

Mars 2026

L'intelligence artificielle au prisme des transitions

Rapport Zenon Research

L'intelligence artificielle au prisme des transitions

Quelles IA pour quelles transitions ?

A propos de ce rapport

La question du rôle de l'intelligence artificielle dans la transition écologique est aujourd'hui traversée par une tension structurelle. D'un côté, le développement accéléré des technologies IA génère une consommation énergétique et matérielle croissante, dont les trajectoires ont fait l'objet d'une analyse approfondie [dans un précédent rapport](#). De l'autre, ces mêmes technologies sont présentées comme des outils potentiellement puissants au service de la décarbonation, de la préservation des écosystèmes et de l'optimisation des ressources. C'est cette seconde dimension que le présent rapport se propose d'examiner.

Ce rapport présente une analyse des différentes technologies d'IA existantes et les secteurs d'application possibles pour la transition. Il souligne également les défis liés au déploiement de l'IA, de son impact énergétique à la fiabilité des données, en passant par l'explicabilité des modèles.

Conditions de diffusion

Cette publication est mise à disposition sous licence libre. La reproduction et la diffusion totale ou partielle des textes de cette publication sont possibles pour toute utilisation non commerciale, en l'état et sans modification.

Comment citer ce rapport : Zhang L., Dupin J, *L'intelligence artificielle au prisme des transitions*, Rapport Zenon Research. Mars 2026.

Où trouver ce rapport

Ressource en ligne / Elle est disponible gratuitement sur zenon.ngo



Auteurs

Lucie Zhang

Analyste

Zenon Research

Sous la direction scientifique
de **Jean-Baptiste Dupin**,
Zenon Research

Contributeurs et relecteurs

Claude Tadonki

Enseignant-Chercheur en informatique
à Mines Paris – PSL

Cyprien Canivenc

Ancien Rapporteur général
de la Commission IA

Denis Trystram

Professeur émérite à l'Université
Grenoble Alpes

Gabriel Kasmi

Post-doctorant à Mines Paris – PSL

Jeanne Bouligny

Policy officer chez Cleantech for France

Roblex Nana Tchakoute

Post-doctorant à Mines Paris – PSL



	Contenu	3
	Résumé exécutif	4
1	Une ou des intelligences artificielles ?	5
	L'éventail des technologies d'intelligence artificielle	6
	Arbre technologique de l'IA	11
2	Applications de l'IA pour la transition écologique	13
	Les transitions nécessaires	14
	Cartographie des cas d'usage	16
3	Défis et limites de l'IA pour la transition	24
	Défis autour du déploiement de l'IA pour la transition	25
	Impact énergétique de l'IA	27
	La nécessité d'un déploiement responsable de l'IA	28
	Références	29

Résumé exécutif

L'IA ne constitue pas une technologie unique, mais un ensemble de méthodes et d'outils adaptés à différents types de problèmes et volumes de données. On distingue notamment :

- L'IA symbolique, fondée sur l'utilisation de règles et de logique explicite.
- Le Machine Learning, qui permet aux ordinateurs d'apprendre à partir de et en s'entraînant sur des données.
- Les neurones artificiels et réseaux de neurones profonds (Deep Learning, sous-branché du Machine Learning), capables de traiter des données complexes et massives.
- L'IA générative, orientée vers la création de contenu nouveau (texte, image, code, etc.).

Le choix d'une technologie d'IA dépend largement de la nature et de la quantité de données disponibles, ainsi que des objectifs visés. L'IA doit être considérée comme une boîte à outils, et non comme une solution universelle, et encore moins être réduite à l'IA générative ou aux réseaux de neurones.

L'IA offre un potentiel notable pour accélérer la transition écologique, mais sa contribution exacte en termes de réduction des émissions reste difficile à quantifier, les estimations allant d'une réduction de -1,5 % -24 % des émissions par rapport à un scénario business as usual. C'est pourquoi il est essentiel de ne pas considérer l'IA comme une solution miracle pour répondre au changement climatique, mais comme un levier complémentaire parmi d'autres instruments de la transition.

Les secteurs d'application de l'IA dans le cadre de la transition écologique sont divers et variés. Les principaux secteurs d'application comprennent l'énergie, les transports, l'industrie, l'agriculture, le bâtiment. Les cas d'usage peuvent être regroupés en grandes typologies :

- Monitoring de systèmes
- Prédiction et planification
- Optimisation en temps réel ou optimisation stratégique de processus, de conception produits, de flux
- Innovation, simulation et création de molécules et matériaux

Le déploiement massif de l'IA soulève néanmoins de nombreux défis :

- **Explicabilité et transparence des résultats** : indispensable pour garantir la confiance dans les décisions automatisées et détecter et éviter les biais.
- **Dépendance aux données** dans le cadre du Machine Learning. Ces dernières doivent être fiables, de qualité et disponibles.
- **Vulnérabilité des infrastructures numériques aux cyberattaques.**
- **Risques d'usages non vertueux** (*AI for brown*) par des industries ayant leur intérêt à accroître les habitudes de consommation (ex : Oil & Gas) et par conséquent augmentant les émissions globales.
- **L'impact énergétique propre à l'utilisation de l'IA (en particulier de l'IA générative) est conséquent** : il reste difficile d'évaluer dans quelle mesure les gains de réduction des émissions par l'IA compensent les émissions générées par son fonctionnement.

Pour maximiser les bénéfices de l'IA dans la transition écologique :

- **Ne pas confondre l'IA générative et l'IA « classique » ou traditionnelle** : la majorité des applications pour la transition repose sur l'IA traditionnelle, et non sur l'IA générative, dont le déploiement massif pourrait avoir des effets néfastes à l'environnement.
- **Développer l'open source en Europe**, afin de favoriser l'innovation locale mais aussi et surtout la disponibilité des données pour entraîner les modèles.
- **Adapter le type d'IA à son cas d'usage**, en privilégiant des modèles frugaux¹, explicables et adaptés au contexte.
- **Privilégier la sobriété et l'efficacité des usages**, avant toute innovation technologique.

L'IA constitue un levier puissant pour soutenir la transition écologique, mais son impact dépendra de choix éclairés, de sobriété dans son usage et de déploiements responsables, adaptés aux données et aux besoins des différents secteurs.

¹ Un modèle d'IA frugale est un système d'IA dimensionné au plus juste par rapport à la tâche qu'il doit accomplir, dont la conception minimise les ressources mobilisées à chaque étape du cycle de vie (données, calcul, énergie, matériels) et dont la pertinence a été questionnée en amont, y compris face à des alternatives non-IA.



1

Une ou des intelligences artificielles ?

L'éventail des technologies d'intelligence artificielle

Un arbre technologique de l'IA

L'éventail des technologies d'intelligence artificielle

Le terme intelligence artificielle est apparu en 1956. Bien que l'IA soit de nos jours devenue synonyme d'IA générative et soit associée à des applications telles que ChatGPT, **l'intelligence artificielle est en réalité un vaste champ de technologies, qui s'est divisé en plusieurs courants et dont l'évolution n'a pas été linéaire.**

L'intelligence artificielle peut se définir comme un **ensemble de technologies permettant aux ordinateurs d'effectuer des tâches qui nécessitaient historiquement l'intelligence humaine**, telles que la prise de décision, la prédiction, la créativité. La définition même de l'intelligence artificielle est néanmoins changeante et sujette à interprétation, ce qui rend d'autant plus complexe la tâche de catégoriser tel ou tel algorithme comme étant de l'IA. Ce qui relevait de l'IA dans les années 1980 est parfois qualifié aujourd'hui de simple algorithme, tant l'extension récente du champ de l'intelligence artificielle en a déplacé les frontières. **Historiquement, deux courants se sont développés et opposés autour de l'IA : l'IA symbolique et l'IA connexionniste.**

IA symbolique

L'objectif de l'IA symbolique était de **reproduire l'intelligence humaine à travers sa capacité de raisonnement**. L'IA symbolique se base ainsi sur un **ensemble de règles et de symboles qu'un programme traite et combine afin d'effectuer une tâche**. Les règles et symboles sont définis par des êtres humains (Datacamp, 2023 ; Hamon, 2023).

Les avantages de l'IA symbolique sont :

- **L'explicabilité** : les résultats des programmes sont issus de raisonnements et suivent des règles explicites, ce qui les rend transparents.
- **L'adaptabilité** : il est possible d'ajouter des nouvelles règles et connaissances qui permettent aux systèmes d'IA symbolique de s'adapter à des nouveaux domaines (Golem AI, 2023).
- **La frugalité** : l'IA symbolique ne nécessite pas de phase d'entraînement qui serait énergivore.

Cependant, la mise à l'échelle des systèmes devient difficile lorsque les règles et connaissances sont nombreuses et complexes. En effet, la programmation des règles se fait de façon manuelle, et la performance des systèmes dépend

de l'exhaustivité des bases de connaissances et des règles. De plus, le raisonnement humain ne s'appuie pas toujours sur des règles rationnelles et formalisées.

Les systèmes experts sont l'instance la plus populaire de l'IA symbolique. Il s'agit de systèmes regroupant un ensemble de connaissances et un ensemble de règles propres à des domaines spécifiques. Les règles sont établies à partir d'une expertise humaine pour formuler des recommandations et des analyses (voir Figure 1). Les systèmes experts reposent sur des raisonnements "Si... Alors".

Les systèmes experts ont connu un déclin après les années 1980 et **l'IA symbolique n'est aujourd'hui plus une branche populaire de l'IA, face à l'essor du Machine Learning (ML)**. Néanmoins, des applications d'IA symbolique subsistent, telles que le web sémantique. Il s'agit d'une extension du web actuel qui vise à rendre les données compréhensibles non seulement par les humains, mais aussi par les machines. Son objectif est de permettre aux ordinateurs d'interpréter le sens de l'information présente sur le web, afin de faciliter l'échange, la recherche et l'intégration de données. Le web sémantique structure l'information de façon standardisée pour que les machines puissent comprendre ce dont parlent les données, établir des relations logiques entre elles et raisonner automatiquement. Le web sémantique peut ainsi être considéré comme une application de l'IA symbolique car il repose sur un ensemble de représentations de la connaissance et de règles logiques (IONOS, 2021).

Populaire dans les années 1950 à 1980, l'IA symbolique a surtout eu des champs d'application tels que la médecine ([MYCIN](#) était un système expert utilisé pour diagnostiquer des infections bactériennes), **et l'analyse et traitement de langage** (le programme [ELIZA](#), mis au point au milieu des années 1960, est considéré comme le premier chatbot).

L'IA symbolique est particulièrement adaptée pour les tâches nécessitant de la logique et un raisonnement structuré, en particulier lorsque les connaissances et les règles sont à la fois stables, formalisables et exhaustives. Elle n'est pas adaptée dès lors que l'environnement devient très variable ou incertain, ou bien que la connaissance est incomplète ou difficilement modélisable.




Figure 1 – : Schématisation d'un système expert (adapté de Hassannayebi et al., 2022)

IA connexionniste et neurone artificiel

L'IA connexionniste s'oppose à l'IA symbolique et vise à reproduire l'intelligence humaine par le procédé de l'apprentissage. Le fondement de l'IA connexionniste réside dans le **neurone artificiel**, dont le fonctionnement s'inspire de celui d'un neurone biologique.

Un neurone artificiel possède plusieurs entrées et une sortie (voir Figure 2). Des coefficients (poids) sont attribués aux entrées pour les pondérer. Le neurone fait la somme des valeurs pondérées d'entrée, à laquelle on applique une fonction d'activation. La sortie obtenue est comparée au résultat attendu grâce à un calcul d'erreur. L'objectif est de minimiser l'erreur en ajustant les poids de façon itérative. Les neurones peuvent être reliés les uns aux autres et la façon dont sont connectés plusieurs neurones donnera lieu à des réseaux de neurones à plusieurs couches pouvant accomplir diverses tâches (Buettgenbach, 2021) (voir section **Deep Learning**).




Figure 2 – Concept de neurone artificiel, adapté de Haykin S., 1998

Le neurone artificiel permet également de poser les bases d'un modèle d'apprentissage à travers la mise au point d'un mécanisme automatique et mathématique qui ajuste les poids en fonction d'une erreur. C'est un saut conceptuel majeur : la machine peut s'améliorer à partir de l'expérience, au lieu d'être uniquement programmée manuellement.

Le neurone artificiel permet notamment de **classer les données d'entrée selon des catégories** grâce à des règles mathématiques simples : par exemple, si les entrées correspondent aux caractéristiques d'un objet (taille, couleur...) et que la sortie est supérieure à un certain seuil, alors l'objet correspond à telle catégorie. Sinon, il correspond à une autre catégorie. **Contrairement à l'IA symbolique, la règle de classification n'a pas besoin d'être connue : l'IA apprend à classer à partir des données qui lui sont fournies, le tout reposant sur les poids des entrées et le seuil d'activation** (Data Scientist, 2021).

Le Perceptron est considéré comme le modèle de base de neurone artificiel. Mis au point par Rosenblatt en 1957, un perceptron est un neurone qui déclenche une sortie binaire – 0 ou 1 si la somme pondérée de ses entrées dépasse un certain seuil. Il s'agit d'un programme qui prend une décision de type binaire.

L'IA connexionniste se développe en parallèle de l'IA symbolique dans les années 60 à 70 et suscite beaucoup d'intérêt à ses débuts. Elle est néanmoins critiquée par les partisans de l'IA symbolique à la fin des années 1970. Ces derniers mettent en avant les limites du perceptron, qui ne pouvait résoudre que des problèmes où les classes à analyser étaient linéairement séparables². Cela provoque alors une diminution de l'intérêt pour l'IA connexionniste ainsi qu'une baisse globale des financements pour la recherche en IA. **La période 1970–1980 a constitué un premier « hiver de l'IA »** (Cardon et al., 2018).

² Des données linéairement séparables signifient que l'on peut tracer une ligne droite (ou un plan, pour les dimensions supérieures) qui sépare parfaitement les classes.

Machine Learning

Le Machine Learning (ou apprentissage automatique) est un sous-ensemble de l'IA qui permet aux machines d'apprendre et de s'améliorer : **la machine découvre des règles à partir des données et des relations entre ces dernières**. Les problèmes réels sont en effet souvent trop complexes pour être programmés explicitement avec de l'IA symbolique.

Le Machine Learning (ML) englobe ainsi les réseaux de neurones artificiels mais également des méthodes statistiques et probabilistes, que l'on pourrait qualifier de Machine Learning "traditionnel" ou "classique". **Une des applications principales du ML est la classification et la prévision de données.**

Le grand intérêt du ML est, en quelque sorte, de renverser le paradigme traditionnel de la programmation : là où on appliquait auparavant des instructions pour résoudre une tâche, le ML permet de résoudre une tâche à partir de données et un objectif fourni ; le système apprend ensuite lui-même les règles qui gouvernent le problème.

Le Machine Learning est fortement adapté en présence de données tabulaires et peut résoudre des tâches rapidement, avec en plus l'avantage d'un entraînement rapide et peu énergivore par rapport au Deep Learning.

L'apprentissage est aujourd'hui au cœur de l'IA telle qu'on l'entend ; différentes techniques d'apprentissage existent pour permettre à un système d'apprendre à effectuer une tâche ou résoudre un problème (voir Figure 3).

Techniques d'apprentissage automatique

Apprentissage supervisé

La machine est entraînée sur des données dites « étiquetées », c'est-à-dire des exemples pour lesquels la réponse correcte est connue. **L'objectif est généralement d'effectuer une régression** (prédire une valeur continue à partir de données existantes) **ou de classer des nouvelles données** (assigner une étiquette à une entrée) en se basant sur ce qui a été appris.

En apprentissage supervisé, l'humain peut intervenir à divers degrés pour effectuer une

sélection des caractéristiques sur lesquelles les algorithmes doivent s'appuyer pour être capables d'effectuer une classification ou une régression (Bergmann, 2026).

Apprentissage non supervisé

En apprentissage non supervisé, les données d'entraînement ne sont pas étiquetées : c'est aux algorithmes d'identifier des structures sous-jacentes dans les données. **L'objectif est de découvrir des relations ou des catégories naturelles dans les données sans indications préalables.**

Cette technique d'apprentissage permet d'effectuer du **clustering** (répartition de données en groupes selon des similitudes ou différences) et de la **réduction de dimensionnalité** (extraction des caractéristiques importantes du jeu de données) (Google, 2026a).

Apprentissage par renforcement

Le système (ou agent) IA apprend un comportement en interagissant avec un environnement par le biais d'essais-erreur. A chaque action que réalise l'agent, ce dernier reçoit une récompense : **l'objectif est donc de choisir des actions qui maximisent la récompense dans le temps**. A travers l'apprentissage par renforcement, l'action de l'agent influe sur l'état de l'environnement (Murel, Kavlakoglu, 2026 ; Google, 2026b).

Cette technique d'apprentissage permet notamment l'interaction de la machine avec l'environnement et la prise de décision dans un environnement incertain. L'apprentissage par renforcement s'applique à la robotique, l'automatisation (pilotage automatique de drones ou de voitures), au traitement du langage naturel. Les premiers algorithmes d'apprentissage par renforcement sont formalisés à la fin des années 1980. L'apprentissage par renforcement est popularisé à partir de 2016 grâce à la victoire d'AlphaGo, entraîné selon cette technique, contre Lee Sedol, joueur de go (Google DeepMind, 2026). Son usage, encore limité jusque récemment, tend à s'étendre.




Figure 3 – Différentes techniques d'apprentissage et leurs fonctionnalités permises

Deep Learning

Le Deep Learning repose sur les réseaux de neurones profonds, comportant de très nombreuses couches (généralement des centaines ou des milliers). Une illustration d'un réseau de neurones multicouches est présentée sur la Figure 4. **Les réseaux de neurones ont fait l'objet de recherches dans les années 1980 et 1990 mais leur expansion se fait réellement à partir de 2012–2013, catalysée par l'essor du big data qui fournit de grandes quantités de données permettant d'entraîner les réseaux de neurones, et ils constituent la majeure partie des applications d'intelligence artificielle aujourd'hui.**

Le Deep Learning est fortement mis en avant aujourd'hui car il permet de traiter et analyser une très grande quantité de données – dépassant généralement les milliers voire millions/milliards de données. Le Deep Learning marque ainsi une avancée par rapport au ML car il permet l'analyse de données non-structurées (images, sons, textes), en très grandes quantités, et est capable d'extraire des représentations profondes et complexes avec un niveau de performance et de qualité élevé.

Le Deep Learning a notamment révolutionné l'analyse d'images grâce aux réseaux de neurones convolutifs (CNN ou Convolutional Neural Networks), qui permettent de traiter des données telles que des images ou des vidéos et sont par exemple utilisés pour la classification d'images ou la détection d'objets (IBM, 2026 ; Open-Classrooms, 2026).

Les réseaux de neurones récurrents (RNN ou Recurrent Neural Networks) sont également des algorithmes puissants de Deep Learning. Ils permettent de traiter des données séquentielles ou des données de série temporelles. Les RNN sont capables de retenir et utiliser des informations issues d'entrées antérieures afin de formuler des prédictions ou prendre des décisions (Stryker, 2026 ; Van Veen, 2017).

Les champs d'application principaux du DL sont le traitement du langage naturel ainsi que la vision ordinateur. **Les algorithmes de Deep Learning sont moins adaptés pour les situations où peu de données existent.** De plus, entraîner des réseaux de neurones profonds se révèle coûteux économiquement et énergétiquement, car la taille des réseaux de neurones devient très importante et le volume de données nécessaires pour un entraînement de qualité est significativement élevé.




Figure 4 – Réseaux de neurones multicouches

IA générative

L'IA générative est un sous-ensemble du Deep Learning qui permet de générer du contenu (texte, image, vidéo, musique, données...). Là où le Deep Learning devenait très bon en classification et analyse d'images et de données complexes, **les modèles d'IA générative ont permis d'aller plus loin en générant des images, des sons et des données réalistes.**

Parmi les modèles notables d'IA générative se trouvent :

- Auto-encodeur Variationnel (VAE) (2013) : un encodeur³ compresse une donnée d'entrée en une version compacte qui capture ses caractéristiques essentielles. Un décodeur reconstruit ou génère des nouvelles données plausibles en utilisant les représentations compactes de l'encodeur (Bergmann, Stryker, 2026a).
- Réseaux Antagonistes Génératifs (GAN) (2014) : mise en compétition de deux algorithmes en apprentissage non-supervisé : un générant du contenu et un devant déterminer l'authenticité du contenu généré (AWS, 2026a ; Lawlor, Chang, 2024).
- Transformers (2017) : très performants pour le traitement de données séquentielles et très utilisés pour le traitement du langage naturel.

Les Transformers représentent une grande avancée dans la continuité des RNN : contrairement aux modèles séquentiels qui traitent les mots uns par uns, les Transformers peuvent traiter tous les mots d'une phrase de façon parallèle. Les Transformers utilisent le mécanisme d'attention pour se concentrer sur les parties importantes des données, ce qui leur permet de traiter rapidement des séquences longues et complexes. Cette architecture permet également une meilleure compréhension du contexte global d'une phrase car l'attention permet de relier des mots éloignés dans une séquence. Le mécanisme d'attention permet au modèle de décider quelles parties de la séquence sont importantes pour comprendre ou prédire chaque élément. (Bergmann, Stryker, 2026b ; AWS, 2026b).

En conclusion, bien que les réseaux de neurones profonds et l'IA générative occupent une place importante dans les applications quotidiennes d'IA, **il est essentiel de rappeler que l'intelligence artificielle est en réalité un vaste ensemble de technologies que les réseaux de neurones ne doivent pas éclipser.** En particulier la quantité et le type de données à disposition ainsi que la complexité de la tâche à réaliser conditionnent le choix d'un modèle.

³ L'encodage consiste à transformer toute information en une représentation numérique manipulable par la machine. Dans le cas du texte, cette unité de base s'appelle un token : il peut correspondre à un mot, une syllabe ou un signe de ponctuation. Concrètement, un grand modèle de langage comme ChatGPT ne fait pas autre chose que prédire, token après token, la suite la plus probable à un texte donné.

Arbre technologique de l'IA




Figure 5 – Infographie des différentes familles d'IA, réalisée avec la contribution de Gabriel Kasmi et Roblex Nana Tchakoute (Mines Paris – PSL)

Cette proposition d'arbre, ou frise technologique permet de **regrouper et classer les différents types d'IA** dans l'objectif de représenter les filiations technologiques entre certains types d'IA.

Plusieurs niveaux sont représentés :

- Les **paradigmes** sont des cadres conceptuels fondamentaux qui structurent la manière dont l'intelligence est représentée, produite et exploitée dans les systèmes d'IA.
- Les **grandes familles ou branches d'IA** regroupent des méthodes partageant un principe algorithmique ou mathématique commun. Ainsi, le Machine Learning peut être considéré à la fois comme un paradigme et une famille d'IA.
- Les **algorithmes et architectures** désignent les formes concrètes prises par les familles d'IA.

Il s'agit également de dater l'**apparition des différents types d'IA**. Il est donc particulièrement intéressant de constater que la **popularité actuelle de certains algorithmes et types d'IA**, tels que les réseaux de neurones profonds, **ne relève pas du fait d'une innovation récente mais davantage d'un cadre contextuel** (ici l'explosion de données permettant d'entraîner les modèles) ayant favorisé l'amélioration des performances de ces derniers et éclipsant ainsi d'autres formes d'IA.

Cet arbre n'a pas pour vocation d'être exhaustif sur toutes les familles et techniques d'IA. Le focus a été fait sur le Machine Learning et les sous-

branches qui en découlent car il s'agit aujourd'hui de la méthode la plus utilisée dans la plupart des applications d'IA. Pour autant, l'IA générative n'est que la partie émergée de l'iceberg, et **un des objectifs de cet arbre est également d'offrir une vision élargie des outils d'IA disponibles pour faire face au changement climatique.**

Par ailleurs, une branche qui s'arrête signifie que le concept a émergé à cette période, et non qu'il a cessé d'évoluer : la majorité de ces approches font toujours l'objet de recherches actives.

Le choix a été fait de ne pas faire figurer les techniques d'apprentissage sur l'arbre car elles sont transversales et applicables à un large éventail de modèles et d'architectures de Machine Learning. L'arbre est ainsi structuré selon les paradigmes et les familles de modèles, indépendamment de la méthode d'apprentissage.

L'exercice d'un tel arbre technologique est complexe car cela revient à la cartographie d'un domaine mouvant et dynamique. Les définitions, concepts et techniques considérés comme relevant de l'IA changent au fil du temps et selon les points de vue, donc la structuration des paradigmes, familles et architectures doit être considérée comme une taxonomie temporaire et susceptible de révision, et non comme une classification figée.



2

Applications de l'IA pour la transition écologique

Les transitions nécessaires

Cartographie des cas d'usage

Les transitions nécessaires

Les émissions de Gaz à Effet de Serre (GES) dans le monde sont principalement issues du secteur de l'énergie. La répartition des émissions de GES dans le monde est la suivante (voir Figure 6) :

- **Énergie** (68 % des émissions en 2023)
- **Agriculture** (11 %) : principalement des émissions de méthane liées à la fermentation entérique du bétail et le dépôt de fumier ;
- **Procédés industriels** (9 %) : principalement des émissions liées à la fabrication du ciment et industrie pétrochimique ;
- **Utilisation des sols** (7 %) : émissions liées à la déforestation.
- **Déchets** (4 %) : émissions de méthane et de protoxyde d'azote issus des décharges (WRI).




Figure 6 – Répartition des émissions mondiales de GES par secteur économique en 2023 (UNEP, 2024)

Le secteur « production d'électricité » correspond aux émissions des centrales électriques et thermiques brûlant des combustibles fossiles. « Transports » comptabilise les émissions liées à la combustion de carburants fossiles. « Industrie manufacturière » correspond aux émissions dues à la combustion d'énergie fossiles pour produire de la chaleur ou de la force motrice, tandis que « procédés industriels » désigne les émissions provenant de réactions chimiques ou physiques. « Bâtiments » correspond à la combustion directe pour chauffage, eau chaude, cuisson (n'inclut pas l'électricité). « Production et transformation des combustibles fossiles » correspond aux émissions liées à l'extraction, au raffinage, au transport et au stockage des combustibles.

L'insaisissable potentiel de réduction des émissions par l'IA

Il apparaît difficile de quantifier de façon globale l'impact positif que l'IA peut avoir sur les émissions de GES, car cela dépend fortement de son adoption dans les différents secteurs. De plus, son impact peut être contrebalancé par sa propre consommation d'énergie, observée à la hausse et analysée dans un précédent rapport Zenon (Zhang, Dupin, 2025).

D'après l'AIE, les réductions d'émissions permises dans le cas d'une adoption généralisée de l'IA dans

le secteur de l'énergie seraient de l'ordre de 4 % en 2035 (AIE, 2025). D'autres études ont montré que l'utilisation de l'IA dans le secteur de l'énergie et en particulier pour les énergies renouvelables éolienne et solaire PV, qui constituent un vaste champ d'application de l'IA (voir partie suivante), permettrait d'éviter la production de 1,8 GtCO₂e d'ici 2035, soit - 16,5 % par rapport à un scénario Business As Usual (Stern, Romani, 2025). En élargissant son déploiement aux transports et à l'alimentation, l'IA pourrait permettre de réduire les émissions de 3,2 – 5,4 GtCO₂e par an d'ici 2035, soit -14 % à -24 % par rapport à un scénario BAU


(voir Figure 7) (Stern et al., 2025). L'IA peut également bénéficier à des secteurs non directement émetteurs de GES mais nécessaires pour la transition, comme l'eau et la biodiversité mais aussi la lutte contre la pollution, les ressources, etc.

Les entreprises de la tech et les acteurs majeurs de l'IA affirment également que cette dernière peut avoir des apports bénéfiques pour le climat et la transition écologique : selon Google et BCG, l'IA pourrait permettre de réduire les émissions globales de GES de 5 à 10 % d'ici 2030 (Brandt, Lesser, 2023). Selon Microsoft et PwC, le potentiel de réduction des émissions par l'IA est de 1,5-4 % d'ici 2030 (Herweijer et al., 2019). Selon CapGemini, ce potentiel est de 16 % d'ici 3 à 5 ans (CapGemini, 2024). Les variabilités de ces estimations doivent alerter sur l'incertitude et la difficulté d'estimer le potentiel de réduction des émissions par l'IA.

De plus, des analyses appellent à la prudence et la prise de recul face aux bénéfices climatiques annoncés attribués à l'IA. Il est notamment souligné que la plupart des discours d'entreprises technologiques présentant l'IA comme une solution clé au changement climatique ne disposent pas de preuves solides, rigoureuses ou

transparentes pour étayer ces affirmations (Joshi, 2026). Surtout, ces discours ne mettent pas en avant la distinction entre l'IA générative et l'IA « traditionnelle » ou « classique », or la majeure partie des bénéfices climatiques prétendument attribués à l'IA découle d'applications relativement modestes de l'IA traditionnelle, comme des modèles d'optimisation ou de prévision en logistique, énergie, etc. (qui sont présentés en deuxième partie de cette analyse). Ainsi, alors que les parties les plus visibles de la révolution IA ne montrent pas de preuve vérifiée d'impact positif net sur le climat, le risque est que les entreprises confondent les bénéfices potentiels de l'IA traditionnelle avec l'IA générative. Cette dernière est nettement plus coûteuse en énergie, ce qui crée une impression trompeuse de bénéfices climatiques généralisés.

Enfin, il ne s'agit pas ici de trancher le débat sur le bilan net de l'IA pour le climat (voir section Impact énergétique de l'IA) ; c'est une question légitime appelant à une comptabilité globale dépassant le périmètre de ce travail. L'objectif de cette partie est d'identifier, de documenter et d'évaluer les usages pour lesquels l'IA apporte une contribution à la transition écologique.



Note, the ambitious emissions reduction scenario is calculated using the IEA's net zero emissions scenario⁴² for Power and Light Road Vehicles and UNEP's 2050 Paris-aligned target³ for Meat and Dairy.

Figure 7 – Estimation des trajectoires d'émissions mondiales de GES avec l'aide de l'IA dans les secteurs de l'énergie, des transports et de l'alimentation (viande et produits laitiers) par rapport à un scénario BAU, (Stern et al., 2025)

Cartographie des cas d'usage

L'IA repose fondamentalement sur la manipulation et l'analyse de grandes quantités de données. La majorité des cas d'usages aujourd'hui ont recours au Machine Learning et au Deep Learning, donc à un processus d'apprentissage utilisant des modèles qui peuvent accomplir des fonctions de :

- **Clustering** : *découvrir* des structures et liens entre des données non étiquetées (il n'y a pas de « bonne réponse » connue).
- **Classification** : *attribuer ou prédire* une catégorie discrète à une donnée, le plus souvent à l'issue d'un entraînement supervisé.
- **Régression** : *prédire* une valeur continue, le plus souvent à l'issue d'un entraînement supervisé.
- **Génération de données** : *produire* de nouvelles données à partir d'un apprentissage sur un corpus de données existant. Il s'agit en fait d'un type particulier de prédiction.

Les cas d'usage de l'IA pour la transition peuvent également se distinguer selon leur(s) finalité(s), dont certaines se recoupent ou vont de pair (Figure 8) :

- **Monitoring**
- **Prévision**
 - Catégorielles
 - Variables quantitatives continues
- **Optimisation**
 - En temps réel
 - A long terme (stratégique/prospective)
- **Innovation/création**

Nous proposons ainsi une cartographie Zenon d'axes d'applications de l'IA pour la transition, en mettant en regard une liste (non-exhaustive) de cas d'usages avec les fonctionnalités clés de l'IA listées précédemment.




Figure 8 – Regroupement des cas d'usages et fonctionnalités de l'IA

IA pour le monitoring

L'IA est utilisée pour le monitoring de systèmes ou d'écosystèmes afin de suivre leur état, leur évolution et détecter des signaux et anomalies. En analysant des données issues de capteurs, d'images satellites, de drones ou de relevés terrain, elle permet un suivi à grande échelle et dans le temps.

Principaux secteurs d'application pour la transition : émissions, gestion de la pollution, du climat, de l'eau et de la biodiversité, agriculture de précision, industrie, réseaux électriques

Exemples de cas d'usages :

- **Le monitoring d'écosystèmes en temps réel :**
 - [StreamOcean](#) : solution de surveillance des océans en temps réel à l'aide de caméras sous-marines et d'algorithmes IA qui extraient des mesures et métriques pour suivre la biodiversité marine.
- **La détection d'anomalies au sein d'un système (industriel, énergétique, naturel...), en temps réel ou différé :**
 - [MethaneWatch\(Kayrros\)](#) : plateforme de surveillance des émissions de méthane à échelle mondiale.
 - [DeepHawk](#) : plateforme logicielle d'IA pour l'inspection visuelle des produits dans l'industrie manufacturière.
 - [DORA par Enedis](#) : plateforme pour détecter et identifier sur des photos les éléments des lignes aériennes HTA moyennes tension (20 kV) ayant besoin d'être remplacés ([Enedis](#), 2024).

Les technologies d'IA employées reposent souvent sur de l'apprentissage supervisé : les modèles sont entraînés pour reconnaître les éléments ciblés. Dans les cas les plus simples/basiques, il s'agit essentiellement d'un problème de classification binaire (anomalie / pas anomalie) ou multi-classe (type d'anomalie). Ce type d'application IA se base souvent sur des données visuelles, en particulier des images satellites, ou des séries temporelles. Cela nécessite donc des technologies d'IA type Machine Learning ou Deep Learning se rapportant à de la vision ordinateur et pouvant traiter les images, telles que les CNN par exemple, et les séries temporelles, telles que les RNN et les LSTM⁴. L'apprentissage non supervisé permet également de détecter des comportements anormaux, sans nécessiter d'exemples étiquetés de pannes, qui sont par définition rares et difficiles à collecter.

Intérêt du recours à l'IA :

- Monitoring à grande échelle
- Détection avec une précision élevée d'anomalies, permettant d'améliorer la qualité des systèmes et d'accélérer les processus de décision

A titre d'exemple, les faux positifs détectés en ligne de production industrielle seraient passés de 20 % à 1,5 % dans le cadre d'un déploiement de DeepHawk chez un industriel (IMT Atlantique, 2023). Grâce à sa plateforme MethaneWatch, Kayrros a pu quantifier la quantité de méthane (127 000 tonnes) émise par une fuite de méthane lors de travaux de forage au Kazakhstan (BBC, 2024). Exploiter l'IA pour améliorer la détection de fuites de méthane pourrait réduire les émissions annuelles de méthane de 2 Mt (Deloitte, 2025) : il s'agit d'un potentiel relativement faible (sur 145 Mt de fuites de méthane annuelles), mais tout de même non-négligeable, étant donné le potentiel de réchauffement⁵ global du méthane.

⁴ Les réseaux LSTM (Long Short-Term Memory) sont un type de réseau de neurones conçu pour traiter des données en séquence (du texte, de l'audio, des séries temporelles), en se souvenant des informations importantes du passé tout en oubliant ce qui n'est pas utile.

⁵ Le potentiel de réchauffement global (PRG) exprime la capacité d'un gaz à piéger la chaleur dans l'atmosphère par rapport au CO₂, en tenant compte de son pouvoir radiatif et de sa durée de vie atmosphérique. Bien qu'il soit présent en bien plus faible concentration dans l'atmosphère, le PRG du méthane est 84 fois supérieur à celui du CO₂ sur 20 ans et 28 fois supérieur sur 100 ans (SDES, 2025).

IA pour la prévision

Prévision et attribution de catégories

L'IA est souvent mobilisée pour des tâches de **maintenance prédictive** : l'IA analyse les données des capteurs d'une machine et classe les événements observés en différentes catégories selon leur niveau de risque ou leur état de fonctionnement. Elle prédit ensuite la probabilité qu'une panne survienne et estime quand elle pourrait se produire. Ces approches sont particulièrement utiles lorsque les volumes de données dépassent les capacités d'analyse humaine ou que les règles de décision sont difficiles à formaliser explicitement, et permet un gain de temps sur les opérations de maintenance. En effet, les approches traditionnelles pour catégoriser des données reposaient sur des seuils fixes et des règles métiers, ignorant les comportements et les interactions complexes entre variables.

Principaux secteurs d'application pour la transition : Industrie

Exemples de cas d'usage :

- Maintenance prédictive pour anticiper les pannes d'installations et systèmes
 - [Senseye predictive maintenance \(Siemens\)](#)

Les technologies IA les plus couramment utilisées vont du **Machine Learning « traditionnel »** (arbres de décision, SVM⁶), au **Deep Learning**. L'apprentissage supervisé, à condition que suffisamment de données d'entraînement existent, offre de bons résultats de précision pour la prédiction de pannes et l'estimation de la « durée de vie » restante d'une machine.

De même que pour la surveillance en temps réel, l'apprentissage non supervisé est utile pour explorer les données non étiquetées ou non structurées et détecter des comportements anormaux (Adimulam *et al.*, 2019).

L'IA **générative** est aussi une technique explorée pour la maintenance prédictive : en effet, un problème récurrent en maintenance prédictive est le manque de données liées à des situations de panne. Par conséquent, entraîner un modèle sur un

set de données qui ne présente pas suffisamment d'exemple de pannes risque de résulter en un modèle moins performant dans la détection des signaux faibles de pannes. Des modèles génératifs peuvent alors produire des scénarios réalistes de défaillance pour enrichir l'entraînement et réduire l'écart entre conditions réelles et données d'entraînement (Micheal, 2025). L'IA générative peut aussi aller plus loin et permettre une interaction de la machine avec l'utilisateur/l'ingénieur de maintenance : c'est par exemple ce qu'ambitionne Veolia en s'associant à Mistral AI pour que les techniciens et opérateurs puissent interagir avec les infrastructures du groupe (Marquez, Oliver, 2025 ; Veolia, 2025). Certaines études soulignent tout de même le fait que les méthodes de Machine Learning traditionnelles (SVM, arbres de décision...) peuvent faire aussi bien, voire mieux, que des modèles de Deep Learning, notamment lorsque les données sont de faible volume ou structurées (Farooq *et al.*, 2024 ; Serradilla *et al.*, 2020).

Intérêt du recours à l'IA :

- Détection plus précoce d'anomalies, de risques ou de situations critiques grâce à l'automatisation de la reconnaissance de motifs, de signaux ou d'anomalies
- Diminution du temps d'arrêt des installations et gains économiques

L'utilisation de l'IA par GE Renewable Energy pour la maintenance prédictive des éoliennes aurait permis une augmentation de la disponibilité des turbines de 25 %, une augmentation de la production annuelle d'énergie de 15 %, et une réduction des coûts de maintenance de 30 % grâce à une précision des prédictions de pannes de 95 % (Hamdan *et al.*, 2024). L'implémentation de Siemens Senseye au sein de BlueScope, une entreprise australienne spécialisée dans la production et la distribution d'acier, aurait permis d'éviter 1 200 heures d'arrêt d'installation en Australie (Siemens, 2026). D'après Deloitte, l'utilisation de l'IA pour la maintenance prédictive des éoliennes offshore pourrait réduire les temps d'arrêt de 15 % et le coût moyen de réparation de 20 % (Deloitte, 2025).

⁶ Les SVM (Support Vector Machines) sont un algorithme d'apprentissage automatique qui cherche à tracer la meilleure frontière possible pour séparer des groupes de données (par exemple, distinguer des emails spam des emails normaux). Cette frontière est calculée pour être la plus éloignée possible des points de chaque groupe, ce qui la rend robuste et efficace même avec peu de données.

Prévision de variables quantitatives continues

L'IA est largement mobilisée pour améliorer les capacités de prévision, en particulier l'anticipation de phénomènes complexes, incertains et fortement dépendants de données hétérogènes. Elle peut être utilisée pour améliorer la prévision de variables quantitatives continues (consommation, température, vitesse...). Lorsque de nombreux paramètres interagissent et évoluent de manière imprévisible, comme c'est le cas pour les évolutions météorologiques, il devient trop complexe de représenter de façon exhaustive toutes les interactions entre ces paramètres. Les modèles traditionnels, basés sur des équations physiques et statistiques peuvent alors se révéler insuffisants (Benti et al., 2023).

Principaux secteurs d'application pour la transition : énergie, climat et environnement (modélisations climatiques, gestion des risques)

Exemples de cas d'usage :

Prévisions météorologiques à long terme

- [GraphCast](#) (Google DeepMind) : outil permettant de générer des prévisions météorologiques jusqu'à 10 jours en avance, entraîné sur des décennies de données météorologiques.
- [Pangu Weather](#) (modèle développé par Huawei), [Artificial Intelligence Forecasting System](#) développé et utilisé par l'European Centre for Medium-Range Weather Forecasts (ECMWF).

Prévisions de production d'énergie renouvelable :

- [Solar NowCasting](#) : initiative pour améliorer les prévisions de production solaire à très court terme (de quelques heures) en Grande-Bretagne.
- [Google DeepMind](#) a développé un algorithme de Deep Learning en 2018 sur 700 MW de capacité éolienne aux Etats-Unis pour prédire la production d'électricité 36h en avance.

Prévisions de la demande en électricité à diverses échelles

- [OpenSTEF](#) : initiative open-source qui fournit un ensemble d'outils de prévision énergétique à court terme (jusqu'à 48h) pour les réseaux électriques.

Ces cas d'usages privilégient généralement l'apprentissage supervisé car on dispose de beaucoup de données historiques associant les

entrées (mesures météo, images satellites...) et les sorties (production d'énergie observée, etc.). Les systèmes appréhendés étant complexes (grande échelle, interaction entre les éléments, dynamiques), les **réseaux de neurones profonds** sont la plupart du temps les plus appropriés pour capturer des relations complexes dans des données multidimensionnelles. En particulier, les LSTM sont adaptés aux données issues de séries temporelles, car ils peuvent capturer des dépendances à long terme.

Pour autant, les **algorithmes de ML classique restent utilisés et ne sont pas nécessairement moins performants** (Gupta et al., 2025). Par exemple, [Windy Smart Grid](#) par Enedis est un outil d'aide à la prévision des coupures sur chaque ligne de moyenne tension du réseau de distribution en cas d'intempéries. L'outil peut être considéré comme de l'IA car il apprend à partir de données pour effectuer des prédictions mais il repose en fait sur une simple modélisation statistique et probabiliste. Il fournit néanmoins des prévisions fiables des coupures probables en cas de tempête à échelle nationale, régionale et départementale, et s'est notamment révélé utile pour aider à préparer et mobiliser les équipes d'intervention à l'avance lors des tempêtes Aurore en 2021 et Ciaran en 2023 (Lair et al., 2022 ; EDSO, 2024).

Intérêt du recours à l'IA :

- Meilleure précision de résultat par rapport aux modèles traditionnels, en particulier la résolution spatiale et temporelle
- Rapidité des temps de calcul
- Capacité à intégrer des données hétérogènes (numériques, images)
- Prévision, anticipation, planification et prise de décision plus robustes face à l'incertitude.

GraphCast est capable d'effectuer des prévisions météorologiques sur 10 jours en moins d'une minute tandis qu'une simulation traditionnelle prendrait plusieurs heures. Dans des tests comparatifs, GraphCast a surpassé le système HRES de l'ECMWF, considéré comme l'un des meilleurs modèles numériques « physique », sur plus de 90 % de variables et horizons de prévisions testés (Google DeepMind, 2023). Solar NowCasting a entraîné des prévisions nationales de production solaire jusqu'à 2,8 fois plus précises que les modèles utilisés auparavant (NESO, 2024).

IA pour l'optimisation

Optimisation stratégique ou prospective

L'IA est mobilisée pour l'optimisation stratégique (planification moyen-long terme) afin d'explorer et de comparer des trajectoires long terme au sein de systèmes complexes et incertains. En combinant modèles prédictifs, scénarios et algorithmes d'optimisation, elle permet d'évaluer des choix d'investissement et de dimensionnement mais aussi d'anticiper des risques, grâce à sa capacité à intégrer à la fois des contraintes techniques, climatiques, économiques. L'IA est aussi utilisée pour optimiser la conception de systèmes, d'infrastructures ou de produits grâce à sa capacité à simuler les différentes configurations possibles. En intégrant dès la phase amont des objectifs de performance énergétique, de sobriété matière, de coût ou d'empreinte carbone, elle permet d'identifier des designs plus efficaces que les approches itératives classiques. Cette optimisation de la conception, qui s'apparente à de l'éco-conception, contribue ainsi à réduire les impacts sur l'ensemble du cycle de vie, avant même la mise en œuvre opérationnelle.

Principaux secteurs d'application pour la transition : énergie, industrie, transports, captation de carbone, agriculture

Exemples de cas d'usages :

Optimisation de la conception d'infrastructures

- **Energétiques :** [Easy Solar AI](#) est une plateforme logicielle destinée à optimiser et automatiser la conception de systèmes solaires et la génération d'offres commerciales à partir de données simples comme une adresse.
- **Industrielles :** [EarthNET](#) est une plateforme d'IA pour géosciences intégrant une fonctionnalité de « CCS Site Screening », qui permet d'identifier des emplacements géologiquement adaptés pour stocker du CO2 capté.

Optimisation de process

- **Agriculture de précision :** [T-irrigate](#) (Topraq) est une solution d'optimisation de l'irrigation exploitant l'IA pour calculer les meilleurs moments et quantités d'eau à appliquer aux cultures.

Optimisation de la conception de produits

- [Autodesk forma](#) permet aux architectes et ingénieurs de respecter la réglementation en termes de construction mais aussi de simuler le comportement d'un bâtiment et comparer les performances entre différents design

L'optimisation à long terme fait appel à plusieurs familles de techniques IA, souvent combinées entre elles. Dans beaucoup de contextes industriels, tester une configuration nécessite généralement une simulation longue. **L'apprentissage supervisé est alors souvent utilisé pour remplacer les simulations physiques** : un modèle est entraîné sur un ensemble de simulations déjà réalisées, pour apprendre à prédire le résultat d'une nouvelle configuration sans avoir à la simuler réellement (Neural Concept, 2026). **Les algorithmes d'optimisation classiques**, qui ne relèvent pas du Machine Learning, restent très présents dans les problèmes d'optimisation (voir Figure 5). Par exemple, les algorithmes génétiques, qui s'inspirent de la sélection naturelle, sont utilisés pour explorer des grands espaces de solutions. Ces méthodes restent très utilisées car elles fonctionnent sans avoir besoin de grandes quantités de données et s'adaptent bien aux problèmes avec de nombreuses contraintes simultanées (Li *et al.*, 2026). **Des modèles d'IA générative sont également utilisés comme outil d'exploration créative en conception**. Ils permettent de générer automatiquement des formes ou des architectures de produits satisfaisant un ensemble de contraintes (Oh *et al.*, 2019). En pratique, ces approches ne s'excluent pas : la plupart des systèmes performants les combinent.

Intérêt du recours à l'IA :

- Exploration d'espaces de solution vastes
- Optimisation multicritères
- Intégration des incertitudes et de scénarios complexes
- Réduction des temps et coûts de R&D

D'après Earth Analytics, utiliser EarthNET pour identifier des sites géologiques adaptés au stockage de carbone serait 10 fois plus rapide que des méthodes traditionnelles.

Optimisation en temps réel et automatisation

Le recours à l'IA pour l'optimisation en temps réel présente un intérêt central dans la transition écologique, car il permet de piloter des systèmes complexes, dynamiques et contraints, dans un contexte d'incertitude croissante et de ressources limitées. L'optimisation en temps réel inclut également l'automatisation et la robotique. L'IA peut être mobilisée pour automatiser des tâches répétitives, complexes ou massives, tout en les optimisant.

Principaux secteurs d'application pour la transition : énergie, transport, industrie, capture et stockage du carbone, déchets, transports, bâtiments

Exemples de cas d'usages :

Optimisation et gestion de smart grids

- L'IA aide à optimiser les flux en temps réel, à anticiper les variations de production et de consommation. En France, [Enedis](#) incorpore l'IA pour gérer les réseaux de distribution. Au Royaume-Uni, [Kraken](#) utilise l'IA pour piloter intelligemment des appareils connectés, formant une centrale électrique virtuelle (VPP) capable d'équilibrer le réseau en temps réel.

Optimisation de la consommation énergétique d'infrastructures

- [Tilt Energy](#) : plateforme logicielle pour optimiser la consommation électrique, piloter la demande et valoriser la flexibilité énergétique des bâtiments tertiaires, des gestionnaires et fournisseurs d'énergie.
- [Carbon Re](#) : développement d'une solution pour maximiser et optimiser l'utilisation de carburants alternatifs en temps réel dans les usines de production de ciment, tout en garantissant la qualité du produit.
- [PureControl](#) : solution permettant de piloter les installations industrielles de façon intelligente pour diminuer leurs coûts d'exploitation et empreinte carbone.

Optimisation de trafic routier

- [Google Green Light](#) : adaptation des feux de circulation au trafic en temps réel, afin de réduire les arrêts, fluidifier la circulation et ainsi diminuer les émissions.

Tri intelligent de déchets

- [AMP Smart Sortation](#) : solution de tri de déchets entièrement automatisée et capable d'identifier, classer et séparer des déchets sans intervention humaine.

L'optimisation voire l'automatisation en temps réel repose beaucoup sur **l'apprentissage par renforcement**, qui permet au modèle de s'adapter en continu aux changements de l'environnement. Il est particulièrement adapté aux systèmes séquentiels et dynamiques, où chaque action influence les états futurs (Powell et al., 2020).

Intérêt du recours à l'IA :

- Gestion de systèmes complexes et dynamiques
- Traitement de grandes quantités de données en temps réel
- Optimisation multicritères et adaptabilité à des conditions changeantes
- Pilotage dynamique et optimisé en temps réel
- Réduction des erreurs et amélioration de la précision par rapport à une gestion manuelle
- Amélioration de l'efficacité opérationnelle

En pilotant de façon automatisée et intelligente une station d'épuration à Rennes, PureControl aurait permis une diminution de consommation d'énergie de 25 % sur un an (Source interne PureControl). Google affirme que son projet Green Light permettrait de réduire les émissions de GES jusqu'à 10 %, néanmoins cette déclaration n'est pas vérifiée (Google, 2026c).

IA pour accélérer l'innovation

L'IA est utilisée comme moteur d'innovation pour chercher à générer de nouvelles solutions qui seraient difficiles ou plus longues à concevoir par des approches classiques. L'utilisation de l'IA pour l'innovation revient presque à faire du *reversed engineering*, c'est-à-dire qu'elle peut partir d'objectifs ou de critères spécifiques pour reconstruire ou générer une solution qui y répond.

Principaux secteurs d'application pour la transition : matériaux, chimie

Exemples de cas d'usages :

Exploration de nouveaux matériaux (par exemple pour améliorer le stockage de l'énergie ou la capture du CO₂)

- [Polaron.ai](#) : Plateforme d'IA générative qui analyse des images de matériaux et explore des combinaisons de designs de matériaux possibles.
- [CuspAI](#) : à partir de propriétés ou de performances souhaitées, la plateforme d'IA génère des candidats de nouveaux matériaux.

Exploration de molécules permettant d'inhiber la production de méthane entérique

- Un projet de recherche mené par [l'United States Department of Agriculture](#) mobilise des méthodes d'intelligence artificielle générative et de simulations moléculaires pour accélérer la découverte d'inhibiteurs potentiels du méthane et ainsi accélérer la découverte de composés capables de réduire les émissions de méthane entérique.

L'IA générative employée dans cette démarche d'innovation est très prometteuse puisque les modèles génératifs sont capables de proposer des nouvelles configurations à partir d'objectifs définis.

L'IA est également utilisée pour **automatiser les cycles d'expérimentation** : un modèle prédictif génère ou sélectionne les candidats les plus prometteurs, puis des systèmes robotisés les synthétisent et mesurent automatiquement leurs propriétés. Les résultats sont immédiatement réinjectés dans le modèle qui choisit l'expérience suivante la plus informative. Ce processus réduit fortement le nombre d'essais nécessaires en évitant les tests redondants ou peu prometteurs. Ainsi, en automatisant et en optimisant chaque itération, les cycles de recherche deviennent continus et automatisés, ce qui accélère significativement la validation expérimentale (Nematov, Hojamberdiev, 2025).

Intérêt du recours à l'IA :

- Accélération des délais et réduction des coûts de R&D

D'après Polaron, leur technologie d'IA déployée pourrait permettre d'améliorer la densité énergétique de batteries de 10 % (Mittal, 2025). Néanmoins, même si l'IA permet d'accélérer les temps de R&D, il s'agit d'un cas d'usage dont les effets ne se verront qu'à moyen-long terme, puisqu'il faut encore le temps de transiter vers des applications industrielles, à travers la validation de tests expérimentaux.

La présentation des technologies d'IA selon leurs fonctionnalités est utile pour en clarifier les mécanismes, mais elle ne reflète pas entièrement la réalité des déploiements. **La plupart des cas d'usage de la transition énergétique mobilisent en effet simultanément plusieurs de ces fonctions.** La gestion des réseaux électriques intelligents en est l'illustration la plus claire : elle repose à la fois sur la prévision de la demande et de la production renouvelable, sur le contrôle en temps réel des flux d'énergie, sur la détection d'anomalies et la maintenance prédictive des équipements, et sur l'optimisation stratégique des investissements réseau. Ces fonctions ne sont pas indépendantes, au contraire elles s'alimentent mutuellement en données et en signaux, formant des boucles de rétroaction qui renforcent la performance globale d'un système.

Par ailleurs, l'IA ne peut pas être dissociée du contexte physique dans lequel elle opère. Par

exemple, dans le pilotage de réseaux électriques ou l'optimisation de procédés industriels, **les modèles d'IA sont souvent couplés à des modèles physiques** qui structurent et contraignent les prédictions. Ce couplage est souvent ce qui permet aux modèles d'IA de rester fiables et d'être acceptés par des ingénieurs dont la confiance dans le modèle repose sur sa cohérence avec les lois physiques connues.

Enfin, **le choix d'un algorithme pour un cas d'usage donné n'appelle pas de réponse unique.** Un même problème peut être traité par plusieurs familles de techniques, avec des compromis différents en termes de quantité de données requises, de transparence du modèle, de coût computationnel ou de capacité à gérer des contraintes physiques. Le choix dépend autant des caractéristiques du problème que des données disponibles et des exigences opérationnelles.



3

Défis et limites de l'IA pour la transition

Défis autour du déploiement de l'IA
pour la transition

Impact énergétique de l'IA

La nécessité d'un déploiement
responsable de l'IA

Défis autour du déploiement de l'IA pour la transition

Explicabilité de l'IA

L'explicabilité de l'IA devient un enjeu majeur de son déploiement à l'échelle industrielle, en particulier lorsqu'il s'agit d'utiliser des réseaux de neurones profonds. Ces derniers sont en effet **caractérisés par l'opacité de leur fonctionnement** (considéré comme une « boîte noire »), ce qui rend difficile le transfert d'un cas d'usage à d'autres. **La difficulté à expliciter les résultats des modèles de Deep Learning limite leur fiabilité et la portée de la prise de décision découlant de ces derniers.** De plus, être en capacité de comprendre et expliquer le fonctionnement d'une IA permet aussi d'identifier les biais ou les facteurs susceptibles de modifier ou perturber les prédictions demandées.

Des techniques existent néanmoins pour rendre l'IA davantage transparente. **Un nouveau paradigme d'IA semble émerger : l'IA explicable (*explainable AI*)** caractérise les modèles d'IA qui sont à la fois performants et dont on peut comprendre et s'approprier le fonctionnement.

Il existe différents moyens permettant d'aboutir à une IA explicable, dont (Arrieta *et al.*, 2019) :

- **La décomposition** : Il s'agit de comprendre chaque composant du modèle séparément. Les entrées doivent être lisibles, les paramètres (ex. : les poids d'une régression linéaire) doivent avoir une interprétation, les calculs doivent être traçables et compréhensibles.
- **La transparence algorithmique** : C'est la capacité à comprendre le mécanisme interne du modèle, c'est-à-dire comment il passe des entrées aux sorties et comment il prend des décisions.

L'explicabilité de l'IA apparaît rapidement nécessaire dans un contexte de généralisation de son usage, cependant il faut également définir des métriques pour évaluer l'explicabilité. De plus, le niveau de détail et de compréhension nécessaire des modèles dépend de l'utilisateur cible (développeur, utilisateur lambda, décideurs, politiques publiques...).

Dépendance aux données

Qualité des données

Le Machine Learning repose fondamentalement sur l'apprentissage à partir de données, donc **la qualité de ces dernières impacte fortement les modèles et les résultats** : les modèles sont mauvais si les données sont incomplètes, bruitées, etc. **La performance d'un modèle diminue si les données réelles/en environnement de production sont différentes des données utilisées pour l'entraîner** – on parle de *Distribution Shift* (Vector Institute, 2021). Ainsi, les modèles entraînés sur des données d'un parc de bâtiments spécifiques peuvent par exemple mal se généraliser dans une autre région ou sous un régime climatique différent.

Accès aux données

La **confidentialité des données** les rend difficilement accessibles. En effet, les données utiles pour l'optimisation du réseau, des centrales, ou des bâtiments (issues de compteurs intelligents, données de consommation) sont souvent détenues par des opérateurs privés qui sont réticents à les partager.

Les Etats-Unis ont une politique très favorable à l'innovation avec peu de régulation sur les données qui a débuté dès les années 2010 (Open Data Policy en 2013), tandis que l'accès aux données est davantage protégé en Europe. Entraîner des modèles IA européens sur des données extra-européennes, faute de données disponibles, peut entraîner des risques de manque de représentativité des spécificités locales et régionales, telles que le langage, le climat, les faits historiques, etc. (OECD, 2024 ; Martens, 2024 ; Kulothungan, Gupta, 2025). Cette même problématique existe pour les pays en développement, pour lesquels il manque des mesures et données fiables pouvant être utilisées comme données d'entraînement (UNFCCC, 2025). Une alternative serait d'avoir recours à des données synthétiques pour entraîner les modèles, mais des biais peuvent être introduits. La mise en place de **réglementations pour assurer le partage et l'accès aux données** pourrait permettre d'accélérer la mise en place d'applications IA, en particulier dans le secteur de l'énergie (Open Climate Fix, 2026).

Au Royaume-Uni, Le Department for Energy Security and Net Zero a lancé en mars 2026 un appel à contributions sur les données nécessaires

au déploiement de l'IA dans le système énergétique. Le gouvernement reconnaît ainsi que les données constituent un goulot d'étranglement critique. L'appel cible des acteurs très précis : développeurs d'IA et entreprises énergétiques capables d'identifier des jeux de données inexistants ou inaccessibles dont la création débloquerait des applications à fort impact (UK Department of Energy Security & Net Zero, 2026). Il apparaît particulièrement important de **développer la culture de l'open data en Europe** car l'accès aux données facilite et accélère le développement de modèles IA souverains européens. **En France, le Gouvernement porte une politique favorable à l'open data** (ex : le portail national des données ouvertes data.gouv.fr) **et est leader en la matière en Europe** (Commission Européenne, 2025). La France a décliné la stratégie européenne de circulation des données à travers le règlement sur la gouvernance des données (Data Governance Act, 2022), qui vise à sécuriser la mise en place d'espaces communs de données qui permettraient la création de plateformes de partage de données à l'échelle locale, ainsi que le règlement sur les données (Data Act, 2023), qui vise à encadrer les conditions du partage de données (Les Interconnectés *et al.*, 2024). Mais le réflexe d'ouverture et de partage des données est encore insuffisant, en particulier au niveau des entreprises, réticentes à partager des données (Parlement Européen, 2025 ; Bernal, 2024).

La gouvernance des modèles (transparence, explicabilité, responsabilité) est un vrai enjeu pour l'acceptabilité et l'usage des IA dans des contextes critiques, telles que les infrastructures énergétiques (Aisleigh *et al.*, 2022).

Sécurité des données

L'accroissement de la digitalisation des infrastructures les rend plus sujettes à des cyberattaques (McKinsey, 2024). Les infrastructures de réseaux et les sites de production énergétique sont particulièrement visés par ces attaques. La mise en place de mesures et protocoles de sécurité robustes est nécessaire pour protéger les systèmes et les données manipulées par les modèles IA. Le projet de loi de transposition de la directive NIS 2 (Network and Information Security), doit entre autres renforcer la cybersécurité des collectivités territoriales et de la chaîne de valeur des acteurs les plus stratégiques.

Face à cette menace croissante, l'IA peut cependant jouer un rôle défensif majeur pour protéger les infrastructures de la transition. Les systèmes de cybersécurité intégrant des techniques d'apprentissage automatique sont capables d'analyser en continu de grands volumes de données issues des réseaux, des systèmes industriels ou des capteurs afin d'identifier des comportements anormaux ou des tentatives d'intrusion. Dans le secteur de l'énergie et des réseaux électriques intelligents, plusieurs travaux montrent que des systèmes de détection d'intrusion basés sur l'IA peuvent améliorer significativement la détection des cybermenaces (Govea *et al.*, 2024). L'IA peut ainsi contribuer à renforcer la résilience des infrastructures énergétiques face à des attaques de plus en plus sophistiquées.

L'IA apparaît ainsi comme une technologie ambivalente : elle peut accroître la surface d'attaque des infrastructures numériques tout en constituant un outil central pour renforcer leur protection.

AI for brown

Bien que beaucoup d'espoirs soient portés sur les impacts positifs de l'IA pour la décarbonation, **il s'agit d'une technologie qui peut aussi être utilisée au profit des industries pétrolières et gazières** et contribuer à l'augmentation des productions et de leur profit (*AI for brown*), et plus généralement profiter à toute industrie ayant un intérêt à maintenir et accroître les modes de consommation actuels. **Les cas d'usages sont sensiblement similaires aux tâches qu'accomplit l'IA au service de la décarbonation** : identification des sites optimaux de forage, optimisation des process, maintenance prédictive des installations, etc. (BCG, 2025).

Bien que les raisons invoquées pour justifier l'utilisation de l'IA dans les industries Oil & Gas soient l'efficacité énergétique (permise par l'optimisation des opérations) et les économies de temps et de ressources (permis par la maintenance prédictive), **l'extraction d'énergies fossiles rendue plus efficace par l'IA pourrait finalement encourager une intensification de la production de pétrole et de gaz** (effets rebonds).

Impact énergétique de l'IA

L'impact énergétique de l'IA a été traité dans un [précédent rapport de Zenon](#). Cette page est une synthèse des conclusions principales de ce rapport.

La consommation énergétique des data centers, colonne vertébrale de l'IA, est estimée à 415 TWh dans le monde en 2024, soit 1,3 % de la consommation électrique mondiale aujourd'hui. Si à l'échelle planétaire, cette consommation ne semble pas importante, c'est sur les réseaux électriques locaux que la répercussion est grande. En effet, la répartition des data centers est loin d'être homogène dans le monde : ces infrastructures sont largement regroupées en cluster dans des régions spécifiques – Etats-Unis,

Asie (Chine), et une poignée de pays en Europe. À l'échelle globale, la consommation des data centers peut sembler négligeable, mais leur expansion peut avoir des répercussions significatives sur les réseaux et ressources locales. Aux Etats-Unis, les data centers représentent, en 2023, 4,4 % de la consommation électrique nationale. L'IA représente environ 15 % du besoin énergétique des data centers aujourd'hui, soit environ 62 TWh, bien qu'il soit difficile d'établir précisément sa consommation. L'augmentation de la taille des modèles, censée garantir de meilleures performances, provoque l'allongement des temps d'entraînement et l'augmentation de la puissance des processeurs utilisés. L'utilisation croissante de l'IA dans les usages quotidiens et économiques entraîne également l'augmentation de sa consommation.




Figure 9 – Sélection de scénarios d'évolution mondiale de la consommation de l'IA (Zhang, Dupin, 2025)

La trajectoire d'évolution de la consommation énergétique de l'IA et des data centers est incertaine, car de nombreux facteurs influent ces derniers. Les scénarios les plus plausibles d'ici 2030 estiment une consommation entre 200 et 400 TWh d'ici 2030. L'IA pourrait passer ainsi de 15 % de la consommation des data centers aujourd'hui à 35 à 50 % en 2030. La demande énergétique des data centers pourrait plus que doubler, et passer de 415 TWh à 945 TWh.

Au-delà de la consommation d'électricité et du mix électrique (dont le recours accru au gaz augmente les émissions indirectes des data centers, qui peuvent atteindre jusqu'à

320 MtCO₂e en 2030), l'empreinte environnementale de l'IA repose sur d'autres facteurs. Par exemple, l'eau est souvent utilisée comme fluide caloporteur pour refroidir les data centers, ce qui contribue à une pression accrue sur les ressources hydriques. Les réflexions actuelles sur l'impact environnemental de l'IA se limitent le plus souvent à sa consommation énergétique en phase d'entraînement et d'usage, sans intégrer les étapes amont et aval de son cycle de vie, or ces dernières mériteraient d'être prises en considération, surtout dans le cas des processeurs conçus spécifiquement pour l'IA.

La nécessité d'un déploiement responsable de l'IA

Il est bon de rappeler également l'**impact énergétique de l'utilisation de l'IA** (qui a fait l'objet d'un rapport Zenon précédent), historiquement dominé par la consommation à l'entraînement des modèles et aujourd'hui tiré par une explosion des usages. En effet, la consommation énergétique des data centers était estimée à 415 TWh dans le monde en 2024, soit 1,3 % de la consommation électrique mondiale, et l'IA représente environ 15 % des besoins énergétiques des data centers aujourd'hui, soit environ 62 TWh. Les scénarios d'évolution de la consommation de l'IA, nombreux et aux estimations variables, chiffrent une consommation énergétique de l'IA entre 200 et 400 TWh d'ici 2030.

L'IA exerce aussi d'autres pressions environnementales, notamment la consommation en eau, qu'il reste encore difficile de quantifier (Zhang, Dupin, 2025).

La question inévitable de la **balance entre les émissions évitées grâce à un usage vertueux de l'IA et les émissions générées à cause d'un usage intensif de l'IA** se pose et invite à une réflexion sur la finalité et les modalités de l'utilisation de l'IA.

Néanmoins, selon les études de l'AIE, Deloitte, et Stern et al., un déploiement global de l'IA contrebalancerait largement l'augmentation des émissions et de la consommation d'énergie liée à un usage intensif de l'IA.

Il est par ailleurs **primordial de distinguer l'IA générative**, très populaire (et énergivore, en particulier pour la génération d'images) aujourd'hui, **de l'ensemble des technologies d'IA existantes** (Luccioni et al., 2024). L'IA générative est loin de convenir à tous les usages : le type d'IA développé doit être adapté et réfléchi en fonction de son application. Même si les réseaux de neurones profonds et l'IA générative sont d'usage quotidien aujourd'hui, leur entraînement et usage sont énergivores. Il est crucial de développer et penser des modèles d'IA frugaux en parallèle d'une application de l'IA pour la transition.

L'IA doit rester un moyen et non une fin en soi, et son déploiement, même à des fins vertueuses, doit rester guidé par une logique de fonctionnement frugal (ex : techniques d'entraînement optimisées pour réduire la consommation d'énergie, utilisation de modèles spécifiques vs généralisés), **et de sobriété des usages**.

Références

- Adimulam T., Bhoyar M., Reddy P., 2019. [AI-driven predictive maintenance in IoT-enabled industrial systems.](#)
- AIE, 2025. [Energy and AI.](#)
- Aisleigh R., Mehmood R., Katib I., 2022. [AI Explainability and governance in smart energy systems : a review.](#)
- Arrieta A. B., Dias-Rodriguez N., Del Ser J., Bennetot A., Tabik S., Barbado A., Garcia S., Gil-Lopez S., Molina D., Benjamins R., Chatila R., Herrera F., 2019. [Explainable Artificial Intelligence \(XAI\): Concepts, Taxonomies, Opportunities and Challenges toward Responsible IA.](#)
- AWS, 2026a. [Qu'est-ce qu'un GAN ?](#)
- AWS, 2026b. [Que sont les transformateurs dans le domaine de l'intelligence artificielle ?](#)
- BBC, 2024. [Kazakhstan : Methane mega-leak went on for months.](#)
- BCG, 2025. [The AI-First Oil and Gas Company.](#)
- Bergmann D., 2026. [What is Machine Learning ?](#), IBM.
- Bergmann D., Stryker C., 2026a. [Qu'est-ce qu'un auto-encodeur variationnel ?](#), IBM.
- Bergmann D., Stryker C., 2026b. [Qu'est-ce qu'un modèle de transformeur ?](#), IBM.
- Bergmann D., Stryker C., 2026c. [Qu'est-ce que la rétropropagation ?](#), IBM.
- Bernal J., 2024. [Private sector trust in data sharing : enablers in the European Union.](#)
- Brandt K., Lesser R., 2023. [AI could accelerate progress toward the world's climate goals. Here's how.](#)
- Buettgenbach M.H., 2021. [Artificial neurons.](#)
- CapGemini, 2024. [Climate AI: How artificial intelligence can power your climate action strategy.](#)
- Cardon D., Cointent J., Mazières A., 2018. [La revanche des neurones - L'invention des machines inductives et la controverse de l'intelligence artificielle.](#)
- Commission Européenne, 2025. [2025 open data maturity assessment – how did European countries do ?](#)
- Datacamp, 2023. [What is symbolic AI ?](#)
- Data Scientist, 2021. [Perceptron : qu'est-ce que c'est et à quoi ça sert ?](#)
- Deloitte, 2025. [Quand l'IA est au service des systèmes énergétiques.](#)
- EDSO, 2024. [Windy Smart Grid : Machine Learning to forecast grid damages and outages caused by storm winds.](#)
- Farooq U., Ademola M., Shaalan A., 2024. [Comparative Analysis of Machine Learning Models for Predictive Maintenance of Ball Bearing Systems.](#)
- Golem AI, 2023. [Intelligence artificielle symbolique et Machine Learning, l'essor des technologies disruptives.](#)
- Google, 2026a. [Qu'est-ce que l'apprentissage non supervisé ?](#)
- Google, 2026b. [Qu'est-ce que le Machine Learning \(ML\) ?](#)
- Google, 2026c. [Using Google AI to reduce traffic emissions.](#)
- Google DeepMind, 2023. [GraphCast : AI model for faster and more accurate global weather forecasting.](#)
- Google DeepMind, 2026. [AlphaGo.](#)
- Govea J., Gaibor-Naranjo W., Villegas-Ch W., 2024. [Transforming Cybersecurity into Critical Energy Infrastructure: A Study on the Effectiveness of Artificial Intelligence.](#)
- Gupta M., Arya A., Varshney U., Mittal J., Tomar A., 2025. [A review of PV power forecasting using Machine Learning techniques.](#)
- Hamdan A., Ibekwe K., Ilojiana V., Sonko S., Etukudoh E., 2024. [AI in renewable energy: A review of predictive maintenance and energy optimization.](#)
- Hamon T., 2023. [Modélisation et représentation des connaissances.](#)
- Hassannayebi E., Nourian R., Mousavi S., Mehdi S., Alizadeh S., Memarpour M., 2022. [Predictive analytics for fault reasoning in gas flow control facility : A hybrid fuzzy theory and expert system approach.](#)
- Haykin S., 1998. [Neural Networks : A comprehensive foundation.](#)
- Herweijer C., Combes B., Gillham J., 2019. [How AI can enable a sustainable future.](#)
- IBM, 2025. [Qu'est-ce qu'un convolutional neural networks \(CNN\) ?](#)
- IMT Atlantique, 2023. [DeepHawk : l'IA frugale au service du contrôle de qualité dans l'industrie.](#)
- IONOS, 2021. [Qu'appelle-t-on Web sémantique ?](#)
- Joshi K., 2026. [The AI climate hoax.](#)
- Kulothungan V., Gupta D., 2025. [Towards adaptative AI governance : comparative insights from the US, EU, and Asia.](#)
- Lair W., Decroix H., Michel G., Meyer F., Chapert M., 2022. [Windy Smart Grid : Prévision de l'impact des tempêtes sur le réseau d'électricité.](#)

- Lawlor P., Chang K., 2024. [The rise of generative AI: A timeline of breakthrough innovations](#), Qualcomm.
- Les Interconnectés, France Urbaine, Intercommunalités de France, 2024. [Data et IA : les nouvelles règles du jeu en Europe](#).
- Li J., Polovina N., Konur S., 2026. [A review of AI-driven engineering modelling and optimization : methodologies, applications and future directions](#).
- Luccioni S., Jernite Y., Strubell E., 2024. [Power hungry processing : Watts driving the cost of AI deployment ?](#)
- Martens B., 2024. [Catch-up with the US or prosper below the tech frontier ? An EU artificial intelligence strategy](#).
- Marquez A., Oliver D., 2025. [Leveraging generative AI for modelling and optimization of maintenance policies in industrial systems](#).
- McKinsey, 2024. [The cybersecurity provider's next opportunity : Making AI safer](#).
- Micheal L., 2025. [Multi-modal generative AI for predictive maintenance : integrating vibration, acoustic and visual data for holistic failure forecasting](#).
- Mittal S., 2025. [Government backs AI start-up that is speeding up materials innovation for cleantech](#).
- Murel J., Kavlakoglu E., IBM, 2026. [Qu'est-ce que l'apprentissage par renforcement ?](#)
- Nematov D., Hojamberdiev M., 2025. [Machine Learning-driven materials discovery : unlocking next generation functional materials – a review](#).
- NESO, 2024. [Solar NowCasting innovation project improves solar forecasting](#).
- OECD, 2024. [Perspectives de l'économie numérique de l'OCDE](#).
- Oh S., Jung Y., Kim S., Lee I., Kang N., 2019. [Deep generative design : integration of topology optimization and generative models](#).
- OpenClassrooms, 2025. [Qu'est-ce qu'un réseau de neurones convolutif \(ou CNN\) ?](#)
- Open Climate Fix, 2026. [The key to unlocking Britain's ambition to be an AI superpower ? Opening access to energy data](#).
- Parlement Européen, 2025. [Data Act : Data sharing and competitiveness](#).
- Powell K., Machalek D., Quah T., 2020. [Real-time optimization using reinforcement learning](#).
- Serradilla O., Zugasti E., Zurutuza U., 2020. [Deep Learning models for predictive maintenance: a survey, comparison, challenges and prospect](#).
- Siemens, 2026. [BlueScope's predictive leap with Senseye](#).
- Stern N., Romani M., 2025. [What is AI's role in the climate transition and how can it drive growth ?](#)
- Stern N., Romani M., Pierfederici R., Braun M., Barraclough D., Lingeswaran S., Weirich-Benet E., Niemann N., 2025. [Green and intelligent: the role of AI in the climate transition](#).
- SDES, 2025. [Causes du changement climatique](#).
- Stryker C., 2026. [Qu'est-ce qu'un réseau neuronal récurrent \(RNN\) ?](#), IBM.
- UK Department of Energy Security & Net Zero, 2026. [Data for AI in the energy system : call for evidence](#).
- UNEP, 2024. [Emissions Gap Report 2024 : No more hot air...please !](#)
- UNFCCC, 2025. [Artificial Intelligence for Climate Action](#).
- Van Veen F., 2017. [Neural network zoo prequel : cells and layers](#).
- Vector Institute, 2021. [Understanding Dataset Shift and potential remedies](#).
- Veolia, 2025. [L'IA générative au cœur de la transformation écologique : Veolia repousse les frontières de l'innovation](#).
- WEF, 2025. [Intelligent Transport, Greener Future: AI as a Catalyst to Decarbonize Global Logistics](#).
- WRI, 2024. [Where do emissions come from ?](#)
- Zhang L., Dupin J., 2025. [Intelligence artificielle : une bombe énergétique ?](#)

A propos de Zenon research

Zenon Research est une association loi 1901 et un think tank indépendant. Ses travaux, fondés sur la science, sont dédiés aux technologies pour un monde bas carbone.

Contactez-nous



[/zenon-research](#)



www.zenon.ngo



contact@zenon.ngo

Pour plus d'informations sur ce sujet

Lucie Zhang

Analyste

Zenon Research

lucie@zenon.ngo

Zenon Research souhaite remercier les experts suivants pour leurs connaissances et leurs contributions sur les différents aspects de l'intelligence artificielle et ses usages pour la transition :

Claire Sagnol – Ekimetrics
Claude Tadonki – Mines Paris – PSL
Cyprien Canivenc – Ancien Rapporteur général de la Commission IA
Denis Trystram – Université Grenoble Alpes
Elisa Fromont – Université de Rennes
Gabriel Kasmi – Mines Paris – PSL
Gautier Avril – PureControl
Jean-Daniel Kant – Sorbonne Université
Jeanne Bouligny – Cleantech for France
Philippe Preux – INRIA
Roblex Nana Tchakouté – Mines Paris – PSL
Stéphane d'Ascoli – Meta
Valentin Drouet – Metroscope

Le contenu de ce rapport représente les opinions de Zenon Research et ne doit pas être considéré comme représentant celles des relecteurs ou des organisations auxquelles ils sont affiliés.

