ces éléments formeront également les fondements d'une éducation performante (voir le Graphique 3.3). Historiquement, le modèle dominant d'IA dans l'éducation est l'automatisation complète, c'est-à-dire un élève apprenant sur un ordinateur intelligent et des enseignants remplacés par la technologie (Blikstein, 2018^[22]). Ce modèle a fait son apparition dans les années 1950 avec les machines à enseigner de Skinner (Wingo, 1961^[23]) et s'est développé avec les systèmes de tutorat intelligents. La recherche a montré qu'un élève aidé individuellement par un tuteur expérimenté peut améliorer sa performance d'apprentissage de deux écarts-types par rapport à la situation où les élèves apprennent dans les conditions classiques d'une salle de classe (Bloom, 1984^[24]). Cela signifie que 98 % des élèves réussiraient mieux grâce à un tutorat humain particulier que grâce à un enseignement classique en classe. Depuis lors, ce « *problème des deux sigmas* » a servi d'argument principal dans la personnalisation de l'apprentissage au moyen des technologies d'apprentissage. Au cœur de cette analogie se trouve l'hypothèse que la technologie, tout comme le tuteur humain, est à même de comprendre un apprenant. La nouvelle analyse des données de Bloom effectuée par VanLehn suggère que l'avantage est moindre en faveur des tuteurs humains (un écart-type d'environ 0,75), et démontre également que des systèmes de tutorat intelligent bien développés peuvent s'avérer tout aussi efficaces que des tuteurs humains (VanLEHN, 2011^[25]). Dans certains cas spécifiques, la technologie a vraiment les mêmes capacités que les bons tuteurs humains (VanLEHN, 2011^[25]), mais cela se limite à des domaines restreints et bien spécifiques. Il convient de retenir que les objectifs de l'éducation vont bien au delà du tutorat dans la matière. La question est de savoir si le but est d'optimiser la technologie pour l'amener à une automatisation complète ou d'optimiser les systèmes combinant humain et IA dans les autres niveaux d'automatisation. Une partie de la réponse repose sur nos capacités à détecter, diagnostiquer et agir. De telles avancées dans la personnalisation de l'apprentissage, tout comme les avancées en matière de véhicules autonomes, reposent sur trois points importants : i) notre capacité à suivre les apprenants dans leur environnement ; ii) notre capacité à diagnostiquer la situation actuelle des apprenants et à anticiper leur développement ; iii) notre capacité à déterminer alors les mesures convenant le mieux à l'optimisation de l'apprentissage. Nous allons maintenant examiner notre capacité actuelle à chaque niveau.

Détecter : suivi des apprenants dans leur environnement

Notre capacité de suivi des apprenants dans leur environnement s'améliore petit à petit (Baker et Inventado, 2014^[26] ; Winne et Baker, 2013^[6]). Les apprenants ne se ressemblent pas et leurs différences constituent des indicateurs significatifs pour la personnalisation de l'apprentissage (Azevedo et Gašević, D., 2019^[27]). La recherche a toujours beaucoup compté sur l'utilisation de données de journal des technologies d'apprentissage pour suivre les apprenants. Bien que cette utilisation reste importante dans le domaine de la personnalisation de l'apprentissage, on fait de plus en plus appel à d'autres sources de données pour comprendre les caractéristiques essentielles des apprenants. On peut considérer ces sources de données multimodales comme des données physiologiques, comportementales et contextuelles.

Graphique 3.4 Des sources de données multimodales pour le traçage des apprenants et de leur environnement



Source. Illustration - Anne Horvers et Inge Molenaar / Adaptive Learning Lab.

Les *données physiologiques* correspondent aux réponses corporelles des élèves durant l'apprentissage. La fréquence cardiaque (FC), l'activité électrodermale (AED), la tension artérielle (TA), la température de la peau et les logiciels de capture des expressions du visage pour évaluer l'état des apprenants en sont autant d'exemples.

Les *données comportementales* détectent des aspects du comportement de l'élève durant l'apprentissage. L'une des sources majeures des données comportementales sont les fichiers-journaux. Ces données répertorient à la milliseconde les séquences des interactions de l'apprenant et de la technologie qui laissent une trace des activités effectuées à l'aide des technologies d'apprentissage. Une autre source de données comportementales sont les mouvements de la souris et les saisies du clavier. Les mouvements oculaires révèlent ce que l'élève regarde durant l'apprentissage et peuvent servir à détecter ce qui accapare l'attention de l'élève, le visionnement de sources multimédia et la lecture dans le cadre des technologies d'apprentissage (Mudrick, Azevedo et Taub, 2019_[28]). Des appareils portatifs de suivi oculaire évaluent également l'interaction avec les objets et l'interaction sociale durant l'apprentissage. En outre, des données spécifiques de suivi oculaire comme la dilatation des pupilles et le clignement des yeux ont aussi été mises en corrélation avec la charge cognitive et les états affectifs.

Les *données contextuelles* procurent des données plus complètes sur les interactions de l'apprenant avec la technologie d'apprentissage, les humains et les ressources dans l'environnement pédagogique. Les enregistrements vidéo et de la voix contiennent des données intéressantes sur la manière dont l'apprenant interagit avec son environnement. Bien que ces données permettent des analyses approfondies du processus d'apprentissage, elles reposent surtout sur le codage, la notation, les annotations, la compréhension et leur interprétation par les chercheurs. Ceci pourrait radicalement changer prochainement grâce aux progrès dans les techniques d'IA, puisque quelques premiers exemples voient déjà le jour (Stewart et al., 2019_[29]). Finalement, il ne faudrait pas négliger l'auto-évaluation, car c'est une source valable de données.

En résumé, l'utilisation des sources de données multimodales peut faire progresser le traçage des apprenants et de leur environnement, ce qui est une étape cruciale vers une automatisation plus poussée.

Diagnostic : évaluation de l'état actuel des apprenants

L'étape suivante consiste à analyser les données afin de poser un diagnostic sur l'état actuel des apprenants et anticiper leur évolution future. Une grande partie des travaux s'est intéressée au diagnostic de l'état des connaissances des élèves et de leur progrès durant l'apprentissage. De nombreux modèles ont été mis au point pour évaluer les connaissances des apprenants durant leur apprentissage en fonction du comportement des élèves lors de la résolution de problèmes et de leurs réponses aux problèmes (Desmarais et Baker, 2011_[30]). Nous en discutons plus en détail dans la section suivante. La recherche s'efforce de plus en plus d'élargir le champ d'évaluation des états des apprenants, comme ceux de la motivation, la métacognition et les émotions (Bosch et al., 2015_[31]). Une grande partie de ces travaux sont effectués dans des matières structurées comme les maths et la physique où les élèves donnent des réponses claires à des problèmes bien précis. Nous observons également une tendance grandissante vers un diagnostic spécifique à la matière et au contexte.

Les avancées dans des techniques spécifiques de l'IA permettent l'évaluation de caractéristiques qui sont primordiales dans les processus d'apprentissage et de développement. Ainsi, les avancées dans la *reconnaissance vocale automatisée* permettent de détecter la manière dont les élèves apprennent à lire². L'analyse de l'oralisation d'un enfant lors de la lecture détectée par reconnaissance vocale automatisée permet d'extraire des particularités qui facilitent le diagnostic sur la capacité de lecture de l'enfant, telles que : les lettres qu'un enfant reconnaît bien ; la vitesse à laquelle il déchiffre des mots de différentes longueurs ; et le type de mots qui ont été automatisés. Ces particularités permettent de poser un diagnostic précis sur l'évolution de la capacité de lecture d'un enfant au fil du temps et peuvent, par conséquent, servir à personnaliser l'enseignement. En plus de la reconnaissance vocale (du texte à la parole), un premier logiciel de diagnostic de la lecture (Lexplore³) est également disponible, qui utilise des données de suivi oculaire pour diagnostiquer l'évolution de la lecture des apprenants.

Dans le même ordre d'idées, on peut diagnostiquer l'évolution des compétences en écriture et même les déficiences motrices comme la dysgraphie (Asselborn et al., 2018_[32]). La méthode d'Asselborn évalue les compétences en écriture d'un élève à l'aide d'une tablette et d'un stylo numérique. Lors de l'apprentissage de l'écriture, on peut mesurer des paramètres importants liés à la trajectoire de développement de l'écriture, tels que la vitesse de l'écriture, la force de la pression du stylo et son orientation. La méthode peut extraire jusqu'à 56 paramètres liés aux compétences en écriture de l'élève, qui peuvent, par conséquent, mener à la mise en place d'un tutorat

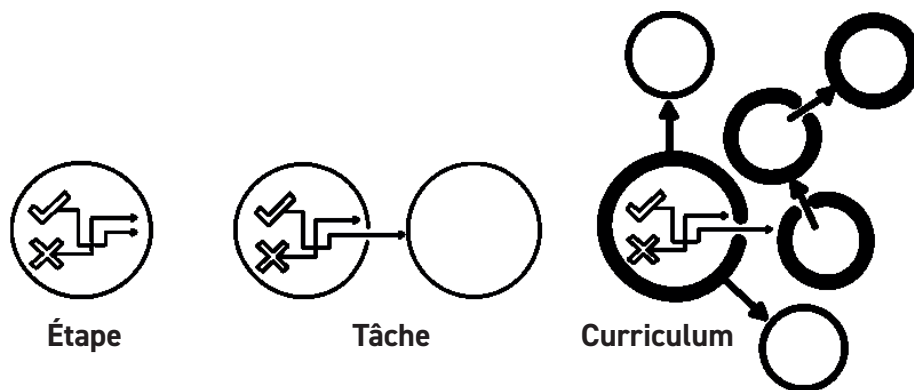
afin d'améliorer son écriture. Les dépistages de la dyslexie fondés sur le type d'erreurs faites par l'élève sur un ensemble de problèmes spécifiques (Dyctective⁴), les diagnostics sur le développement du langage (Lingvist⁵) et sur les compétences fonctionnelles en écriture (Letrus⁶) sont d'autres exemples de mécanismes de diagnostics propres à une matière.

En résumé, le développement d'outils de diagnostic génériques et spécifiques dans une matière basés sur les techniques d'IA avancées nous aide à mieux comprendre l'état des apprenants et à prévoir leur évolution. C'est une deuxième étape importante vers des niveaux avancés d'automatisation des technologies d'apprentissage.

Agir : déterminer les actions pertinentes

La dernière étape consiste à interpréter le diagnostic posé sur l'état de l'apprenant et à le traduire en actions qui optimiseront l'apprentissage (Shute et Zapata-Rivera, 2012). Passer du diagnostic à des interventions pédagogiques efficaces est sans doute l'étape la plus difficile (Koedinger, Booth et Klahr, 2013_[33]). Comme le décrit le document cadre *Knowledge-Learning-Instruction Framework* (savoirs-apprentissage-enseignement) (Koedinger, Corbett et Perfetti, 2012_[34]), il existe une infinité de modèles de réponses possibles, mais peu d'éléments factuels quant aux interventions les plus efficaces dans certaines circonstances. Même s'il est désormais possible de poursuivre des recherches avancées à grande échelle en éducation sur les interventions efficaces dans le cadre des technologies d'apprentissage, les contraintes relatives au financement de la recherche empêchent le terrain de tirer pleinement parti de ces opportunités. La prise en compte de cette complexité a entraîné le développement de solutions analytiques qui fournissent aux enseignants des informations supplémentaires leur permettant d'apporter des réponses pédagogiques viables. Ainsi, les tableaux de bord des enseignants qui fournissent des informations simultanées sur les activités, les bonnes réponses et les progrès des apprenants permettent aux enseignants d'améliorer leurs pratiques de rétroaction et les résultats d'apprentissage (Knoop-van Campen et Molenaar, 2020_[35] ; Holstein, McLaren et Aleven, 2018_[36]). Ces tableaux se sont révélés être une intervention efficace en soi et constituent des outils permettant de définir des interventions efficaces que les technologies pédagogiques se chargeront d'exécuter. La distinction entre analyse extraite et intégrée est une étape essentielle pour développer des modèles de réponses avancés qui tiennent compte des connaissances et compétences pédagogiques des enseignants et reconnaissent la nécessité de développer une meilleure compréhension de ces relations dans le cadre de la recherche (Wise, 2014_[37]).

Graphique 3.5 Trois types d'interventions dans les actions indépendantes de la matière



Source : Illustration - Anne Horvers et Inge Molenaar / Adaptive Learning Lab.

Lorsque des adaptations génériques de la matière sont effectuées dans les technologies d'apprentissage, elles mettent généralement en œuvre trois types d'actions : voir le Graphique 3.5 (Vanlehn, 2006_[5]). La première est une action au niveau de l'étape : les commentaires sont personnalisés en fonction des besoins de l'apprenant dans l'exercice. Les apprenants reçoivent des commentaires détaillés leur indiquant la bonne méthode à suivre au cours d'une étape particulière de l'exercice de résolution de problèmes. La deuxième est une action au niveau de la tâche : la tâche ou le problème pertinent suivant est choisi en fonction des performances de l'élève. Les élèves doivent travailler sur un exercice en adéquation avec leur socle de connaissances actuel, en fonction de leurs

réponses au problème précédent. La troisième est une action au niveau du programme de cours : l'organisation des sujets d'enseignement est adaptée à l'apprenant. Cette action implique de faire une sélection approfondie des sujets les mieux adaptés à la trajectoire de développement des élèves. Par contraste, les adaptations spécifiques à une matière suivent une logique qui est adaptée à la matière, comme le montre l'exemple de la lecture décrit ci-dessus où les adaptations sont motivées par des connaissances approfondies sur le développement de la lecture.

En conclusion, la détection et le diagnostic sont mis en œuvre dans différentes actions pédagogiques en lien avec la technologie d'apprentissage, adaptant les étapes, les tâches ou le type d'enseignement. En plus de la mise en œuvre directe, il est également possible de faire remonter le diagnostic à l'enseignant pour qu'il détermine des expériences pédagogiques efficaces. Cette tendance est le reflet d'une prise de conscience que les interventions basées sur des données probantes sont essentielles pour progresser vers une automatisation plus poussée dans le domaine de l'éducation. Comme mentionné plus haut, une grande partie des travaux dans ce domaine se sont concentrés sur la détection, le diagnostic et les actions basées sur les connaissances des élèves. Dans la section suivante, nous examinerons les récentes innovations dans le domaine.

La personnalisation en fonction des connaissances des élèves

La personnalisation en fonction des connaissances et compétences de l'apprenant étant l'approche la plus répandue, nous continuerons d'étudier la détection, le diagnostic ainsi que l'adoption de la personnalisation en fonction des connaissances et compétences des apprenants. La plupart des travaux de recherche se sont penchés sur la détection à partir des données de journal, le diagnostic sur l'état des connaissances des élèves et l'évolution de ces connaissances au cours de l'apprentissage, ainsi que leur transposition en actions pédagogiques. Comme mentionné plus haut, les adaptations en fonction du diagnostic posé sur la connaissance des élèves sont en général fournies au niveau de l'étape, au niveau de la tâche ou du programme de cours.

L'adaptation des problèmes au niveau de la tâche

Traditionnellement, les adaptations au niveau de la tâche se faisaient en fonction des évaluations des connaissances des élèves *avant* de commencer l'apprentissage. Il en est ainsi pour les exercices et pratiques mis en œuvre à des fins de rattrapage, c'est-à-dire pour aider les élèves à combler des lacunes précises dans leurs connaissances. On a constaté que les programmes d'enseignement assisté par ordinateur (EAO) améliorent l'apprentissage en s'appuyant sur les résultats des élèves à une évaluation formative pour sélectionner un ensemble prédéfini de problèmes adaptés au niveau de connaissances des élèves, mais ces programmes n'ont pas la souplesse nécessaire pour s'adapter à l'évolution des connaissances des apprenants durant leur apprentissage (Dede, 1986_[38]).

Pour répondre à cette difficulté, les travaux de recherche se sont penchés sur la détection de l'évolution des connaissances des élèves pendant l'apprentissage. Les technologies détectent l'évolution des connaissances *au cours* de l'apprentissage en s'appuyant sur les données de journal, telles que l'exactitude des réponses et le temps de réponse (Koedinger et Corbett, 2006_[18]). Ce développement s'appuie sur les hypothèses théoriques de la *pédagogie de la maîtrise selon* lesquelles chaque étudiant a des besoins individuels en ce qui concerne l'enseignement, le type de soutien et sa durée (Bloom, 1984_[24]). La première étape consiste à adapter le temps alloué à l'élève pour apprendre un sujet spécifique (Corbett et Anderson, 1995_[39]). Le raisonnement est le suivant : avant de passer à un autre sujet, l'apprenant doit maîtriser les sujets préalables. Les réponses de l'élève permettent à la technologie de déterminer s'il maîtrise suffisamment un sujet spécifique pour pouvoir passer à un autre. Ainsi, l'élève bénéficie d'une durée d'apprentissage personnalisée lui permettant de travailler suffisamment longtemps sur un sujet pour pouvoir le maîtriser.

En plus de l'individualisation de la durée de l'apprentissage consacré à un sujet, les technologies d'apprentissage peuvent également adapter chaque problème aux connaissances de l'élève. La technologie d'apprentissage adaptif *mathgarden*, par exemple, évalue les connaissances actuelles de l'élève afin de déterminer la tâche mathématique suivante qui lui conviendra le mieux (Klinkenberg, Straatemeier et van der Maas, 2011_[40]). De cette manière, non seulement le temps nécessaire pour arriver à maîtriser un sujet, mais aussi le rythme d'apprentissage de l'élève sont personnalisés. Grâce à ces technologies d'apprentissage, les exercices correspondent au niveau de connaissance détecté chez l'élève. Deux éléments entrent en jeu : i) tous les problèmes sont évalués en fonction de leur difficulté et ii) les connaissances des élèves sont évaluées en fonction de leurs réponses à ces problèmes.

C'est ainsi que la technologie permet d'adopter une approche adaptative grâce à laquelle elle choisit des problèmes correspondant au niveau de difficulté relative de chaque élève. Un certain nombre de pays de l'OCDE ont désormais mis en place ces technologies à grande échelle (voir Encadré 3.1).

L'adaptation des commentaires au niveau de l'étape

En plus des adaptations au niveau de la tâche, un ensemble de technologies opère des adaptations au niveau de l'étape. On résout, par exemple, des problèmes de maths complexes en plusieurs étapes. Dans des matières structurées comme les maths, la physique et la chimie, ces étapes peuvent être reliées aux sujets spécifiques qu'elles abordent. À partir de ces informations, les algorithmes peuvent non seulement détecter le niveau de connaissances actuelles des élèves, mais également analyser le type d'erreurs qu'ils commettent (Baker, Corbett et Aleven, 2008_[41]). Celles-ci sont de deux types : i) les erreurs que l'élève commet alors même qu'il connaît les réponses, en inversant, par exemple, les chiffres et ii) les erreurs qu'il commet lorsqu'il a mal compris, ce qui entraîne une mauvaise réponse. Cette distinction est importante, car elle permet de déterminer le commentaire adapté. En fonction du type d'erreurs commises, la technologie peut adapter le commentaire aux besoins de l'élève ou suggérer des étapes de résolution de problèmes pour arriver à une bonne compréhension. Ainsi, à la fin d'une première série de calcul, l'élève reçoit des commentaires sur l'exactitude des étapes suivies et des réponses données. Un bon nombre de technologies de pointe, souvent désignés comme des systèmes de tutorat intelligents, fournissent à l'élève des commentaires personnalisés dans le cadre d'une tâche ou d'un exercice (VanLEHN, 2011_[25]). Ces systèmes étudient les réponses de l'élève à une tâche afin de fournir des commentaires automatisés et détaillés à chacune des étapes. Les systèmes aident ainsi l'élève dans la résolution de problèmes au niveau de la tâche (voir Encadré 3.2 Le tuteur cognitif, MATHia : un exemple de technologie adaptative d'apprentissage largement répandu en mathématiques).

Adaptation des modules au niveau du programme de cours

Enfin, l'optimisation au niveau du programme de cours correspond à l'ordre dans lequel l'élève travaille sur différents sujets. On appelle également cet ordre le parcours d'apprentissage. Dans ce cas, la technologie vise à établir une vue d'ensemble des connaissances et compétences de l'apprenant afin d'éclairer les futures décisions pédagogiques (Falmagne et al., 2006_[50]). Ces systèmes déterminent l'ordre dans lequel les apprenants peuvent le mieux aborder un sujet dans une matière. Ils proposent différents parcours pour aborder les sujets qui sont tous reliés entre eux en fonction de l'ordre dans lequel les élèves maîtrisent les sujets et, par conséquent, personnalisent l'ordre dans lequel l'élève apprend dans une matière. ALEKS⁷ est un exemple de technologie d'apprentissage qui utilise cette méthode et adapte la sélection des modules d'enseignement en fonction des résultats précédents de l'élève.

Le moment opportun de la révision est un autre élément essentiel qui peut être adapté au niveau du programme de cours. *L'effet d'espacement* indique qu'il y a un délai optimal entre l'apprentissage de sujets donnés. On peut déterminer ce temps en fonction du rythme auquel l'apprenant oublie (Pavlik et Anderson, 2005_[51]). La modélisation de cette courbe d'oubli permet de déterminer à quel moment un apprenant devrait revoir un sujet donné (Pashler et al., 2007_[52]). Ceci s'est avéré un facteur essentiel dans l'apprentissage des mots, par exemple, pour améliorer la mémorisation du nouveau vocabulaire. WRTS⁸ est un exemple d'une telle application dans les technologies d'apprentissage : il utilise un algorithme pour déterminer les courbes d'oubli chez l'élève lors de l'acquisition d'un vocabulaire nouveau dans une langue étrangère. À partir de la courbe d'oubli de chaque élève, le système détermine l'intervalle auquel les mots sont répétés dans les problèmes pratiques. Ces deux exemples permettent d'adapter les parcours et les schémas de répétition à chaque élève, ce qui serait impossible sans l'algorithme. Enfin, les réponses des élèves peuvent servir à diagnostiquer une mauvaise compréhension, laquelle peut être traitée au niveau de l'étape (voir le système MATHia dans Encadré 3.2), mais également au niveau du programme de cours. Dans ce cas, le système opère une analyse des erreurs commises durant l'exercice, qui se traduisent en lacunes d'apprentissage que l'on peut combler par l'ajout de modules d'exercices supplémentaires. Le système Mindspark illustré dans l'Encadré 3.3 ci-dessous en est un exemple.

Encadré 3.1 Le système Snappet : un exemple de technologie d'apprentissage adaptif mise en œuvre à grande échelle aux Pays-Bas

Détecter :

- Les réponses des élèves aux problèmes dans une matière et avec un certain niveau de difficulté

Diagnostiquer :

- L'évolution des connaissances de l'élève au cours de l'apprentissage à l'aide de l'algorithme ELO
- Analyse prédictive de l'évolution de l'élève au fil du temps

Agir :

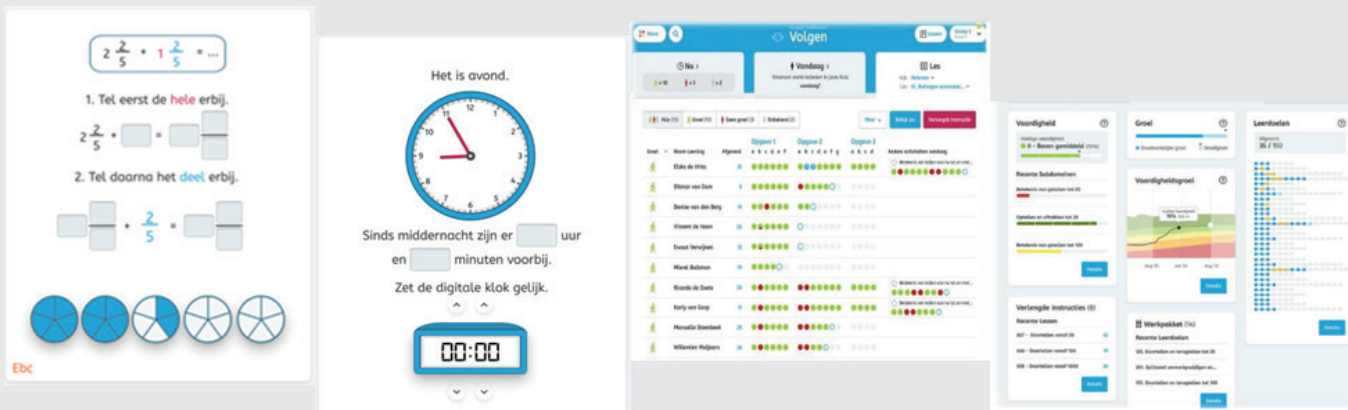
Automatisation partielle :

- Fournit un commentaire direct à la suite des réponses de l'élève (niveau de l'étape)
- Choisit les problèmes adaptés aux connaissances de l'élève (niveau de la tâche)
- Détermine le moment de passer au sujet suivant en fonction de l'analyse prédictive (niveau du programme de cours)

Enseignement assisté :

- Fournit des tableaux de bord en temps réel permettant aux enseignants de voir les progrès et les résultats au niveau de la classe
- Fournit des tableaux de bord en temps réel permettant aux enseignants d'avoir une vue d'ensemble de l'évolution de l'étudiant et des analyses prédictives
- Fournit aux élèves des tableaux de bord contenant des informations sur leurs progrès

Graphique 3.6 Les problèmes et les tableaux de bord du système Snappet



Source: Illustration – Snappet (s.d._[42]).

Information sur la mise en œuvre :

Élèves : Enseignement primaire de la première à la cinquième année (Espagne) et jusqu'à la sixième année (Pays-Bas)

Matières : Arithmétique, mathématiques, orthographe et grammaire néerlandaise, compréhension de l'écrit

Échelle : 2 800 établissements scolaires (45 % des établissements primaires des Pays-Bas) et 1 000 établissements en Espagne

Résultats : améliorations des résultats en maths au bout de 6 mois (Faber, Luyten et Visscher, 2017_[43]), amélioration des résultats en maths et légère amélioration de l'orthographe au bout d'un an (Molenaar et van Campen, 2016_[44]), des résultats diversifiés sur plusieurs années de mise en œuvre (Molenaar, Knoop-van Campen et Hasselman, 2017_[45]) par rapport à d'autres méthodes sur papier.

Encadré 3.2 Le tuteur cognitif MATHia : un modèle de technologie d'apprentissage adaptif largement répandu en mathématiques (États-Unis)

Détecter :

- Les réponses des élèves aux problèmes et à diverses étapes dans le cadre d'exercices de maths

Diagnostiquer :

- L'évolution des connaissances des élèves au cours de l'apprentissage à l'aide de l'algorithme de traçage bayésien des connaissances
- Les erreurs des élèves sur des problèmes et à diverses étapes dans le cadre d'exercices de maths

Agir :

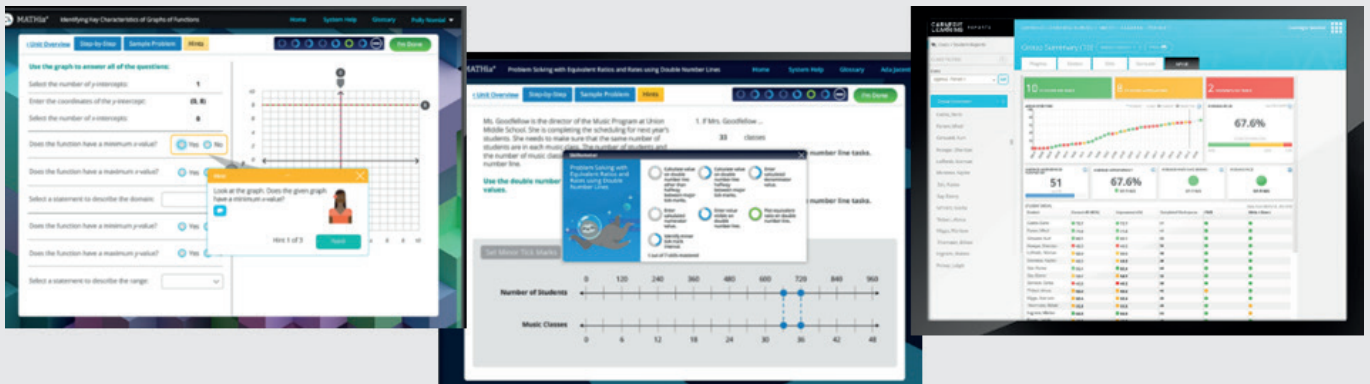
Automatisation conditionnelle :

- Fournit des commentaires directs et détaillés sur les réponses de l'élève à un problème (niveau de l'étape)
- Assigne les étapes suivantes en fonction des réponses de l'élève (niveau de l'étape)
- Détermine à quel moment l'élève maîtrise un sujet (niveau du programme de cours)

Enseignement assisté :

- Fournit des rapports permettant d'adapter la pédagogie
- Fournit des rapports de planification aux enseignants et administrateurs ainsi que des tableaux de bord en temps réel (LiveLab) à l'intention des enseignants.

Graphique 3.7 Les exercices et tableaux de bord dans MATHia



Source : Illustration - Carnegie Learning (s.d._[46]).

Information sur la mise en œuvre :

Élèves : de la sixième à la douzième année

Matières : Mathématiques

Échelle : 600 000 élèves

Résultats : amélioration des résultats en maths (Koedinger et Corbett, 2006_[18] ; Pane et al., 2010_[47] ; Pane et al., 2014_[48] ; Ritter et al., 2007_[49]) par rapport à des méthodes sur papier ou aux différentes interventions de systèmes de tutorat intelligents.

Encadré 3.3 Mindspark : Un exemple de technologie d'apprentissage adaptatif en Inde

Détecter :

- Les élèves effectuent un test diagnostique afin d'évaluer leurs connaissances et leurs idées fausses sur un sujet
- Les élèves répondent à des questions conçues pour déterminer le type d'incompréhension détecté sur un sujet (des lacunes dans les connaissances)

Diagnostiquer :

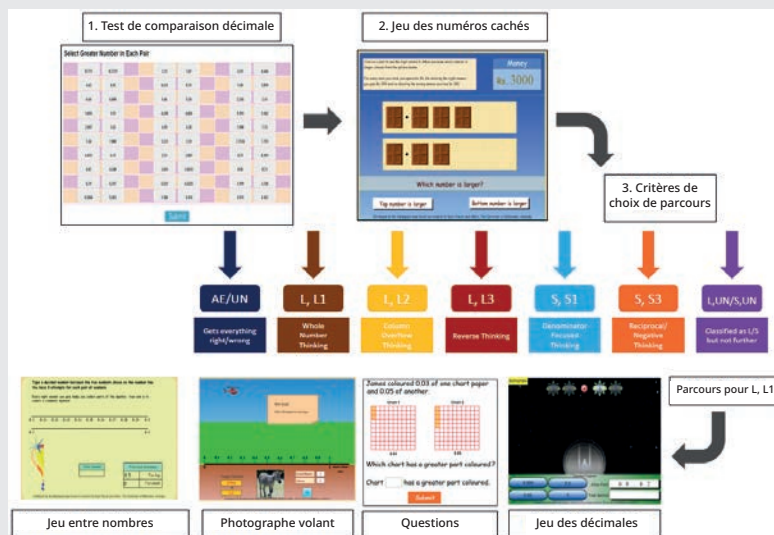
- Les schémas d'erreurs dans les réponses des élèves sur un sujet
- Un enseignement correctif ciblé est assigné en fonction du blocage conceptuel détecté

Agir :

Automatisation conditionnelle :

- Fournit divers supports pédagogiques (questions, jeux interactifs, activités) conçus spécialement pour répondre aux incompréhensions et aux lacunes qui ont été diagnostiquées (niveau de la tâche)
- Fournit des commentaires spécifiques et ponctuels lorsqu'une mauvaise réponse est donnée (niveau de l'étape)
- Détermine si l'élève peut passer au niveau de difficulté suivant (niveau de la tâche ou du programme de cours)

Graphique 3.8 Activités correctives personnalisées pour apprendre les décimales en fonction des schémas d'erreurs



Remarque : Illustration de l'adaptabilité en fonction des schémas d'erreurs : un enfant peut se voir assigner le « test de comparaison décimale ». S'il répond correctement à la plupart des questions de ce test, il se voit alors assigner le jeu des numéros cachés (Hidden Number Game), un exercice légèrement plus difficile. Par contre, s'il ne répond pas correctement à la plupart des questions, il se verra assigner une activité correctrice en fonction de son type d'incompréhension. Par exemple, si ses erreurs sont dues à une pensée centrée sur le nombre entier (p. ex., croire que 3,27 est plus grand que 3,3 parce qu'il compare les nombres à droite de la virgule et en conclut (de manière erronée) que puisque 27 est plus grand que 3, alors 3,27 est plus grand que 3,3), il se verra assigner le jeu des décimaux (Decimalians Game) conçu pour répondre à ce type d'idées fausses. Développé par l'équipe de Mindspark d'après les recherches de Kaye Stacey et autres, Université de Melbourne.

Source : Muralidharan, Singh et Ganimian (2019_[53]), Graphique D.1.

Information sur la mise en œuvre :

Élèves : de la première à la dixième année

Matières : Mathématiques, Hindi, anglais

Résultats : un programme extrascolaire combinant Mindspark et un enseignement en groupe a amélioré les résultats d'apprentissage (Muralidharan, Singh et Ganimian, 2019_[53]).

Ci-dessous, nous examinerons à quels niveaux ces récentes innovations se situent dans le modèle d'automatisation.

Place des technologies d'apprentissage actuelles dans les niveaux du modèle d'automatisation

Comme nous l'avons vu plus haut, il y a eu des progrès dans la détection et le diagnostic des connaissances et compétences des élèves durant l'apprentissage, qui s'effectuent le plus souvent au niveau de la tâche, du problème ou du programme de cours. On situe le plus souvent les technologies d'apprentissage existantes dans les trois premiers niveaux du modèle d'automatisation. Premièrement, au niveau de l'enseignement assisté, les technologies fournissent les tableaux de bord des enseignants. Deuxièmement, au niveau de l'automatisation partielle, les diagnostics posés sur les connaissances des élèves et sur l'évolution de ces connaissances servent à apporter des ajustements au niveau de l'étape, de la tâche ou du programme de cours. Ils débouchent sur l'automatisation des commentaires, la sélection des exercices et l'optimisation du programme de cours. Lorsque ces niveaux s'appliquent séparément, ce sont des exemples d'automatisation partielle, mais si on les combine, ces dispositifs correspondent davantage à de l'automatisation conditionnelle.

Les établissements scolaires des pays de l'OCDE font de plus en plus appel aux technologies en classe afin de faciliter l'enseignement et l'apprentissage des maths, des sciences et de la lecture. Cela peut se faire sous différentes formes, notamment par l'utilisation croissante des ordinateurs pour chercher des informations, pour mettre en pratique des compétences en maths, en sciences et en lecture, etc. (Vincent-Lancrin et al., 2019^[54]). Dans le but de personnaliser l'apprentissage des compétences de base en mathématiques, en grammaire et en orthographe, de nombreux établissements de l'enseignement primaire et secondaire ont intégré une variété de technologies d'apprentissage adaptatif et de systèmes de tutorat intelligents (STI) dans leur routine quotidienne en classe. En général, les jeunes élèves font leurs exercices de langue ou de mathématiques sur une tablette ou un ordinateur, qui recueillent alors de nombreuses données sur leurs performances. La génération actuelle des technologies utilise les données des élèves pour adapter les problèmes à leur niveau de connaissances prévu et, en parallèle, alimente les tableaux de bord des enseignants sur les progrès des élèves. Cette utilisation de la technologie favorise un enseignement plus efficace des compétences fondamentales (Faber, Luyten et Visscher, 2017^[43]) et, en principe, permet de libérer du temps pour travailler sur des compétences plus complexes comme la résolution de problèmes, l'autorégulation et la créativité.

La plupart des technologies d'apprentissage adaptatif ne s'adaptent qu'au niveau de la tâche et sont, par conséquent, des exemples d'automatisation partielle. Les systèmes de tutorat intelligents constituent une exception et peuvent être catégorisés comme des exemples d'automatisation conditionnelle. Ces technologies prennent le contrôle sur un large ensemble d'éléments dans l'organisation de l'environnement d'apprentissage. La plupart des systèmes intelligents opèrent des adaptations au niveau de la tâche et au niveau de l'étape, mais ils sont peu nombreux à contrôler les trois niveaux. En outre, alors que les systèmes de tutorat intelligents fonctionnent très bien dans des matières structurées, comme les maths et les sciences, peu conviennent aux matières non structurées (VanLehn, 2015^[55]). Bien que ces systèmes aient montré qu'ils amélioreraient les résultats d'apprentissage et optimiseraient l'apprentissage (Kulik et Fletcher, 2016^[56]), leur mise en œuvre dans les établissements reste limitée (Baker, 2016^[57]).

À cet égard, deux paramètres d'importance peuvent expliquer cette lente adoption dans la pratique. Le premier concerne les enseignants qui ont souvent l'impression que ces technologies les mettent à l'écart (Holstein, McLaren et Aleven, 2019^[58]), ce qui pourrait expliquer qu'ils ne les utilisent pas dans la pratique (Baker, 2016^[57]). S'attaquer efficacement aux limites de ces technologies pourrait marquer une étape importante vers une plus large acceptation de ces technologies. Les fonctionnalités des tableaux de bord ont été développées depuis longtemps dans ces systèmes, pourtant peu de travaux de recherche ont été menés pour développer l'utilité de ces tableaux de bord pour les enseignants. Ce n'est que récemment que des tableaux de bord ont été élaborés afin d'impliquer les enseignants (Feng et Heffernan, 2005^[59] ; Holstein, McLaren et Aleven, 2017^[19]). Bien que ces développements n'en soient encore qu'à leurs débuts, les premiers résultats montrent qu'il s'agit d'un nouveau et puissant moyen de faire participer les enseignants (Knoop-van Campen et Molenaar, 2020^[35]).

Le second paramètre est celui de l'apprentissage qui, il faut le souligner, se fait en groupes dans la plupart des établissements scolaires, ce qui rend difficile l'intégration des technologies qui s'adressent plutôt à des individus. En outre, il existe de fortes présomptions théoriques que l'apprentissage est un processus social grâce auquel les élèves apprennent ensemble. C'est pour cela que se développent des solutions qui combinent la personnalisation

aux niveaux de la classe et de l'individu. Dans ces cas, la personnalisation de l'apprentissage au niveau individuel est intégrée dans un programme de cours au rythme de la classe. Les technologies ainsi configurées peuvent être mises en place dans l'environnement actuel des établissements sans nécessiter de réorganisation majeure. Il est peut-être plus facile d'adopter ces technologies que celles à caractère exclusivement individuel.

Personnalisation de l'apprentissage grâce à l'apprentissage autorégulé

Indépendamment de la personnalisation en fonction des connaissances de l'élève, il existe une grande variété de caractéristiques de l'apprenant qui pourraient permettre des formes plus poussées de personnalisation. Bien que les expériences soient encore en cours, les premiers prototypes avancés sont testés à l'heure actuelle dans des laboratoires de recherche des pays de l'OCDE.

Ces dernières années, on s'est intéressé à des caractéristiques autres que les connaissances et les compétences de l'apprenant, telles que la capacité à autoréguler l'apprentissage, à appliquer des compétences métacognitives, à contrôler et suivre les activités d'apprentissage, à s'automotiver afin de s'efforcer d'apprendre et à réguler les réponses émotionnelles. Toutes ces caractéristiques sont des données potentielles pour la personnalisation (Bannert et al., 2017_[60] ; Järvelä et Bannert, 2019_[61]). Cette attention envers les caractéristiques et le comportement de l'apprenant durant l'apprentissage se combine parfaitement avec le rôle essentiel que jouent les données dans la compréhension des apprenants (Azevedo et Gašević, D., 2019_[27]). Cette tendance à percevoir l'apprenant comme un tout s'appuie sur des recherches qui montrent que l'apprentissage autorégulé, la motivation et les émotions sont primordiaux pendant l'apprentissage (Azevedo, 2009_[62]).

La théorie de l'apprentissage autorégulé définit l'apprentissage comme un processus axé sur les objectifs grâce auquel les élèves font des choix éclairés en vue de la réalisation d'objectifs d'apprentissage, résolvent des problèmes, raisonnent sur des données, entre autres, sur des sujets, dans des matières et contextes divers (Winne, 2017_[63] ; Winne et Hadwin, 1998_[64]). Les apprenants qui s'autorégulent font appel aux processus cognitifs (p. ex., lire, pratiquer, élaborer) pour étudier un sujet, et font appel aux processus métacognitifs (p. ex., l'orientation, la planification, la fixation d'objectifs, le suivi et l'évaluation) pour suivre et contrôler activement leur apprentissage, leur raisonnement, les processus de résolution de problèmes et les états affectifs (p. ex., l'ennui, la confusion, la frustration), et pour se motiver davantage (p. ex. accroître la valeur et l'intérêt de la tâche) pour fournir le niveau d'efforts qui convient (Greene et Azevedo, 2010_[65]).

L'intérêt de soutenir l'apprentissage autorégulé est double. En premier lieu, on estime que les compétences nécessaires à l'apprentissage autorégulé seront essentielles pour les humains dans les décennies à venir. L'intelligence artificielle va de plus en plus augmenter l'intelligence humaine. L'action humaine est nécessaire pour jouer un rôle de premier plan dans ces transformations et les compétences en régulation sont essentielles dans des environnements où l'automatisation et la robotisation de l'économie s'intensifient (OECD, 2019_[66]). Dans le cadre de cette évolution, la capacité intellectuelle de l'humain à résoudre les problèmes les plus sérieux de la société sera très recherchée (Luckin, 2017_[67]). Ces compétences humaines que l'IA ne peut reproduire facilement seront nécessaires pour réussir dans un monde en rapide mutation (World Economic Forum, 2018_[68]). La capacité de s'autoréguler, c'est-à-dire de prendre des initiatives, de se fixer des objectifs et d'assurer un suivi pour soi et les autres, est au cœur de ces compétences humaines. Les apprenants à même de s'autogérer apprennent de manière plus efficace et développent des structures mentales plus sophistiquées leur permettant d'appliquer leurs connaissances dans des situations variées (Paans et al., 2018_[69]). En second lieu, les compétences en apprentissage autorégulé sont nécessaires à l'apprentissage tout au long de la vie (au sein des établissements d'enseignement et dans le milieu de travail) pour donner aux apprenants la capacité d'agir, le sentiment de contrôler leur propre vie et leur fournir un moyen d'adapter et de contrôler leur comportement dans des situations difficiles au cours de leur vie (p. ex., en famille, dans les loisirs et au travail).

Intégrer l'apprentissage autorégulé dans les approches visant à personnaliser l'enseignement pourrait en conséquence être avantageux pour l'apprentissage *aujourd'hui* comme pour demain (Molenaar, Horvers et Baker, 2019_[70]). Pourtant, alors que les chercheurs et développeurs ont mis au point des moyens efficaces pour mesurer les connaissances des élèves durant leur apprentissage, la personnalisation en fonction d'un large éventail de caractéristiques de l'apprenant fait face à un premier obstacle qui réside justement dans cette mesure de l'apprentissage autorégulé durant l'apprentissage. On cherche de plus en plus à comprendre les processus d'apprentissage autorégulé à l'aide de données multimodales, car ils peuvent constituer des solutions de mesure

discrètes et évolutives. Les différents flux de données mentionnés ci-dessus sont utilisés dans la recherche afin d'améliorer les mesures, mais n'ont été utilisés que de manière restreinte dans les interventions pédagogiques. Ainsi, le système Wayang Outpost se sert des états affectifs des élèves pour adapter son commentaire en vue d'augmenter leur motivation (Arroyo et al., 2014_[20]) et AtGentive (Molenaar, Van Boxtel et Sleegers, 2011_[71]) fournit des échafaudages métacognitifs aux apprenants en fonction de leurs progrès. Les élèves de MetaTutor reçoivent des messages d'un agent de stratégie pour fixer des objectifs en fonction de leur comportement de navigation (Harley et al., 2015_[72]). D'Mello (D'Mello, 2021_[7]) examine cette question de la mesure dans le cas de l'« implication dans l'apprentissage ».


Pour illustrer ce développement, le Graphique 3.9 montre une intervention qui fait appel à des données du journal pour détecter les processus d'apprentissage autorégulé en fonction des données des technologies d'apprentissage adaptif utilisées à grande échelle. Un algorithme d'apprentissage *moment-by-moment* a été développé pour visualiser la probabilité que l'apprenant a acquis une compétence spécifique sur un problème particulier (Baker et al., 2013_[73]). Ces visuels illustrent ce que l'apprenant est susceptible d'avoir appris à chaque occasion de résolution de problème, ce qui est une représentation des progrès de l'apprenant au fil du temps. Baker, Goldstein et Heffernan (2011_[74]) ont constaté que les pics dans le graphique, qui illustrent la probabilité qu'un apprenant vient juste d'apprendre quelque chose à un moment précis, sont associés à un gain d'apprentissage soutenu au cours de leur expérience. Par ailleurs, les différents schémas visuels de la probabilité que l'apprenant vient d'apprendre, les courbes du moment, sont liés aux différents résultats d'apprentissage : par exemple un pic immédiat est lié aux résultats du post-test (Baker et al., 2013_[73]).

Graphique 3.9 L'algorithme d'apprentissage Moment-by-Moment

Personnalisation s'appuyant sur l'apprentissage autorégulé



Détecter



Diagnostiquer



Agir

Source: Illustrations - Inge Molenaar/Adaptive Learning Lab.

Ces schémas visuels reflètent également la régulation des apprenants (Molenaar, Horvers et Baker, 2019_[75]). À ce titre, ils fournissent un aperçu de la façon dont les élèves régulent leur attention et leur apprentissage au fil du temps en apprenant à l'aide des technologies d'apprentissage adaptif (Molenaar, Horvers et Baker, 2019_[70]). C'est sur cette base que les tableaux de bord personnalisés pour les élèves ont été développés, pour fournir des commentaires aux apprenants. Ainsi, le tableau de bord de l'apprenant, qui au départ était destiné à examiner ce que l'apprenant a appris, a intégré également l'aspect du *comment* il l'a fait. Les résultats de l'étude indiquent que les apprenants recevant des tableaux de bord amélioreraient la régulation durant l'apprentissage, atteignaient de meilleurs résultats et assuraient un suivi plus précis (Molenaar et al., 2020_[76]). En général, ces conclusions montrent que les tableaux personnalisés ont eu un impact très positif sur les élèves au cours de leur apprentissage.

Cet exemple (Graphique 3.9) illustre qu'en diversifiant les indicateurs suivis et en augmentant la portée du diagnostic, on peut favoriser la personnalisation de l'apprentissage, améliorer notre capacité à bien cerner l'état actuel de l'apprenant et affiner la prédiction concernant son évolution future. Il favorise de meilleures approches quant à la personnalisation de l'apprentissage qui intègrent des caractéristiques plus diversifiées de l'apprenant et une meilleure compréhension de l'environnement de ce dernier.

Les défis qui attendent la personnalisation de l'apprentissage à l'avenir

Nous avons commencé ce chapitre en présentant le modèle des *six niveaux d'automatisation de l'apprentissage personnalisé* pour situer le rôle de l'IA dans l'éducation et pour susciter une discussion sur le niveau d'automatisation envisagé pour l'IA dans l'éducation. L'automatisation totale n'est peut-être pas le modèle d'automatisation idéal pour l'IA dans le cadre de l'enseignement formel. Les systèmes hybrides dans lesquels l'humain et l'intelligence artificielle se renforcent mutuellement marquent un nouveau tournant dans ces contextes. Malgré l'afflux rapide de technologies éducatives mises en œuvre à grande échelle, les technologies de pointe favorisant la personnalisation poussée de l'apprentissage ne sont pas encore souvent très répandues dans les établissements scolaires. Il y a toujours un fossé entre les technologies mises en œuvre à grande échelle dans les établissements et les technologies de pointe à l'œuvre dans les laboratoires de recherche. La plupart des technologies sont mises en place à grande échelle au niveau de l'enseignement assisté pour aider l'enseignant (matériel numérique) et au niveau de l'automatisation partielle. Même dans les technologies de pointe, l'accent est mis sur la personnalisation en fonction des connaissances des élèves. On pourrait encore améliorer la personnalisation si l'on se concentrait sur l'élève dans son *ensemble* en tenant compte de caractéristiques plus larges de l'apprenant comme l'autorégulation, les émotions et la motivation. Dans cette quête, les flux de données multiples offrent de nouvelles occasions de détecter ces diverses caractéristiques et de poser un diagnostic.

L'évolution vers des formes plus poussées de personnalisation est complexe et nécessite une collaboration internationale en matière de recherche et développement (R-D) pour pouvoir progresser. Une orchestration au niveau gouvernemental est nécessaire pour que ces innovations technologiques voient le jour. Afin de parvenir à un plus vaste déploiement des technologies de pointe, ce chapitre termine sur trois recommandations à l'intention des responsables politiques : *i) Encadrer l'éthique dès la conception, la transparence et l'utilisation des données ; ii) améliorer les technologies d'apprentissage grâce à des partenariats public-privé ; et iii) faire en sorte que les enseignants et les professionnels de l'éducation soient parties prenantes de ces transformations.*

Recommandation 1. Encadrer l'éthique dès la conception, notamment en matière de transparence et de protection des données

Bien que ce chapitre n'ait pas vocation à discuter de questions éthiques relatives à l'IA dans le monde de l'éducation, il est essentiel que les gouvernements veillent à ce que les développements de l'IA et la personnalisation de l'apprentissage continuent de soutenir le bien commun (Sharon, 2018_[77]). L'éducation est un droit humain fondamental et les gouvernements doivent prendre les mesures qui s'imposent pour garantir l'accès à une éducation ouverte et impartiale pour tous (UNESCO, 2019_[78]). Dans cette optique, il faudra une réflexion approfondie sur les infrastructures de données, la gouvernance des données et le cadre de travail juridique nécessaire pour garantir ces droits humains fondamentaux ainsi que la vie privée, la sécurité et le bien-être des apprenants. Les gouvernements devront élaborer des lois et des cadres réglementaires détaillés en matière de protection des données afin de garantir une utilisation et une réutilisation éthiques, non discriminatoires, transparentes et vérifiables des données relatives aux apprenants (UNESCO, 2019_[78]). Il est nécessaire que les professionnels de l'éducation utilisent les technologies de manière responsable, particulièrement les données servant à la détection et les algorithmes servant au diagnostic. La recherche a un rôle essentiel à jouer dans l'analyse critique préalable des solutions d'IA afin de garantir la transparence du secteur.

Recommandation 2. Améliorer les technologies d'apprentissage à l'aide de partenariats public-privé

Comme mentionné ci-dessus, il y a encore une marge entre les technologies mises en œuvre à grande échelle dans les établissements et les technologies de pointe disponibles dans les laboratoires de recherche. Malgré la forte augmentation de l'utilisation des technologies dans les salles de classe au cours des dix dernières années (Vincent-Lancrin et al., 2019_[54]), rien ne démontre que les établissements scolaires exploitent le plein potentiel des technologies d'apprentissage en vue de la personnalisation de l'apprentissage. Il n'y a aucune solution technologique éducative avancée qui intègre les trois niveaux d'adaptation (tâche, étape et programme de cours) et les caractéristiques générales de l'apprenant. Les gouvernements peuvent encourager les développements en coordonnant des partenariats public-privé entre les instituts de recherche et les compagnies EdTech. Dans tous les secteurs, les grandes quantités de données combinées à l'apprentissage automatique entraînent des transformations et des perturbations sur les marchés (Bughin et al., 2018_[79]). De vastes ensembles de données sont nécessaires pour bâtir des applications factuelles d'apprentissage automatique en éducation. Les partenariats

entre ceux qui collectent les données à l'aide de technologies exploitées à grande échelle (principalement les entreprises privées et les organes publics chargés de l'éducation), ceux qui possèdent l'expertise pour faire progresser le domaine (principalement les chercheurs des universités et les entreprises privées), et ceux qui façonnent l'éducation (principalement les enseignants et les responsables de l'éducation dans les établissements) sont essentiels pour garantir une personnalisation accrue de l'apprentissage. Les collaborations avec ce « triangle d'or » (Cukurova, Luckin et Clark-Wilson, 2018_[80]) ont le pouvoir d'accélérer la personnalisation de l'apprentissage et, par conséquent, de faire progresser les niveaux d'automatisation dans l'éducation. Le projet EDUCATE du University College London⁹ et l'initiative Simon de la Carnegie Mellon University¹⁰ sont des exemples probants de ces partenariats.

Recommandation 3. Faire participer les enseignants et les professionnels de l'éducation à la R-D

Les six niveaux du modèle d'automatisation peuvent également aider les enseignants et les professionnels de l'éducation à comprendre le rôle de l'IA dans l'éducation. Le recours traditionnel aux technologies a été faible et la résistance à l'automatisation complète a été élevée (Tondeur et al., 2013_[4]). Imaginez que vous puissiez monter demain dans une voiture entièrement automatisée : combien de temps continuerez-vous à suivre ou même contrôler le fonctionnement de la voiture ? Une transition progressive à travers les niveaux d'automatisation renforcera la confiance des enseignants dans l'IA et contribuera à développer des preuves de son efficacité. La recherche montre que lorsque les enseignants font l'expérience de l'« enseignement assisté » du niveau 1, ils voient leur autonomie renforcée et peuvent concevoir de futurs scénarios éducatifs plus perfectionnés (Molenaar et Knoop-van Campen, 2019_[16]). Les enseignants sont responsables du bien-être de leurs élèves ; les technologies devraient leur permettre de s'acquitter de cette responsabilité. Des dialogues interactifs pour débattre du rôle des données, de l'analyse de l'apprentissage et de l'IA dans l'éducation nous permettront d'innover au-delà de ce que nous comprenons aujourd'hui et d'apprendre comment appréhender les possibilités infinies que l'IA offre à l'éducation.

Remarques

1. <https://www.alelo.com/about-us/>
2. <http://hstrik.ruhosting.nl/DART/>
3. <https://www.lexplore.com/>
4. <https://www.changedyslexia.org/>
5. <https://lingvist.com/>
6. <https://www.letrus.com.br/>
7. <https://www.aleks.com/>
8. <https://wrts.nl/>
9. <https://www.ucl.ac.uk/ioe/departments-and-centres/centres/ucl-knowledge-lab/educate>
10. <https://www.cmu.edu/simon/>

Références

- Aleven, V. et E.A. McLaughlin** (2016), « Instruction Based on Adaptive Learning Technologies? », dans *Handbook of Research on Learning and Instruction*, Routledge Handbooks, <http://dx.doi.org/10.4324/9781315736419>. [1]
- Arroyo, I., B. Park Woolf, W. Burelson, K. Muldner, D. Rai et M. Tai** (2014), « A Multimedia Adaptive Tutoring System for Mathematics that Addresses Cognition, Metacognition and Affect », *International Journal of Artificial Intelligence in Education*, Vol. 24/4, pp. 387-426, <http://dx.doi.org/10.1007/s40593-014-0023-y>. [20]
- Asselborn, T., T. Gargot, Ł. Kidziński, W. Johal, D. Cohen, C. Jolly et P. Dillenbourg** (2018), « Automated human-level diagnosis of dysgraphia using a consumer tablet », *npj Digital Medicine*, Vol. 1/1, <http://dx.doi.org/10.1038/s41746-018-0049-x>. [32]
- Awad, E., S. Dsouza, R. Kim, J. Schultz, J. Henrich, A. Shariff, J-F. Bonnefon et I. Rahwan** (2018), « The Moral Machine experiment », *Nature*, Vol. 563/7729, pp. 59-64, <http://dx.doi.org/10.1038/s41586-018-0637-6>. [11]
- Azevedo, R.** (2009), « Theoretical, conceptual, methodological, and instructional issues in research on metacognition and self-regulated learning: A discussion », *Metacognition and Learning*, Vol. 4/1, pp. 87-95, <http://dx.doi.org/10.1007/s11409-009-9035-7>. [62]
- Azevedo, R. et Gašević, D.** (2019), « Analyzing Multimodal Multichannel Data about Self-Regulated Learning with Advanced Learning Technologies: Issues and Challenges », *Computers in Human Behavior*, Vol. 96, pp. 207-210. [27]
- Baker, R.** (2016), « Stupid Tutoring Systems, Intelligent Humans », *International Journal of Artificial Intelligence in Education*, Vol. 26/2, pp. 600-614, <http://dx.doi.org/10.1007/s40593-016-0105-0>. [57]
- Baker, R., A. Corbett et V. Aleven** (2008), « More Accurate Student Modeling through Contextual Estimation of Slip and Guess Probabilities in Bayesian Knowledge Tracing », dans *Intelligent Tutoring Systems, Lecture Notes in Computer Science*, Springer Berlin Heidelberg, Berlin, Heidelberg, http://dx.doi.org/10.1007/978-3-540-69132-7_44. [41]
- Baker, R., A. Goldstein et N. Heffernan** (2011), « Detecting learning moment-by-moment », *International Journal of Artificial Intelligence in Education*, Vol. 21/1-2, pp. 5-25, <https://doi.org/10.3233/JAI-2011-015>. [74]
- Baker, R., A. Hershkovitz, L.M. Rossi, A.B. Goldstein et S.M. Gowda** (2013), « Predicting robust learning with the visual form of the moment-by-moment learning curve », *Journal of the Learning Sciences*, Vol. 22/4, pp. 639-666. [73]
- Baker, R. et P. Inventado** (2014), *Educational data mining and learning analytics*, Springer. [26]
- Bannert, M., I. Molenaar, R. Azevedo, S. Järvelä et D. Gašević** (2017), « Relevance of learning analytics to measure and support students' learning in adaptive educational technologies », *Proceedings of the Seventh International Learning Analytics & Knowledge Conference*, <http://dx.doi.org/10.1145/3027385.3029463>. [60]
- Blikstein, P.** (2018), *Time for hard choices in AIED*, Keynote at London Festival of Learning, <https://vimeo.com/283023489>. [22]
- Bloom, B.** (1984), « The 2 Sigma Problem: The Search for Methods of Group Instruction as Effective as One-to-One Tutoring », *Educational Researcher*, Vol. 13/6, pp. 4-16, <http://dx.doi.org/10.3102/0013189x013006004>. [24]
- Bodily, R., J. Kay, V. Aleven, J. Jivet, D. Davis, F. Xhakaj et K. Verbert** (2018), « Open learner models and learning analytics dashboards », *Proceedings of the 8th International Conference on Learning Analytics and Knowledge*, <http://dx.doi.org/10.1145/3170358.3170409>. [15]
- Bosch, N., S. D'Mello, R. Baker, J. Ocumpaugh, V. Shute, M. Ventura, L. Wang et W. Zhao** (2015), « Automatic Detection of Learning-Centered Affective States in the Wild », *Proceedings of the 20th International Conference on Intelligent User Interfaces - IUI '15*, <http://dx.doi.org/10.1145/2678025.2701397>. [31]
- Bughin, J., J. Seong, J. Manyika, M. Chui et R. Joshi** (2018), « Notes from the AI frontier: Modeling the global economic impact of AI », *McKinsey Global Institute: Vol. September*, <http://www.mckinsey.com/mgi>. [79]
- Carnegie Learning** (s.d.), Carnegie Learning, <https://www.carnegielearning.com/products/software-platform/mathia-learning-software> (consulté le 1 décembre 2020). [46]
- Corbett, A. et J. Anderson** (1995), « Knowledge tracing: Modeling the acquisition of procedural knowledge », *User Modelling and User-Adapted Interaction*, Vol. 4/4, pp. 253-278, <http://dx.doi.org/10.1007/bf01099821>. [39]
- Corno, L.** (2008), « On Teaching Adaptively », *Educational Psychologist*, Vol. 43/3, pp. 161-173, <http://dx.doi.org/10.1080/00461520802178466>. [2]

- Cukurova, M., R. Luckin et A. Clark-Wilson** (2018), « Creating the golden triangle of evidence-informed education technology with EDUCATE », *British Journal of Educational Technology*, Vol. 50/2, pp. 490-504, <http://dx.doi.org/10.1111/bjjet.12727>. [80]
- Dede, C.** (1986), « A review and synthesis of recent research in intelligent computer-assisted instruction », *International Journal of Man-Machine Studies*, Vol. 24/4, pp. 329-353, [http://dx.doi.org/10.1016/s0020-7373\(86\)80050-5](http://dx.doi.org/10.1016/s0020-7373(86)80050-5). [38]
- Desmarais, M. et R. Baker** (2011), « A review of recent advances in learner and skill modeling in intelligent learning environments », *User Modeling and User-Adapted Interaction*, Vol. 22/1-2, pp. 9-38, <http://dx.doi.org/10.1007/s11257-011-9106-8>. [30]
- Dillenbourg, P.** (2021), « Classroom analytics: Zooming out from a pupil to a classroom », dans *OECD Digital Education Outlook 2021: Pushing the frontiers with AI, blockchain, and robots*, OECD Publishing. [14]
- D'Mello, S.** (2021), « Improving student engagement in and with digital learning technologies », dans *OECD Digital Education Outlook 2021: Pushing the frontiers with AI, blockchain, and robots*, OECD Publishing. [7]
- Faber, J., H. Luyten et A. Visscher** (2017), « The effects of a digital formative assessment tool on mathematics achievement and student motivation: Results of a randomized experiment », *Computers & Education*, Vol. 106, pp. 83-96, <http://dx.doi.org/10.1016/j.compedu.2016.12.001>. [43]
- Falmagne, J-C., E. Cosyn, J-P. Doignon et N. Thiéry** (2006), « The Assessment of Knowledge, in Theory and in Practice », dans *Formal Concept Analysis, Lecture Notes in Computer Science*, Springer Berlin Heidelberg, Berlin, Heidelberg, http://dx.doi.org/10.1007/11671404_4. [50]
- Feng, M. et N. Heffernan** (2005), « Informing Teachers Live about Student Learning : Reporting in the Assistent System », *Tech., Inst., Cognition and Learning*, Vol. 3/508, pp. 1-14. [59]
- Greene, J. et R. Azevedo** (2010), « The Measurement of Learners' Self-Regulated Cognitive and Metacognitive Processes While Using Computer-Based Learning Environments », *Educational Psychologist*, Vol. 45/4, pp. 203-209, <http://dx.doi.org/10.1080/00461520.2010.515935>. [65]
- Harari, Y.** (2018), *21 Lessons for the 21st Century*, Random House. [10]
- Harley, J., F. Bouchet, M. Sazzad Hussain, R. Azevedo et R. Calvo** (2015), « A multi-componential analysis of emotions during complex learning with an intelligent multi-agent system », *Computers in Human Behavior*, Vol. 48, pp. 615-625. [72]
- Holstein, K., B. McLaren et V. Aleven** (2019), « Co-designing a real-time classroom orchestration tool to support teacher-AI complementarity », *Journal of Learning Analytics*, Vol. 6/2, pp. 27-52. [58]
- Holstein, K., B. McLaren et V. Aleven** (2018), « Student Learning Benefits of a Mixed-Reality Teacher Awareness Tool in AI-Enhanced Classrooms », dans *Lecture Notes in Computer Science, Artificial Intelligence in Education*, Springer International Publishing, Cham, http://dx.doi.org/10.1007/978-3-319-93843-1_12. [36]
- Holstein, K., B. McLaren et V. Aleven** (2017), « Intelligent tutors as teachers' aides », *Proceedings of the Seventh International Learning Analytics & Knowledge Conference*, <http://dx.doi.org/10.1145/3027385.3027451>. [19]
- Järvelä, S. et M. Bannert** (2019), « Temporal and adaptive processes of regulated learning - What can multimodal data tell? », *Learning and Instruction*, pp. 101268, <http://dx.doi.org/10.1016/j.learninstruc.2019.101268>. [61]
- Kamar, E.** (2016), « Directions in Hybrid Intelligence: Complementing AI Systems with Human Intelligence », *IJCAI*, pp. 4070-4073. [8]
- Klinkenberg, S., M. Straatemeier et H. van der Maas** (2011), « Computer adaptive practice of Maths ability using a new item response model for on the fly ability and difficulty estimation », *Computers & Education*, Vol. 57/2, pp. 1813-1824, <http://dx.doi.org/10.1016/j.compedu.2011.02.003>. [40]
- Knoop-van Campen, C. et I. Molenaar** (2020), « How Teachers integrate Dashboards into their Feedback Practices », *Frontline Learning Research*, pp. 37-51, <http://dx.doi.org/10.14786/flr.v8i4.641>. [35]
- Koedinger, K., J. Booth et D. Klahr** (2013), « Instructional Complexity and the Science to Constrain It », *Science*, Vol. 342/6161, pp. 935-937, <http://dx.doi.org/10.1126/science.1238056>. [33]
- Koedinger, K. et A. Corbett** (2006), « Cognitive Tutors: Technology Bringing Learning Sciences to the Classroom - Chapter 5 », *The Cambridge Handbook of: The Learning Sciences*, pp. 61-78, <https://www.academia.edu/download/39560171/koedingercorbett06.pdf>. [18]

- Koedinger, K., A. Corbett et C. Perfetti** (2012), « The Knowledge-Learning-Instruction Framework: Bridging the Science-Practice Chasm to Enhance Robust Student Learning », *Cognitive Science*, Vol. 36/5, pp. 757-798, <http://dx.doi.org/10.1111/j.1551-6709.2012.01245.x>. [34]
- Kulik, J. et J. Fletcher** (2016), « Effectiveness of Intelligent Tutoring Systems », *Review of Educational Research*, Vol. 86/1, pp. 42-78, <http://dx.doi.org/10.3102/0034654315581420>. [56]
- Luckin, R.** (2017), « Towards artificial intelligence-based assessment systems », *Nature Human Behaviour*, Vol. 1/3, <http://dx.doi.org/10.1038/s41562-016-0028>. [67]
- Miller, W., R. Baker, M.J. Labrum, K. Petsche, Y. Han Liu et A.Z. Wagner** (2015), « Automated detection of proactive remediation by teachers in reasoning mind classrooms », *Proceedings of the Fifth International Conference on Learning Analytics And Knowledge - LAK '15*, <http://dx.doi.org/10.1145/2723576.2723607>. [17]
- Molenaar, I., A. Horvers et R. Baker** (2019), « Towards Hybrid Human-System Regulation », *Proceedings of the 9th International Conference on Learning Analytics & Knowledge*, <http://dx.doi.org/10.1145/3303772.3303780>. [70]
- Molenaar, I., A. Horvers et R. Baker** (2019), « What can moment-by-moment learning curves tell about students' self-regulated learning? », *Learning and Instruction*, pp. 101206, <http://dx.doi.org/10.1016/j.learninstruc.2019.05.003>. [75]
- Molenaar, I., A. Horvers, R. Dijkstra et R. Baker** (2020), « Personalized visualizations to promote young learners' SRL », *Proceedings of the Tenth International Conference on Learning Analytics & Knowledge*, <http://dx.doi.org/10.1145/3375462.3375465>. [76]
- Molenaar, I. et C. Knoop-van Campen** (2019), « How Teachers Make Dashboard Information Actionable », *IEEE Transactions on Learning Technologies*, Vol. 12/3, pp. 347-355, <http://dx.doi.org/10.1109/tlt.2018.2851585>. [16]
- Molenaar, I., C. Knoop-van Campen et F. Hasselman** (2017), « The effects of a learning analytics empowered technology on students' arithmetic skill development », *Proceedings of the Seventh International Learning Analytics & Knowledge Conference*, <http://dx.doi.org/10.1145/3027385.3029488>. [45]
- Molenaar, I., C. Van Boxtel et P. Sleegers** (2011), « The Effect of Dynamic Computerized Scaffolding on Collaborative Discourse », dans *Towards Ubiquitous Learning, Lecture Notes in Computer Science*, Springer Berlin Heidelberg, Berlin, Heidelberg, http://dx.doi.org/10.1007/978-3-642-23985-4_39. [71]
- Molenaar, I. et C. van Campen** (2016), « Learning analytics in practice », *Proceedings of the Sixth International Conference on Learning Analytics & Knowledge - LAK '16*, <http://dx.doi.org/10.1145/2883851.2883892>. [44]
- Mudrick, N., R. Azevedo et M. Taub** (2019), « Integrating metacognitive judgments and eye movements using sequential pattern mining to understand processes underlying multimedia learning », *Computers in Human Behavior*, Vol. 96, pp. 223-234. [28]
- Muralidharan, K., A. Singh et A. Ganimian** (2019), « Disrupting education? Experimental evidence on technology-aided instruction in India », *American Economic Review*, Vol. 109/4, pp. 1426-60. [53]
- OECD** (2019), *OECD Skills Outlook 2019 : Thriving in a Digital World*, OECD Publishing, Paris, <https://dx.doi.org/10.1787/df80bc12-en>. [66]
- Paans, C., E. Segers, I. Molenaar et L. Verhoeven** (2018), « The quality of the assignment matters in hypermedia learning », *Journal of Computer Assisted Learning*, Vol. 34/6, pp. 853-862, <http://dx.doi.org/10.1111/jcal.12294>. [69]
- Pane, J., B.A. Griffin, D.F. McCaffrey et R. Karam** (2014), « Effectiveness of Cognitive Tutor Algebra I at Scale », *Educational Evaluation and Policy Analysis*, Vol. 36/2, pp. 127-144, <http://dx.doi.org/10.3102/0162373713507480>. [48]
- Pane, J., D.F. McCaffrey, M.E. Slaughter, J.L. Steele et G.S. Ikemoto** (2010), « An Experiment to Evaluate the Efficacy of Cognitive Tutor Geometry », *Journal of Research on Educational Effectiveness*, Vol. 3/3, pp. 254-281, <http://dx.doi.org/10.1080/19345741003681189>. [47]
- Parasuraman, R., T. Sheridan et C. Wickens** (2000), « A Model for Types and Levels of Human Interaction with Automation », *SYSTEMS AND HUMANS*, Vol. 30/3, <https://ieeexplore.ieee.org/abstract/document/844354/>. [13]
- Pashler, H., D. Rohrer, N.J. Capeda et S.K. Carpenter** (2007), « Enhancing learning and retarding forgetting: Choices and consequences », *Psychonomic Bulletin & Review*, Vol. 14/2, pp. 187-193, <http://dx.doi.org/10.3758/bf03194050>. [52]
- Pavlik, P. et J. Anderson** (2005), « Practice and Forgetting Effects on Vocabulary Memory: An Activation-Based Model of the Spacing Effect », *Cognitive Science*, Vol. 29/4, pp. 559-586, http://dx.doi.org/10.1207/s15516709cog0000_14. [51]
- Ritter, S., J. Kulikowich, P. Lei, C. Mcguire et P. Morgan** (2007), « What evidence matters? A randomized field trial of Cognitive Tutor Algebra I. », *Proceeding of the 15th International Conference on Computers in Education, ICCE 2007, November 5-9, 2007, Hiroshima, Japan*. [49]

- Robinson, K.** (2010), *Changing Education Paradigms*, [3]
https://www.ted.com/talks/sir_ken_robinson_changing_education_paradigms (consulté le 26 novembre 2020).
- Sharon, T.** (2018), « When digital health meets digital capitalism, how many common goods are at stake? », [77]
Big Data & Society, Vol. 5/2, pp. 205395171881903, <http://dx.doi.org/10.1177/2053951718819032>.
- Shladover, S.** (2018), « Connected and automated vehicle systems: Introduction and overview », [21]
Journal of Intelligent Transportation Systems, Vol. 22/3, pp. 190-200, <http://dx.doi.org/10.1080/15472450.2017.1336053>.
- Snappet** (s.d.), *Snappet*, <http://www.snappet.org> (consulté le 1 décembre 2020). [42]
- Stewart, A., H. Vrzakova, C. Sun, J. Yonehiro, C. Stone, N. Duran, V. Shute et S. D'Mello** (2019), « I Say, You Say, We Say », [29]
Proceedings of the ACM on Human-Computer Interaction, Vol. 3/CSCW, pp. 1-19, <http://dx.doi.org/10.1145/3359296>.
- Stiftung, R.** (dir. pub.) (2018), *Technology-enhanced Personalised Learning: Untangling the Evidence Other How to cite*, [9]
<http://www.studie-personalisiertes-lernen.de/en/> (consulté le 26 novembre 2020).
- Tondeur, J., L.H. Kershaw, R.R. Vanderlinde et J. van Braak** (2013), « Getting inside the black box of technology integration in education: Teachers' stimulated recall of classroom observations », [4]
Australasian Journal of Educational Technology 3, <https://ajet.org.au/index.php/AJET/article/view/16>.
- Topol, E.** (2019), « High-performance medicine: the convergence of human and artificial intelligence », [12]
Nature Medicine, Vol. 25/1, pp. 44-56, <http://dx.doi.org/10.1038/s41591-018-0300-7>.
- UNESCO** (2019), *Beijing Consensus on Artificial Intelligence and Education*, [78]
<https://unesdoc.unesco.org/ark:/48223/pf0000368303>.
- VanLEHN, K.** (2011), « The Relative Effectiveness of Human Tutoring, Intelligent Tutoring Systems, and Other Tutoring Systems », [25]
Educational Psychologist, Vol. 46/4, pp. 197-221, <http://dx.doi.org/10.1080/00461520.2011.611369>.
- VanLehn, K.** (2015), « Regulative Loops, Step Loops and Task Loops », [55]
International Journal of Artificial Intelligence in Education, Vol. 26/1, pp. 107-112, <http://dx.doi.org/10.1007/s40593-015-0056-x>.
- VanLehn, K.** (2006), « The Behavior of Tutoring Systems », [5]
International Journal of Artificial Intelligence in Education, Vol. 16.
- Vincent-Lancrin, S., J. Urgel, S. Kar et G. Jacotin** (2019), *Measuring Innovation in Education 2019: What Has Changed in the Classroom?*, Educational Research and Innovation, OECD Publishing, Paris, <https://dx.doi.org/10.1787/9789264311671-en>. [54]
- Wingo, G.** (1961), « Teaching Machines », [23]
Journal of Teacher Education, Vol. 12/2, pp. 248-249, <http://dx.doi.org/10.1177/002248716101200225>.
- Winne, P.** (2017), « Learning Analytics for Self-Regulated Learning », dans *Handbook of Learning Analytics*, Society for Learning Analytics Research (SoLAR), <http://dx.doi.org/10.18608/hla17.021>. [63]
- Winne, P. et R. Baker** (2013), « The Potentials of Educational Data Mining for Researching Metacognition, Motivation and Self-Regulated Learning », [6]
JEDM - Journal of Educational Data Mining, Vol. 5/1, pp. 1-8, <https://doi.org/10.5281/zenodo.3554619>.
- Winne, P. et A. Hadwin** (1998), « Studying as self-regulated learning », [64]
Metacognition in educational theory and practice.
- Wise, A.** (2014), « Designing pedagogical interventions to support student use of learning analytics », [37]
Proceedings of the Fourth International Conference on Learning Analytics And Knowledge - LAK '14, <http://dx.doi.org/10.1145/2567574.2567588>.
- World Economic Forum** (2018), *The future of jobs report*. [68]



Extrait de :

OECD Digital Education Outlook 2021

Pushing the Frontiers with Artificial Intelligence, Blockchain and Robots

Accéder à cette publication :

<https://doi.org/10.1787/589b283f-en>

Merci de citer ce chapitre comme suit :

Molenaar, Inge (2022), « Personnalisation de l'apprentissage : Vers une forme hybride des technologies d'apprentissage combinant l'humain et l'IA », dans OCDE, *OECD Digital Education Outlook 2021 : Pushing the Frontiers with Artificial Intelligence, Blockchain and Robots*, Éditions OCDE, Paris.

DOI: <https://doi.org/10.1787/0943da96-fr>

Cet ouvrage est publié sous la responsabilité du Secrétaire général de l'OCDE. Les opinions et les arguments exprimés ici ne reflètent pas nécessairement les vues officielles des pays membres de l'OCDE.

Ce document, ainsi que les données et cartes qu'il peut comprendre, sont sans préjudice du statut de tout territoire, de la souveraineté s'exerçant sur ce dernier, du tracé des frontières et limites internationales, et du nom de tout territoire, ville ou région. Des extraits de publications sont susceptibles de faire l'objet d'avertissements supplémentaires, qui sont inclus dans la version complète de la publication, disponible sous le lien fourni à cet effet.

L'utilisation de ce contenu, qu'il soit numérique ou imprimé, est régie par les conditions d'utilisation suivantes :

<http://www.oecd.org/fr/conditionsdutilisation>.