



Artificial intelligence and Education

Elie Allouche

► To cite this version:

Elie Allouche. Artificial intelligence and Education: Research contributions and challenges for public policies. Ministère de l'éducation nationale. 2024, <https://edunumrech.hypotheses.org/10764>. hal-04543937

HAL Id: hal-04543937

<https://hal.science/hal-04543937>

Submitted on 12 Apr 2024

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

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



Open licence - etalab



MINISTÈRE
DE L'ÉDUCATION
NATIONALE
ET DE LA JEUNESSE

*Liberté
Égalité
Fraternité*

Intelligence artificielle et éducation

Apports de la recherche
et enjeux pour les politiques
publiques

Janvier 2024



GTnum

État des lieux sur les apports de la recherche et les lignes directrices des institutions internationales sur l'intelligence artificielle et l'éducation :

définitions et approches, politiques publiques, enjeux éthiques, applications, tournant des IA génératives.



Current situation on the Research Contributions Guidelines of international institutions on artificial intelligence and education:

definitions and proposals, public policies, ethical issues, applications, turning point of Generative AI.




Table des matières

Résumé.....	4
À retenir.....	5
1. L'intelligence artificielle (IA) : une diversité de définitions et d'approches.....	6
2. Quels enjeux pour les politiques publiques? ...	13
3. Quels enjeux éthiques?.....	23
4. Quels domaines d'application?	25
5. Quelles pistes de travail pour former à l'IA et l'enseigner?	30
6. Le tournant des systèmes d'IA générative et des grands modèles de langage	38
Références.....	50

Résumé

Ce document, réalisé par la Direction du numérique pour l'éducation / ministère de l'Éducation nationale et de la Jeunesse, propose un état des lieux (janvier 2024) sur les apports de la recherche et les lignes directrices des institutions internationales sur l'intelligence artificielle (IA) et l'éducation : diversité des définitions et des approches, enjeux pour les politiques publiques, enjeux éthiques, domaines d'application, pistes de travail pour former et enseigner, perspectives avec le tournant actuel des systèmes d'IA générative et des grands modèles de langage.

Abstract

This document, produced by the Digital Directorate for Education (Ministry of National Education and Youth), offers an inventory (January 2024) of the contributions of research and the guidelines of international institutions on the artificial intelligence (AI) and education: diversity of definitions and approaches, issues for public policies, ethical issues, fields of application, avenues for training and teaching, perspectives with the turning point of generative AI and large language models.


Resumo

Este documento, producido por el Departamento de Educación Digital (Ministerio de Educación Nacional y Juventud), ofrece un inventario (Enero de 2024) de las contribuciones de la investigación y las directrices de las instituciones internacionales sobre la inteligencia artificial (IA) y la educación: diversidad de definiciones y enfoques, cuestiones para las políticas públicas, cuestiones éticas, campos de aplicación, vías de formación y enseñanza, perspectivas con el giro actual de las IA generativas y los grandes modelos de lenguaje.

À retenir


L'intelligence artificielle : une diversité de définitions et d'approches

« De façon surprenante, le terme récemment retenu pour qualifier ces stupéfiantes prouesses calculatoires est celui d'intelligence artificielle (IA). Le retour sur le devant de la scène de ce vocable forgé en 1956 par John McCarthy constitue une intéressante énigme pour l'histoire des sciences et des techniques. »
(Cardon *et al.*, 2018)



Quels enjeux pour les politiques publiques ?

« La stratégie de l'IA en éducation doit proposer des solutions aux professionnels de l'enseignement et de la formation, aider aux apprentissages et aux décisions sans jamais se substituer aux personnes. »
(Gouvernement - Direction générale des entreprises, 2023)



Quels enjeux éthiques ?

Quatre considérations clés à intégrer proposées par la Commission européenne : action humaine et contrôle humain, équité, humanité, justification des choix, transparence et explicabilité. D'après (Directorate-General for Education, Youth, Sport and Culture & European Commission, 2022)



Les domaines d'application pour l'éducation

« L'intelligence artificielle joue un rôle important et croissant dans l'éducation. Un cas important est celui des systèmes d'enseignement personnalisés qui sont déjà bien établis, avec des preuves croissantes de leur efficacité pour améliorer l'apprentissage. »
(Khosravi *et al.*, 2022)




Quelles pistes de travail pour former à l'IA et l'enseigner ?

Une proposition de parcours en cinq piliers
1. Incertitude et caractère aléatoire
2. Codage et calcul
3. Sensibilisation aux données
4. Pensée critique
5. Humanisme post-IA
D'après (de la Higuera & Bocquet, 2020)



Le tournant des systèmes d'IA générative et des grands modèles de langage

« Au cours des deux dernières années, une pléthore de grands modèles génératifs tels que ChatGPT ou Stable Diffusion ont été publiés. Ils sont capables d'effectuer des tâches telles qu'un système général de questions-réponses ou la création automatique d'images artistiques qui révolutionnent plusieurs secteurs. »
(Gozalo-Brizuela & Garrido-Merchan, 2023)



1. L'intelligence artificielle (IA) : une diversité de définitions et d'approches

1.1 Origines et actes fondateurs

En remontant à ses origines, en tant que nouvelle science, l'IA « reposait sur la conjecture selon laquelle toutes les **facultés cognitives**, en particulier le raisonnement, le calcul, la perception, la mémorisation, voire la découverte scientifique ou la créativité artistique, pourraient être décrites avec une précision telle qu'il devrait être **possible de les reproduire à l'aide d'un ordinateur**. » D'après (Ganascia, 2022)

« Outre un article majeur sur la morphogénèse en 1952, [les] deux papiers les plus fameux [de Turing] dans le monde de l'informatique sont "*On Computable Numbers, With an Application to the Entscheidungsproblem*" en 1937, où il pose les bases de la **machine de Turing** et de la calculabilité, et "*Computing Machinery and Intelligence*" en 1950, où il pose la **question de l'intelligence pour les machines** et énonce le **test de Turing**. » (Le Blanc, 2014)

« Une définition classique précise que l'IA est un domaine de recherche qui développe des technologies capables de faire des choses qui exigeraient de l'intelligence si elles étaient faites par des humains (Minsky, 1969). Cette approche trouve son origine chez **Turing**, ayant proposé que si une **simulation d'être humain intelligent** ne peut être distinguée d'une personne réelle, les questions relatives à l'intelligence deviennent sans objet (Turing, 1950). De nombreux spécialistes des sciences cognitives et certains chercheurs et philosophes spécialisés dans l'IA ont adopté un point de vue plus ferme, affirmant que la recherche sur l'IA peut révéler comment fonctionne l'esprit humain (Gardner, 1985). » (Holmes et al., 2022) traduction par (Bocquet, 2023)

« S'il faut un début à l'histoire, commençons par la **conférence de Dartmouth** où surgit le terme désormais consacré d'« intelligence artificielle ». Elle est organisée durant l'été **1956** au Dartmouth College, près de Hanover (New Hampshire), par **Marvin Minsky et John McCarthy**, les deux pionniers. » (Le Cun et al., 2019)

« De façon surprenante, le terme récemment retenu pour qualifier ces stupéfiantes prouesses calculatoires est celui d'intelligence artificielle (IA). Le retour sur le devant de la scène de ce **vocabulaire forgé en 1956 par John McCarthy** constitue une intéressante énigme pour l'histoire des sciences et des techniques. La plupart des observateurs rigoureux soulignent en effet que c'est dans le seul domaine des méthodes d'apprentissage et, notamment, de l'apprentissage profond (*deep learning*), que des progrès sensibles de la prédiction calculée ont lieu actuellement. Or l'appartenance de ces techniques au champ de l'IA n'est pas toujours allée de soi. (...) »

Les **réseaux de neurones** trouvent leur origine dans l'histoire pionnière de l'informatique et de la première cybernétique. Bien que l'étiquette soit postérieure, celle-ci peut en effet être dite « connexionniste » et ne cessera de se référer à la proposition de modéliser mathématiquement un réseau de neurones faite par le neurophysiologiste **Warren McCulloch** et le logicien **Walter Pitts en 1943**. Cet article fondateur continue, jusque dans les citations actuelles des articles de *deep learning*, à être donné comme le point de départ de l'aventure connexionniste. » (Cardon et al., 2018)

Quelques étapes dans l'histoire de l'IA

1943	Article sur les neurones artificiels de McCulloch et Pitts.
1950	Article de Turing « <i>Computing Machinery and Intelligence</i> » à la base du « test de Turing ».
1956	Le terme « intelligence artificielle » est utilisé pour la première fois lors d'une conférence à Dartmouth College .
1958	John McCarthy invente le langage de programmation LISP.
1964-1966	Le programme Eliza , un des premiers chatbots , est développé par Joseph Weizenbaum. Il donne naissance à « l'effet Eliza » (tendance à attribuer involontairement des traits humains à des suites de symboles générées par un ordinateur).
1972-1981	Le système expert MYCIN est développé pour aider les médecins à diagnostiquer les maladies infectieuses.
1974	Paul Werbos développe le premier algorithme de rétropropagation, une méthode clé pour le deep learning/apprentissage profond .
1997	Deep Blue , l'ordinateur d'échecs développé par IBM, bat le champion du monde d'échecs, Garry Kasparov.
2011	Le système Watson d'IBM remporte le jeu télévisé Jeopardy! contre deux anciens champions humains.
2012	Le réseau de neurones convolutifs AlexNet remporte le concours ImageNet, ce qui marque le début de l'ère du deep learning .
2016	AlphaGo , un programme d'IA développé par Google DeepMind, bat le champion du monde de Go Lee Sedol. Google développe son assistant vocal.
2017	Article sur les Transformers de (Vaswani et al.) [Google Research].
2018	Google développe son modèle de langage BERT , améliorant les performances en traitement automatique du langage naturel.
2019	Pluribus est un programme développé par Facebook AI qui a réalisé une percée dans le domaine du poker.
2022	Ouverture au public de ChatGPT par OpenAI.
2023	Développement rapide des systèmes d'IA générative et des grands modèles multimodaux (texte, image, son, vidéo).

1.2 Choix humains, modélisation et automatisatisation de tâches cognitives

« L'expression "intelligence artificielle", créée dans les années 1950, désigne le **domaine de recherche qui étudie les mécanismes de l'intelligence** en les modélisant avec des algorithmes et en les expérimentant avec des machines. Ces mécanismes incluent par exemple la faculté de trouver automatiquement des solutions à des problèmes, qui peut mettre en œuvre des capacités de planification, de prédiction, de contrôle, de mémorisation ou d'apprentissage. Par extension, le terme "intelligence artificielle" est souvent utilisé pour désigner des **algorithmes** [enchaînements d'actions élémentaires pour résoudre un problème] **simulant ou ayant des points communs avec certaines des capacités d'intelligence des êtres vivants.** » (Inria & Class'Code, 2020)



L'IA désigne « un **système automatisé** qui, pour un ensemble donné d'objectifs définis par l'humain, est **en mesure d'établir des prévisions, de formuler des recommandations, ou de prendre des décisions** influant sur des environnements réels ou virtuels. Les systèmes d'IA interagissent avec nous et influent de façon directe ou indirecte sur notre environnement. Ils semblent souvent fonctionner de façon autonome et peuvent adapter leur comportement en fonction du contexte. » D'après (UNICEF, 2021) repris par (Holmes & Tuomi, 2022) traduction par (Bocquet, 2023)

C'est aussi « un **domaine interdisciplinaire à la fois théorique et pratique** qui allie les technologies numériques, mathématiques, statistiques et algorithmiques. » (Grand lexique français de l'Intelligence artificielle, 2021)

« Nous pouvons définir l'intelligence artificielle (IA) comme des **systèmes informatiques capables de s'engager dans des processus de type humain** tels que l'apprentissage, l'adaptation, la synthèse, l'autocorrection et l'utilisation de données pour des tâches de traitement complexe. » (Popenici & Kerr, 2017) « [Cette définition] permet de **dépasser l'opposition entre l'intelligence humaine et l'IA et d'envisager des interactions complexes entre les deux.** » (Romero et al., 2023)

1.3 Les types d'IA

On distingue plusieurs types d'IA :

Selon leur technologie

« Une **IA basée sur les données**, ou apprentissage automatique (*machine learning* en anglais) et une autre IA basée sur les connaissances ou **IA symbolique**. Un troisième modèle conceptuel, l'**IA hybride**, combine les approches basées sur les données et les connaissances avec la cognition humaine. » D'après (Holmes et al., 2022)
traduction par (Bocquet, 2023)


Selon leur portée

« On distingue l'**IA faible** de l'**IA forte** selon la portée d'application de ces programmes informatiques. L'intelligence artificielle faible (*weak AI*) est une intelligence artificielle qui se concentre sur une tâche précise alors que l'IA forte (*strong AI*) ou l'intelligence artificielle générale (*AGI : artificial general intelligence*) s'applique à tout problème. Tous les systèmes d'IA existants sont considérés actuellement comme des intelligences artificielles faibles. » (*Grand lexique français de l'Intelligence artificielle*, 2021)

« **Intelligence artificielle complète ou forte** : une intelligence artificielle qui serait capable de copier les aptitudes humaines (apprendre, comprendre, appréhender, raisonner, prendre des décisions, avoir une conscience, des émotions...).

À ce jour, l'intelligence artificielle forte n'existe pas, c'est une croyance.

Intelligence artificielle faible : c'est l'intelligence artificielle qu'on connaît aujourd'hui : c'est un algorithme "apprenant", en adaptant ses paramètres à des données d'apprentissage, non pourvu de capacités mentales et cognitives, mais capable d'effectuer avec beaucoup plus d'efficacité, parfois plus que l'être humain, une tâche précise. » (Inria & Class'Code, 2020)



IA classique et apprentissage automatique

IA classique : « Une grande partie de l'IA des débuts ou "classique", connue sous le nom d'**"IA symbolique"**, d'"IA à base de règles" ou de "bonne vieille IA" (en anglais *GOF AI*), implique l'écriture de séquences de SI... ALORS... et d'autres règles de logique conditionnelle, c'est-à-dire des étapes que l'ordinateur suit pour accomplir une tâche. Au fil du temps, des **"systèmes experts" d'IA** basés sur des règles ont été créés et développés pour un large éventail d'applications, telles que les diagnostics médicaux, les notations de crédit et la production. Les systèmes experts sont basés sur une approche connue sous le nom d'"ingénierie des connaissances", qui consiste à obtenir et à modéliser les connaissances des experts dans un domaine donné, ce qui représente une tâche exigeante en ressources et qui n'est pas sans complications. (...) »

Apprentissage automatique (AA) : de nombreuses avancées récentes en matière d'IA – notamment le traitement du langage naturel, la reconnaissance faciale et les voitures autonomes – ont été rendues possibles par les progrès des approches informatiques basées sur l'apprentissage automatique. Plutôt que d'utiliser des règles, l'apprentissage **automatique (AA, *machine learning*, ML, en anglais) analyse de grandes quantités de données pour identifier des modèles** et construire un modèle qui est ensuite utilisé pour extrapoler les données futures : c'est en ce sens que les algorithmes, plutôt que d'être préprogrammés, sont dits "apprenants".

Il existe **trois approches principales de l'AA :**


- **supervisée ;**
 - **non supervisée ;**
 - **par renforcement.**
- **L'apprentissage supervisé** implique que les données ont déjà été identifiées et décrites, par exemple des milliers de photographies de personnes préalablement "étiquetées" par des humains. L'apprentissage supervisé relie les données aux étiquettes, afin de construire un modèle qui peut être appliqué à des données similaires, par exemple pour identifier automatiquement des personnes sur de nouvelles photographies. Dans l'apprentissage non supervisé, l'IA dispose d'une quantité de données encore plus importante, mais les données n'ont alors pas été préalablement identifiées, catégorisées ou étiquetées.
- **L'apprentissage non supervisé** vise à découvrir des similitudes, des modèles cachés dans les données, les ensembles de données qui peuvent être utilisés pour classer de nouvelles données. Par exemple, il devient possible d'identifier automatiquement les lettres et les chiffres d'une écriture manuscrite en recherchant des modèles dans des milliers d'exemples disponibles. Dans l'apprentissage supervisé comme dans l'apprentissage non supervisé, le modèle obtenu à partir des données est fixe, et si les données changent, il est nécessaire de reprendre l'analyse.
- À l'inverse, la troisième approche de l'AA, à savoir **l'apprentissage par renforcement**, implique l'amélioration continue du modèle sur la base du retour d'information (en anglais *feedback*) – en d'autres termes, il s'agit d'un apprentissage automatique dans le sens où l'apprentissage est continu. L'IA reçoit des données initiales à partir desquelles elle élabore un modèle, qui est évalué comme correct ou incorrect et, selon le résultat, "récompensé" ou "éliminé", autrement dit gardé ou rejeté. (...)

Un **réseau neuronal artificiel, ou réseau de neurones artificiel (RNA)**, est une approche de l'IA qui s'inspire de la structure des réseaux neuronaux biologiques – le cerveau des animaux. Les RNA comprennent chacun trois types de couches interconnectées de neurones artificiels : une couche d'entrée, une ou plusieurs couches de calcul intermédiaires cachées, enfin une couche de sortie qui fournit le résultat. (...)

L'apprentissage profond [*deep learning*] fait référence aux RNA qui comprennent plusieurs couches intermédiaires. C'est cette approche qui est à l'origine de nombreuses applications de l'IA récentes et prometteuses (par exemple dans le traitement du langage naturel, la reconnaissance vocale, la vision par ordinateur, la création d'images, la découverte de médicaments ou la génomique). »


(UNESCO, 2021)

Fonctionnement d'un réseau de neurones simple



(Cardon et al., 2018)

IA, apprentissage automatique, réseau de neurones et apprentissage profond




(UNESCO, 2021)

Qu'est-ce que l'IA en périphérie du réseau (Edge AI)?

« L'IA à la pointe de la technologie consiste à utiliser l'IA dans des appareils du monde réel. *Edge AI* fait référence à la pratique consistant à effectuer des calculs d'IA à proximité des utilisateurs en périphérie du réseau au lieu d'un emplacement centralisé comme le centre de données d'un fournisseur de services cloud ou le propre entrepôt de données privé d'une entreprise. »

(Singh & Gill, 2023)

IA en périphérie du réseau (Edge AI)



2. Quels enjeux pour les politiques publiques ?

2.1 Le consensus de Beijing

« Le Consensus de Beijing recommande aux gouvernements et aux autres parties prenantes des États membres de l'UNESCO de :

- **planifier l'IA dans les politiques de l'éducation** pour tirer parti des possibilités et relever les défis qu'apportent les technologies d'IA, adopter des approches engageant le gouvernement tout entier, intersectorielles et multipartites qui permettent aussi de mettre en place des priorités stratégiques locales pour atteindre les objectifs de l'ODD 4 [Objectif de développement durable 4 : Assurer l'accès de tous à une éducation de qualité, sur un pied d'égalité, et promouvoir les possibilités d'apprentissage tout au long de la vie] ;
- **soutenir le développement de nouveaux modèles** rendus possibles par les technologies d'IA pour la fourniture de services d'éducation et de formation là où les avantages l'emportent clairement sur les risques, et utiliser des outils d'IA pour proposer des systèmes d'apprentissage tout au long de la vie qui permettent un apprentissage personnalisé à tout moment, en tout lieu, pour tous ;
- **envisager l'utilisation de données pertinentes**, le cas échéant, afin d'encourager la planification de politiques fondées sur des données probantes ;
- veiller à ce que les technologies d'IA servent à **autonomiser les enseignants au lieu de les remplacer** et développer des programmes appropriés pour le renforcement des capacités afin que les enseignants travaillent aux côtés des systèmes d'IA ;
- préparer la prochaine génération de travailleurs en **l'équipant des valeurs et des compétences nécessaires pour la vie et au travail**, les plus pertinentes à l'ère de l'IA ;
- promouvoir une **utilisation équitable et inclusive** de l'IA, indépendamment du handicap, du statut social ou économique, de l'origine ethnique ou culturelle ou de la situation géographique, en insistant sur l'égalité des sexes, tout en assurant des usages éthiques, transparents et vérifiables des données éducatives. »

(D'après UNESCO, 2019)




2.2 Les recommandations et prévisions de l'UNESCO et de l'OCDE

Recommandations pour les décideurs politiques

1. Une vision et des priorités stratégiques à l'échelle systémique

- Définir à l'échelle du système une vision des politiques de l'IA et de l'éducation :
 - garantir l'utilisation inclusive et équitable de l'IA dans l'éducation ;
 - tirer au mieux parti de l'IA pour améliorer l'éducation et l'apprentissage ;
 - promouvoir le développement de compétences nécessaires à la vie à l'ère de l'IA, notamment en enseignant le fonctionnement de l'IA et ses implications pour l'humanité ;
 - garantir l'utilisation transparente et contrôlable des données relatives à l'éducation.
- Évaluer l'état de préparation de l'ensemble du système et choisir les priorités stratégiques.



2. Principe directeur en matière de politiques d'IA et d'éducation

- Adopter une approche humaniste comme principe général des politiques de l'IA et de l'éducation.

3. Planification interdisciplinaire et gouvernance intersectorielle

- Mobiliser l'expertise interdisciplinaire et multipartite pour éclairer la planification des politiques et renforcer la capacité des décideurs.
- Mettre en place des mécanismes de gouvernance et de coordination intersectoriels.

4. Politiques et réglementations pour une utilisation équitable, inclusive et éthique de l'IA

- Définir des objectifs stratégiques transversaux et planifier des règlements et des programmes, afin de garantir l'utilisation équitable et inclusive de l'IA dans le champ éducatif.

5. Plans directeurs pour l'utilisation de l'IA dans la gestion de l'éducation, l'enseignement, l'apprentissage et l'évaluation

- L'utilisation de l'IA pour stimuler et améliorer la gestion de l'éducation et les prestations.
- Cultiver une utilisation de l'IA centrée sur l'apprenant pour améliorer l'apprentissage et l'évaluation.
- Veiller à ce que l'IA soit utilisée pour renforcer les dynamiques des enseignants.
- Planifier l'utilisation de l'IA pour soutenir l'apprentissage tout au long de la vie, quels que soient l'âge, le lieu et le contexte.
- Développer des valeurs et des compétences pour la vie et le travail à l'ère de l'IA.

6. Essais pilotes, suivi et évaluation, et constitution d'une base de données fiable

- Construire une base de données fiable pour soutenir l'utilisation de l'IA dans l'éducation.
- Renforcer la recherche et l'évaluation dans le domaine de l'IA et de l'éducation.

7. Encourager les innovations locales en matière d'IA pour l'éducation

- Promouvoir le développement local des technologies de l'information dans le champ éducatif.

D'après (UNESCO, 2021) (Extraits)

Les nouveaux enjeux de l'IA générative

« Les implications de l'IA générative pour l'évaluation vont bien au-delà des préoccupations immédiates concernant la tricherie des apprenants sur les devoirs écrits. Nous devons composer avec le fait que **l'IA générative peut produire des articles et des essais relativement bien organisés et des œuvres d'art impressionnantes**, et peut réussir certains examens basés sur les connaissances dans certains domaines. Nous devons donc repenser ce qui doit être exactement appris et à quelles fins, ainsi que la manière dont l'apprentissage doit être évalué et validé. (...) »

La perspective la plus fondamentale des implications à long terme de l'IA générative pour l'éducation et la recherche concerne toujours **la relation complémentaire entre l'action humaine et les machines**. L'une des questions clés est de savoir si les humains peuvent éventuellement céder des niveaux fondamentaux de réflexion et de processus d'acquisition de compétences à l'IA et plutôt se concentrer sur des capacités de réflexion d'ordre supérieur basées sur les résultats fournis par l'IA. »

(Miao & Holmes, 2023)

« Les modèles d'IA générative qui génèrent du texte, des images, des vidéos et du contenu audio (musique, parole, etc.) progressent à une vitesse fulgurante. Cela ouvre des **possibilités infinies, démontrées dans un nombre croissant de domaines**. Cependant, la technologie pose également de nombreux défis et risques pour les individus, les entreprises, les économies, les sociétés et les décideurs politiques du monde entier, allant de la perturbation du marché du travail et de la désinformation à court terme aux défis potentiels à long terme en matière de contrôle des actions des machines. Les trajectoires futures de l'IA générative sont difficiles à prédire, mais les gouvernements doivent les explorer pour pouvoir les façonner. »

Le développement technologique de l'IA générative en est à son stade naissant, avec des pionniers tels que des acteurs technologiques établis comme Microsoft, Google et Meta, et des laboratoires de recherche privés comme OpenAI, Midjourney et Stability.AI. Ces entreprises poursuivent des stratégies multiples pour tirer parti de l'IA générative et, dans une certaine mesure, atténuer ses inconvénients.

Le débat public sur l'IA générative date de moins d'un an. Alors que les entreprises technologiques mettent sur le marché des applications d'IA générative, les décideurs politiques du monde entier sont aux prises avec ses implications. Les chercheurs appliqués et universitaires sont engagés dans un débat acharné sur la manière de gérer l'IA générative, depuis les mesures d'atténuation dans la conception et le développement des modèles, jusqu'au lancement sur le marché et au-delà.

La voie à suivre n'est pas claire et les perspectives divergent. L'un des extrêmes plaide pour un moratoire sur les expériences d'IA générative plus avancées que le GPT-4 (Future of Life Institute, 2023), tandis que l'autre estime que les risques existentiels supposés de l'IA sont exagérés (LeCun et Ng, 2023). D'autres – peut-être la plupart – se situent quelque part entre les deux. Quelle que soit la position idéologique sur ces questions, **il est urgent de poursuivre les recherches pour se préparer aux différents scénarios possibles de l'IA générative.** Compte tenu de la grande incertitude et de l'impact potentiellement important que la technologie pourrait avoir aux niveaux micro et macro, les décideurs politiques doivent rester informés et prêts à prendre des mesures appropriées par le biais de politiques d'IA tournées vers l'avenir.

L'OCDE souhaite que ce document serve de tremplin pour aider les gouvernements à progresser dans ce domaine. L'Observatoire des politiques d'IA de l'OCDE et son nouveau Groupe d'experts de l'OCDE sur l'avenir de l'IA serviront, aux côtés d'autres organismes compétents, de forum de dialogue sur ces sujets, en générant des idées et des recommandations exploitables pour les gouvernements. Des travaux complémentaires sont également en cours dans le cadre d'autres initiatives de l'OCDE, telles que les travaux menés par le Comité de l'emploi, du travail et des affaires sociales, le centre de ressources DIS/MIS de l'OCDE et l'initiative horizontale "Going Digital" de l'OCDE.»

(Lorenz et al., 2023)

2.3 Une stratégie nationale

« L'intelligence artificielle (IA) est une priorité pour la France sur le plan de la recherche, de l'économie, de la modernisation de l'action publique, de la régulation et de l'éthique. Le Gouvernement a initié en 2018 une stratégie nationale pour l'IA.

À la suite du rapport "Donner un sens à l'intelligence artificielle : pour une stratégie nationale et européenne" (2018) et dans le cadre du plan France 2030, le Gouvernement a lancé en 2018 une **stratégie nationale pour l'intelligence artificielle (SNIA)**. Cette stratégie a pour objectif de positionner la France comme un des leaders européens et mondiaux de l'intelligence artificielle (IA).

La stratégie nationale pour l'intelligence artificielle a pour ambition de préserver et consolider la souveraineté économique, technologique et politique de la France et de mettre l'IA au service de l'économie et de la société. Elle est rattachée au volet maîtrise de technologies numériques souveraines et sûres de France 2030.

La stratégie nationale pour l'IA se divise en deux phases :

PHASE 1 (2018-2022)

Doter la France de capacités de recherche compétitives. Cette première étape a été financée à hauteur de 1,85 milliard d'euros. Elle a notamment financé la création et le développement d'un réseau d'instituts interdisciplinaires d'intelligence artificielle, la mise en place de chaires d'excellence et de programmes doctoraux, ainsi que le déploiement du supercalculateur Jean Zay.

PHASE 2 (2021-2025)

Diffuser des technologies d'intelligence artificielle au sein de l'économie et soutenir le développement et l'innovation dans des domaines prioritaires comme l'IA embarquée, l'IA de confiance, l'IA frugale et l'IA générative. Cette seconde phase est dotée de 1,5 milliard d'euros dans le cadre de France 2030. Cette nouvelle phase de la SNIA s'articule autour de trois piliers stratégiques : le soutien à l'offre *deep tech*, la formation et l'attraction des talents, le rapprochement de l'offre et de la demande de solutions en IA. »


(Gouvernement – Direction générale des Entreprises, 2023)

Chronologie et implantation géographique

Les étapes d'élaboration de la stratégie nationale en IA



Implantation des instituts thématiques en IA (3IA PR[AI]RIE, MIAI, 3IA Côte d'Azur et ANITI) et des centres d'excellence (SCAI, DATAIA et Hi! PARIS) en regard des zones historiquement actives dans ce domaine



Source : Cour des comptes

Note de lecture : L'activité historique en IA est mesurée à travers la répartition départementale des thèses en IA soutenues entre 1989 et 2019 dans les établissements français d'enseignement supérieur à partir des données ouvertes de theses.fr (ABES). Les thèses sont données par année de soutenance. La détection des thèses en IA est réalisée suivant la méthode sémantique développée par la cour. Les logos des 3IA et des centres d'excellence en IA sont tirés de leurs sites web officiels.

(Cour des comptes, 2023)

2.4 Une loi européenne sur l'IA (AI Act)

« Les députés [du Parlement européen] sont parvenus à un accord politique avec le Conseil sur un projet de loi visant à garantir que l'IA en Europe soit sûre, respecte les droits fondamentaux et la démocratie, tandis que les entreprises peuvent prospérer et se développer.

Vendredi [08/12/23], les négociateurs du Parlement et du Conseil sont parvenus à un accord provisoire sur la loi sur l'intelligence artificielle. Ce règlement vise à garantir que les droits fondamentaux, la démocratie, l'État de droit et la durabilité environnementale soient **protégés contre l'IA à haut risque**, tout en stimulant l'innovation et en faisant de l'Europe un leader dans le domaine. Les règles établissent des obligations pour l'IA en fonction de ses risques potentiels et de son niveau d'impact. (...)

Parmi les applications interdites : systèmes de catégorisation biométrique qui utilisent des caractéristiques sensibles, récupération non ciblée d'images faciales provenant d'Internet ou de séquences de vidéosurveillance pour créer des bases de données de reconnaissance faciale, reconnaissance des émotions sur le lieu de travail et dans

les établissements d'enseignement, notation sociale basée sur le comportement social ou les caractéristiques personnelles, systèmes d'IA qui manipulent le comportement humain pour contourner leur libre arbitre, exploitation des vulnérabilités des personnes (en raison de leur âge, de leur handicap, de leur situation sociale ou économique).

Mesures de soutien à l'innovation et aux PME : les députés voulaient garantir que les entreprises, en particulier les PME, puissent développer des solutions d'IA sans pression induite de la part des géants industriels contrôlant la chaîne de valeur. À cette fin, l'accord promeut ce que l'on appelle les bacs à sable réglementaires et les tests en conditions réelles, établis par les autorités nationales pour développer et former une IA innovante avant sa mise sur le marché. »

Classification des systèmes d'IA

« L'accord de compromis prévoit une couche horizontale de protection, incluant une classification à haut risque, afin de ne pas englober les systèmes d'IA qui ne sont pas susceptibles de causer des violations graves des droits fondamentaux ou d'autres risques importants. Les **systèmes d'IA ne présentant qu'un risque limité** seraient soumis à des obligations de transparence très peu contraignantes, par exemple celle consistant à faire savoir que le contenu a été généré par l'IA, de façon à ce que les utilisateurs puissent prendre des décisions éclairées sur la poursuite de leur utilisation.

Un large éventail de **systèmes d'IA à haut risque** seraient autorisés, mais seraient soumis à un ensemble d'exigences et d'obligations pour accéder au marché de l'UE. Ces exigences ont été clarifiées et adaptées par les colégislateurs de sorte qu'il soit, pour les parties intéressées, techniquement plus faisable et moins contraignant de s'y conformer, par exemple en ce qui concerne la qualité des données ou la documentation technique que les PME devraient établir pour démontrer que leurs systèmes d'IA à haut risque sont conformes aux exigences.

Étant donné que les systèmes d'IA sont développés et distribués au moyen de chaînes de valeur complexes, l'accord de compromis comprend des **modifications clarifiant la répartition des responsabilités et des rôles des différents acteurs** de ces chaînes, en particulier les fournisseurs et les utilisateurs de systèmes d'IA. Il clarifie également la relation entre responsabilités au titre de la législation sur l'IA et responsabilités qui existent déjà en vertu d'autres actes législatifs, tels que la législation pertinente de l'UE en matière de protection des données ou la législation sectorielle.

Pour certaines utilisations de l'IA, le risque est jugé inacceptable et, par conséquent, ces systèmes seront interdits dans l'UE. L'accord provisoire interdit, par exemple, la manipulation comportementale cognitive, le moissonnage non ciblé d'images faciales provenant de l'internet ou de la vidéosurveillance, la reconnaissance d'émotions sur le lieu de travail et dans les établissements d'enseignement, la notation sociale, la catégorisation biométrique pour en déduire des données sensibles, telles que l'orientation sexuelle ou des croyances religieuses, et certains cas de police prédictive appliquée à la personne. »

D'après (Parlement européen, 2023) et (Conseil de l'Europe, 2023)

2.5 Actions et productions des groupes thématiques numériques (#GTnum)

Actions du GTnum IA et éducation ouverte



Avec le soutien de

Nos Contributeurs

Nos Partenaires

Retrouvez-nous :

chaireunescorelia.univ-nantes.fr
twitter.com/Chaire_RELIA
mediaserver.univ-nantes.fr/channels/#chaire-rel
edunumrech.hypotheses.org

conception : www.audisarnent.fr

(DNE-TN2, 2023a)

Portfolios des GTnum sur l'IA



Détails et contenu du portfolio (DNE-TN2, 2023c)



Détails et contenu du portfolio (DNE-TN2, 2023b)

2.6 Les performances de l'IA en lecture et en mathématiques

«[Cette] étude fait partie d'un projet global d'évaluation des capacités de l'IA et de leurs implications pour le travail et l'éducation, dirigé par le Centre de recherche et d'innovation dans l'enseignement (CERI) de l'OCDE. Le **projet sur l'IA et l'avenir des compétences (AIFS)** vise à développer des mesures des capacités de l'IA qui soient compréhensibles, complètes, reproductibles et pertinentes pour les politiques. En utilisant diverses sources d'information sur l'IA, y compris des évaluations d'experts, le projet vise à fournir aux décideurs politiques les connaissances dont ils ont besoin pour élaborer des politiques de l'éducation et du marché du travail tournées vers l'avenir. Le rapport montre des améliorations significatives des capacités de l'IA en lecture depuis 2016, qui reflètent les **progrès du traitement du langage naturel (NLP)** au cours des dernières années. Les capacités de l'IA à résoudre des tâches mathématiques n'ont pas progressé au même rythme. Toutefois, **les experts prévoient que l'augmentation des investissements dans la recherche et le développement de l'IA conduira à des progrès significatifs de l'IA à la fois en lecture et en mathématiques dans les années à venir.** Le rapport démontre également que l'IA pourrait surpasser une grande partie de la population en lecture et en mathématiques. Cela a des conséquences importantes pour l'emploi et l'éducation, car les travailleurs risquent d'être de plus en plus concurrencés par les machines dans ces domaines de compétences à l'avenir. Il souligne également la nécessité de **renforcer les compétences de base de la main-d'œuvre et de la préparer à collaborer avec l'IA dans des domaines clés.** En fournissant un exemple de la manière dont les capacités de l'IA s'améliorent par rapport à deux compétences cognitives clés des humains, cette étude souligne **l'importance d'un suivi périodique et systématique de l'évolution des capacités de l'IA et de leur comparaison avec les compétences humaines.** Cela sera utile aux décideurs politiques, aux éducateurs et aux chercheurs qui cherchent à comprendre les implications des avancées technologiques pour l'avenir du travail et de l'éducation.»

(OCDE, 2023)

3. Quels enjeux éthiques ?

3.1 Des lignes directrices issues des institutions internationales

« Il est essentiel de comprendre que les systèmes d'IA ne relèvent pas de la magie.

Des personnes conçoivent, entraînent et guident l'IA, qu'il s'agisse de celles qui définissent les politiques et stratégies en matière d'IA, des programmeurs de logiciels qui construisent les systèmes d'IA, des individus qui collectent et classent les données utilisées par ces systèmes ou de ceux qui interagissent avec eux. Cela signifie que **tous les acteurs de l'écosystème de développement des technologies de l'IA doivent comprendre les principaux enjeux** qui leur imposent de contribuer à une utilisation responsable de l'IA. Il peut notamment s'agir de **savoir pourquoi et comment un système d'IA a été conçu, par qui et dans quel but**. » (UNICEF, 2021)

« Pour une utilisation éthique de l'IA et des données dans l'enseignement, l'apprentissage et l'évaluation, **la Commission européenne propose quatre considérations clés** à intégrer :

- **action humaine et contrôle humain** : capacité d'action des acteurs de l'éducation (enseignants, apprenants, chefs d'établissement);
- **équité** : impartialité, inclusion, non-discrimination et juste répartition des droits et des responsabilités;
- **humanité** : considération pour les personnes, leur identité, leur intégrité et leur dignité;
- **justification des choix, transparence et explicabilité** : utilisation de connaissances, de faits et de données pour justifier les choix collectifs dans l'environnement scolaire, via des modèles participatifs et collaboratifs de prise de décision. »

D'après (Directorate-General for Education, Youth, Sport and Culture & European Commission, 2022)

Le Conseil de l'Europe met en avant plusieurs principes pour une utilisation de l'IA en éducation respectueuse des **droits fondamentaux** :

- « *Droit à la dignité humaine*. L'enseignement, l'évaluation et l'accréditation ne doivent pas être délégués à un système d'IA.
- *Droit à l'autonomie*. Les enfants devraient avoir le droit d'éviter d'être profilés individuellement, d'éviter les parcours d'apprentissage dictés, et de protéger leur développement et leur vie future.
- *Le droit d'être entendu*. Les enfants devraient avoir le droit de ne pas s'engager dans l'utilisation d'un système d'IA, sans que cela n'affecte négativement leur éducation.

- *Droit de ne pas souffrir de discrimination.* Tous les enfants devraient avoir la possibilité de bénéficier de l'utilisation des technologies, et pas seulement ceux issus des groupes socio-économiques qui peuvent se le permettre.
- *Droit à la confidentialité et à la protection des données.* Les enfants doivent avoir le droit que leurs données ne soient pas agrégées et utilisées à des fins commerciales sans leur bénéfice direct.
- *Droit à la transparence et à l'explicabilité.* Les enfants et leurs parents doivent pouvoir comprendre et contester toute décision prise par un système IA. »

D'après (Holmes et al., 2022)

3.2 La diversité des enjeux éthiques vue par la recherche

« Les enjeux éthiques et critiques que soulève l'IA en éducation sont multiples et ont des origines diverses : utilisation de **données massives**, pouvant avoir un impact sur le **respect de la vie privée** des élèves et du personnel scolaire, production par des entreprises privées plutôt que par des instances scolaires, par la recherche en informatique ou en sciences, technologies, ingénierie et mathématiques plutôt que par les sciences de l'éducation, **biais de représentativité** par manque de diversité au sein des équipes de conception. »

D'après (Collin & Marceau, 2021)

3.3 L'enjeu de l'explicabilité

« Dans le domaine éducatif, deux catégories d'utilisateurs doivent s'approprier l'environnement numérique : les apprenants et les enseignants. **La question de l'appropriation des EIAH [Environnements informatiques pour l'apprentissage humain] par les enseignants est essentielle pour que ces outils soient davantage utilisés dans l'enseignement.** Il faut donc concevoir des systèmes que les enseignants pourront adapter afin qu'ils répondent à leurs besoins. Pour cela, **l'enseignant doit pouvoir comprendre les décisions ou recommandations du système d'IA concernant ses élèves**, pour avoir confiance dans le système et, d'une certaine façon, "faire corps" avec lui pour être capable d'expliquer le comportement conjugué du dispositif tel qu'il a été mis en place. Cela nécessite une représentation explicite des connaissances et des processus de décision. **La question de l'explicabilité doit être prise en compte dès la conception.** »

(Association Française pour l'Intelligence Artificielle (AFIA), 2022)

4. Quels domaines d'application ?

4.1 Catégorisation et taxonomie

Catégorisation proposée par la Commission européenne

Enseignement	Soutien à l'apprenant	Soutien à l'enseignant	Soutien au système éducatif
• Environnement informatique pour l'apprentissage humain • Systèmes tutoriels fondés sur le dialogue • Applications d'aide à l'apprentissage des langues	• Environnements d'apprentissage exploratoire • Évaluation formative des écrits • Apprentissage collaboratif assisté par l'IA	• Évaluation sommative des écrits, notation • Repérage de mots-clés dans les forums d'apprenants • Assistants pédagogiques basés sur l'IA • Recommandation de ressource pédagogique	• Exploration des données éducatives pour l'allocation des ressources • Diagnostic des difficultés d'apprentissage • Services d'orientation

D'après (European Commission. Directorate General for Education, Youth, Sport and Culture, 2022)

Autre catégorisation issue des groupes thématiques numériques

- Systèmes adaptatifs et personnalisés (recommandation et sélection de contenus, de ressources), évaluation adaptative et correction automatique.
- Robots conversationnels et systèmes de tutorat intelligent, par ex. pour l'enseignement de la démarche d'investigation et de la démarche scientifique (Cisel & Baron, 2019).
- Anticipation précoce, prédiction et prévention de l'abandon scolaire.
- Détection et remédiation aux difficultés d'apprentissage.
- Utilisation de savoirs produits par la recherche avec l'IA (analyse d'image, annotation, classification et résumé/synthèse automatiques, traitement de données massives sur des corpus textuels ou iconographiques).
- Usages administratifs.

D'après (DNE-TN2, 2021) (DNE-TN2, 2022) (Lepage Alexandre, 2022) (Romero et al., 2021)

Taxonomie d'après la revue de littérature de (Holmes et al., 2022)

IA au service des élèves

Systèmes de tutorat intelligents

Applications assistées par l'IA (par exemple, mathématiques, synthèse vocale, apprentissage des langues)

Simulations assistées par l'IA (par exemple, apprentissage par le jeu, réalité virtuelle, réalité augmentée)

IA pour aider les apprenants à besoins éducatifs particuliers

Rédaction automatique d'essais

Agents conversationnels

Évaluation formative automatique

Orchestrateurs de réseaux d'apprentissage

Systèmes de tutorat basés sur le dialogue

Environnements d'apprentissage exploratoire

Assistant d'apprentissage tout au long de la vie assisté par l'IA

IA au service de l'enseignant

Détection de plagiat

Curation intelligente du matériel d'apprentissage

Surveillance de la classe

Évaluation sommative automatique

IA d'assistance de l'enseignant (y compris assistant d'évaluation)

Orchestration de la salle de classe

IA au service des institutions

Admissions (par exemple, sélection des élèves)

Planification des cours – Planification des horaires – Programmation horaire

Sécurité des écoles

Identification précoce des *décrocheurs* et des élèves à risque

e-Proctoring (surveillance des examens à distance)

D'après (Holmes et al., 2022) traduction par (Bocquet, 2023)

Enfin, (Ouyang & Jiao, 2021) proposent une catégorisation selon trois paradigmes

	Fondements théoriques	Implémentations	Techniques d'IA	Exemples
Paradigme 1 : dirigé par l'IA, l'apprenant en tant que destinataire	Behaviorisme <i>[L'IA représente les connaissances du domaine et dirige les processus d'apprentissage.]</i>	Travaux antérieurs sur les systèmes de tutorat intelligents	IA basée sur des techniques relationnelles statistiques	Tuteur de programmation ACT (Anderson et al., 1990) ; Stat Lady (Shute, 1995)
Paradigme 2 : soutenu par l'IA, l'apprenant en tant que collaborateur	Constructivisme cognitif et social <i>[Le système d'IA comme outil de soutien, tandis que l'apprenant collabore pour se concentrer sur le processus d'apprentissage.]</i>	• Systèmes de tutorat basés sur le dialogue • Environnements d'apprentissage exploratoire	Réseau bayésien, traitement du langage naturel, arbres de décision de Markov	Environnement exploratoire QUE (Metzler & Martincic, 1998)
Paradigme 3 : l'IA partie d'un système où l'apprenant est pilote	Connectivisme, système adaptatif complexe <i>[L'IA pour augmenter l'intelligence humaine, l'apprenant est placé au cœur du dispositif.]</i>	• Coopération homme-ordinateur • Apprentissage personnalisé/adaptatif	Interface cerveau-ordinateur, apprentissage automatique, apprentissage profond	Modélisation prédictive MOOC en temps réel (Le et al., 2018)


Tableau d'après (Ouyang & Jiao, 2021)

4.2 Quels apports pour l'expérience d'apprentissage ?

« L'intelligence artificielle joue un rôle important et croissant dans l'éducation. Un cas important est celui des **systèmes d'enseignement personnalisés** qui sont déjà bien établis, avec des **preuves croissantes de leur efficacité pour améliorer l'apprentissage** (VanLehn, 2011 ; Kulik & Fletcher, 2016 ; Steenbergen-Hu & Cooper, 2014, 2013 ; Ma, Adesope, Nesbit, & Liu, 2014 ; du Boulay, 2016). Les systèmes d'IA dans l'éducation (AIED) peuvent également faire un **usage diversifié et sophistiqué de l'IA pour créer l'interface si importante pour l'expérience d'apprentissage**. Par exemple, l'interface peut utiliser le **traitement et la génération du langage naturel**, les **interfaces vocales**, les **avatars**, l'**analyse vidéo de l'apprenant** pour juger de son attention et de son émotion. » [Traduction].

(Khosravi et al., 2022)

« En utilisant des algorithmes, **l'apprentissage peut être adaptatif**. En analysant les traces d'apprentissage de l'élève, comme des résultats à des questionnaires ou des données d'utilisation d'un logiciel, le système peut modifier son fonctionnement pour s'adapter à la personne, notamment à travers la **sélection de contenus et du niveau de difficulté**. Il commence à être possible d'analyser son comportement grâce à des capteurs, certains externes comme une caméra, et d'autres plus intrusifs comme une interface cerveau-ordinateur. Ce principe d'adaptation est au cœur de la pédagogie numérique, et se rencontre le plus souvent dans un contexte



où sont aussi poursuivis des **objectifs de ludification** ; l'apprenant s'inscrivant alors dans un jeu pédagogique avec la machine, parfois en collaboration avec d'autres apprenants (Giraudon et al., 2020). Le projet KidLearn (...) propose une activité d'apprentissage dont les multiples variantes impliquant additions ou soustractions de nombres entiers ou décimaux ont été conçues et mises en place par des didacticiens. Ces variantes sont organisées sous forme d'un graphe de difficultés croissantes, en respectant le concept de zone proximale de développement (Vygotsky, 1978). Ce concept est fondé sur l'idée que, entre un exercice trop difficile qui décourage et un exercice trop facile qui lasse, il existe une zone optimale qui maximise le progrès d'apprentissage, mesuré ici en observant les performances de l'élève au fil du jeu. Ce sont ces éléments qui sont intégrés à l'algorithme, qui va s'adapter automatiquement à la personne apprenante (Oudeyer et al., 2020).»

(Romero et al., 2023)

Exemple d'enseignement adaptatif pour l'apprentissage de la lecture et du français

«Lalilo développe un assistant pédagogique pour les enseignant-e-s de CP, CE1 et CE2, afin de les aider à **différencier leur enseignement de la lecture en fonction de l'avancement de chaque élève**, grâce à des technologies d'intelligence artificielle. L'assistant est une plateforme en ligne, avec une interface élève et une interface professeur-e. Il est co-construit avec les professeur-e-s des écoles : l'amélioration de la plateforme est continue, prenant en compte les retours des enseignant-e-s. (...)

Un algorithme d'apprentissage adaptatif : l'objectif de Lalilo, aider les enfants à apprendre à lire à leur propre rythme, repose sur une progression pédagogique fixée, divisée en leçons. Chaque leçon contient plusieurs "objectifs d'apprentissage", qui contiennent à leur tour une large gamme de questions. Par exemple, la leçon "voyelle [a]" contient deux objectifs d'apprentissage : "reconnaître le graphème a" et "décoder le phonème [a]". (...) Le système d'apprentissage adaptatif permet de choisir le meilleur exercice pour un enfant à un moment donné en fonction de sa progression et des exercices effectués.»

(Gelin, 2022)

[Lalilo fait partie des projets lauréats du partenariat d'innovation intelligence artificielle (P2IA) soutenus par le ministère de l'Éducation nationale et de la Jeunesse.]


4.3 IA et production de connaissances : l'exemple des humanités numériques

«...La linguistique de corpus et la sémantique se sont considérablement développées grâce aux analyses d'IA sur la représentation des connaissances et sur l'apprentissage automatique. De même, de nombreux développements ont ouvert des **perspectives sur les études littéraires**. Au début du millénaire, sous la pression d'éditeurs (et non de scientifiques) le terme anglais *Humanities Computing* qui caractérisait les recherches à la frontière des humanités au sens anglo-saxon, c'est-à-dire des **sciences de la culture**, se transforma en *Digital Humanities* ("humanités numériques"). Ce changement de dénomination signifiait que les humanités n'étaient plus simplement instrumentées par l'utilisation d'ordinateurs, mais qu'elles se transformaient en devenant numériques. On a parlé de **"tournant calculatoire"** pour caractériser cette évolution vue comme fondamentale. Le renouvellement qui s'en est suivi a été très fructueux. Dans tous les pays, de nombreuses équipes de recherche travaillant dans le champ des humanités classiques, que ce soit en histoire, en archéologie ou en littérature, ont renouvelé leurs approches en collaboration avec des informaticiens.»

(Ganascia, 2022)

5. Quelles pistes de travail pour former à l'IA et l'enseigner ?

5.1 Les pistes proposées par AI4K12



1. Perception : les ordinateurs (et les terminaux numériques) perçoivent le monde via des capteurs.

2. Représentation et raisonnement : les agents d'IA entretiennent des représentations du monde, via des structures de données, et les utilisent pour raisonner, via des algorithmes, mais sans penser comme un humain.

3. Apprentissage : les ordinateurs (et les terminaux numériques) peuvent apprendre à partir de données via des algorithmes d'apprentissage.

4. Interaction naturelle : les agents d'IA nécessitent de nombreux types de connaissances pour interagir « naturellement » avec les humains (conversation, reconnaissance faciale, etc.) mais ne peuvent raisonner.

5. Impact sociétal : l'IA peut avoir un impact à la fois positif et négatif sur la société et nous devons en être conscients car ces technologies changent nos façons de travailler, de voyager, de communiquer, etc.

D'après (Association for the Advancement of Artificial Intelligence & Computer Science Teachers Association, 2020)

5.2 Cadre de compétences de la littératie en IA

Compétence Description/résultats d'apprentissage

1. Reconnaître l'IA

Reconnaître les artefacts technologiques qui utilisent ou non l'IA.

2. Comprendre l'intelligence

Analyser et discuter de manière critique les caractéristiques qui rendent une entité « intelligente ». Débattre des différences entre l'intelligence humaine, animale et artificielle.

3. Pratiquer l'interdisciplinarité

Considérer qu'il existe de nombreuses façons de penser et de développer des machines « intelligentes ». Identifier une variété de technologies qui utilisent l'IA, y compris des technologies couvrant les systèmes cognitifs, la robotique et l'apprentissage machine (AM).

4. Identifier l'IA générale vs. étroite

Faire la distinction entre l'IA générale et l'IA étroite.

5. Forces et faiblesses de l'IA

Identifier les types de problèmes dans lesquels l'IA excelle ou non. Déterminer quand il est pertinent d'utiliser l'IA et quand il faut faire appel aux compétences humaines.

6. Imaginer la future IA

Imaginer les applications futures possibles de l'IA et réfléchir aux effets de ces applications sur le monde.

7. Représentations

Comprendre ce qu'est une représentation des connaissances et décrire quelques exemples de représentations des connaissances.

8. Prise de décision

Reconnaître et décrire des exemples de la manière dont les ordinateurs raisonnent et prennent des décisions.

9. Étapes AM

Comprendre les étapes de l'apprentissage automatique (AM) ainsi que les pratiques et les défis que chaque étape implique.

10. Place de l'humain dans l'IA

Être conscient que les humains jouent un rôle important dans la programmation, le choix des modèles et la mise au point des systèmes d'IA.

11. Connaître les données

Comprendre les concepts de base de la maîtrise des données.

12. Apprendre à partir des données

Savoir que les ordinateurs apprennent souvent à partir de données (y compris leurs propres données).

13. Interprétation critique des données

Comprendre que les données nécessitent une interprétation. Décrire comment les exemples d'entraînement fournis pour un ensemble de données initial peuvent affecter les résultats d'un algorithme.

14. Action et réaction

Comprendre que certains systèmes d'IA ont la capacité d'agir physiquement sur le monde. Cette action peut être dirigée par un raisonnement élaboré (par exemple, marcher le long d'un chemin planifié) ou par des impulsions réactives (par exemple, sauter en arrière pour éviter un obstacle détecté).

15. Capteurs

Comprendre ce que sont les capteurs par lesquels les ordinateurs perçoivent le monde. Identifier les capteurs sur une variété de dispositifs. Être conscient du fait que différents capteurs permettent différents types de représentation et de raisonnement sur le monde.

16. Éthique

Identifier et décrire les différents points de vue sur les principales questions éthiques entourant l'IA : vie privée, emploi, désinformation, « singularité » (point à partir duquel l'IA devient plus intelligente que les humains et peut s'accompagner de craintes que l'IA ne nuise intentionnellement aux humains), prise de décision, diversité, partialité, transparence et responsabilité.

17. Programmabilité

Comprendre que les agents sont programmables.

D'après (Long et Magerko, 2020) cité par (UNESCO, 2022)

5.3 Pour une formation citoyenne à l'IA

« L'IA concerne tous les citoyens d'abord parce qu'elle est de plus en plus présente dans tous les secteurs de la société et ensuite parce qu'**il est nécessaire de la comprendre pour participer aux débats éthiques** qu'elle engendre. **Il est normal de se questionner sur la pertinence de confier à des algorithmes des tâches qui mènent à des décisions cruciales**, par exemple en matière de justice, d'embauche, ou d'autres situations à fortes conséquences humaines. (...) **Le MOOC [« intelligence artificielle avec intelligence » de l'Inria] adopte une approche pédagogique ludique et expérientielle.** (...) Les participants sont mis en action dans des activités concrètes : ils manipulent des réseaux de neurones, essaient de faire reconnaître leurs dessins par une IA, sont invités à entraîner des modèles d'apprentissage automatique eux-mêmes. Ils sont invités à réfléchir collectivement, via les forums de discussion, à des questions soulevées par le développement de l'IA. »

(Romero *et al.*, 2023)

Production d'un module d'initiation à l'IA par trois agents conversationnels

Réponse produite par ChatGPT (06/12/23)

Instruction (prompt)

Dans le contexte de l'enseignement scolaire en France. Proposer, sous la forme d'un tableau, un module de formation d'environ une heure d'initiation à l'intelligence artificielle pour les professeurs (enseignement primaire et secondaire). Ce module doit présenter les origines de l'IA, les définitions de base, les enjeux pour l'éducation, les enjeux éthiques et des exemples d'application pédagogique.

Réponse

« Bien sûr, voici une proposition de module d'initiation à l'intelligence artificielle pour les enseignants du primaire et du secondaire en France, présentée sous la forme d'un tableau :

Temps	Contenu	Objectif
0-5 min	Introduction	Sensibiliser les enseignants à l'importance de l'intelligence artificielle dans le monde moderne. Présenter brièvement les origines de l'IA.
5-15 min	Définitions de base	Expliquer les concepts fondamentaux de l'intelligence artificielle tels que les algorithmes, l'apprentissage automatique et les réseaux neuronaux. Utiliser des termes simples pour assurer une compréhension de base.
15-25 min	Enjeux pour l'éducation	Discuter de l'impact potentiel de l'IA sur l'éducation. Mettre en avant les avantages tels que la personnalisation de l'apprentissage et les défis tels que la nécessité d'acquérir de nouvelles compétences.
25-35 min	Enjeux éthiques	Examiner les questions éthiques liées à l'utilisation de l'IA dans l'éducation, en mettant l'accent sur la confidentialité des données, la discrimination algorithmique et la transparence. Encourager une réflexion sur la responsabilité éthique des enseignants.
35-45 min	Exemples d'application pédagogique	Présenter des exemples concrets d'utilisation de l'IA dans l'éducation, tels que les tutoriels intelligents, l'analyse automatisée des performances des élèves et les outils d'assistance à l'apprentissage. Encourager les enseignants à imaginer comment ils pourraient intégrer ces technologies dans leur enseignement.
45-55 min	Questions et discussions	Inviter les enseignants à poser des questions et à partager leurs préoccupations. Faciliter une discussion sur la manière dont l'IA peut être intégrée de manière positive dans l'environnement éducatif.
55-60 min	Conclusion	Résumer les points clés du module. Fournir des ressources supplémentaires pour approfondir les connaissances. Encourager les enseignants à rester informés sur les développements futurs de l'IA dans l'éducation.

Ce module vise à offrir une introduction équilibrée et accessible à l'intelligence artificielle tout en mettant l'accent sur les aspects pertinents pour les enseignants du primaire et du secondaire en France.»

Source : <https://chat.openai.com/chat>

Réponse produite par Llama (07/12/23)

Instruction (prompt)

Dans le contexte de l'enseignement scolaire en France. Proposer, sous la forme d'un tableau, un module de formation d'environ une heure d'initiation à l'intelligence artificielle pour les professeurs (enseignement primaire et secondaire). Ce module doit présenter les origines de l'IA, les définitions de base, les enjeux pour l'éducation, les enjeux éthiques et des exemples d'application pédagogique.

Réponse

« Voici un exemple de module de formation d'environ une heure d'initiation à l'intelligence artificielle pour les professeurs :

Durée	Partie	Description
10 min	Introduction	Présentation du module et de l'objectif : initier les professeurs à l'intelligence artificielle et ses applications pédagogiques.
20 min	Origines de l'IA	Présentation des origines de l'intelligence artificielle, des premiers concepts et des développements historiques.
20 min	Définitions de base	Explications des termes clés tels que l'apprentissage automatique, le <i>deep learning</i> , le <i>big data</i> , etc.
15 min	Enjeux pour l'éducation	Discussion des enjeux de l'intelligence artificielle pour l'éducation, notamment en ce qui concerne la personnalisation de l'apprentissage, l'efficacité des méthodes pédagogiques et l'accessibilité des ressources éducatives.
20 min	Enjeux éthiques	Présentation des enjeux éthiques liés à l'intelligence artificielle, tels que la vie privée, le biais, la responsabilité, etc.
25 min	Exemples d'application pédagogique	Présentation d'exemples concrets d'applications de l'intelligence artificielle dans l'enseignement primaire et secondaire, tels que l'utilisation de chatbots pour aider les étudiants dans leur apprentissage, l'analyse de données pour améliorer la gestion de la classe, etc.
10 min	Conclusion	Bilan de la session et proposition d'actions pour aller plus loin dans l'exploration de l'intelligence artificielle dans l'enseignement.

Ce module peut être adapté en fonction des besoins et des niveaux des professeurs, et peut être complété par des ressources complémentaires telles que des vidéos, des articles et des exercices pratiques. »

Source : <https://poe.com/>

Réponse produite par Claude (07/12/23)

« Voici un tableau présentant un module de formation d'initiation à l'intelligence artificielle d'environ une heure pour les professeurs :

Durée	Contenu	Objectif
5 min	Introduction : présentation du module et de son objectif de sensibilisation à l'IA	Situer le cadre de la formation.
10 min	Historique et définitions de base de l'IA	Comprendre les origines et les concepts clés de l'IA.
10 min	Enjeux de l'IA pour l'éducation	Identifier le potentiel et les défis de l'IA pour l'enseignement et l'apprentissage.
10 min	Enjeux éthiques de l'IA	Prendre conscience des questions éthiques soulevées par le développement de l'IA.
15 min	Exemples concrets d'applications pédagogiques de l'IA	Illustrer le potentiel de l'IA pour enrichir les pratiques pédagogiques.
10 min	Bilan et perspective	Synthétiser les points clés abordés et ouvrir sur la suite.

Ce module aborde de manière synthétique mais concrète les fondamentaux de l'IA et son impact sur l'éducation afin de sensibiliser les enseignants aux opportunités et défis posés par cette technologie. Des temps d'échanges sont prévus pour répondre aux questions.»

Source : <https://poe.com/>

5.4 Une proposition de parcours en cinq piliers

« L'intelligence artificielle n'a pas atteint sa maturité. Le sujet tel qu'il a été défini en 1956, étudié pendant 40 ans, a atteint ses résultats spectaculaires depuis 2012 et est encore difficile à comprendre. Il est encore plus difficile de prévoir comment les technologies vont évoluer, même dans un avenir proche. Si la construction d'un programme d'études complet est hors de portée de ce document, il est possible de proposer cinq piliers et de s'appuyer sur ceux-ci. (...) »

1. Incertitude et caractère aléatoire

Les données sont incohérentes. Elles ne démontrent pas une stricte nature causale.

2. Codage et calcul

Le codage et la pensée informatique font aujourd'hui partie des programmes d'études de nombreux pays, conformément aux recommandations des experts.

3. Sensibilisation aux données

Une éducation aux données (sciences de la donnée ou *data science*) reposera sur des activités où les données sont collectées et visualisées, manipulées et analysées.

4. Pensée critique

Les sciences sociales peuvent et doivent apporter leur contribution à de nombreuses questions éthiques soulevées par l'IA. La pensée critique est un aspect important, mais il est essentiel qu'elle repose sur une réelle compréhension du fonctionnement de la technologie.

5. Humanisme post-IA

L'idée clé est que les progrès de l'IA nous font reconsidérer, en tant qu'êtres humains, certaines vérités de base.»

D'après (de la Higuera & Bocquet, 2020)

5.5 Formation à l'IA et prévention du décrochage scolaire

« La **Scientothèque** est une association sans but lucratif installée au sein de l'Expérimentarium, musée de Physique de l'Université Libre de Bruxelles. Depuis sa fondation en 2001, sa mission principale est de contribuer à la diminution des inégalités sociales. Deux réalités ont mené à la mise en place de l'association : d'une part, le risque accru de décrochage scolaire et la difficulté d'accès aux études supérieures pour les jeunes issus de milieux précarisés (Coslin, 2012) et, d'autre part, la désaffection pour les études scientifiques de la part du public féminin. Il a d'ailleurs été démontré qu'il était moins évident d'attirer les filles vers les projets à caractère scientifique ou technologique (Blanchard, 2021). (...) Une sélection d'activités a été proposée à deux groupes de jeunes de 10-12 ans durant l'année scolaire 2020-2021 lors d'**ateliers extrascolaires hebdomadaires** à l'Institut des Ursulines à Koekelberg. Ce projet, financé par la région de Bruxelles-Capitale, visait à diminuer le décrochage scolaire pour des élèves vivant dans des quartiers précarisés. Tout au long des séances, les jeunes ont pu, grâce à une **approche ludique et collaborative**, découvrir l'histoire des machines, établir des liens avec l'intelligence biologique, comprendre ce qui se cache derrière le mot "algorithme", observer et programmer des robots Thymio, s'initier à la programmation sur la plateforme Scratch, et débattre des conséquences de l'IA sur la société. »

(Romero et al., 2023)

5.6 Le projet européen « AI4T » : Mooc « Intelligence artificielle pour et par les enseignants »

« Ce cours a pour objectif d'aider les enseignants et la communauté éducative dans son ensemble à acquérir une compréhension générale sur l'IA – ses usages, ses technologies et ses limites, et à les accompagner vers un usage éclairé des outils basés sur l'IA dans le contexte de l'Éducation.

Le Mooc est organisé en quatre modules :

- Module 1 : Utiliser l'IA en éducation.
- Module 2 : Qu'est-ce que l'IA ?
- Module 3 : Comment fonctionne l'IA ?
- Module 4 : L'IA à notre service en tant qu'enseignants ?

Chaque module propose des vidéos, des textes, des activités, des quiz et un accès au forum pour partager vos expériences et interagir avec l'équipe pédagogique et avec les autres participants. L'ensemble du parcours peut être réalisé en deux ou trois heures.

Avant et après ces 4 modules de cours, la partie "Présentation générale" présente les objectifs de la formation et vous guide dans l'utilisation de la plateforme du cours.

La partie "Conclusion" aborde les aspects éthiques liés à l'utilisation de l'IA dans l'enseignement. (...)



Ce cours a été développé et expérimenté auprès d'enseignants et chefs d'établissement dans le cadre du **projet européen AI4T, réunissant cinq pays : la France, l'Italie, l'Irlande, le Luxembourg et la Slovaquie.**

Dans ce contexte, les contenus ont été élaborés avec les cinq ministères de l'éducation impliqués dans le projet et notamment le MENJ (Direction du numérique pour l'éducation).»

Le MOOC est accompagné d'un manuel ouvert AI4T (Open TextBook) via la Chaire UNESCO RELIA :

<https://chaireunescorelia.univ-nantes.fr/2023/11/16/le-manuel-ouvert-ai4t-en-route-pour-la-deuxieme-edition/>

<https://pressbooks.pub/iapourlesenseignants>

D'après (Inria & AI4T, 2023)



6 Le tournant des systèmes d'IA générative et des grands modèles de langage

6.1 Le développement de l'IA générative

Présentation générale

«Avant 2014, tous les modèles d'apprentissage profond existants étaient principalement descriptifs, se concentrant sur le résumé ou les schémas et les relations de données existants. Ces modèles visaient à expliquer les schémas de données et à prédictions basées sur les informations présentes. Cependant, (Goodfellow et al., 2014) ont introduit le **Generative Adversarial Network (GAN)**, ce qui a ouvert une nouvelle ère de l'intelligence artificielle générative (GAI). Contrairement à leurs homologues descriptifs, les modèles génératifs, tels que les GAN, sont conçus pour apprendre la distribution de probabilité sous-jacente des données. Leur objectif principal est de **générer de nouveaux échantillons de données qui ressemblent étroitement aux modèles observés dans les données d'apprentissage**. La percée du GAN a marqué une rupture significative des méthodes traditionnelles d'apprentissage profond, ouvrant des possibilités passionnantes pour l'intelligence artificielle générative. L'intelligence artificielle générative a depuis lors suscité une grande attention en raison de son **impact transformateur** dans divers domaines de la vie. Elle offre des solutions élégantes à des problèmes complexes, ce qui permet de créer des données synthétiques, du contenu artistique et des images réalistes. Ce changement de paradigme dans la technologie de l'IA a profondément influencé la nouvelle perception, la mise en œuvre et l'utilisation de l'intelligence artificielle, suscitant l'innovation et de nouvelles possibilités d'application dans tous les secteurs. (...) Le travail novateur de Vaswani et al. **"Attention Is All You Need" [2017]** par l'équipe de Google Brain a introduit un **modèle de transformateur [Transformer]** capable d'analyser des ensembles de données à grande échelle. [Ce modèle] a été initialement développé pour le traitement du naturel (NLP), mais a ensuite été adapté à d'autres domaines de l'apprentissage automatique, tels que la vision par ordinateur. (...) Ainsi, la solution proposée présentait une nouvelle façon de traiter les tâches comme la traduction, la génération de contenu et l'analyse d'émotion.»

(Bengesi et al., 2023)

«Au cours des deux dernières années, une **pléthore de grands modèles génératifs** tels que ChatGPT ou Stable Diffusion ont été publiés. Concrètement, ces modèles sont capables d'effectuer des tâches telles qu'un système général de questions-réponses ou la création automatique d'images artistiques **qui révolutionnent plusieurs secteurs**.

Par conséquent, les implications que ces modèles génératifs ont dans l'industrie et la société sont considérables, car plusieurs tâches professionnelles peuvent être transformées. Par exemple, l'IA générative est capable de transformer de manière efficace et créative des textes en images, comme le modèle DALL-E-2 ; des textes en images 3D, comme le modèle Dreamfusion ; des images en texte, comme le modèle Flamingo ; des textes en vidéo, comme le modèle Phenaki ; des textes en audio, comme le modèle AudioLM ; des textes en d'autres textes, comme ChatGPT ; des textes en code, comme le modèle Codex ; des textes en textes scientifiques, comme le modèle Galactica ou même créer des algorithmes comme AlphaTensor.»

L'**IA générative** désigne les technologies d'IA entraînées sur des données massives (ensemble de Wikipédia, GitHub, réseaux sociaux, Google Images, etc.) et **pouvant générer de nouveaux contenus** (texte, image, audio, vidéo) de façon aléatoire à partir d'une information d'entrée (« *prompt* ») saisie par l'utilisateur.

Les **modèles d'IA générative** (réseaux de neurones profonds, *transformers* et autres modèles, tels que les réseaux antagonistes génératifs, [GAN : *generative adversarial networks*]), qui se multiplient surtout depuis 2022, peuvent être répartis selon la taxonomie suivante :

- texte à image (ex. DALL-E 2 d'OpenAI) ;
- texte à représentations 3D (ex. Dreamfusion de Google Research) ;
- image à texte (ex. Flamingo de Deepmind) ;
- texte à vidéo (ex. Phenaki de Google Research) ;
- texte à audio (Jukebox d'OpenAI) ;
- texte à texte (ex. ChatGPT d'OpenAI) ;
- texte à code (ex. Codex d'OpenAI) ;
- texte à formule scientifique (ex. Galactica de Meta AI) ;
- autres modèles.

D'après (Gozalo-Brizuela & Garrido-Merchan, 2023)

Les modèles de fondation

« Un modèle de fondation (*Foundation Model*), selon l'appellation introduite par l'université Stanford, est un modèle de grande taille fondé sur une architecture de réseau de neurones profond, entraîné sur une grande quantité de données non annotées (généralement par apprentissage autosupervisé). Les grands modèles de langue (LLM pour *Large Language Model*) sont des cas particuliers des modèles de fondation qui sont entraînés sur un corpus de textes. Ces modèles de fondation ouvrent de **nouvelles perspectives et introduisent un nouveau paradigme dans le traitement de la langue, mais aussi dans le traitement des signaux multimodaux** (son, image, vidéo, etc.). Ces modèles pré-entraînés sur de grands corpus peuvent être optimisés pour réaliser une nouvelle application en utilisant peu de données supplémentaires spécifiques à cette tâche. »

(CNPEN, 2023)

6.2 Grands modèles de langage et nouvelle génération d'agents conversationnels

Comment fonctionnent les grands modèles de langage ?


Le principe des modèles de langage (ou LLM : *Large Language Models*) n'est **pas nouveau** : ce type d'algorithme est déjà présent quotidiennement avec les **assistants de rédaction des messages** instantanés. Son fonctionnement consiste à **prédire le mot suivant** à partir d'une instruction (« *prompt* ») saisie par l'utilisateur. La **phase d'entraînement** permet d'ajuster les paramètres internes à partir de données textuelles issues du web (non vérifiées). Une quantité massive de données et de paramètres permet d'améliorer les performances de prédiction. On ne peut pas pour autant parler de « compréhension » ou de « personnalité » de l'algorithme, il s'agit d'abord de **réponses produites à partir de régularités statistiques**. Par ailleurs, ces modèles peuvent produire des « **hallucinations** », en inventant de fausses informations, ce qui nécessite la plus grande vigilance de la part de l'utilisateur. Actuellement les modèles de langage les plus puissants sont détenus par de grandes entreprises qui communiquent très peu sur leurs données d'entraînement.

D'après (Inria Flowers, 2023a)

Voir aussi (Inria Flowers, 2023b) sur le « *prompting* » : « faire réaliser une certaine tâche à un modèle de langage (...) en lui expliquant cette tâche au moyen de phrases en langage naturel. » Deux méthodes sont présentées : « expliquer la tâche en langage naturel, et donner des exemples de réalisation de la tâche. »

Fonctionnement d'un grand modèle de langage et *prompting*


Instruction (*prompt*)



Réponse

D'après (Inria Flowers, 2023)

Principe de base : la prédiction de mots



Comment faire réaliser une tâche à un modèle de langage ?

Inria
flowers

Le « tournant ChatGPT » : origines et socle technologique

Dans cette catégorie des IA génératives, l'application ChatGPT, ouverte au public par société OpenAI depuis le 30 novembre 2022, représente une **nouvelle génération d'agent conversationnel** (*chatbot* en anglais), « agent qui dialogue avec un utilisateur dans le but de faire une recherche, de trouver une réponse à sa question ou encore de s'exercer dans une discipline donnée » (CSEN & DNE-TN2, 2022). En raison des performances affichées, elle constitue manifestement un **« saut qualitatif »** dans les technologies de traitement automatique du langage (TAL) – ou **analyse du langage naturel (Natural Language Processing – NLP)** (Boisson & DNE-TN2, 2023).

Ce **« prototype d'agent conversationnel (...) »**, modèle de langage affiné à l'aide de techniques d'apprentissage supervisé et d'apprentissage par renforcement » (« ChatGPT », 2023), basé sur une intelligence artificielle générative, capable de générer des textes à la demande ou du code informatique à partir de questions en langage naturel, est une **application propriétaire développée** à partir d'une optimisation du modèle algorithmique GPT-3.5.

« Le GPT-3 est plus important que le GPT-2, avec 175 milliards de paramètres. Pour avoir une idée plus précise de la dimension de cet algorithme, les données de Wikipédia, qui comprennent environ 6 millions d'articles, ne représentent que 0,06 % des données entraînées par le GPT-3. »

(Boa Sorte et al., 2021)

Les technologies qui fondent ChatGPT peuvent être résumées ainsi :

- il s'agit d'un **« modèle de langage étendu »**, un type d'intelligence artificielle qui utilise l'apprentissage profond (une forme d'apprentissage automatique) pour traiter et générer des textes en langage naturel (...) [Ce type de modèle est] formé sur des **quantités massives de données textuelles, lui permettant d'apprendre les nuances et les complexités du langage humain** » d'après (Susnjak, 2022);
- son appellation résulte d'une contraction entre « chat » pour conversation et « GPT » [*Generative Pre-trained Transformer*], qui est un « modèle de transduction de langage prédictif » (transduction : transformation d'une donnée représentée sous une forme en une donnée représentée sous une autre forme);
- son algorithme basé sur un **« transformer »** (Vaswani et al., 2017) correspond à un modèle d'architecture de réseau de neurones qui utilise le **mécanisme d'auto-attention permettant d'établir des relations entre les mots et de déterminer le sens d'un mot en fonction du contexte**, en se focalisant sur les mots les plus pertinents, permettant ainsi de s'approcher de façon crédible du langage naturel ;
- il fonctionne selon un **modèle de prédiction de mots**, à partir des instructions / consignes ou « *prompts* » de l'utilisateur en langage naturel, combinant dans sa phase d'entraînement apprentissage par renforcement et apprentissage supervisé à partir des rétroactions humaines;
- il est donc important de rappeler que, comme toute technologie IA, les textes produits sont générés et renforcés à partir d'**actions et de travail humains** (des personnes qui conçoivent l'algorithme jusqu'à celles qui identifient, vérifient des données, ou interagissent avec le programme).

Le socle technologique de ChatGPT est le résultat d'**« une combinaison de deux modèles »** : un modèle **linguistique** (dont les références s'arrêtent en 2021), GPT, modèle géant de prédiction de texte et modèle encyclopédique, et un modèle **conversationnel**

(qui s'affine en fonction du retour des utilisateurs), InstructGPT, version "redressée" de GPT-3 à partir de l'annotation de textes générés.»

C'est aussi le résultat d'«une série de **strates issues de la recherche en linguistique et en informatique** :

- la **statistique sémantique**, avec le concept de "fenêtre contextuelle" (le sens procède de la position relative des mots les uns avec les autres);
- la **vectorisation de mots** (*word embedding* ou "plongement lexical") permettant de caractériser un mot au sein d'espaces contextuels en fonction des mots voisins;
- les **réseaux de neurones** pour reconnaître les relations syntaxiques et sémantiques précises entre les mots et gérer les transferts linguistiques (les réponses aux instructions des utilisateurs peuvent ainsi s'appuyer sur un espace sémantique multilingue);
- les **modèles transformers** (2017) fondés sur le mécanisme d'attention et modélisant les formules syntaxiques;
- le développement des **grands modèles de langage**, à partir de 2018 avec BERT (Google) puis GPT-2 et 3 (OpenAI).»

D'après (Langlais, 2023)

Le 14 mars 2023, OpenAI annonce la montée en version de son modèle avec le lancement de **GPT-4** (service payant à ce jour ou disponible dans la nouvelle version du moteur de recherche Bing) : « **modèle multimodal** à grande échelle qui peut accepter des entrées d'image et de texte et produire des sorties de texte. Bien que moins capable que les humains dans de nombreux scénarios du monde réel, GPT-4 présente des performances de niveau humain sur divers critères professionnels et académiques, y compris la réussite d'un examen du barreau simulé avec un score autour des 10% des meilleurs candidats. » (OpenAI, 2023)

Les autres grands modèles de langage

Parmi les autres grands modèles de langage, on peut citer notamment, en open source :

- **Bert** (*Bidirectional Encoder Representations from Transformers*), développé par Google en 2018 (Devlin et al., 2019);
- **Bloom**, initié par la start-up franco-américaine Hugging Face, entraîné sur la machine « Jean Zay » « un des plus puissants supercalculateurs d'Europe » (CNRS, 2022);
- **LLaMA** de Meta AI (Touvron et al., 2023).

Pour plus de détails consulter aussi (Pôle d'expertise de la régulation numérique, 2023).

Exemples de grands modèles de langage à l'état de l'art et des politiques d'ouverture associées

	Année	Nb. maximal de paramètres (en mds)	Architecture publique	Modèle entraîné ouvert	Données ouvertes	Conversationnel (RLHF)	Accessible aux utilisateurs (UI ou API)
BigScience BLOOM	2022	175	✓	✓	✓	✗	✓
Google GLaM/PaLM	2021/ 2022	1200/540	✓	✗	✗	✗	✓ API payante
Google LaMDA/Bard	2022	137/?	✓/✗	✗	✗	✓	✓ UK/US
Meta OPT	2022	175	✓	✓	✓	✗	✗
Meta BlenderBot3	2022	175	✓	✓	✓	✓	✓ US
Meta LLaMA	2023	65	✓	✓	✓	✗	✗
OpenAI GPT-3	2020	175	✓	✗	✓ 1 ^{re} version seulement	✗	✓ option payante
OpenAI GPT-3.5 (InstructGPT / ChatGPT)	2022	175/?	✓/✗	✗	✗	✓	✓ option payante
OpenAI GPT-4	2023	?	✗	✗	✗	✓	✓ API et UI payante

(Pôle d'expertise de la régulation numérique, 2023)

En décembre 2023, Google présente **Gemini** (*Generalized Multimodal Intelligence Network*) sa nouvelle intelligence artificielle multimodale (Hsiao, 2023).


Les réactions et interrogations

Depuis l'ouverture de l'application ChatGPT les réactions et **les débats ont été très nombreux** dans les médias et dans de nombreux milieux professionnels, parmi lesquels la recherche et l'éducation.

« Ces IA génératives multilingues, multitâches et interactives posent de **nombreuses questions** : les données choisies pour les entraîner, la répartition des langues dans un système multilingue, les paramètres d'optimisation des systèmes, la propriété des contenus générés, etc. De plus, le pouvoir génératif des IA est souvent amplifié par des **filtres qui permettent de censurer certains sujets** et des modules de déduction logique dans le but de vérifier la véracité des énoncés. Une poignée d'humains (ingénieurs, transpositeurs, évaluateurs) ont créé ce type de système utilisé par des millions de personnes. Ces systèmes d'intelligence artificielle utilisés massivement posent donc des **défis éthiques majeurs** parmi lesquels la transformation de la notion de production d'information, le rapport à la vérité et les risques massifs liés à la désinformation et la manipulation. »

(Devillers, 2023)

Les réactions ont été **de la fascination**, face au caractère crédible et vraisemblable des « conversations » produites et à la pertinence – au moins apparente – de certaines réponses, **à l'inquiétude** en raison des mésusages possibles (possibilité de triche pour réaliser des travaux scolaires, de fraude aux examens, doute sur la paternité des écrits produits dans tel ou tel contexte personnel ou professionnel) et des **incertitudes sur les technologies, les données** mobilisées et la fiabilité des réponses produites.



Quelles potentialités pédagogiques ?

Ce type d'application offre plusieurs potentialités pédagogiques très activement explorées et partagées actuellement par la communauté des enseignants :

- une **assistance à l'ingénierie pédagogique** (conception de séquences d'enseignement et d'apprentissage, voir proposition de matrice ci-dessous) ;
- un **soutien à la créativité** en proposant, à partir des requêtes et questions posées, une première base de rédaction ou de code ;
- un **soutien à l'apprentissage du français et des langues étrangères** par la fonction de suivi conversationnel ;
- une **assistance** pour amorcer ou optimiser une tâche rédactionnelle ;
- un **nouveau défi pour l'éducation aux médias et à l'information (EMI)** et un cadre pour la **formation à l'esprit critique**, qui nécessite de la part des enseignants et de leurs élèves de vérifier systématiquement le contenu et la pertinence des réponses fournies.

Ces potentialités ont déjà fait l'objet de plusieurs publications, parmi lesquelles (Kasneci et al., 2023) qui pointe les possibilités suivantes : apprentissage personnalisé (analyse de travaux et suggestion de matériels pédagogiques adaptés), planification des cours (assistance à la création de plans et d'activités inclusives), apprentissage des langues (résumés et traductions).

Par ailleurs, plusieurs **guides pédagogiques** proposent des pistes d'utilisation pour l'enseignant. Ainsi le guide produit par (Herft, 2023), enseignant australien, et traduit en français, propose une série d'exemples d'instructions à saisir pour en faire un assistant pédagogique et didactique. Ex. : « Créez un plan de cours pour une classe... qui couvre le concept de ... et comprend une variété d'activités et d'évaluations. »

Prompting et ingénierie pédagogique : exemple de matrice pour une fiche d'instruction

Information	Situation pédagogique	Champ à compléter
Identité Contexte Discipline / domaine d'apprentissage	Je suis professeur de [...] dans [tel type d'établissement].	
Cadre d'action Contraintes Difficultés	L'établissement ou les élèves a/ont [tel profil], doivent faire face à [telle difficulté].	
Finalités Objectifs Public cible / niveau Actions visées	J'enseigne à des élèves de [tel niveau, tel âge] – je souhaite les faire progresser ou leur enseigner [telle thématique, tel point du programme, telle compétence].	
Question Demande	Je souhaite construire [telle séquence], produire [telle ressource, telle situation d'apprentissage] pour / avec mes élèves.	
Style Format Mots-clés Étapes	Je souhaite la réponse sous forme de [liste/tableau...], pour produire un visuel, un schéma, dans un langage adapté à [tel niveau], en utilisant les mots-clés suivants : ... <i>Compléter éventuellement par un exemple de la production attendue.</i> <i>Au besoin détailler les étapes à suivre pour améliorer le résultat (prompting par « chaîne de pensée »).</i>	

(Allouche, 2023b)

Fonctions de ChatGPT pour soutenir les enseignants dans leurs pratiques

Aspect	Fonction	Citations représentatives
Préparation pédagogique	Générer des supports de cours	« Nous avons demandé à ChatGPT de créer l'un des dialogues ci-dessus dans un format pouvant être importé dans DialogFlow. ChatGPT a pu le générer avec succès. »
	Fournir des suggestions	« J'ai dit à ChatGPT que l'apprenant souffrait de dyslexie, et finalement ChatGPT a recommandé du matériel d'apprentissage spécifique pour l'apprenant. »
	Effectuer une traduction linguistique	« ChatGPT peut être utilisé pour traduire du matériel pédagogique dans différentes langues. »
Évaluation	Générer des tâches d'évaluation	« Une autre utilisation de ChatGPT est sa capacité à générer des exercices, des quiz et des scénarios qui peuvent être utilisés en classe pour faciliter la pratique et l'évaluation. »
	Évaluation des performances des apprenants	« ChatGPT peut être formé pour noter les dissertations des apprenants, offrant ainsi aux enseignants plus de temps pour se concentrer sur d'autres aspects de l'enseignement. »

D'après (Lo, 2023)

Les perspectives des grands modèles de langage pour les personnes handicapées

« Afin d'autonomiser les apprenants handicapés, [ils] peuvent être utilisés en combinaison avec des solutions de conversion de la parole en texte ou du texte en parole pour aider les personnes souffrant de déficience visuelle. En combinaison avec les possibilités de tutorat en groupe et à distance mentionnées précédemment, les modèles de langage peuvent être utilisés **pour développer des stratégies d'apprentissage inclusives** avec un soutien adéquat dans des tâches telles que l'écriture adaptative, la traduction et la mise en évidence de contenus importants dans différents formats. Cependant, il est important de noter que l'utilisation de grands modèles de langage **doit être accompagnée de l'aide de professionnels** tels que des orthophonistes, des éducateurs et d'autres spécialistes qui peuvent adapter la technologie aux besoins spécifiques des handicaps de l'apprenant. » [Traduction]

(Kasneci et al., 2023)

Quels limites et points de vigilance (dimensions éthiques, pédagogiques et scientifiques) ?

Plusieurs tests ont été réalisés pour évaluer les performances et limites de ChatGPT (GPT-3.5) (Allouche, 2023a). Le schéma ci-dessous propose une modélisation de parcours utilisateur critique, intégrant des consignes qui peuvent être simples ou complexes, allant d'une simple demande d'information à une problématisation.

Modélisation de parcours utilisateur critique avec un agent conversationnel



(Allouche, 2023a) mis à jour

À l'issue de ces tests, plusieurs limites et points de vigilance peuvent être relevés (sachant que dans le cadre du **RGPD**, l'application n'est pas utilisable dans un cadre scolaire, seules sont possibles des utilisations à titre individuel, sous le régime du contrat privé) :

- pour l'instant les réponses fournies ne sont **pas basées sur des données en temps réel** via une connexion au web (sous réserve de vérification, il s'agit des données issues du web, antérieures à 2022) ;
- elles contiennent des **biais** en raison de la nature des données traitées, même si des filtres sont appliqués pour limiter les biais les plus flagrants ;
- les **erreurs factuelles** et possibles « hallucinations » nécessitent quasi systématiquement une vérification des contenus par l'utilisateur, ce qui peut constituer à la fois une limite et un atout dans un cadre pédagogique pour développer l'esprit critique et établir une distance avec les contenus générés ;
- le risque de produire et de diffuser des infox ou des informations tronquées, erronées ou non vérifiables ;
- une telle technologie, en raison même de ses performances et de la masse des données traitées (sans transparence sur la nature de celles-ci), soulève inévitablement les questions du référencement (peut-on se référer aux réponses produites alors qu'elles ne sont pas systématiquement sourcées ni reproductibles ?), de la paternité des contenus (à qui appartiennent-ils, peut-on attribuer la paternité d'une œuvre à une IA ?) (Stokel-Walker, 2023) ou du **droit d'auteur** (les réponses générées à partir de ces données massives respectent-elles le droit d'auteur lorsque celui-ci s'applique ? par exemple sur une œuvre scientifique ou littéraire qui n'est pas sous licence libre) ;
- **l'absence de sources** – ou le caractère possiblement erroné de celles qui sont citées – constitue une véritable difficulté pour une utilisation dans un cadre académique (éducation, recherche, documentation), sauf si l'utilisateur en fait la demande expresse, et sous réserve que celui-ci vérifie une à une les références citées.

En réponse à ce problème, d'autres applications complémentaires ou concurrentes, comme Bing Chat (moteur de recherche de Microsoft qui intègre désormais GPT-4) ou Perplexity (<https://www.perplexity.ai/>), proposent de fournir des sources (mais sans garantir pour autant la pertinence ou la complétude de celles-ci).


On peut noter aussi l'**impact environnemental** de ce type de modèle, non spécifique à ChatGPT :

« On estime que l'entraînement du modèle GPT-3 d'OpenAI a nécessité autant d'énergie que le voyage aller-retour d'une voiture sur la lune, générant ainsi l'équivalent de 85 000 kg d'émissions de CO₂ (Quach, 2020). Il est désormais largement admis que la consommation d'énergie constitue un défi majeur pour l'IA axée sur les données (Strubell et al., 2019). » (Holmes & Tuomi, 2022) traduction par (Bocquet, 2023)

En résumé, les principales pistes à explorer relèvent surtout de l'assistance (voir exemples p.33-34-35), de l'inspiration, du complément ou de l'approfondissement. En effet, un tel saut technologique invite surtout les chercheurs et les pédagogues à, davantage encore, innover, collaborer, s'informer et se former, **mettre à distance et faire preuve d'esprit critique** pour accompagner les élèves et les étudiants dans leur apprentissage et leur formation.

Comme le suggère le schéma ci-dessous, parmi les défis à relever figure la **distinction à établir avec les élèves entre ce qui relève exclusivement de l'humain** : donner du sens à une information, une connaissance, une œuvre littéraire ou artistique, **et ce qui peut effectivement être confié à une IA** : le traitement et le calcul de données massives, au-delà des capacités humaines, à des fins de prédiction, de probabilité ou d'optimisation, mais sans intention ni compréhension de ce qui est produit.

Ce qui peut relever ou pas d'une IA



(DNE-TN2, 2023)

Références

Allouche, E. (2023a, janvier 5). Sens et finalités du numérique en éducation – Hors-série : Tests et simulations d'«entretien» avec ChatGPT (Open AI) [Billet]. *Éducation, numérique et recherche*. <https://edunumrech.hypotheses.org/7635>

Allouche, E. (2023b, octobre 2). IA génératives et ingénierie pédagogique : Le *prompting*, pistes de travail et applications [Billet]. *Éducation, numérique et recherche*. <https://edunumrech.hypotheses.org/9934>

Association for the Advancement of Artificial Intelligence, & Computer Science Teachers Association. (2020). AI4K12. AI4K12. <https://ai4k12.org/>

Association Française pour l'Intelligence Artificielle (AFIA). (2022, janvier 6). Journée Enseignement et Formation en IA : « IA pour l'enseignement ». AfIA. <https://afia.asso.fr/efia-2022/>

Bengesi, S., El-Sayed, H., Sarker, M. K., Houkpati, Y., Irungu, J., & Oladunni, T. (2023). *Advancements in Generative AI: A Comprehensive Review of GANs, GPT, Autoencoders, Diffusion Model, and Transformers* (arXiv:2311.10242). arXiv. <https://doi.org/10.48550/arXiv.2311.10242>

Boa Sorte, P., Farias, M. A. de F., dos Santos, A. E., Santos, J. do C. A., & Dias, J. S. dos S. R. (2021). Artificial intelligence in academic writing: What is in store with the GPT-3 algorithm? *Revista EntreLínguas*, 7(00). <https://periodicos.fclar.unesp.br/entrelinguas/article/download/15352/11410/51225>

Bocquet, F. (2023, janvier 23). État de l'art et de la pratique de l'intelligence artificielle dans l'éducation (Holmes & Tuomi, 2022) [Traduction] [Billet]. *Éducation, numérique et recherche*. <https://edunumrech.hypotheses.org/8350>

Boisson, J., & DNE-TN2. (2023, janvier 12). Intelligence artificielle, traitement automatique des langues et agents conversationnels [Billet]. *Éducation, numérique et recherche*. <https://edunumrech.hypotheses.org/8235>

Cardon, D., Cointet, J.-P., & Mazieres, A. (2018). La revanche des neurones : L'invention des machines inductives et la controverse de l'intelligence artificielle. *Réseaux*, 5(211). <https://doi.org/10.3917/res.211.0173>

Cisel, M., & Baron, G.-L. (2019). Vers des intelligences artificielles pour l'enseignement de la démarche d'investigation. *Educational Journal of the University of Patras UNESCO Chair*, 0, Article 0. <https://doi.org/10.26220/une.2990>

CNPEN. (2023, juin 30). Avis 7 du CNPEN Systèmes d'intelligence artificielle générative : *Enjeux d'éthique*. Comité Consultatif National d'Éthique. <https://www.ccne-ethique.fr/fr/publications/avis-7-du-cnpén-systemes-dintelligence-artificielle-generative-enjeux-dethique>

CNRS. (2022, juillet 12). *Livraison du plus grand modèle de langue multilingue « open science » jamais entraîné*. CNRS. <https://www.cnrs.fr/fr/livraison-du-plus-grand-modele-de-langue-multilingue-open-science-jamais-entraîne>

Collin, S., & Marceau, E. (2021). L'intelligence artificielle en éducation : Enjeux de justice. *Formation et profession*, 29(2), 1. <https://doi.org/10.18162/fp.2021.a230>

Conseil de l'Europe. (2023, décembre 9). Législation sur l'intelligence artificielle : Le Conseil et le Parlement parviennent à un accord sur les premières règles au monde en matière d'IA. Conseil européen - Conseil de l'Union européenne. <https://www.consilium.europa.eu/fr/press/press-releases/2023/12/09/artificial-intelligence-act-council-and-parliament-strike-a-deal-on-the-first-worldwide-rules-for-ai/>

Cour des comptes. (2023). *La stratégie nationale de recherche en intelligence artificielle*. Cour des comptes. <https://www.ccomptes.fr/fr/publications/la-strategie-nationale-de-recherche-en-intelligence-artificielle>

CSEN, & DNE-TN2. (2022, novembre 7). Synthèse et recommandations du groupe de travail « Intelligence artificielle et numérique pour l'éducation » du CSEN [Billet]. *Éducation, numérique et recherche*. <https://edunumrech.hypotheses.org/6707>

De la Higuera, C., & Bocquet, F. (2020, juillet 9). L'éducation, la formation des enseignants et l'apprentissage de l'intelligence artificielle : Un aperçu des questions clés [Billet]. *Éducation, numérique et recherche*. <https://edunumrech.hypotheses.org/1973>

Devlillers, L. (2023, février 20). ChatGPT et « intelligences » artificielles : Comment déceler le vrai du faux. *The Conversation*. <http://theconversation.com/chatgpt-et-intelligences-artificielles-comment-deceler-le-vrai-du-faux-200181>

Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019). *BERT : Pre-training of Deep Bidirectional Transformers for Language Understanding* (arXiv:1810.04805). arXiv. <https://doi.org/10.48550/arXiv.1810.04805>

Directorate-General for Education, Youth, Sport and Culture, Y., & European Commission. (2022). *Lignes directrices pour les enseignants et les éducateurs en matière de lutte contre la désinformation et de promotion de l'habileté numérique par l'éducation et la formation*. Publications Office of the European Union. <https://op.europa.eu/en/publication-detail/-/publication/a224c235-4843-11ed-92ed-01aa75ed71a1/language-fr>

DNE-TN2. (2021, juin 30). Le deep learning, un tournant épistémologique pour les SHS ? (Huma-Num LAB, 2020) [Billet]. *Éducation, numérique et recherche*. <https://edunumrech.hypotheses.org/3203>

DNE-TN2. (2022, janvier 20). Les enjeux éducatifs à l'ère de l'Intelligence Artificielle : GTnum #Scol_IA – Maison de l'Intelligence artificielle [Billet]. *Éducation, numérique et recherche*. <https://edunumrech.hypotheses.org/3898>

DNE-TN2. (2023a, mars 9). Intelligence artificielle et éducation ouverte : Retour sur la journée du GTnum #IA_EO (26/01/23) [Billet]. *Éducation, numérique et recherche*. <https://edunumrech.hypotheses.org/8605>

DNE-TN2. (2023b, juillet 10). Enseigner et apprendre à l'ère de l'intelligence artificielle : Portfolio du GTnum #Scol_IA [Billet]. *Éducation, numérique et recherche*. <https://edunumrech.hypotheses.org/9593>

DNE-TN2. (2023c, septembre 6). Intelligence artificielle et éducation ouverte : Portfolio du GTnum #IA_EO [Billet]. *Éducation, numérique et recherche*. <https://edunumrech.hypotheses.org/9781>

European Commission. Directorate General for Education, Youth, Sport and Culture. (2022). *Lignes directrices éthiques sur l'utilisation de l'intelligence artificielle (IA) et des données dans l'enseignement et l'apprentissage à l'intention des éducateurs*. Publications Office. <https://data.europa.eu/doi/10.2766/153756>

Ganascia, J.-G. (2022, juin 10). *Intelligence artificielle et épistémologie. Allers-retours indispensables*. JECIS. <https://hal.science/hal-03760357>

Gelin, L. (2022). *Reconnaissance automatique de la parole d'enfants apprenants-tes lecteurs-trices en salle de classe : Modelisation acoustique de phones* [Thèse, Toulouse 3]. <https://hal.science/tel-03715653v1>

Gouvernement - Direction générale des Entreprises. (2023). *Éduquer à l'Intelligence artificielle. Stratégie nationale pour l'intelligence artificielle*. <https://www.entreprises.gouv.fr/fr/numerique/enjeux/developper-ecosysteme-de-talents>

Gozalo-Brizuela, R., & Garrido-Merchan, E. C. (2023). *ChatGPT is not all you need. A State of the Art Review of large Generative AI models*. <https://doi.org/10.48550/ARXIV.2301.04655>

Grand lexique français de l'Intelligence artificielle. (2021). DataFranca Wiki. <https://datafranca.org/wiki/Accueil>

Herft, A. (2023). *Guide de l'enseignant—L'usage de ChatGPT « ce qui marche le mieux »* (A. Gagné, Trad.). <https://labua.univ-angers.fr/wp-content/uploads/2023/01/ChatGPT-Guide-de-lenseignant-FR.pdf>

Holmes, W., Persson, J., Chounta, I.-A., Wasson, B., & Dimitrova, V. (2022). *Artificial intelligence and education—A critical view through the lens of human rights, democracy and the rule of law*. Council of Europe. <https://rm.coe.int/artificial-intelligence-and-education-a-critical-view-through-the-lens/1680a886bd>

Holmes, W., & Tuomi, I. (2022). State of the art and practice in AI in education. *European Journal of Education*, n/a(n/a). <https://doi.org/10.1111/ejed.12533>

Hsiao, S. (2023, décembre 6). *Bard gets its biggest upgrade yet with Gemini*. Google. <https://blog.google/products/bard/google-bard-try-gemini-ai/>

Inria, & AI4T. (2023). *Intelligence artificielle pour et par les enseignants*. FUN MOOC. <http://www.fun-mooc.fr/fr/cours/intelligence-artificielle-pour-et-par-les-enseignants-ai4t/>

Inria, & Class'Code. (2020). *L'Intelligence Artificielle... avec intelligence ! (MOOC)*. FUN-MOOC. <https://www.fun-mooc.fr/fr/cours/lintelligence-artificielle-avec-intelligence/>

Inria Flowers (Réalisateur). (2023a, mars 8). *Comment fonctionne ChatGPT ? Un tour d'horizon en moins de 5mn*. <https://www.youtube.com/watch?v=K8gOvC8gvB4>

Inria Flowers (Réalisateur). (2023b, mars 13). *Le prompting, ou l'art de se faire comprendre par ChatGPT : Explication en 5mn*. https://www.youtube.com/watch?v=8lQ9i_QoA3A

Kasneci, E., Seßler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F., Gasser, U., Groh, G., Günemann, S., Hüllermeier, E., Krusche, S., Kutyniok, G., Michaeli, T., Nerdel, C., Pfeffer, J., Poquet, O., Sailer, M., Schmidt, A., Seidel, T., ... Kasneci, G. (2023). *ChatGPT for Good? On Opportunities and Challenges of Large Language Models for Education*. <https://doi.org/10.35542/osf.io/5er8f>

- Khosravi, H., Shum, S. B., Chen, G., Conati, C., Gasevic, D., Kay, J., Knight, S., Martinez-Maldonado, R., Sadiq, S., & Tsai, Y.-S. (2022). Explainable Artificial Intelligence in education. *Computers and Education: Artificial Intelligence*, 100074. <https://doi.org/10.1016/j.caeai.2022.100074>
- Langlais, P.-C. (2023, février 7). ChatGPT : Comment ça marche ? [Billet]. *Sciences communes*. <https://scoms.hypotheses.org/1059>
- Le Blanc, B. (2014). Alan Turing : Les machines à calculer et l'intelligence. *Hermès, La Revue*, 68(1), 123-126. <https://doi.org/10.3917/herm.068.0123>
- Le Cun, Y., Brizard, C., & Brizard, C. (2019). *Quand la machine apprend : La révolution des neurones artificiels et de l'apprentissage profond*. Odile Jacob.
- Lepage Alexandre (Réalisateur). (2022, mars 3). *L'intelligence artificielle en éducation*. <https://www.youtube.com/watch?v=ZAtu0xllcls>
- Lo, C. K. (2023). What Is the Impact of ChatGPT on Education? A Rapid Review of the Literature. *Education Sciences*, 13(4), Article 4. <https://doi.org/10.3390/educsci13040410>
- Lorenz, P., Perset, K., & Berryhill, J. (2023). *Initial policy considerations for generative artificial intelligence*. OCDE. <https://doi.org/10.1787/fae2d1e6-en>
- Miao, F., & Holmes, W. (2023). *Guidance for generative AI in education and research*. UNESCO Bibliothèque Numérique. <https://unesdoc.unesco.org/ark:/48223/pf0000386693>
- OCDE. (2023, mars 28). *Is Education Losing the Race with Technology?: AI's Progress in Maths and Reading*. OCDE. <https://www.oecd.org/education/is-education-losing-the-race-with-technology-73105f99-en.htm>
- OpenAI. (2023). *GPT-4 Technical Report*. OpenAI. <https://cdn.openai.com/papers/gpt-4.pdf>
- Ouyang, F., & Jiao, P. (2021). Artificial intelligence in education : The three paradigms. *Computers and Education: Artificial Intelligence*, 2, 100020. <https://doi.org/10.1016/j.caeai.2021.100020>
- Parlement européen. (2023, décembre 9). *Artificial Intelligence Act: Deal on comprehensive rules for trustworthy AI*. News European Parliament. <https://www.europarl.europa.eu/news/en/press-room/20231206IPR15699/artificial-intelligence-act-deal-on-comprehensive-rules-for-trustworthy-ai>
- Pôle d'expertise de la régulation numérique. (2023). ChatGPT ou la percée des modèles d'IA conversationnels. *Gouvernement français*, 6. https://www.peren.gouv.fr/rapports/2023-04-06_Eclairage%20sur_CHATGPT_FR.pdf
- Popenici, S. A. D., & Kerr, S. (2017). Exploring the impact of artificial intelligence on teaching and learning in higher education. *Research and Practice in Technology Enhanced Learning*, 12(1), 22. <https://doi.org/10.1186/s41039-017-0062-8>
- Romero, M., Aloui, H., Heiser, L., Galindo, L., & Lepage, A. (2021). *Un bref parcours sur les ressources, pratiques et acteurs en IA et éducation*. <https://hal.archives-ouvertes.fr/hal-03190014>

Romero, M., Heiser, L., Lepage, A., Gagnebien, A., Bonjour, A., Lagarrigue, A., Palaude, A., Boulord, C., Gagneur, C.-A., Mercier, C., Caucheteux, C., Guidoni-Stoltz, D., Tressols, F., Alexandre, F., Céci, J.-F., Metral, J.-F., Camponovo, J., Henry, J., Fouché, L., ... Borgne, Y.-A. L. (2023). *Enseigner et apprendre à l'ère de l'intelligence artificielle : Livre blanc du GThum #Scol_IA*. Vol. Livre blanc. <https://hal.science/hal-04013223>

Singh, R., & Gill, S. S. (2023). Edge AI : A survey. *Internet of Things and Cyber-Physical Systems*, 3, 71-92. <https://doi.org/10.1016/j.iotcps.2023.02.004>

Stokel-Walker, C. (2023). ChatGPT listed as author on research papers: Many scientists disapprove. *Nature*. <https://doi.org/10.1038/d41586-023-00107-z>

Susnjak, T. (2022). *ChatGPT: The End of Online Exam Integrity?* (arXiv:2212.09292). arXiv. <https://doi.org/10.48550/arXiv.2212.09292>

Touvron, H., Lavril, T., Izacard, G., Martinet, X., Lachaux, M.-A., Lacroix, T., Rozière, B., Goyal, N., Hambro, E., Azhar, F., Rodriguez, A., Joulin, A., Grave, E., & Lample, G. (2023). LLaMA : *Open and Efficient Foundation Language Models* (arXiv:2302.13971). arXiv. <https://doi.org/10.48550/arXiv.2302.13971>

UNESCO. (2019). *Consensus de Beijing sur l'intelligence artificielle et l'éducation*. UNESCO Bibliothèque Numérique. <https://unesdoc.unesco.org/ark:/48223/pf0000368303>


UNESCO. (2021). *IA et éducation : Guide pour les décideurs politiques*. UNESCO Bibliothèque Numérique. <https://unesdoc.unesco.org/ark:/48223/pf0000380006>

UNESCO. (2022). *K-12 AI curricula: A mapping of government-endorsed AI curricula*. UNESCO Bibliothèque Numérique. <https://unesdoc.unesco.org/ark:/48223/pf0000380602>

UNICEF. (2021, novembre). *Orientations stratégiques sur l'IA destinée aux enfants 2.0*. UNICEF. <https://www.unicef.org/globalinsight/fr/rapports/orientations-strat%C3%A9giques-sur-lia-destin%C3%A9e-aux-enfants>

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I. (2017). *Attention Is All You Need*. <https://doi.org/10.48550/ARXIV.1706.03762>

Référence de l'article : DNE-TN2 (2024). Intelligence artificielle et éducation : Apports de la recherche et enjeux pour les politiques publiques (édition 2024) [Billet]. Éducation, numérique et recherche.
<https://edunumrech.hypotheses.org/10764>



Carnet Hypothèses

Éducation, numérique et recherche



<https://edunumrech.hypotheses.org/>

Contact



**Direction du numérique pour l'éducation
(Ministère de l'Éducation nationale et de la Jeunesse)**
Bureau du soutien à l'innovation numérique
et à la recherche appliquée (DNE TN2)

@Edu_Num

 Licence
Ouverte 2.0