

Louvain School of Management

**Comment les études existantes
évaluent-elles l'impact
environnemental de l'IA en imagerie
médicale et quelles en sont les
principales limites ?**

Auteure : Maud Mercier
Promoteur : Xavier Marichal
Année académique 2025-2026
Travail de fin d'études (TFE) en vue d'obtenir le titre de
Master [120] en Ingénieur de gestion,
Marketing Strategy for Connected Brands
Horaire de jour

DECLARATION

The declaration below is **mandatory and must appear on the first page (after the front page) of your master's thesis.**

STATEMENTS ON YOUR USE OF GENERATIVE AI

Confirm the following statements:

Statements on responsible use of generative AI	Your answer
The content of my/our master's thesis is my/our original output, even if I/we used generative AI to help prepare it.	☒ Yes ☐ No
I/we master the theories, tools and methods that I/we use for the thesis.	☒ Yes ☐ No
I/we verified that the output presented in the thesis is accurate and valid, and that it contains no hallucination, no false reference, etc.	☒ Yes ☐ No
I/we acknowledge that I/we master the final output and that I am/we are able to explain it and answer questions about it.	☒ Yes ☐ No
I/we made sure not to provide generative AI tools with access to confidential data or information	☒ Yes ☐ No

SIGNATURE

Sign your declaration:

Author last name, first name(s)	Date	Signature
1 Mercier, Maud	Sunday, May 24, 2026	
2		

Dans le cadre de la rédaction de ce mémoire, j'ai utilisé des outils d'intelligence artificielle générative, notamment ChatGPT (OpenAI) et NotebookLM (Google). Ces outils ont été utilisés à titre de soutien rédactionnel, pour la reformulation et la clarification de certains passages, l'aide à la structuration des idées, ainsi que pour des besoins de traduction.

Je tiens tout d'abord à remercier mon promoteur, Monsieur Xavier Marichal, pour son accompagnement, ses conseils avisés et ses retours constructifs tout au long de la réalisation de ce mémoire.

Je remercie également mon frère qui a pris le temps de relire ce travail et de m'apporter ses remarques, qui m'ont permis d'améliorer la qualité de ce mémoire. Mes remerciements vont aussi à ma famille, pour son soutien constant, sa patience et ses encouragements tout au long de mes études.

Enfin, je remercie mes amis et mes proches pour leur présence, leur écoute et les moments de soutien partagés durant cette période.

Ce travail ne contient pas de données confidentielles et est destiné à une diffusion publique.

Table des matières

Introduction	1
Chapitre 1. Cadre conceptuel : intelligence artificielle, imagerie médicale et impact environnemental	3
1.1. L'intelligence artificielle dans le domaine de la santé	3
1.2. Les applications de l'intelligence artificielle en imagerie médicale	5
1.3. Les spécificités techniques de l'imagerie médicale	7
1.4. L'impact environnemental de l'IA	9
1.5. La montée des préoccupations de durabilité dans le secteur de la santé.....	12
Chapitre 2. Cadre méthodologique de l'évaluation environnementale.....	13
2.1. Les principes d'une évaluation environnementale rigoureuse.....	13
2.2. L'analyse du cycle de vie	14
2.3. Les principaux indicateurs mobilisables.....	15
2.4. Le cadre des effets d'usage selon Hilty	17
Chapitre 3. Méthodologie de la revue de littérature	19
3.1. La recherche documentaire	19
3.2. La construction de la grille d'analyse comparative.....	20
3.3. Limites de la démarche méthodologique	20
Chapitre 4. Analyse comparative des études existantes.....	21
4.1. Présentation et synthèse du corpus	21
4.2. Types d'études	22
4.3. Dimensions environnementales évaluées	22
4.4. Étapes du cycle de vie couvertes	24
4.5. Méthodes/outils.....	25
4.6. Effets d'usage et impacts structurels	27
Chapitre 5. Les principales limites des études existantes	29
5.1. Le manque de normalisation et de comparabilité	29
5.2. Des périmètres d'analyse souvent trop restreints.....	30
5.3. Une focalisation sur l'énergie et le CO ₂	31
5.4. L'absence d'analyse du cycle de vie complet	32
5.5. Une prise en compte limitée des effets indirects	33
Chapitre 6. Discussion	34
6.1. Ce que la littérature permet réellement de conclure	34
6.2. Écarts entre les exigences méthodologiques et les pratiques observées	35
6.3. Apports du mémoire à la compréhension du sujet	37

6.4. Implications pour la recherche future	37
6.5. Limites du mémoire	39
Conclusion générale.....	40
Bibliographie	41
Annexe 1. Tableau comparatif des études retenues.....	46

Introduction

Aujourd'hui, l'intelligence artificielle (IA) occupe une place de plus en plus importante dans le domaine de la santé, et particulièrement en imagerie médicale. Elle permet notamment d'améliorer la qualité des images, d'accélérer certains examens, d'automatiser des tâches et d'aider les professionnels dans le diagnostic. Grâce à ces avancées, l'IA est donc souvent présentée comme une technologie capable d'améliorer l'efficacité des services de radiologie.

Cependant, son développement amène aussi des questions d'impact environnemental. Les systèmes d'IA nécessitent des ressources informatiques importantes, des centres de données, des équipements spécialisés et de grandes capacités de stockage. Leur entraînement et leur utilisation peuvent produire une consommation élevée d'énergie, des émissions de gaz à effet de serre et une utilisation importante de ressources matérielles. Plusieurs études montrent donc que les bénéfices de l'IA doivent être évalués en tenant compte de ses coûts écologiques (Jallais et al., 2026 ; Thomson et al., 2025 ; Champendal et al., 2025).

Ce sujet a été choisi parce que l'IA en imagerie médicale est une avancée technologique importante, dont les implications environnementales sont encore peu étudiées. L'objectif de ce mémoire est donc d'analyser la manière dont son empreinte environnementale est évaluée dans la littérature scientifique, et quelles en sont les principales limites méthodologiques. Il ne cherche pas à obtenir une mesure empirique de cet impact, mais à analyser les apports, les différences et les limites des approches existantes.

Pour répondre à cette problématique, ce travail est basé sur une revue de littérature critique et méthodologique. Les études sélectionnées ont été comparées selon plusieurs critères : type de publication, dimensions environnementales évaluées, étapes du cycle de vie prises en compte, méthodes et outils utilisés, effets d'usage et impacts structurels considérés, principaux résultats et principales limites méthodologiques. L'analyse se base aussi sur une logique inspirée de l'analyse du cycle de vie et sur le modèle de Hilty, afin de tenir compte des effets directs et indirects des technologies numériques.

Plusieurs difficultés ont été rencontrées. La première concerne la constitution du corpus, car la littérature du domaine reste encore limitée et dispersée. Les publications disponibles n'ont pas toujours le même objectif. Certaines proposent des mesures quantitatives précises, tandis que d'autres ont une approche plus générale. Une deuxième difficulté est la comparaison des

études, qui utilisent des indicateurs, des unités et des périmètres d'analyse différents. Enfin, l'application de cadres comme l'analyse du cycle de vie ou le modèle de Hilty a parfois été limitée par le manque d'informations dans les articles.

Le mémoire s'organise en six chapitres. Le premier chapitre présente le cadre conceptuel en expliquant l'intelligence artificielle en santé, ses applications en imagerie médicale, les spécificités techniques du domaine ainsi que les principales dimensions de son impact environnemental. Le deuxième chapitre expose le cadre méthodologique de l'évaluation environnementale, avec l'analyse du cycle de vie, les principaux indicateurs utilisables et le modèle des effets selon Hilty. Le troisième chapitre présente la méthodologie de la revue de littérature et la manière dont le corpus a été construit. Le quatrième chapitre propose une analyse comparative des études retenues. Le cinquième chapitre met en évidence les principales limites méthodologiques de la littérature existante. Enfin, le dernier chapitre discute les principaux constats du mémoire, ses apports, ses limites et les implications pour la recherche future.

Chapitre 1. Cadre conceptuel : intelligence artificielle, imagerie médicale et impact environnemental

1.1. L'intelligence artificielle dans le domaine de la santé

Le domaine de la santé est aujourd'hui l'un des principaux champs d'application de l'intelligence artificielle (Richie et al., 2025 ; Thomson et al., 2025 ; Ueda et al., 2024). L'IA regroupe un ensemble de techniques permettant à des systèmes informatiques d'exécuter des tâches habituellement réalisées avec l'intelligence humaine. Le terme ne désigne toutefois pas l'ensemble des outils numériques utilisés en imagerie médicale. En effet, ce domaine utilise depuis longtemps des algorithmes conventionnels, c'est-à-dire sans IA, basés sur une programmation avec des règles codées par des experts humains (Barragán-Montero et al., 2021). À l'inverse, les outils d'IA utilisent l'apprentissage par expérience. Au lieu d'être programmés pour chaque cas, ils sont entraînés sur de grandes bases de données pour trouver eux-mêmes des relations entre les données (Barragán-Montero et al., 2021 ; Castiglioni et al., 2021). Dans cet ensemble, l'apprentissage automatique, ou *machine learning*, correspond aux méthodes par lesquelles un système apprend à partir de données. L'apprentissage profond, ou *deep learning*, en est une sous-catégorie particulièrement efficace pour traiter des données complexes, notamment dans le secteur de la santé (Wong et al., 2019 ; Barragán-Montero et al., 2021 ; Castiglioni et al., 2021). L'IA en santé ne comporte donc pas une unique technologie, mais plutôt une « constellation » de technologies différentes (Katirai, 2024).

Les recherches dans ce domaine remontent aux années 1950, mais les algorithmes ont longtemps donné des performances inférieures à celles de l'être humain (Mandal et al., 2018). Un tournant important s'observe aujourd'hui, basé sur deux évolutions majeures. La première est le développement du deep learning, qui s'inspire de la structure et du fonctionnement du cerveau humain pour traiter des données complexes (Wong et al., 2019 ; Barragán-Montero et al., 2021). La seconde est le développement du *big data*, soit l'augmentation massive des données disponibles, permettant un meilleur entraînement des algorithmes. Combinées aux progrès du matériel informatique, ces évolutions ont permis aux algorithmes d'atteindre, dans certaines tâches spécifiques, des performances comparables voire supérieures à celles de l'humain (Mandal et al., 2018 ; Katirai, 2024 ; Thomson et al., 2025).

L'IA est souvent présentée comme une solution susceptible d'améliorer la qualité des diagnostics et l'efficacité des soins (Thomson et al., 2025 ; Katirai, 2024). Plusieurs catégories d'utilisation peuvent être distinguées. La première est l'extraction et l'interprétation des données cliniques complexes, notamment des images médicales, permettant de réduire les erreurs de diagnostic et d'éviter certaines procédures inutiles (Katirai, 2024 ; Ranganathan et al., 2025). L'IA se distingue entre autres par sa capacité à reconnaître des motifs invisibles à l'œil nu (Vafaei Sadr et al., 2024 ; Pinto-Coelho, 2023). La deuxième catégorie est le traitement des données de santé. En effet, le système de santé génère une grande quantité de données, qu'il s'agisse de dossiers médicaux électroniques, de données génétiques, de données issues de capteurs et d'objets connectés, ou encore de données de santé publique (Richie et al., 2025). L'IA permet d'analyser ces données afin d'aider au diagnostic, de détecter des maladies, de personnaliser la médecine ou d'améliorer la gestion hospitalière (Richie et al., 2025 ; Quttainah et al., 2025). Une troisième catégorie concerne l'administration directe des soins, où l'IA est utilisée dans les robots chirurgicaux, les robots d'assistance aux patients ou encore les chatbots pour la santé mentale (Richie et al., 2025).

Bien que l'IA dans le domaine de la santé offre des avantages, de nombreux chercheurs mettent en évidence une contradiction importante, appelée le « paradoxe de la durabilité » ou une « épée à double tranchant » (Kocak et al., 2025 ; Doo et al., 2024). En effet, d'un côté, l'IA peut améliorer la durabilité en optimisant la gestion des ressources hospitalières, en réduisant les déchets médicaux et en limitant les déplacements des patients via la télémédecine (Bignami et al., 2025 ; Quttainah et al., 2025). De l'autre, son développement et son déploiement génèrent eux-mêmes des impacts environnementaux, qui restent encore souvent sous-estimés dans la littérature (Katirai, 2024). À ce problème environnemental s'ajoute un écart, cette fois entre les performances académiques annoncées et les conditions réelles de déploiement en pratique clinique. Cette différence est connue sous le nom de « fossé de l'IA » et vient de la difficulté à généraliser les modèles hors des conditions de test idéales, ainsi que du manque de transparence sur l'impact réel de ces outils (Kelly et al., 2022).

Ces différentes limites montrent que l'évaluation de l'IA en santé ne peut pas se réduire à ses seules performances techniques ou cliniques. Pour que l'IA remplisse réellement ses promesses en matière de santé, les auteurs insistent sur le fait qu'elle ne doit pas compromettre la santé planétaire (Bignami et al., 2025 ; Kocak et al., 2025). En contribuant à

la pollution et au changement climatique, elle contribue en effet à ce que l'Organisation mondiale de la Santé considère comme la plus grande menace pour la santé mondiale (Doo et al., 2024).

1.2. Les applications de l'intelligence artificielle en imagerie médicale

Parmi les nombreux champs d'application de l'IA en santé, l'imagerie médicale est un domaine particulièrement stratégique. En raison de l'importance de l'image dans le diagnostic et du développement rapide des outils d'analyse automatisée, les applications de l'IA y sont aujourd'hui nombreuses et variées (Mandal et al., 2018 ; Thomson et al., 2025 ; Doo et al., 2024).

1.2.1. Analyse des images

Une première application de l'intelligence artificielle dans l'imagerie médicale est l'analyse des images. Elle est constituée de trois tâches principales. La première est la segmentation, qui est l'usage le plus fréquent dans la littérature, avec environ 39 % des applications (Kelly et al., 2022). Elle consiste à délimiter précisément des structures anatomiques ou pathologiques pixel par pixel (Mandal et al., 2018 ; Prajwal et al., 2025). Plusieurs exemples de cette tâche sont la segmentation de l'aorte, des vertèbres, des tumeurs rénales, de la prostate ou encore des lésions cérébrales (Thomson et al., 2025 ; Pinto-Coelho, 2023).

La deuxième tâche est la classification, qui représente environ 31 % des usages identifiés (Kelly et al., 2022). Elle permet de catégoriser une image ou une région d'intérêt. Les applications incluent entre autres le diagnostic binaire, par exemple la présence ou l'absence de syndrome des ovaires polykystiques (SOPK) sur échographie, la sous-classification de certains cancers ou encore le score de gravité d'une pathologie comme le COVID-19 (Laçi & Sevrani, 2025 ; Lan et al., 2024 ; Champendal et al., 2025 ; Pinto-Coelho, 2023).

Enfin, la dernière et troisième grande tâche est la détection. Son but est d'identifier et de localiser des anomalies spécifiques sur les images médicales. Elle peut par exemple repérer des nodules pulmonaires sur un scanner thoracique, des embolies pulmonaires, ou des dépôts de calcium coronarien (Doo et al., 2024 ; Pinto-Coelho, 2023).

1.2.2. Amélioration de la qualité et de la formation des images

Une deuxième application importante de l'IA est l'amélioration de la qualité et de la formation des images. Une des utilisations les plus prometteuses pour la durabilité est l'accélération de l'acquisition des images. En effet, certains travaux montrent que l'IA peut réduire le temps de passage dans l'IRM de 25 % à 75 % grâce à des algorithmes capables de reconstruire des images à partir de données sous-échantillonnées (Afat et al., 2025 ; Woolen et al., 2025). Par exemple, la séquence DL-HASTE pour l'imagerie abdominale réduit le temps d'examen de 62,5 % tout en améliorant la clarté des images (Gotta et al., 2026).

L'IA est également utilisée pour la réduction du bruit dans les images, ce qui permet d'améliorer leur qualité visuelle. Cela peut permettre de diminuer les doses de radiation ou de produits de contraste données aux patients. D'autres applications incluent la super-résolution, qui améliore artificiellement la netteté d'une image, ainsi que la synthèse intermodale, qui consiste à créer des images synthétiques susceptibles d'éviter la réalisation d'un second examen (Doo et al., 2024 ; Ueda et al., 2024 ; Woolen et al., 2025 ; Mandal et al., 2018 ; Kocak et al., 2025 ; Pinto-Coelho, 2023).

1.2.3. Aide au diagnostic et au triage

L'IA peut assister le clinicien dans le diagnostic et le triage des patients. En effet, elle peut contribuer à prioriser les cas critiques dans la liste de travail du radiologue. Par exemple, certains systèmes peuvent détecter une pneumonie sur des radiographies thoraciques et donc donner une alerte pour prioriser le patient (Ranganathan et al., 2025). Par ailleurs, l'IA peut aussi extraire des données d'un examen réalisé pour d'autres raisons. Doo et al. (2024) mentionnent par exemple la possibilité de mesurer la densité osseuse sur un scanner abdominal de routine afin de détecter une éventuelle ostéoporose. Enfin, l'IA peut aussi contribuer à éviter certains examens inutiles en analysant les antécédents, les facteurs de risque et les résultats biologiques du patient, afin d'évaluer si un examen d'imagerie a un bénéfice clinique réel (Doo et al., 2024).

1.2.4. Optimisation des flux de travail et gestion opérationnelle

En plus de l'interprétation des images médicales, l'IA peut aussi améliorer l'efficacité globale des services. En effet, elle peut être utilisée pour la planification intelligente. Cela va optimiser les rendez-vous en prédisant les risques d'absentéisme des patients et en alignant les horaires sur la disponibilité des machines et du personnel (Ueda et al., 2024 ; Doo et al., 2024). L'IA

peut également analyser la demande d'examen pour sélectionner automatiquement le protocole d'acquisition le plus adapté au patient, c'est-à-dire les réglages techniques utilisés (Ueda et al., 2024 ; Kocak et al., 2025).

1.2.5. Médecine de précision et pathologie numérique

L'IA contribue au développement de la radiomique et de la génomique de l'imagerie. La radiomique consiste à extraire automatiquement de nombreuses caractéristiques à partir d'images médicales, tandis que la génomique de l'imagerie cherche à relier ces caractéristiques à des informations biologiques ou génétiques. Cela permet notamment de mieux prévoir l'évolution d'une maladie ou la réponse à un traitement (Mandal et al., 2018 ; Pinto-Coelho, 2023). En pathologie numérique, l'IA permet aussi d'analyser des images de lames entières, c'est-à-dire des lames de tissu numérisées en très haute résolution, qui sont parmi les types de données les plus volumineuses de la médecine clinique (Vafaei Sadr et al., 2024).

En résumé, l'IA en imagerie médicale intervient désormais à plusieurs étapes du processus depuis l'analyse et la reconstruction des images jusqu'à l'aide au diagnostic, au triage et à l'optimisation des flux de travail. Cette diversité d'applications montre la place croissante qu'elle occupe dans les services d'imagerie médicale. Cependant, ces applications utilisent des infrastructures, des volumes de données et des ressources informatiques spécifiques, qui ne sont pas sans conséquences environnementales.

1.3. Les spécificités techniques de l'imagerie médicale

L'imagerie médicale a des spécificités techniques qui la distinguent d'autres domaines d'application de l'intelligence artificielle. Elle repose en effet sur des équipements lourds, des flux de données importants, des besoins de stockage élevés et des infrastructures techniques complexes (Doo et al., 2024 ; Dietrich & Hanneman, 2025). Ces spécificités contribuent à expliquer pourquoi l'évaluation environnementale de l'IA en imagerie médicale nécessite une attention particulière.

1.3.1. Importance des volumes de données et leur complexité

Une première spécificité de l'imagerie médicale est l'importance des volumes de données utilisés. Les examens de radiologie, qu'il s'agisse d'IRM, de scanners ou de radiographies,

gènèrent des fichiers volumineux qui doivent être acquis, transférés, stockés, archivés et parfois retraités à plusieurs reprises. Ces données sont parmi les plus volumineuses produites en médecine clinique (Vafaei Sadr et al., 2024, Pinto-Coelho, 2023). Certains examens comme l'IRM et le scanner traitent des données en trois dimensions, ce qui augmente énormément la complexité mathématique des analyses (Nanekaran & Ukwatta, 2025). Enfin, le volume des données médicales à stocker est en forte croissance car le nombre d'examens par patient et le niveau de détail des images augmentent (Doo et al., 2024 ; Kocak et al., 2025).

1.3.2. Infrastructure très spécialisée

Avec le développement du deep learning, l'imagerie médicale dépend de plus en plus d'une forte puissance de calcul fournie par des processeurs spécialisés (Quttainah et al., 2025). En effet, les unités de traitement graphiques, ou GPU, sont devenues indispensables car elles permettent d'effectuer un grand nombre de calculs en même temps (Vafaei Sadr et al., 2024). Dans certains cas, des composants encore plus spécialisés, comme les TPU, c'est-à-dire des processeurs conçus spécialement pour l'intelligence artificielle, ou les FPGA, qui sont des circuits électroniques configurables, sont aussi utilisés pour améliorer les performances (Kocak et al., 2025 ; Quttainah et al., 2025).

1.3.3. Spécificités énergétiques des appareils

Une autre spécificité importante est le fait que l'IA s'intègre à des dispositifs d'imagerie déjà fortement consommateurs de ressources. Afat et al. (2025) montrent par exemple que les scanners IRM font partie des équipements les plus énergivores. En effet, une part importante de la consommation énergétique ne vient pas uniquement de l'acquisition des images, mais aussi du maintien permanent de certaines conditions techniques, comme le refroidissement nécessaire au fonctionnement de l'aimant supraconducteur de l'IRM (Afat et al., 2025). Ces exigences s'ajoutent aux coûts de calcul liés à l'IA. L'impact de l'IA en imagerie médicale doit donc être pris en compte dans un environnement qui est déjà, à lui seul, très exigeant du point de vue énergétique.

1.3.4. Chaines de traitement techniques et stockage

L'imagerie médicale ne se limite pas à la production d'une image. Elle suit des chaines de traitement très structurées, comprenant l'acquisition, la reconstruction, le post-traitement, l'interprétation et l'archivage (Ranganathan et al., 2025). L'intégration de l'IA dans ce

processus ne concerne donc pas seulement l'analyse de l'image elle-même, mais aussi l'ensemble de l'infrastructure nécessaire pour faire circuler, traiter et stocker les données. Cela ajoute des besoins supplémentaires en calcul, en stockage et en transfert de données. Les centres de données utilisés pour traiter et conserver ces informations nécessitent eux-mêmes des ressources importantes, notamment en énergie et en eau (Bignami et al., 2025 ; Kocak et al., 2025).

En résumé, l'imagerie médicale est un cas particulier pour l'étude de l'IA. Non seulement les images sont importantes pour le diagnostic médical, mais l'imagerie médicale utilise aussi des infrastructures techniques lourdes, de grandes quantités de données et des équipements spécialisés. Ces particularités montrent en partie pourquoi l'évaluation de l'IA dans ce domaine ne peut pas se limiter à ses résultats diagnostiques ou cliniques. Elle doit aussi tenir compte des moyens matériels, énergétiques et organisationnels nécessaires à son fonctionnement. C'est précisément ce qui amène à s'interroger sur son impact environnemental (Kelly et al., 2022 ; Doo et al., 2024 ; Thomson et al., 2025).

1.4. L'impact environnemental de l'IA

L'impact environnemental de l'intelligence artificielle est généralement réduit à son besoin en énergie. Pourtant, il englobe aussi la dépense énergétique durant la conception et l'utilisation du système, les rejets de gaz à effet de serre, les matières premières nécessaires, l'utilisation de l'eau, la production de déchets électroniques et divers impacts indirects (Bieser, 2024 ; Bignami et al., 2025). Plusieurs auteurs recommandent donc une perspective plus étendue, qui serait capable de prendre en compte les différentes ressources consommées, ainsi que les conséquences au-delà de leur seule phase opérationnelle (Bratan et al., 2024 ; Richie et al., 2025 ; Ueda et al., 2024 ; Bignami et al., 2025).

1.4.1. La consommation énergétique

L'IA est énergivore, car une grande quantité de calculs itératifs lui est nécessaire (Kocak et al., 2025 ; Ueda et al., 2024). Cette consommation ne provient pas uniquement de l'algorithme lui-même, mais de l'ensemble des ressources utilisées tout au long de son cycle de vie.

Deux phases principales sont généralement distinguées. La première est l'entraînement. C'est le processus par lequel le modèle est présenté à d'énormes volumes de données pour ajuster

ses réglages internes et apprendre à accomplir une tâche spécifique (Doo et al., 2024 ; Kocak et al., 2025). La seconde est l'inférence, autrement dit l'utilisation opérationnelle du modèle déjà entraîné sur de nouvelles données. À grande échelle, cette phase risque de consommer plus d'énergie que l'entraînement si le système est utilisé de façon intensive et répétée (Doo et al., 2024 ; Kocak et al., 2025).

En plus de cela, l'intelligence artificielle utilise des centres de données pour stocker les informations nécessaires à son fonctionnement. Ce sont des bâtiments massifs remplis de disques durs et de serveurs nécessitant une alimentation continue. Selon plusieurs études, ces derniers consomment entre 1 et 2 % de l'électricité mondiale (Kocak et al., 2025 ; Quttainah et al., 2025 ; Ueda et al., 2024).

1.4.2. Les émissions de gaz à effet de serre (GES)

Les émissions de gaz à effet de serre sont une autre dimension centrale de l'impact environnemental de l'IA. Elles sont généralement estimées en convertissant la consommation électrique en équivalent CO₂, en fonction de l'intensité carbone du mix énergétique local (Vafaei Sadr et al., 2024 ; Woolen et al., 2025 ; Lan et al., 2024).

Plusieurs auteurs rappellent qu'un grand modèle d'IA peut générer des émissions très élevées lors de son entraînement. Une étude démontre en particulier que l'entraînement peut émettre l'équivalent des émissions produites par cinq voitures moyennes, pendant leur cycle de vie (Doo et al., 2024 ; Bignami et al., 2025 ; Richie et al., 2025 ; Quttainah et al., 2025). L'impact peut donc varier beaucoup en fonction de la localisation des serveurs. Un entraînement dans un pays alimenté par hydroélectricité aura une empreinte bien plus faible qu'un autre pays dépendant davantage des énergies fossiles (Doo et al., 2024 ; Selvan et al., 2022).

1.4.3. Les ressources matérielles

L'IA a besoin de processeurs comme les GPU et les TPU pour pouvoir fonctionner et réaliser un grand nombre de calculs en même temps (Quttainah et al., 2025 ; Kocak et al., 2025). La fabrication de ces composants utilise des minéraux essentiels comme le cobalt, le lithium, le tantale ou certains métaux rares (Katirai, 2024 ; Richie et al., 2025 ; Kocak et al., 2025). Or, l'extraction de ces ressources entraîne fréquemment de grandes conséquences écologiques, en plus de questions sociales et morales importantes (Katirai, 2024 ; Quttainah

et al., 2025). Cette dépendance montre donc que l’empreinte environnementale de l’IA débute bien avant que les modèles ne soient entraînés (Katirai, 2024 ; Champendal et al., 2025).

1.4.4. La consommation d’eau

L’empreinte hydrique est une dimension souvent négligée alors que l’IA est qualifiée de technologie « assoiffée » (Bieser, 2024 ; Champendal et al., 2025 ; Lan et al., 2024). En effet, les centres de données consomment des milliards de litres d’eau, pour le refroidissement des serveurs afin d’éviter leur surchauffe (Bignami et al., 2025 ; Quttainah et al., 2025). Cette dimension est moins visible mais fait entièrement partie de l’empreinte environnementale de l’IA, rappelant que plusieurs indicateurs sont nécessaires à son évaluation.

1.4.5. Déchets électroniques et impacts indirects

La croissance rapide de l’IA accélère le renouvellement du matériel informatique, créant un problème majeur de gestion des déchets. Comme les modèles d’IA exigent toujours plus de puissance, les remplacements de matériel sont fréquents, même avant la fin de leur vie opérationnelle réelle (Bratan et al., 2024 ; Quttainah et al., 2025). Cela engendre des déchets électroniques et seulement 20 % d’entre eux sont recyclés en sécurité. Le reste libère des substances toxiques qui polluent les sols et les habitats (Katirai, 2024 ; Kocak et al., 2025).

Enfin, plusieurs sources montrent l’existence d’impacts indirects, notamment les effets rebond. Ceux-ci apparaissent lorsque les gains d’efficacité permis par l’IA, par exemple des examens plus rapides ou des processus plus fluides, entraînent finalement une augmentation de la demande et donc une hausse de l’empreinte environnementale totale (Bieser, 2024 ; Bratan et al., 2024).

Finalement, cette multitude de facettes explique pourquoi les évaluations partielles, qui se concentrent uniquement sur l’énergie ou le carbone, semblent souvent inadéquates pour comprendre la véritable complexité de la situation (Hilty & Aebischer, 2015 ; Kocak et al., 2025). Cela aide à mettre en évidence plus généralement le problème de la durabilité dans le domaine de la santé.

1.5. La montée des préoccupations de durabilité dans le secteur de la santé

Après avoir présenté les principales dimensions de l'impact environnemental de l'IA, il est nécessaire de replacer cette question dans un contexte plus large. La question de la durabilité est de plus en plus discutée dans les réflexions sur les systèmes de santé (Ueda et al., 2024 ; Bignami et al., 2025). Dans ce contexte, la littérature rappelle que le secteur de la santé représente une partie importante des émissions mondiales de gaz à effet de serre, estimée entre 4 % et 5 % selon les sources (Champendal et al., 2025 ; Richie et al., 2025 ; Bratan et al., 2024). Une partie importante de ces émissions provient de la chaîne d'approvisionnement, tandis qu'une autre concerne le fonctionnement des hôpitaux, en particulier le chauffage ou l'électricité (Bignami et al., 2025). Cette prise de conscience a favorisé l'objectif de compatibilité entre le secteur de la santé et les objectifs de durabilité environnementale.

Au sein de ce secteur, la radiologie occupe une place importante. Selon plusieurs sources, c'est l'un des services les plus consommateurs de ressources. En effet, l'imagerie médicale utilise des équipements qui sont énergivores. Elle implique aussi le stockage de grandes quantités de données, et l'utilisation de produits de contraste et d'autres matériels à usage unique (Champendal et al., 2025 ; Afat et al., 2025 ; Doo et al., 2024 ; Woolen et al., 2025). Certaines sources indiquent même que l'imagerie médicale représenterait à elle seule jusqu'à 1 % des émissions mondiales de gaz à effet de serre, ce qui confirme l'importance de ce domaine dans les débats sur la durabilité dans le secteur de la santé (Doo et al., 2024 ; Bignami et al., 2025).

La croissance rapide de l'IA en santé présente ainsi un nouveau paradoxe. D'un côté, l'IA est perçue comme un outil qui pourrait diminuer l'impact environnemental du secteur, par exemple en améliorant les processus, en raccourcissant les temps d'examens ou en évitant des examens inutiles (Champendal et al., 2025 ; Ueda et al., 2024). De l'autre, son développement et son déploiement exigent des infrastructures énergivores et des ressources matérielles conséquentes (Kocak et al., 2025 ; Doo et al., 2024 ; Prajwal et al., 2025). Ce paradoxe justifie l'apparition de nouveaux concepts dans la littérature tels que la « Green AI ». Ce concept cherche à inclure l'efficacité énergétique et les conséquences environnementales parmi les critères d'évaluation des systèmes d'IA, en plus de la performance technique seule (Champendal et al., 2025 ; Ordoumpozanis & Papakostas, 2024 ; Ranganathan et al., 2025).

De plus, cette évolution s'accompagne de nouvelles réglementations. Par exemple, le règlement européen sur l'IA (AI Act), qui impose de la clarté sur la consommation d'énergie des systèmes d'IA à haut risque (Kocak et al., 2025 ; Ranganathan et al., 2025). Même si ces évolutions sont encore récentes, elles montrent que la durabilité devient une préoccupation importante pour le développement et l'usage de l'IA en santé.

En somme, les préoccupations croissantes liées à la durabilité dans le secteur de la santé et de l'imagerie médicale viennent d'une double réalisation. D'une part, le système de santé possède lui-même une empreinte environnementale significative. D'autre part, les technologies censées améliorer son efficacité, comme l'intelligence artificielle, produisent aussi leurs propres impacts.

Chapitre 2. Cadre méthodologique de l'évaluation environnementale

Le premier chapitre a montré que l'IA en imagerie médicale a d'importants impacts environnementaux. Cependant, exposer ces impacts ne suffit pas. Il est également nécessaire de comprendre comment ils peuvent être évalués de manière rigoureuse. En effet, l'évaluation environnementale d'une technologie s'appuie sur des choix méthodologiques importants, notamment en ce qui concerne les indicateurs retenus, le périmètre d'analyse ou encore la prise en compte des différentes étapes du cycle de vie. Ce chapitre présente donc le cadre méthodologique de l'évaluation environnementale sur lequel s'appuie ce mémoire, en commençant par les principes généraux auxquels doit répondre une évaluation rigoureuse.

2.1. Les principes d'une évaluation environnementale rigoureuse

Le cadre méthodologique de l'évaluation environnementale de l'intelligence artificielle est basé sur une approche multidimensionnelle. L'objectif est de quantifier non seulement les impacts physiques directs de cette technologie, mais aussi certains effets systémiques. En effet, selon plusieurs sources, une évaluation rigoureuse ne peut se limiter à la seule consommation électrique, mais doit aussi prendre en compte la complexité des ressources matérielles ainsi que les changements comportementaux causés par l'utilisation de l'IA (Hilty & Aebischer, 2015 ; Kocak et al., 2025 ; Pohl et al., 2019).

Une évaluation de qualité doit être à la fois holistique, transparente et multidimensionnelle (Kocak et al., 2025). La littérature insiste également sur l'importance de la transparence des

données et de la normalisation des rapports, notamment pour limiter les risques de greenwashing, c'est-à-dire le fait de présenter une technologie comme plus durable qu'elle ne l'est réellement (Bignami et al., 2025 ; Champendal et al., 2025 ; Kocak et al., 2025). Dans ce contexte, les hypothèses retenues, les choix méthodologiques et les sources de données doivent être explicités afin de permettre aux personnes concernées d'évaluer la solidité des résultats (Commission européenne, 2021 ; International Organization for Standardization, 2006).

Une évaluation rigoureuse requiert aussi l'utilisation de méthodes et de données pertinentes, l'intégration de tous les flux de matières et d'énergie importants et le respect des étapes nécessaires pour assurer la comparabilité des résultats (Commission européenne, 2021). Enfin, une telle évaluation doit être interdisciplinaire, en faisant appel à des experts en informatique, en environnement et en sciences sociales, pour mieux comprendre les interactions complexes entre technologie et comportements humains (Pohl et al., 2022).

Parmi les approches permettant de répondre à ces exigences de rigueur, l'analyse du cycle de vie est souvent présentée comme un cadre particulièrement adapté à une évaluation environnementale globale.

2.2. L'analyse du cycle de vie

L'analyse du cycle de vie (ACV) est la méthode d'évaluation environnementale complète la plus recommandée dans la littérature. Elle est considérée par de nombreux auteurs comme essentielle pour évaluer de manière rigoureuse et exhaustive l'impact environnemental de l'IA en santé (Bratan et al., 2024 ; Champendal et al., 2025 ; Hilty et al., 2009 ; Woolen et al., 2025 ; Ranganathan et al., 2025 ; Ueda et al., 2024). Cette méthode consiste à analyser les impacts d'un produit ou d'un service depuis l'extraction des matières premières jusqu'à sa fin de vie (Hilty et al., 2009 ; Hilty & Aebischer, 2015). Encadrée par les normes internationales ISO 14040 et ISO 14044, cette perspective « du berceau à la tombe » aide particulièrement à empêcher le transfert de la pollution entre les phases du cycle de vie ou entre types d'impacts (Hilty et al., 2009 ; Pohl et al., 2019 ; International Organization for Standardization, 2006).

Selon les normes ISO 14040/14044 et les recommandations de la Commission européenne, l'analyse du cycle de vie se structure en quatre phases. La phase initiale est la définition des

objectifs et du champ de l'étude. La deuxième est l'inventaire du cycle de vie (ICV), qui consiste à quantifier tous les flux de matières, d'énergie et de déchets entrant et sortant du système. Deux approches fondamentales peuvent alors être distinguées. L'approche attributionnelle utilise une représentation statique des conditions moyennes d'un modèle à un moment donné et comptabilise uniquement les flux tels qu'ils se produisent réellement. L'approche conséquentielle, quant à elle, cherche à identifier les conséquences environnementales d'une décision ou d'un changement de système (International Organization for Standardization, 2006).

La troisième phase est l'évaluation des impacts du cycle de vie, au cours de laquelle les données de l'inventaire sont associées à des catégories d'impact environnemental et converties en unités communes. Enfin, la quatrième phase clé est l'interprétation des résultats, permettant de tirer des conclusions et de formuler des recommandations afin d'améliorer la performance environnementale du système étudié (Commission européenne, 2021 ; International Organization for Standardization, 2006).

Pour assurer la rigueur de l'analyse, des concepts clés doivent être précisés. L'unité fonctionnelle (UF) est la performance quantifiée du système et sert d'unité de référence. Elle répond aux questions : quoi, combien, comment et pendant combien de temps ? Ensuite, le flux de référence est la quantité de produit ou de service nécessaire pour assurer la fonction définie par l'unité fonctionnelle. Enfin, les frontières du système déterminent quelles étapes sont incluses ou exclues de l'analyse. Une approche rigoureuse doit, dans la mesure du possible, comptabiliser l'ensemble de la chaîne d'approvisionnement et des étapes pertinentes du système étudié (Commission européenne, 2021). L'application concrète de l'analyse du cycle de vie nécessite également des indicateurs pertinents, permettant de mesurer les différentes dimensions de l'impact environnemental.

2.3. Les principaux indicateurs mobilisables

L'analyse de l'impact environnemental de l'intelligence artificielle est basée sur un nombre important d'indicateurs quantitatifs. Ceux-ci permettent de transformer des flux physiques complexes en données comparables. Selon le modèle de Graedel et al., cité dans Champendal et al. (2025), trois catégories d'indicateurs se distinguent.

La première catégorie se compose des indicateurs d'entrée, qui mesurent les ressources naturelles et l'énergie prélevées dans l'environnement. Ils rassemblent notamment la consommation d'énergie, exprimée en kWh ou en joules, qui concerne l'entraînement des modèles, l'inférence clinique et le stockage des données (Champendal et al., 2025 ; Bieser, 2024 ; Prajwal et al., 2025). Ils incluent aussi l'empreinte hydrique, souvent exprimée en litres ou en gallons, liée soit directement au refroidissement des centres de données, soit indirectement à la production de l'électricité utilisée (Champendal et al., 2025 ; Commission européenne, 2021). Enfin, la catégorie inclut aussi l'épuisement des ressources abiotiques, c'est-à-dire la mesure des minéraux et métaux rares nécessaires à la fabrication du matériel informatique (Bieser, 2024 ; Commission européenne, 2021 ; Quttainah et al., 2025).

La deuxième catégorie comprend les indicateurs de processus, qui servent à mesurer l'efficacité technique et la charge de calcul des systèmes. Parmi eux, le PUE (*power usage effectiveness*) mesure l'efficacité énergétique des centres de données en comparant l'énergie totale consommée à l'énergie réellement utilisée par l'équipement informatique (Champendal et al., 2025). Le temps d'entraînement et de calcul, exprimé en heures ou en secondes, est la durée nécessaire pour optimiser un modèle ou exécuter une tâche d'inférence (Champendal et al., 2025 ; Bieser, 2024). Les FLOPs, c'est-à-dire le nombre d'opérations de calcul nécessaire au fonctionnement d'un modèle, mesurent quant à eux la charge de calcul utilisée par un algorithme. Le nombre de paramètres d'un modèle constitue également un indicateur de sa complexité et de sa taille, influençant directement ses besoins en ressources (Vafaei Sadr et al., 2024 ; Champendal et al., 2025). Enfin, le nombre d'époques peut aussi être utilisé. Il correspond au nombre de fois qu'un modèle parcourt l'ensemble des données d'entraînement. Le taux d'utilisation du matériel, notamment du GPU, permet lui aussi de mesurer l'intensité et l'efficacité d'utilisation des ressources de calcul (Laçi & Sevrani, 2025 ; Ranganathan et al., 2025).

La troisième catégorie correspond aux indicateurs de sortie, soit les conséquences environnementales générées par l'activité numérique. L'indicateur principal est celui des émissions de gaz à effet de serre, mesurées en équivalents CO₂ (CO₂eq ou CO₂e) (Prajwal et al., 2025 ; Champendal et al., 2025). Cet indicateur traduit la consommation électrique en potentiel de réchauffement global en fonction de l'intensité carbone du mix énergétique local (Doo et al., 2024 ; Lan et al., 2024). D'autres indicateurs peuvent également être utilisés pour

une contextualisation, comme l'équivalence en kilomètres parcourus en voiture ou le temps de séquestration carbone nécessaire à un arbre pour absorber le CO₂ émis (Champendal et al., 2025). Enfin, les déchets électroniques constituent un indicateur de sortie important. En effet, ce dernier mesure la quantité de matériel informatique jetée suite à de l'obsolescence rapide, causée par les besoins croissants en performance (Quttainah et al., 2025).

Enfin, certaines études proposent des indicateurs intégrés et multidimensionnels. Le score ESPer (*Environmentally Sustainable Performance*) combine la précision du modèle sur la tâche diagnostique étudiée et son coût en CO₂eq afin d'identifier les systèmes les plus durables à niveau de précision égal (Lan et al., 2024). Le WUE (*Water Usage Effectiveness*) est, quant à lui, utilisé pour mesurer plus spécifiquement l'efficacité de l'utilisation de l'eau dans les centres de données (Champendal et al., 2025). À cela s'ajoutent les indicateurs proposés dans les cadres européens, tels que l'acidification, la toxicité humaine, l'occupation des sols ou encore l'eutrophisation, soit l'enrichissement excessif des milieux aquatiques en nutriments. Ces indicateurs permettent une évaluation multicritère plus complète (Commission européenne, 2021).

Toutefois, les indicateurs quantitatifs ne suffisent pas à comprendre l'ensemble des effets environnementaux associés à l'IA. Plusieurs auteurs montrent en effet que ces technologies modifient aussi les usages, les pratiques et les organisations, ce qui mène à prendre en compte des effets d'usage plus indirects. C'est dans ce contexte que le cadre proposé par Hilty est particulièrement utile.

2.4. Le cadre des effets d'usage selon Hilty

Le cadre théorique développé par Lorenz Hilty, souvent en collaboration avec Aebischer, est une référence importante pour structurer l'évaluation environnementale du numérique et de l'intelligence artificielle (Pohl et al., 2019 ; Bieser, 2024). Ce modèle, souvent appelé modèle LES (*Life-cycle, Enabling, Structural*), distingue trois niveaux d'impacts. Il permet d'analyser à la fois les impacts directs liés au cycle de vie de la technologie, les effets d'usage qu'elle provoque et les transformations plus structurelles qu'elle peut causer à plus long terme (Hilty & Aebischer, 2015 ; Hilty et al., 2009).

2.4.1. Niveau 1 : les impacts de cycle de vie

Le niveau 1, ou les impacts du cycle de vie, désigne les conséquences environnementales directes liées à l'existence matérielle des technologies, de leur fabrication à leur fin de vie. Il est évalué par l'analyse du cycle de vie et comporte l'extraction des matières premières, la production, la consommation d'énergie pour l'utilisation et l'élimination des déchets (Hilty & Aebischer, 2015).

2.4.2. Niveau 2 : les impacts indirects ou effets d'usage

Les effets d'usage montrent comment l'application de l'IA transforme des processus de production ou de consommation dans le secteur où elle est utilisée, et parfois, plus largement dans d'autres secteurs liés (Bieser, 2024 ; Hilty & Aebischer, 2015). Hilty les divise en quatre catégories principales. Les deux premières sont généralement des effets favorables sur le plan environnemental, tandis que les deux dernières sont plutôt des effets susceptibles d'augmenter l'impact.

La première catégorie est l'optimisation, qui désigne l'usage de l'IA pour améliorer l'efficacité d'un processus existant et réduire la consommation d'une ressource. La deuxième est la substitution, où le service numérique remplace partiellement ou totalement un service physique ou conventionnel. Par exemple en santé, la télémédecine est souvent citée comme un substitut à certains déplacements physiques des patients. La troisième est l'induction, qui intervient lorsque l'usage de l'IA augmente la consommation d'une autre ressource ou crée un nouveau besoin. Enfin, la quatrième catégorie d'effets est l'obsolescence induite, notamment lorsque l'introduction de nouveaux logiciels ou modèles d'IA rend le matériel existant obsolète avant sa fin de vie technique. Ce phénomène est parfois appelé l'effet SIHO (*Software-Induced Hardware Obsolescence*) (Hilty & Aebischer, 2015 ; Quttainah et al., 2025 ; Hilty et al., 2009).

2.4.3. Niveau 3 : Les impacts structurels

Le troisième niveau concerne les changements à plus long terme des structures économiques et des modes de vie. À ce niveau, l'effet le plus souvent cité est l'effet rebond, parfois appelé le paradoxe de Jevons (Bieser, 2024 ; Hilty & Aebischer, 2015). Il représente le fait que les gains d'efficacité obtenus grâce à l'optimisation peuvent conduire à une augmentation globale de la demande, annulant ainsi les bénéfices environnementaux initiaux (Hilty et al., 2009 ;

Hilty & Aebischer, 2015). Par exemple en santé, si l'IA permet de faire passer davantage de patients dans un scanner sur une même période, la baisse des coûts ou des délais peut inciter les médecins à prescrire plus d'exams, ce qui risque d'augmenter l'empreinte totale du service au lieu de la réduire (Bratan et al., 2024 ; Pohl et al., 2019 ; Hilty & Aebischer, 2015).

En conclusion, ces repères forment le cadre qui permet d'examiner les études existantes de manière critique. Le chapitre suivant présente donc la méthodologie utilisée pour créer le corpus de ce mémoire et étudier la littérature sélectionnée.

Chapitre 3. Méthodologie de la revue de littérature

Après avoir présenté, dans le chapitre précédent, les principales références méthodologiques de l'évaluation environnementale, il est maintenant temps de présenter la démarche suivie pour analyser et construire le corpus de sources de ce mémoire. Ce mémoire est une revue de littérature critique et méthodologique. Il ne cherche pas à obtenir une mesure empirique de l'impact environnemental de l'IA en imagerie médicale, mais à analyser la manière dont les études existantes évaluent cet impact, ainsi que les principales limites de leurs approches.

3.1. La recherche documentaire

La recherche documentaire a été menée à partir de plusieurs bases de données et de moteurs de recherche académiques, notamment Google Scholar, PubMed, IEEE Xplore et Scopus. Ces derniers ont permis de trouver à la fois des articles généraux sur l'IA et la durabilité en santé, des publications empiriques appliquées à l'imagerie médicale, et des revues de synthèse sur les méthodes d'évaluation environnementale de l'IA.

Plusieurs mots-clés ont aussi été utilisés, la plupart du temps en anglais car la majorité de la littérature pertinente est publiée dans cette langue. Certains exemples de mots-clés utilisés sont « artificial intelligence », « medical imaging », « radiology », « environmental impact », « sustainability », « carbon footprint », « energy consumption », « life cycle assessment » et « green AI ». Ces mots-clés ont été combinés avec des opérateurs booléens afin d'obtenir les travaux les plus pertinents.

Les articles qui ont été retenus en priorité respectent plusieurs critères. Ce sont des publications académiques portant sur l'IA en santé, l'imagerie médicale ou la radiologie. Un autre critère était que les publications parlent explicitement de la question de l'impact

environnemental, de la durabilité, de la consommation énergétique, des émissions de carbone ou des méthodes d'évaluation associées. Les articles sans lien avec les coûts écologiques de l'IA, ou les textes trop éloignés de la santé ou de l'imagerie médicale, n'ont pas été retenus.

La construction du corpus des sources s'est réalisée de manière progressive. Tout d'abord, une première large sélection a été faite, avec toutes les publications potentiellement pertinentes. Une seconde phase a été d'examiner les titres, résumés et mots-clés afin de retenir les sources les plus pertinentes et liées à la question de recherche. Enfin, certains articles ont été ajoutés à partir des références citées dans d'autres publications déjà retenues.

3.2. La construction de la grille d'analyse comparative

La grille d'analyse comparative a été construite sous la forme d'un tableau comparatif, inspiré de certaines revues existantes, mais adapté au corpus de sources de ce mémoire (Thomson et al., 2025 ; Champendal et al., 2025). Les éléments analysés pour chaque étude sont : le type de publication, les dimensions environnementales évaluées, les étapes du cycle de vie intégrées, les outils de mesure et les méthodes utilisées, les effets d'usage et les impacts structurels considérés, les principaux résultats rapportés par les travaux ainsi que les limites méthodologiques récurrentes. Ce tableau permet de structurer l'analyse et de rendre possible une comparaison transversale des études.

3.3. Limites de la démarche méthodologique

Cette analyse a cependant certaines limites. La littérature sur l'impact environnemental de l'IA en imagerie médicale reste encore émergente, hétérogène et dispersée. Les publications rassemblées portent sur des objets, des métriques et des périmètres d'analyse très variés, ce qui rend les comparaisons parfois compliquées. Enfin, ce mémoire n'a pas pour objectif de réaliser une revue systématique à grande échelle, mais bien d'utiliser un corpus suffisamment pertinent pour faire une analyse méthodologique et critique.

La méthodologie décrite dans ce chapitre a aidé à rassembler un ensemble de sources et à définir les critères d'analyse retenus. En se basant sur ces éléments, il devient maintenant possible de mener une comparaison des études sélectionnées, pour mieux comprendre comment elles évaluent l'impact environnemental de l'IA en imagerie médicale et quelles tendances se dégagent des publications.

Chapitre 4. Analyse comparative des études existantes

4.1. Présentation et synthèse du corpus

Afin de construire le tableau comparatif des études existantes, dix-sept articles ont été sélectionnés. La majorité se compose d'articles de recherche scientifique, en plus de revues de portée, de revues systématiques, de revues pédagogiques et d'éditoriaux. Cette variété d'articles trouve son explication dans la nature nouvelle et disparate de la documentation existante sur ce sujet.

Les études sélectionnées peuvent être regroupées en deux grandes catégories. Une première catégorie comprend des travaux empiriques ciblés, qui mesurent certains impacts environnementaux dans des cas d'usage précis. Une deuxième catégorie regroupe des publications plus générales, qui ont une approche de synthèse ou de réflexion.

Pour analyser ces articles, une lecture croisée est requise, compte tenu de leur nature diverse. Pour cela, cette lecture s'appuie sur plusieurs points clés comme les types d'études, les dimensions environnementales évaluées, les étapes du cycle de vie prises en compte, les méthodes et outils mobilisés, les effets d'usage et impacts structurels considérés. Ces critères permettent de dépasser une simple présentation article par article et de faire ressortir les tendances communes, les différences et les angles morts de la littérature.

Plusieurs constats transversaux ont été faits. Premièrement, la littérature se concentre surtout sur la consommation d'énergie, les émissions de CO₂ et, dans certains cas, les ressources de calcul. D'autres dimensions environnementales, comme la consommation d'eau, les déchets électroniques ou l'épuisement des ressources matérielles, restent beaucoup moins étudiées. Deuxièmement, les phases du cycle de vie les plus souvent analysées sont l'entraînement, l'inférence et parfois la gestion des données, tandis que la fabrication du matériel, la maintenance et la fin de vie sont rarement intégrées de manière détaillée. Troisièmement, les outils les plus utilisés sont des logiciels d'estimation et de suivi de la consommation énergétique ou des émissions, alors que les mesures physiques directes sont plus rares. Enfin, le corpus met surtout en avant des effets d'optimisation, comme la réduction du temps d'examen ou de certains coûts de calcul, tandis que les effets d'induction, de rebond, d'obsolescence ou les transformations structurelles sont beaucoup moins documentés.

Dans l'ensemble, cette synthèse montre donc une littérature encore fragmentée et peu normalisée, mais qui permet déjà d'identifier les principales orientations et limites de l'évaluation environnementale de l'IA en imagerie médicale. Il est maintenant temps d'entrer plus en détail dans les différents critères d'analyse, en commençant par les types d'études sélectionnées.

4.2. Types d'études

L'analyse du corpus des sources a révélé une forte différence entre les types d'articles. En effet, il y a des articles de recherche empirique, des revues de portée, une revue systématique, une revue pédagogique ainsi qu'un éditorial.

Les articles de recherche empirique sont la majorité du corpus. Ces études portent généralement sur des cas d'usage très précis. Par exemple, il y a une étude sur l'empreinte carbone de l'affinage de modèles pré-entraînés pour l'analyse d'échographies mammaires, ou encore une étude sur une approche durable et décentralisée pour le triage des radiographies pulmonaires (Ordoumpozanis & Papakostas, 2024 ; Ranganathan et al., 2025). Elles cherchent souvent à mesurer la consommation énergétique ou l'efficacité de calcul de solutions techniques particulières. Ce type d'étude permet d'obtenir des résultats quantifiés dans des contextes précis.

Une autre catégorie d'articles est celle des articles de synthèse, comme les revues de portée et les revues systématiques. Elles permettent d'identifier les grandes tendances de la littérature, les dimensions environnementales les plus souvent étudiées, ainsi que les limites méthodologiques qui reviennent régulièrement (Doo et al., 2024 ; Champendal et al., 2025 ; Thomson et al., 2025).

Dans l'ensemble, le corpus est donc composé d'une diversité de travaux empiriques et d'articles de synthèse ou de réflexion. Cette diversité permet d'obtenir une richesse de sources avec plusieurs niveaux d'analyse.

4.3. Dimensions environnementales évaluées

L'analyse comparative du recueil de documents montre que les dimensions environnementales évaluées dans la littérature ne sont pas toutes analysées de la même

façon. La consommation d'énergie et les émissions de gaz à effet de serre sont les deux dimensions les plus fréquemment étudiées.

La consommation d'énergie est la dimension la plus souvent prise en compte. Elle est généralement mesurée en kilowattheures, wattheures ou joules, selon le type de système observé. Dans les études empiriques, cette mesure concerne l'entraînement des modèles mais aussi leur inférence, ainsi que l'utilisation de certains appareils d'imagerie, comme l'IRM (Lan et al., 2024 ; Prajwal et al., 2025 ; Afat et al., 2025 ; Selvan et al., 2022). Certains travaux étudient aussi la répartition de la consommation entre différents composants tels que le CPU, le GPU ou encore les systèmes de refroidissement (Prajwal et al., 2025 ; Afat et al., 2025).

La deuxième dimension la plus fréquente est celle de l'empreinte carbone, qui traduit l'énergie consommée en émissions de gaz à effet de serre. Pour rendre ce chiffre plus concret, certaines sources utilisent des équivalences comme la distance parcourue en voiture ou le potentiel de séquestration carbone, exprimé en nombre d'arbres ou de surface de forêt nécessaire (Champendal et al., 2025 ; Afat et al., 2025 ; Vafaei Sadr et al., 2024 ; Selvan et al., 2022).

Une troisième dimension régulièrement utilisée est celle des ressources de calcul. Plusieurs études cherchent à caractériser la charge de calcul des systèmes étudiés. Cette charge inclut le nombre de paramètres du modèle, les FLOPs, l'utilisation GPU, le nombre d'échanges entre les centres dans les systèmes d'apprentissage décentralisé ou encore l'utilisation de la mémoire (VRAM/RAM) (Jallais et al., 2026 ; Champendal et al., 2025 ; Prajwal et al., 2025 ; Ordoumpozanis & Papakostas, 2024 ; Nanekaran & Ukwatta, 2025).

Cependant, d'autres dimensions sont, quant à elles, plus rarement quantifiées. La consommation d'eau est très peu étudiée et concerne principalement le refroidissement des centres de données. Même situation pour les déchets électroniques et l'épuisement des ressources naturelles, cités dans certaines publications mais rarement quantifiés.

Dans l'ensemble, les articles mettent donc en évidence une forte concentration de la littérature sur l'énergie consommée et le carbone.

4.4. Étapes du cycle de vie couvertes

L'analyse des articles montre que les études couvrent des étapes variées du cycle de vie des systèmes d'IA en imagerie médicale. Les étapes les plus fréquemment couvertes sont l'entraînement et l'inférence, tandis que d'autres étapes comme la fabrication du matériel, la maintenance ou la fin de vie apparaissent beaucoup moins souvent dans les publications.

Les publications analysées s'intéressent surtout aux phases de développement et d'entraînement, qui sont les plus directement associées à la consommation d'énergie (Doo et al., 2024 ; Jallais et al., 2026). L'analyse est réalisée notamment dans des tâches de segmentation, de classification ou d'apprentissage décentralisé. D'autres articles portent également sur la phase d'utilisation. Elle est principalement analysée dans les articles cliniques qui mesurent l'impact de l'IA sur la routine radiologique, par exemple la réduction du temps de scan en IRM (Afat et al., 2025 ; Gotta et al., 2026).

Quelques étapes situées avant l'entraînement commencent néanmoins à être intégrées dans certaines publications, comme la préparation et la gestion des données (Dietrich & Hanneman, 2025 ; Vafaei Sadr et al., 2024). Ces étapes incluent entre autres le prétraitement et l'annotation (Dietrich & Hanneman, 2025 ; Laçi & Sevrani, 2025), la réduction de dimensionnalité (Nanekaran & Ukwatta, 2025) ou encore le stockage des données, via le choix entre stockage sur site ou dans le cloud (Jallais et al., 2026). Dans le cas de l'apprentissage décentralisé, certaines études prennent aussi en compte les échanges entre les centres, ce qui élargit partiellement la phase de développement au-delà du seul entraînement du modèle (Nanekaran & Ukwatta, 2025). D'autres travaux rappellent également que cette phase de développement comprend souvent la sélection des modèles et des hyperparamètres, qui implique de nombreux essais successifs et peut représenter un coût de calcul important (Selvan et al., 2022).

Cependant, les phases du cycle de vie liées au matériel apparaissent beaucoup moins souvent dans les publications du corpus. Les processus de fabrication du matériel, d'extraction des métaux rares, d'acheminement et d'élimination des équipements à la fin de vie sont parfois mentionnés dans les revues et dans les articles de prospective, mais rarement de manière détaillée dans une approche quantitative (Doo et al., 2024 ; Kocak et al., 2025 ; Quttainah et al., 2025). La fin de vie est une étape très peu abordée, plusieurs auteurs notant que le

recyclage, le déclassement ou la question des déchets électroniques sont encore rarement pris en compte dans la littérature existante (Champendal et al., 2025 ; Kocak et al., 2025).

En outre, certains travaux portant sur l'imagerie médicale prennent en compte le cycle de vie de l'IA seule, mais aussi celui de la machine médicale elle-même. Ainsi, des recherches sur l'IRM montrent qu'en plus de l'impact environnemental de l'IA, celui-ci provient également de la machine elle-même, de ses périodes d'inactivité et des systèmes de refroidissement (Afat et al., 2025 ; Doo et al., 2024).

Dans l'ensemble, la couverture des étapes du cycle de vie est partielle et variée. Ainsi, les phases liées au processus d'entraînement, d'inférence et à la gestion des données sont bien prises en compte, tandis que les phases de fabrication du matériel, de maintenance et de fin de vie des équipements sont moins souvent intégrées.

4.5. Méthodes/outils

L'évaluation des effets environnementaux de l'IA en imagerie médicale utilise une grande variété de méthodes et d'outils, allant de calculateurs logiciels automatisés à des mesures physiques directes sur le matériel.

Une première catégorie regroupe les études avec des mesures directes. Certaines évaluations utilisent des analyseurs de puissance ou des systèmes de monitoring pour quantifier la consommation d'énergie dans des conditions réelles d'usage. C'est notamment le cas d'Afat et al. (2025), qui associent un analyseur physique externe avec Siemens Fleet Cockpit, utilisé pour enregistrer l'activité des scanners IRM. Gotta et al. (2026) adoptent quant à eux une approche indirecte, en estimant la consommation d'énergie en multipliant le temps de scan par la puissance théorique indiquée par le fabricant.

Une deuxième catégorie concerne les solutions logicielles d'estimation et de suivi. Ce sont les plus répandues parce qu'elles permettent aux chercheurs de suivre l'empreinte carbone et énergétique directement pendant le développement des modèles. En effet, plusieurs articles utilisent ces logiciels car ils permettent d'estimer la consommation d'énergie et les émissions de CO₂ à partir des processeurs (CPU/GPU) et de la mémoire pendant l'entraînement et l'inférence des modèles. L'outil CodeCarbon est le plus utilisé (Prajwal et al., 2025 ; Laçi & Sevrani, 2025 ; Ordoumpozanis & Papakostas, 2024 ; Ranganathan et al., 2025). D'autres

travaux utilisent `experiment-impact-tracker`, qui a le même fonctionnement que `CodeCarbon` mais qui permet de mesurer l'énergie consommée également par le système de refroidissement interne de l'ordinateur (Lan et al., 2024 ; Vafaei Sadr et al., 2024). Selvan et al. (2022) comparent également plusieurs outils de suivi du carbone, notamment `Machine Learning Emissions Calculator`, `Experiment-Impact-Tracker`, `CarbonTracker` et `CodeCarbon`, en montrant qu'ils n'offrent pas tous les mêmes possibilités de suivi, de prédiction ou de visualisation. Des outils plus ciblés sont parfois utilisés en complément, comme `nvidia-smi` pour suivre la puissance du GPU en temps réel (Ranganathan et al., 2025), ou `GPUMonitorCallback` pour observer l'utilisation du GPU et de la mémoire vidéo pendant l'entraînement (Laçi & Sevrani, 2025).

Un troisième type de méthodes est basé sur des comparaisons expérimentales entre différents types d'architectures, de protocoles et même de configurations techniques. En effet, plusieurs articles comparent différentes architectures de modèles, différents formats de modèles, différentes stratégies de compression, et même des solutions avec traitement sur le cloud versus un traitement local (Prajwal et al., 2025 ; Ordoumpozanis & Papakostas, 2024 ; Jallais et al., 2026 ; Ranganathan et al., 2025). Dans de tels cas, l'analyse environnementale est incluse dans une évaluation comparative plus large de la performance, qui s'efforce d'aboutir à des solutions performantes et moins consommatrices de ressources. L'impact environnemental est quantifié à l'aide de différents indicateurs comme le temps d'entraînement, le nombre de paramètres, les FLOPs ou l'énergie consommée par composant matériel.

Les trois familles précédentes sont des approches quantitatives, mais il y a aussi des approches plus théoriques. En effet, plusieurs publications utilisent des méthodes de synthèse de la littérature, comme les revues de portée ou les revues systématiques (Champendal et al., 2025 ; Thomson et al., 2025 ; Doo et al., 2024 ; Kocak et al., 2025). Ces travaux ne donnent pas de mesures environnementales mais ils permettent d'identifier les métriques les plus utilisées, les outils les plus fréquents et les principales limites méthodologiques. Ils permettent une structuration dans le domaine, encore très récent.

Enfin, quelques recherches proposent des cadres ou des outils plus novateurs. C'est par exemple le cas de l'ESPer, un score qui combine mathématiquement la capacité du modèle à

réaliser correctement une tâche diagnostique et le coût carbone opérationnel. Cela reste une proposition de recherche à ce stade (Lan et al., 2024). Il peut également être question de méthodes multicritères ou de méthodologies de décision qui servent à prioriser les différents facteurs de l'impact environnemental (Qutainah et al., 2025). Ces initiatives restent encore relativement rares, mais il y a une certaine volonté d'aller plus loin que les simples indicateurs.

4.6. Effets d'usage et impacts structurels

L'étude du corpus indique que les effets d'usage et les impacts structurels de l'IA en imagerie médicale sont présents dans la littérature, mais de façon inégale. Bien sûr, tous les articles ne font pas toujours explicitement mention du modèle de Hilty, néanmoins, l'analyse permet d'identifier des effets d'optimisation, de substitution, d'induction et d'obsolescence, et plus rarement, des impacts structurels.

L'effet d'usage le plus documenté est celui de l'optimisation. De nombreuses études montrent que l'IA peut réduire le temps d'examen, diminuer la consommation d'énergie par tâche ou améliorer l'efficacité des infrastructures existantes. Dans les travaux portant sur l'IRM, par exemple, les séquences accélérées par apprentissage profond permettent de raccourcir les temps de scan et de réduire la consommation énergétique associée (Afat et al., 2025 ; Gotta et al., 2026). D'autres articles montrent que des modèles plus compacts, des stratégies de compression ou des approches de réduction des données permettent également de limiter la consommation de ressources pour des performances similaires (Vafaei Sadr et al., 2024 ; Lan et al., 2024 ; Jallais et al., 2026 ; Laçi & Sevrani, 2025 ; Ranganathan et al., 2025 ; Nanekaran & Ukwatta, 2025). L'IA permet également de réduire les doses de produit de contraste nécessaires en restaurant la qualité d'image, ce qui limite leur rejet dans les eaux usées (Thomson et al., 2025 ; Doo et al., 2024). Les travaux analysés présentent donc fréquemment l'IA comme un outil d'optimisation technique et organisationnelle.

La substitution est un deuxième effet d'usage relativement présent dans la littérature analysée. Cet effet s'observe quand l'IA remplace partiellement une procédure, un traitement de données ou une infrastructure plus lourde. Certaines publications évoquent par exemple la possibilité de générer certaines informations de manière logicielle plutôt que par un examen médical supplémentaire (Doo et al., 2024 ; Dietrich & Hanneman, 2025). D'autres travaux montrent que le passage d'une inférence centralisée sur le Cloud à un traitement local

sur des appareils de périphérie réduit la dépendance au réseau et la consommation énergétique liée au transfert de données (Ranganathan et al., 2025).

L'induction est également citée dans plusieurs publications, bien qu'elle soit moins souvent mise en avant. Certains travaux suggèrent ainsi que l'IA peut augmenter les besoins computationnels, élargir le champ des tâches automatisées ou encore générer des flux de données plus importants à traiter et à conserver (Quttainah et al., 2025 ; Kocak et al., 2025). Les effets liés à l'obsolescence apparaissent aussi moins souvent et sont surtout discutés dans les revues ou les articles de cadrage. Plusieurs auteurs expliquent que la course à la performance de l'IA renforce la dépendance à des matériels spécialisés, peut accélérer le renouvellement des équipements et contribuer à la production de déchets électroniques (Kocak et al., 2025 ; Quttainah et al., 2025).

La littérature ne s'arrête cependant pas aux seuls effets d'usage. Certains travaux identifient également des impacts plus larges, correspondant au niveau structurel du modèle de Hilty. L'effet le plus souvent cité est l'effet rebond. Plusieurs auteurs alertent sur le fait que les gains d'efficacité pourraient paradoxalement aggraver l'empreinte environnementale totale. Par exemple, l'accélération des examens et la baisse des coûts pourraient causer une hausse continue du nombre d'études d'imagerie par patient, annulant les économies d'énergie réalisées par l'efficacité améliorée d'un scan individuel (Afat et al., 2025 ; Doo et al., 2024 ; Kocak et al., 2025 ; Selvan et al., 2022). Dans le même sens, les besoins de calcul pour l'IA doublent à peu près tous les 3 mois depuis 2012, augmentant ainsi la pression sur les infrastructures énergétiques mondiales (Prajwal et al., 2025). D'autres travaux mentionnent plus largement des effets structurels, comme la dépendance au cloud ou aux infrastructures de réseau (Doo et al., 2024 ; Ranganathan et al., 2025), ainsi que des effets sur les inégalités d'accès aux soins. L'IA peut les réduire grâce à des modèles légers adaptés aux zones à faibles ressources, mais elle peut aussi les renforcer si les outils ne correspondent pas aux contextes locaux, avec un risque de « néocolonialisme » technologique (Jallais et al., 2026 ; Ranganathan et al., 2025 ; Kocak et al., 2025).

Globalement, le corpus montre que les effets d'usage sont bel et bien analysés dans la littérature, mais qu'ils sont pris en compte de façon déséquilibrée. Les effets d'optimisation sont les plus fréquemment documentés, suivis des effets de substitution et de rebond, qui

apparaissent dans un nombre limité de travaux. Les effets d'induction, d'obsolescence et les transformations structurelles restent quant à eux les moins représentés. La grande majorité de ces effets sont abordés de façon qualitative plutôt que mesurés quantitativement.

En conclusion, le chapitre montre que la littérature analysée s'intéresse principalement à l'énergie et au CO₂, que l'estimation par logiciel est la méthode la plus répandue, et que les effets d'optimisation sont les mieux documentés. Le chapitre suivant examine les principales limites méthodologiques de ces approches.

Chapitre 5. Les principales limites des études existantes

L'analyse du corpus actuel sur l'impact environnemental de l'IA en imagerie médicale permet d'identifier plusieurs limites méthodologiques importantes et récurrentes.

5.1. Le manque de normalisation et de comparabilité

L'une des principales limites dans la littérature est le manque de normalisation des mesures. Les études n'utilisent pas les mêmes outils, ni les mêmes indicateurs, ni les mêmes hypothèses de calcul, ce qui complique les comparaisons et réduit la solidité des conclusions.

Cette difficulté est d'abord présente dans la diversité des métriques utilisées. La consommation d'énergie est exprimée dans différentes unités : en joules, en watts ou en kilowattheures. Concernant les émissions, elles sont exprimées en CO₂eq, mais parfois aussi sous forme d'équivalences en kilomètres parcourus, en nombre d'arbres ou en surface forestière nécessaire à la compensation. En plus de cela, les calculs n'ont pas tous les mêmes hypothèses. Certains se basent sur le mix énergétique local, d'autres sur des données historiques ou sur des moyennes. Les résultats obtenus sont donc difficiles à mettre en parallèle.

La même hétérogénéité concerne les outils de mesure et d'estimation. Certaines recherches reposent sur des mesures physiques directes, alors que d'autres utilisent des estimateurs logiciels comme CodeCarbon ou experiment-impact-tracker. Tous ces outils n'apportent cependant pas exactement les mêmes fonctions. Certains servent surtout à suivre les émissions pendant l'entraînement, tandis que d'autres permettent aussi de prédire la consommation future ou de visualiser les résultats. Ils ne couvrent pas non plus toujours les mêmes composants matériels. De plus, certaines contraintes techniques empêchent parfois

de mesurer correctement certains éléments. Par exemple, l'utilisation de serveurs en conteneurs peut rendre difficile l'estimation de la consommation de la RAM avec CodeCarbon, obligeant les auteurs à l'exclure du calcul final (Ordoumpozanis & Papakostas, 2024).

Le manque de transparence de certaines données aggrave le problème, particulièrement dans le cas des infrastructures cloud. Les fournisseurs communiquent rarement sur le mix énergétique réel, la consommation d'eau pour le refroidissement ou les conditions exactes du fonctionnement des centres de données. Les chercheurs doivent alors travailler à partir d'approximations ou de données moyennes. Ce fait engendre une diminution de la précision des estimations.

Enfin, cette absence de normalisation touche aussi les objets étudiés. Les études portent sur des tâches, des architectures et des contextes techniques très différents, ce qui empêche toute comparaison générale. Sans méthodes communes pour mesurer et présenter les résultats, il reste difficile de tirer des conclusions solides sur l'impact environnemental de l'IA en imagerie médicale.

5.2. Des périmètres d'analyse souvent trop restreints

Un autre manquement important est le fait que les périmètres d'analyse sont souvent trop restreints. Beaucoup de recherches étudient uniquement des situations très spécifiques : une seule tâche, un seul type d'imagerie, un seul modèle ou un seul environnement technique. Cette précision peut être utile, mais elle réduit fortement la portée des résultats.

Cette caractéristique s'observe d'abord dans les objets étudiés. Certains travaux étudient une séquence IRM précise, une tâche précise de segmentation ou de classification, ou encore un cadre d'apprentissage décentralisé bien spécifique (Afat et al., 2025 ; Gotta et al., 2026 ; Prajwal et al., 2025). Les conclusions concernent donc un usage précis et ne peuvent pas être facilement généralisées à l'ensemble du domaine.

Le problème concerne aussi les contextes d'évaluation. Plusieurs études sont réalisées dans un seul centre, sur un ensemble matériel particulier ou dans un environnement expérimental très contrôlé (Nanekaran & Ukwatta, 2025 ; Laçi & Sevrani, 2025 ; Ordoumpozanis & Papakostas, 2024). Certaines utilisent des simulations ou des équipements locaux qui ne représentent pas totalement la réalité de l'usage clinique. Pourtant, les performances

environnementales d'un système peuvent beaucoup varier selon le matériel, le stockage ou le réseau. Un même entraînement ou un même déploiement peut donc avoir un impact carbone différent selon la région où il est réalisé, en fonction du mix énergétique utilisé (Selvan et al., 2022 ; Ordoumpozanis & Papakostas, 2024).

Un autre point important est l'absence fréquente de comparaison avec un scénario de référence plus large. Beaucoup de publications comparent des modèles d'IA entre eux, mais beaucoup plus rarement un système avec IA à une situation sans IA ou à un diagnostic humain (Thomson et al., 2025 ; Ranganathan et al., 2025). Sans cela, il est difficile de savoir si les gains observés correspondent à une amélioration environnementale réelle et globale, ou seulement à une optimisation entre plusieurs solutions numériques.

Enfin, ces périmètres limités ont tendance à isoler l'IA de son environnement réel. Pourtant, en imagerie médicale, son impact dépend aussi du scanner, du stockage des données, des flux de travail, du réseau et de l'organisation des soins. Afat et al. (2025) montrent par exemple que le refroidissement de l'aimant représente à lui seul 42 % de la consommation totale d'un scanner IRM, qui est un élément rarement intégré dans les études portant uniquement sur l'algorithme d'IA. Lorsqu'une étude ne prend en compte qu'une petite partie de cet ensemble, elle risque de sous-estimer la complexité du problème et de donner une vision partielle de l'impact réel.

5.3. Une focalisation sur l'énergie et le CO₂

Une autre limite importante de la littérature existante est sa forte focalisation sur la consommation d'énergie et les émissions de CO₂. Ces dimensions sont les plus étudiées car elles sont les plus facilement quantifiables et les plus directement liées au fonctionnement technique de l'IA (Vafaei Sadr et al., 2024 ; Afat et al., 2025 ; Champendal et al., 2025). Toutefois, cette concentration réduit souvent l'évaluation environnementale à une partie seulement du problème.

D'autres dimensions, comme la consommation d'eau, l'extraction de ressources naturelles, les terres rares ou les déchets électroniques, restent beaucoup moins étudiées et sont souvent mentionnées de manière qualitative (Kocak et al., 2025 ; Champendal et al., 2025 ; Quttainah

et al., 2025). Cette situation mène à une vision partielle de l'impact environnemental de l'IA en imagerie médicale, centrée surtout sur les coûts énergétiques et climatiques directs.

Cette focalisation est un problème méthodologique important. Une technologie peut sembler économe en énergie ou en carbone dans son utilisation, tout en utilisant beaucoup de ressources matérielles ou en générant d'autres formes d'impacts. Quttainah et al. (2025) montrent bien ce décalage. En effet, leurs experts identifient l'épuisement des ressources matérielles comme l'impact le plus critique, devant la consommation d'énergie, ce qui est contraire à la hiérarchie observée dans la majorité des études empiriques. Analyser uniquement le CO₂ et l'énergie peut donc conduire à sous-estimer l'empreinte globale de ces systèmes.

5.4. L'absence d'analyse du cycle de vie complet

La faible prise en compte du cycle de vie complet est le manquement le plus fréquemment cité. La plupart des études se concentrent sur la phase opérationnelle, c'est-à-dire principalement l'entraînement et l'inférence, à la place d'une vision plus globale.

Cette focalisation est compréhensible, car ces étapes sont les plus facilement mesurables et les plus directement associées au fonctionnement de l'IA. Cependant, l'évaluation environnementale se retrouve alors réduite à la seule phase opérationnelle du système. Certaines publications vont un peu plus loin en intégrant la gestion des données, le stockage sur serveurs ou les infrastructures cloud, mais cela reste insuffisant pour prendre en compte l'ensemble du cycle de vie (Dietrich & Hanneman, 2025 ; Jallais et al., 2026 ; Doo et al., 2024).

Les étapes liées au matériel sont encore largement négligées. La fabrication du matériel, l'extraction des métaux rares, le transport, l'installation, la maintenance ou le renouvellement des équipements sont rarement intégrés de manière détaillée. La fin de vie est un véritable problème dans les études existantes. En effet, aucune étude n'aborde quantitativement le déclassement du matériel, le recyclage des composants ou la gestion des déchets électroniques toxiques générés par l'obsolescence rapide des infrastructures de calcul (Champendal et al., 2025 ; Kocak et al., 2025).

Cette couverture partielle du cycle de vie est un vrai problème méthodologique, car elle peut conduire à sous-estimer l'empreinte environnementale réelle des systèmes étudiés. Une

amélioration observée à une étape particulière ne mène pas nécessairement à une réduction de l'impact global.

5.5. Une prise en compte limitée des effets indirects

Une autre limite importante est le fait que les effets indirects soient encore trop peu pris en compte. Pourtant, le cadre de Hilty montre précisément que ces effets peuvent annuler les bénéfices directs observés, ce que la majorité des études n'évaluent pas (Hilty & Aebischer, 2015 ; Bieser, 2024).

L'effet le plus souvent mis en avant est celui de l'optimisation, ce qui crée un déséquilibre important. Les mécanismes de substitution, d'induction, d'effet rebond et d'obsolescence restent beaucoup moins étudiés, alors qu'ils sont importants pour évaluer l'impact environnemental global.

Concernant la substitution, elle est parfois expliquée. Mais peu d'articles mesurent véritablement le gain environnemental net d'un scénario avec IA par rapport à un scénario sans IA. Thomson et al. (2025) sont parmi les rares à mettre en évidence explicitement cette absence comme une limite majeure de la littérature existante. Sans cette base de comparaison, il est difficile d'évaluer les gains d'efficacité réels de ces substitutions.

L'induction et l'effet rebond sont encore moins intégrés de manière quantitative. Selvan et al. (2022) avertissent pourtant que les gains d'efficacité peuvent paradoxalement augmenter la consommation globale. Mais ce risque est rarement mesuré dans les études empiriques (Qutainah et al., 2025 ; Kocak et al., 2025).

Enfin, les effets logistiques, organisationnels, structurels et d'obsolescence sont eux aussi peu mesurés dans les évaluations. Certains travaux rapportent des modifications dans la planification des examens, les flux de patients, les transports ou encore l'accès aux soins dans des contextes à faibles ressources (Doo et al., 2024 ; Kocak et al., 2025). Ces dimensions apparaissent dans la littérature, mais elles sont rarement mesurées de façon systématique alors qu'elles sont essentielles pour comprendre les conséquences sur le long terme du déploiement de l'IA en imagerie médicale.

Dans l'ensemble, les recherches existantes permettent déjà de mieux comprendre certaines dimensions des coûts écologiques de l'IA en imagerie médicale, mais elles présentent plusieurs limites méthodologiques importantes. Le manque de normalisation, les périmètres d'analyse souvent limités, la focalisation sur l'énergie et le CO₂, la faible prise en compte du cycle de vie complet et l'intégration encore limitée des effets indirects diminuent la portée des résultats disponibles. Ces cinq limites amènent à un constat important : la littérature existante évalue l'IA en imagerie médicale de manière partielle, en privilégiant ce qui est facilement mesurable plutôt que d'avoir une vision globale. Le chapitre suivant propose donc une discussion des résultats, afin de mieux préciser ce que la littérature permet réellement de conclure.

Chapitre 6. Discussion

Après avoir présenté les résultats de l'analyse du corpus et les principales limites méthodologiques des études existantes, il est maintenant possible de prendre du recul sur l'ensemble des constats réalisés.

6.1. Ce que la littérature permet réellement de conclure

La littérature existante permet d'identifier plusieurs constats sur l'évaluation de l'impact environnemental de l'IA en imagerie médicale. D'un côté, elle montre que cet impact est principalement évalué avec la consommation d'énergie, les émissions de CO₂ et certains indicateurs de ressources de calcul. De l'autre, elle expose le fait que, dans certains cas précis, l'IA peut améliorer l'efficacité localement, par exemple en réduisant le temps de calcul, la consommation de certaines ressources ou la durée de certains examens (Afat et al., 2025 ; Gotta et al., 2026 ; Jallais et al., 2026).

Cependant, ces résultats doivent rester nuancés. Premièrement, ils restent souvent limités à des usages précis, à des environnements techniques particuliers ou à des comparaisons entre solutions numériques similaires. Deuxièmement, les résultats dépendent fortement du contexte de développement, du matériel utilisé, de l'utilisation ou non du cloud, du mix énergétique local ainsi que du périmètre méthodologique retenu (Selvan et al., 2022 ; Ordoumpozanis & Papakostas, 2024). Globalement, les travaux du corpus montrent donc déjà quelques tendances et plusieurs points d'attention, mais ils ne permettent pas encore d'évaluer de manière globale, solide et stabilisée les effets environnementaux de l'IA en

imagerie médicale. La réponse à la question de recherche doit donc être tout aussi nuancée. Les études existantes montrent comment l'impact environnemental de l'IA est aujourd'hui évalué, mais elles révèlent aussi que ces évaluations restent encore partielles. En d'autres termes, la littérature permet déjà d'identifier des modes d'évaluation dominants et certains gains d'efficacité locaux, mais elle ne permet pas encore de conclure sur la durabilité globale de ces technologies

6.2. Écarts entre les exigences méthodologiques et les pratiques observées

L'un des principaux enseignements de ce mémoire est l'existence d'un écart entre les exigences méthodologiques définies dans le cadre théorique et ce qui est réellement fait dans les études analysées.

Un premier décalage concerne les dimensions environnementales mesurées. Le chapitre 2 rappelait qu'une évaluation environnementale rigoureuse devrait être multidimensionnelle, c'est-à-dire capable d'intégrer non seulement l'énergie et le carbone, mais aussi d'autres catégories d'impact, comme l'eau, les ressources matérielles, les déchets électroniques ou encore certaines catégories multicritères issues des cadres européens. En pratique, la majorité des études s'en éloigne en se limitant à ces deux premières dimensions. Cela implique concrètement qu'il est impossible de comparer les systèmes d'IA sur l'ensemble de leur empreinte environnementale, et que des décisions d'adoption pourraient être prises sans avoir une vue complète de leurs coûts écologiques réels.

Le cycle de vie est un autre écart observé. Le cadre méthodologique présenté dans le chapitre 2 montrait que l'ACV exige de définir clairement l'unité fonctionnelle, le flux de référence et les frontières du système, puis de couvrir l'ensemble des étapes du cycle de vie, depuis l'extraction des matières premières jusqu'à la fin de vie. Pourtant, les études analysées définissent rarement ces éléments de manière explicite et elles se concentrent presque exclusivement sur les phases opérationnelles. De plus, aucune étude ne précise si elle adopte une approche attributionnelle ou conséquentielle, ce qui rend les résultats encore moins comparables. Cela signifie que les impacts liés à la fabrication du matériel, au transport ou au recyclage sont presque toujours absents des bilans environnementaux disponibles, ce qui mène inévitablement à une sous-estimation de l'empreinte réelle.

Un troisième écart est la comparabilité et la transparence des travaux. Le chapitre 2 insistait sur la nécessité d'hypothèses explicites, de données traçables, de méthodes cohérentes et de résultats présentés dans des formats comparables, notamment pour limiter les risques de greenwashing. Pourtant, les études analysées utilisent des outils, des unités, des indicateurs et des périmètres très variés, ce qui est encore aggravé par le manque de transparence des fournisseurs cloud sur leurs données énergétiques (Doo et al., 2024 ; Ordoumpozanis & Papakostas, 2024). Ce manque de transparence peut créer des conditions favorables au greenwashing mentionné au chapitre 2, où une technologie risque d'être présentée comme plus durable qu'elle ne l'est réellement (Bignami et al., 2025 ; Champendal et al., 2025). Il devient alors difficile de formuler des conclusions solides au niveau du secteur.

Les effets indirects sont une quatrième preuve de décalage. Le cadre de Hilty présenté dans le chapitre 2 montrait qu'une évaluation pertinente ne doit pas seulement prendre en compte les impacts directs du cycle de vie, mais aussi les transformations causées par l'utilisation des technologies, que ce soit de l'optimisation, de la substitution, de l'induction, de l'obsolescence ou encore de l'effet rebond. Le corpus analysé ne suit cependant pas cette logique. Les effets d'optimisation sont les plus privilégiés, tandis que les autres mécanismes restent beaucoup moins observés. En pratique, cela signifie que la littérature rend surtout visibles les gains locaux d'efficacité, sans permettre d'évaluer si ces gains se traduisent réellement par une réduction de l'empreinte environnementale globale.

Enfin, un cinquième écart concerne l'interdisciplinarité. Le chapitre 2 soulignait la nécessité d'une approche interdisciplinaire, réunissant des expertises en informatique, en environnement et en sciences sociales. Pourtant, Bratan et al. (2024) notent l'absence de groupes de recherche capables de combiner simultanément les expertises en santé, en IA et en environnement. Les études restent ainsi souvent dominées par une approche technique, centrée sur la performance, comme la précision et le temps de calcul, plutôt que sur les dimensions organisationnelles et comportementales. Certaines revues de synthèse commencent néanmoins à avoir des perspectives plus larges, en associant des profils cliniques, techniques et environnementaux (Thomson et al., 2025 ; Champendal et al., 2025). Ces initiatives restent cependant encore minoritaires. Face à ce constat, plusieurs auteurs appellent à une collaboration élargie entre radiologues, informaticiens, éthiciens et décideurs

politiques pour intégrer pleinement les dimensions environnementales, économiques et sociales dans le déploiement de l'IA (Kocak et al., 2025 ; Bieser, 2024 ; Katirai, 2024).

Dans l'ensemble, la littérature actuelle témoigne d'une prise de conscience croissante des exigences méthodologiques, mais leur application reste encore partielle et inégale. Cela confirme que ce domaine est jeune et encore en train de se structurer, où les outils, les normes et les pratiques sont en cours de développement.

6.3. Apports du mémoire à la compréhension du sujet

Le principal apport de ce mémoire est d'avoir rassemblé, dans une même analyse, des articles empiriques et des revues de synthèse, permettant d'avoir une perspective transversale que chaque type de publication pris séparément ne permettrait pas d'obtenir. Ce mémoire montre d'abord que la littérature ne manque pas totalement de méthodes et d'outils, mais que les évaluations existantes restent souvent partielles et difficile à comparer. Il met également en évidence que les bénéfices souvent attribués à l'IA concernent surtout des gains locaux d'efficacité, qui ne suffisent pas pour prouver une durabilité globale.

L'application du cadre de Hilty à ce corpus est un autre apport méthodologique. En structurant l'analyse en fonction des trois niveaux d'impacts, c'est-à-dire le cycle de vie, les effets d'usage et les impacts structurels, ce mémoire permet d'aller plus loin qu'une simple description des méthodes existantes pour identifier ce qu'elles ne mesurent pas encore. Ce travail aide ainsi à mieux comprendre où sont les manquements de la littérature actuelle et contribue donc à amener de nouvelles pistes pour les recherches futures.

L'apport de ce mémoire n'est pas d'apporter une nouvelle mesure empirique, mais de proposer une lecture critique et structurée de la littérature existante. Il aide à mieux comprendre ce que les articles montrent déjà, mais aussi ce qu'ils ne permettent pas encore d'évaluer de manière satisfaisante.

6.4. Implications pour la recherche future

Les résultats de ce mémoire permettent d'identifier plusieurs pistes d'amélioration pour les recherches futures sur l'impact environnemental de l'IA en imagerie médicale.

Premièrement, il serait utile de mieux normaliser les méthodes d'évaluation. Même si l'analyse du cycle de vie est déjà soutenue par les normes ISO 14040 et 14044, plusieurs travaux montrent que ces normes restent relativement générales et laissent une marge importante d'interprétation, ce qui peut affecter la cohérence et la comparabilité des résultats (International Organization for Standardization, 2006 ; European Commission, 2010 ; Prado et al., 2022). Des protocoles standardisés adaptés spécifiquement à l'IA en santé seraient une avancée importante.

Deuxièmement, les futures recherches devraient utiliser des périmètres d'analyse plus larges. Une évaluation plus complète devrait intégrer non seulement l'entraînement et l'inférence, mais aussi la fabrication des équipements, le stockage, la maintenance et la fin de vie. Des méthodes plus proches de l'ACV complète seraient donc particulièrement utiles.

Troisièmement, il serait souhaitable d'élargir les dimensions environnementales étudiées. L'énergie et le CO₂ sont des indicateurs centraux, mais ils ne suffisent pas à eux seuls pour rendre compte de l'empreinte environnementale réelle des systèmes d'IA.

Quatrièmement, un autre élément intéressant serait de mieux prendre en compte les effets indirects. Les mécanismes de substitution, d'induction, de rebond et d'obsolescence sont encore peu étudiés, alors qu'ils sont importants pour comprendre l'impact réel de l'IA à grande échelle. Dans le même sens, il serait aussi utile de comparer plus souvent des scénarios avec IA et sans IA, afin d'évaluer les gains environnementaux réels plutôt que des optimisations relatives entre solutions numériques.

Cinquièmement, les recherches futures devraient favoriser des approches interdisciplinaires, en associant des experts en informatique, en environnement et en sciences sociales. Cela permettrait de mieux prendre en compte les dimensions organisationnelles et comportementales de l'impact environnemental, notamment les effets de rebond et d'induction qui proviennent des changements de pratiques cliniques (Bratan et al., 2024 ; Pohl et al., 2022).

Enfin, la recherche future devrait davantage utiliser des contextes cliniques variés et dans des conditions de développement plus proches de la réalité. Cela permettrait de mieux

comprendre comment les résultats évoluent selon les contextes techniques, organisationnels et géographiques.

6.5. Limites du mémoire

Ce mémoire a, lui-même, plusieurs limites qu'il est important de reconnaître.

La première limite est la démarche choisie. Ce n'est pas une revue systématique et exhaustive, mais une revue de littérature critique et méthodologique. Elle est fondée sur un corpus choisi pour sa pertinence par rapport à la question de recherche. Ce choix ouvre la voie à une analyse approfondie, mais il implique aussi que certaines études potentiellement pertinentes n'ont pas été incluses.

La seconde limite est liée à l'état actuel des travaux existants. Les recherches sur les coûts écologiques de l'IA appliquée à l'imagerie médicale sont encore très récentes, éparpillées et très disparates. Cette situation limite l'ampleur des comparaisons possibles. L'interprétation des résultats doit donc être faite de manière prudente.

Ce mémoire, d'autre part, ne propose pas de mesure empirique propre. Il n'est pas basé sur l'évaluation directe d'un système d'IA, d'un hôpital ou d'un cas particulier, mais sur l'analyse critique des publications existantes. Son apport est donc surtout analytique et méthodologique, ce qui le distingue des travaux empiriques existants. Il aide ainsi à mieux cerner la façon dont la littérature évalue aujourd'hui l'impact environnemental de l'IA, sans cependant pouvoir répondre à la question de la durabilité de ces technologies.

Enfin, certaines conclusions de ce travail restent limitées par la nature du corpus étudié. La littérature, en effet, est en train de se structurer. Ce travail permet donc d'éclairer un domaine encore émergent, mais ne prétend pas apporter une réponse définitive à toutes les questions relatives au sujet.

Ce chapitre a permis de discuter les principaux résultats de l'analyse, d'identifier les apports et les limites de ce mémoire, et de proposer des pistes pour la recherche future. Ces éléments posés, il est maintenant possible de formuler la conclusion générale de ce travail.

Conclusion générale

Ce mémoire avait pour objectif d'analyser la manière dont l'impact environnemental de l'intelligence artificielle est aujourd'hui évalué dans le domaine de l'imagerie médicale. À l'aide d'une revue de littérature critique et méthodologique, il montre que cette question est de plus en plus présente dans la recherche, mais que les méthodes d'évaluation restent encore hétérogènes et incomplètes.

L'analyse du corpus permet de formuler un constat central : l'IA en imagerie médicale ne peut être considérée ni comme une solution d'office durable, ni comme une technologie nécessairement problématique sur le plan environnemental. Son impact varie selon les choix techniques, les infrastructures utilisées, les conditions de déploiement et le périmètre d'évaluation considéré. Des études montrent des gains d'efficacité, notamment par la réduction du temps d'examen, l'optimisation des flux de travail ou l'utilisation de modèles plus légers. Toutefois, ces bénéfices restent souvent locaux et partiels. À l'inverse, le développement et l'utilisation de l'IA reposent sur des infrastructures énergivores, des volumes de données importants et des équipements spécialisés ayant eux-mêmes une empreinte environnementale non négligeable. En outre, la littérature se concentre surtout sur la consommation d'énergie et les émissions de CO₂, tandis que d'autres dimensions, comme la consommation d'eau, les déchets électroniques ou l'extraction des ressources naturelles, restent peu étudiées. Les effets indirects, comme l'effet rebond, sont eux aussi rarement intégrés de manière complète.

À mon sens, l'un des principaux enseignements de ce mémoire est que la littérature actuelle continue de valoriser encore fortement les performances techniques de l'IA, sans toujours intégrer de manière suffisante les conséquences environnementales globales de son déploiement. Il me paraît donc important que la durabilité devienne un véritable critère d'évaluation des systèmes d'IA, au même niveau que la précision diagnostique ou la rapidité.

Ce travail montre ainsi la nécessité de développer des approches plus complètes et plus comparables. Les recherches futures devraient davantage s'appuyer sur des logiques de cycle de vie, intégrer plusieurs dimensions environnementales et comparer de façon plus systématique des scénarios avec et sans IA. L'enjeu aujourd'hui est d'allier progrès médical, performance technique et responsabilité environnementale.

Bibliographie

- Afat, S., Wohlers, J., Herrmann, J., Brendlin, A. S., Gassenmaier, S., Almansour, H., & Küstner, T. (2025). Reducing energy consumption in musculoskeletal MRI using shorter scan protocols, optimized magnet cooling patterns, and deep learning sequences. *European Radiology*, 35(4), 1993–2004. <https://doi.org/10.1007/s00330-024-11011-8>
- Barragán-Montero, A., Javaid, U., Valdés, G., Nguyen, D., Desbordes, P., Macq, B., Willems, S., Vandewinckele, L., Holmström, M., Löfman, F., Michiels, S., Souris, K., Sterpin, E., & Lee, J. A. (2021). Artificial intelligence and machine learning for medical imaging: A technology review. *Physica Medica*, 83, 242–256. <https://doi.org/10.1016/j.ejimp.2021.04.016>
- Bieser, J. (2024). AI and climate protection: Research gaps and needs to align machine learning with greenhouse gas reductions. Dans *2024 10th International Conference on ICT for Sustainability (ICT4S)* (pp. 1–9). IEEE. <https://doi.org/10.1109/ICT4S60173.2024.00011>
- Bignami, E., Darhour, L. J., & Bellini, V. (2025). Sustainable AI in medicine: Navigating innovation, challenges, and environmental impact. *Health Economics Review*, 15(1), 110. <https://doi.org/10.1186/s13561-025-00597-w>
- Bratan, T., Heyen, N. B., Hüsing, B., Marscheider-Weidemann, F., & Thomann, J. (2024). Hypotheses on environmental impacts of AI use in healthcare. *The Journal of Climate Change and Health*, 16, 100299. <https://doi.org/10.1016/j.joclim.2024.100299>
- Castiglioni, I., Rundo, L., Codari, M., Di Leo, G., Salvatore, C., Interlenghi, M., Gallivanone, F., Cozzi, A., D'Amico, N. C., & Sardanelli, F. (2021). AI applications to medical images: From machine learning to deep learning. *Physica Medica*, 83, 9–24. <https://doi.org/10.1016/j.ejimp.2021.02.006>
- Champendal, M., Lokaj, B., de Gevigney, V. D., Brulé, G., Zaghir, J., Boiko, P., Lovis, C., Müller, H., Schmid, J., & Ribeiro, R. T. (2025). Exploring environmental sustainability of artificial intelligence in radiology: A scoping review. *European Journal of Radiology*, 194, 112558. <https://doi.org/10.1016/j.ejrad.2025.112558>

- Commission européenne. (2021). Recommandation (UE) 2021/2279 de la Commission du 15 décembre 2021 relative à l'utilisation de méthodes d'empreinte environnementale pour mesurer et indiquer la performance environnementale des produits et des organisations sur l'ensemble du cycle de vie. *Journal officiel de l'Union européenne*, L 471, 1–396.
- Dietrich, N., & Hanneman, K. (2025). Greener by design: Weighing the environmental impact of radiology AI development. *Canadian Association of Radiologists Journal*, 77(2), 267–268. <https://doi.org/10.1177/08465371241308010>
- Doo, F. X., Vosschenrich, J., Cook, T. S., Moy, L., Almeida, E. P. R. P., Woolen, S. A., Gichoya, J. W., Heye, T., & Hanneman, K. (2024). Environmental sustainability and AI in radiology: A double-edged sword. *Radiology*, 310(2), e232030. <https://doi.org/10.1148/radiol.232030>
- European Commission, Joint Research Centre, Institute for Environment and Sustainability. (2010). *International Reference Life Cycle Data System (ILCD) handbook: General guide for life cycle assessment — Provisions and action steps* (1re éd.). Publications Office of the European Union.
- Gotta, J., Bachir, A. A., Gruenewald, L. D., Strecker, R., Nickel, D., Martin, S. S., & Koch, V. (2026). Deep learning HASTE for upper abdominal MRI: Improved image quality, speed, and energy efficiency in a prospective study. *NMR in Biomedicine*, 39(1), e70183. <https://doi.org/10.1002/nbm.70183>
- Hilty, L. M., & Aebischer, B. (2015). ICT for sustainability: An emerging research field. Dans L. M. Hilty & B. Aebischer (Éds.), *ICT innovations for sustainability* (pp. 3–36). Springer.
- Hilty, L. M., Coroama, V., De Eicker, M. O., Ruddy, T., & Müller, E. (2009). *The role of ICT in energy consumption and energy efficiency*. Report to the European Commission, DG INFSO, Project ICT ENSURE: European ICT Sustainability Research. Graz University.
- International Organization for Standardization. (2006). *Environmental management — Life cycle assessment — Principles and framework* (2e éd., ISO 14040:2006). ISO.

- Jallais, M., Mancini, M., & Palombo, M. (2026). *GAIA — Green artificial intelligence for accelerated medical imaging: Sustainable and efficient diffusion MRI analysis* [Prétirage]. ResearchGate. <https://doi.org/10.13140/RG.2.2.15336.12807>
- Katirai, A. (2024). The environmental costs of artificial intelligence for healthcare. *Asian Bioethics Review*, 16(3), 527–538. <https://doi.org/10.1007/s41649-024-00316-4>
- Kelly, B. S., Judge, C., Bollard, S. M., Clifford, S. M., Healy, G. M., Aziz, A., & Killeen, R. P. (2022). Radiology artificial intelligence: A systematic review and evaluation of methods (RAISE). *European Radiology*, 32(11), 7998–8007. <https://doi.org/10.1007/s00330-022-08784-6>
- Kocak, B., Ponsiglione, A., Romeo, V., Ugga, L., Huisman, M., & Cuocolo, R. (2025). Radiology AI and sustainability paradox: Environmental, economic, and social dimensions. *Insights into Imaging*, 16(1), 88. <https://doi.org/10.1186/s13244-025-01961-5>
- Laçi, H., & Sevrani, K. (2025, mai). Enhancing automation and sustainability in AI-driven medical imaging. Communication présentée à la 10th Business & Entrepreneurial Economics 2025 Conference, Dubrovnik, Croatie.
- Lan, Y. C., Strauch, M., Pilva, P., Schmitz, N. E., Sadr, A. V., Niggemeier, L., & Boor, P. (2024). Ecologically sustainable benchmarking of AI models for histopathology. *NPJ Digital Medicine*, 7(1), 378. <https://doi.org/10.1038/s41746-024-01397-x>
- Mandal, S., Greenblatt, A. B., & An, J. (2018). Imaging intelligence: AI is transforming medical imaging across the imaging spectrum. *IEEE Pulse*, 9(5), 16–24. <https://doi.org/10.1109/MPUL.2018.2857226>
- Nanekaran, N. P., & Ukwatta, E. (2025). A novel federated learning framework for medical imaging: Resource-efficient approach combining PCA with early stopping. *Medical Physics*, 52(8), e18064. <https://doi.org/10.1002/mp.18064>
- Ordoumpozanis, K., & Papakostas, G. A. (2024). Green AI: Assessing the carbon footprint of fine-tuning pre-trained deep learning models in medical imaging. Dans 2024

International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT) (pp. 214–220). IEEE.
<https://doi.org/10.1109/3ict64318.2024.10824571>

Pinto-Coelho, L. (2023). How artificial intelligence is shaping medical imaging technology: A survey of innovations and applications. *Bioengineering*, 10(12), 1435.
<https://doi.org/10.3390/bioengineering10121435>

Pohl, J., Frick, V., Finkbeiner, M., & Santarius, T. (2022). Assessing the environmental performance of ICT based services: Does user behaviour make all the difference? *Sustainable Production and Consumption*, 31, 828–838.
<https://doi.org/10.1016/j.spc.2022.03.022>

Pohl, J., Hilty, L. M., & Finkbeiner, M. (2019). How LCA contributes to the environmental assessment of higher order effects of ICT application: A review of different approaches. *Journal of Cleaner Production*, 219, 698–712.
<https://doi.org/10.1016/j.jclepro.2019.02.018>

Prado, V., Seager, T. P., & Guglielmi, G. (2022). Challenges and risks when communicating comparative LCA results to management. *International Journal of Life Cycle Assessment*, 27, 1164–1169. <https://doi.org/10.1007/s11367-022-02090-5>

Prajwal, R., Pawan, S. J., Nazarian, S., Heller, N., Weight, C. J., Duddalwar, V., & Kuo, C. C. J. (2025). A study on energy consumption in AI-driven medical image segmentation. *Journal of Imaging*, 11(6), 174.
<https://doi.org/10.3390/jimaging11060174>

Quttainah, M. A., Singh, P., & Rana, S. (2025). Assessing the environmental impact of AI-based medical diagnosis using grey relational analysis. *Arab Journal of Administrative Sciences*. <https://doi.org/10.34120/ajas.2025.1387>

Ranganathan, R., Annamalai, A., Ruban, S., Mythili, S., Shuriya, B., & Balajishanmugam, V. (2025). Sustainable AI for medical imaging: A federated, edge-based approach to chest X-ray triage. Dans *2025 International Conference on Modern Sustainable Systems (CMSS)* (pp. 945–952). IEEE.

- Richie, C., Hinrichs-Krapels, S., Dobbe, R., French, P., Wei, J. C., Diehl, J. C., & Kong, R. (2025). Environmental impacts of artificial intelligence in health care: Considerations and recommendations. *Health and Technology*, 15(6), 1087–1093. <https://doi.org/10.1007/s12553-025-01006-3>
- Selvan, R., Bhagwat, N., Wolff Anthony, L. F., Kanding, B., & Dam, E. B. (2022). Carbon footprint of selecting and training deep learning models for medical image analysis. Dans L. Wang, Q. Dou, P. T. Fletcher, S. Speidel, & S. Li (Éds.), *Medical Image Computing and Computer Assisted Intervention – MICCAI 2022* (Lecture Notes in Computer Science, vol. 13435, pp. 506–516). Springer. https://doi.org/10.1007/978-3-031-16443-9_49
- Thomson, R. M., Perdomo Lampignano, J., Fisher, E., Wati, C., Jeyakumar, G., Duncan, S., & Lowe, D. J. (2025). Evaluating the environmental sustainability of AI in radiology: A systematic review of current practice. *BMJ Digital Health and AI*, 1(1). <https://doi.org/10.1136/bmjdhai-2025-000073>
- Ueda, D., Walston, S. L., Fujita, S., Fushimi, Y., Tsuboyama, T., Kamagata, K., & Naganawa, S. (2024). Climate change and artificial intelligence in healthcare: Review and recommendations towards a sustainable future. *Diagnostic and Interventional Imaging*, 105(11), 453–459. <https://doi.org/10.1016/j.diii.2024.06.002>
- Vafaei Sadr, A., Bülow, R., von Stillfried, S., Schmitz, N. E. J., Pilva, P., Hölscher, D. L., Ha, P. P., Schweiker, M., & Boor, P. (2024). Operational greenhouse-gas emissions of deep learning in digital pathology: A modelling study. *The Lancet Digital Health*, 6(1), e58–e69. [https://doi.org/10.1016/S2589-7500\(23\)00219-4](https://doi.org/10.1016/S2589-7500(23)00219-4)
- Wong, S. H., Al-Hasani, H., Alam, Z., & Alam, A. (2019). Artificial intelligence in radiology: How will we be affected? *European Radiology*, 29(1), 141–143. <https://doi.org/10.1007/s00330-018-5644-3>
- Woolen, S. A., Martin, M., Foster, C. A., MacEachern, M. P., & Maturen, K. E. (2025). Green imaging: Scoping review of radiology's environmental impact. *Journal of the American College of Radiology*. Publication avancée en ligne. <https://doi.org/10.1016/j.jacr.2025.09.013>

Annexe 1. Tableau comparatif des études retenues

Les principaux termes techniques utilisés dans le tableau sont définis ci-dessous afin de faciliter la lecture de l'annexe.

Terme	Définition
Distillation de connaissances	Technique consistant à compresser un réseau de neurones large et complexe en un modèle plus petit qui conserve des performances similaires tout en réduisant significativement les coûts de calcul et l'empreinte énergétique.
Fine-tuning, affinage ou réglage fin	Consiste à prendre un modèle ayant déjà appris sur une base de données massive et à l'entraîner à nouveau sur un jeu de données plus petit et spécifique à une tâche précise.
Quantification	Technique de compression visant à réduire la taille d'un modèle et sa consommation d'énergie sans réduire fortement ses performances diagnostiques.
Tuiles	Petites zones extraites d'une image médicale de grande taille
Apprentissage fédéré	Approche d'apprentissage automatique décentralisé qui permet à plusieurs institutions d'entraîner ensemble un modèle d'intelligence artificielle sans partager directement leurs données.
Arrêt précoce	Stratégie d'optimisation utilisée pour interrompre l'entraînement d'un modèle d'IA dès que ses performances cessent de s'améliorer sur un ensemble de données.
Convolutions	Opération utilisée par les réseaux de neurones pour extraire des caractéristiques visuelles à partir d'images.
Précision mixte	Technique qui utilise des calculs moins lourds pour réduire la mémoire, le temps de calcul et la consommation d'énergie lors de l'entraînement d'un modèle.
Calcul local	Calcul réalisé localement, au lieu d'envoyer les données vers le Cloud.
Recherche par grille	Méthode qui teste systématiquement plusieurs combinaisons de paramètres afin de trouver les meilleurs réglages du modèle.
Pathomique	Méthode d'analyse histopathologique qui combine la segmentation par IA et l'extraction à grande échelle de caractéristiques quantitatives.
FLOPs	Nombre d'opérations de calcul effectuées par un modèle.
Curation	Ensemble des processus de préparation, d'organisation et de nettoyage des jeux de données cliniques réels pour les rendre exploitables par des algorithmes.
Dépistage opportuniste	Utilisation de l'IA pour extraire des données utiles mais secondaires d'un examen d'imagerie initialement réalisé pour un autre motif.

Article	Type	Objet étudié	Dimensions environnementales	Étapes du cycle de vie	Méthode / Outils	Effets d'usage et impacts structurels	Principaux résultats	Limites
A. Études expérimentales, quantitatives et de modélisation								
AFAT et al. (2025)	Article de recherche scientifique	Optimisation de la consommation énergétique des scanners d'IRM	Énergie : Mesure centrale de l'étude, quantifiée en kWh ou Wh. Mesure de l'énergie consommée lors des phases actives (pendant les scans), des temps d'inactivité et des périodes où le système est éteint. Attention particulière pour la consommation du système de refroidissement de l'aimant. Le temps d'acquisition est utilisé comme indicateur indirect, car un examen plus court réduit le temps d'utilisation de la machine et donc la consommation énergétique. Empreinte carbone : En kilogrammes de CO₂ économisés par scanner et par an. Calculs basés sur l'intensité carbone du mix énergétique local (385 g CO₂/kWh en Allemagne). Ressources matérielles : Surveille également les niveaux d'hélium du scanner. Vérifie que l'activation du mode	Inférence : Mesure la consommation d'énergie lors des scans actifs, des temps d'inactivité et du mode veille sur des scanners IRM réels. Prise en compte de l'énergie nécessaire au refroidissement de l'aimant (42 % de la consommation totale). Fabrication du matériel : Mentionne que la consommation lors de la fabrication peut dépasser l'usage opérationnel annuel, mais ne l'intègre pas dans ses calculs chiffrés.	Méthode : Étude comparative de trois modes de fonctionnement pour l'IRM : le mode de référence, des protocoles économiques (réduisant la résolution et augmentant l'accélération parallèle classique) et des séquences accélérées par apprentissage profond (<i>deep learning</i>). L'étude évalue également l'optimisation du système de refroidissement avec le mode Eco Power. Outils : Analyseur de qualité de puissance UMG 512 (Janitza), plateforme Siemens Fleet Cockpit pour l'enregistrement des activités du scanner et analyses statistiques réalisées avec R et Python.	Niveau 2 - Effets d'usage : Optimisation : Les séquences accélérées par deep learning réduisent fortement le temps d'examen. La méthode Eco Power réduit la consommation énergétique. Induction : Le gain de temps pourrait permettre de réaliser plus d'examens avec le même scanner. Niveau 3 - Impacts structurels : Effet rebond : Note que l'accélération des examens pourrait causer une augmentation du volume total de scans.	L'utilisation de l'apprentissage profond a permis une réduction de 72 % de la consommation d'énergie et de 71 % du temps d'examen par rapport à la méthode standard. En mode veille, l'activation du mode Eco Power réduit la consommation de 30 %, économisant environ 4 881 € par scanner annuellement.	- Mesures énergétiques moyennées sur des intervalles de 10 minutes, nécessitant des interpolations pour déterminer les consommations exactes des séquences. - Recherche limitée à un seul type d'image : l'IRM. - Solutions logicielles spécifiques à un seul constructeur. - Fabrication du matériel mentionnée comme importante, mais non intégrée dans les calculs quantitatifs.

			Eco Power, qui optimise le refroidissement, n'entraîne aucune perte de cette ressource.					
GOTTA et al. (2026)	Article de recherche	Comparaison entre une séquence IRM abdominale classique et une séquence accélérée par deep learning pour l'imagerie de l'abdomen supérieur.	Énergie : Mesure de l'énergie électrique nécessaire à l'acquisition des images (en kilowatts). Le temps est considéré également car la réduction de la durée de fonctionnement de la machine réduit le temps d'utilisation de la machine.	Inférence : L'analyse porte exclusivement sur l'utilisation en routine clinique pour comparer des séquences conventionnelles et optimisées par IA. Développement : Mentionne brièvement les conditions d'entraînement pour contextualiser le modèle.	Méthode : Étude prospective menée sur 166 patients, comparant une séquence IRM abdominale standard à une séquence accélérée par deep learning (DL-HASTE). L'étude évalue aussi la qualité d'image avec des mesures qualitatives et quantitatives. Outils : Logiciel 3D Slicer avec l'extension PyRadiomics, logiciels statistiques R et MedCalc, et station de travail GE Centricity PACS.	Niveau 2 - Effets d'usage : Optimisation : Réduction de 62,5 % de la durée des scans abdominaux avec une baisse de l'énergie absorbée par le patient pendant l'IRM. En pratique, un examen plus court pourrait permettre de prendre en charge davantage de patients et de réduire les temps d'attente.	L'IA appliquée aux séquences HASTE abdominales a réduit le temps d'acquisition de 62,5 %. Cela se traduit par une économie de 0,34 kWh par examen (soit 12 410 kWh par an pour 100 examens quotidiens), tout en offrant une qualité d'image supérieure.	- L'énergie n'est pas mesurée physiquement, mais estimée à partir des spécifications du constructeur et des temps de scan, omettant les variations réelles de demande de puissance. - Étude réalisée dans un seul centre médical. - Taille limitée de l'échantillon (166 patients). - L'évaluation de la qualité d'image repose sur une interprétation subjective par des lecteurs, ce qui introduit des biais potentiels.
JALLAIS et al. (2026)	Article de recherche / Poster scientifique	Utilisation de la distillation de connaissances pour créer des modèles d'IA plus légers et moins énergivores en imagerie médicale.	Énergie : Consommation énergétique totale. Énergies du processeur graphique (GPU) et du processeur central (CPU) mesurées en kilowattheures.	Développement : Entraînement du modèle étudiant à partir du modèle enseignant plus lourd. Inférence : Évalue la consommation d'énergie et les	Méthode : Distillation de connaissances où un modèle étudiant compact (U-Net 3D) est entraîné pour reproduire les prédictions d'un modèle enseignant	Niveau 2 - Effets d'usage : Optimisation : Création de modèles étudiants compacts (réduction de 78 % de la taille). Niveau 3 - Impacts structurels :	La distillation de connaissances permet de réduire la taille du modèle de 78 %. Cela entraîne une baisse de 35 % de l'énergie totale et des émissions de CO ₂ par	- Application limitée à une seule tâche très spécifique. - Estimations de CO ₂ basées exclusivement sur les données du

			Empreinte carbone : Estimations basées sur les données du réseau national britannique. Les auteurs évaluent cette dimension par examen individuel mais aussi à grande échelle. Ils calculent le pourcentage de CO ₂ en moins par déploiement. Ressources computationnelles : Complexité de l'architecture (profondeur, paramètres) et efficacité du calcul.	émissions pendant l'utilisation répétée du modèle. Stockage : Mentionne les demandes liées au stockage de grands volumes de données.	plus large et énergivore. Outils : Architecture U-Net 3D, optimiseur Adam, et calculs basés sur les données du réseau électrique britannique.	Accès facilité : Amélioration de l'accessibilité des outils dans les structures ayant moins de ressources informatiques.	rapport au modèle enseignant.	réseau électrique britannique. - Taille limitée de l'échantillon (161 sujets).
LAÇI & SEVRANI (2025)	Article de recherche	Évaluation d'une méthode de deep learning pour classer automatiquement des images échographiques liées au syndrome des ovaires polykystiques (SOPK)	Énergie : Consommation de l'unité centrale (CPU) et de la mémoire (RAM) estimée par CodeCarbon. Empreinte carbone : Émissions produites lors des phases d'extraction de caractéristiques, de fine-tuning et d'inférence. Ressources computationnelles : Taux d'utilisation du GPU et occupation de la VRAM par cycle d'entraînement.	Préparation : Intègre le prétraitement et l'augmentation des données. Développement : Analyse séparément l'extraction de caractéristiques et l'affinage. Inférence : Mesure l'impact sur l'ensemble de test.	Méthode : Étude menée sur 4838 images échographiques. Le modèle extrait d'abord les caractéristiques des images, puis les 10 dernières couches sont ajustées pour la classification. Outils : Bibliothèque CodeCarbon 2.8.3 pour l'énergie et le CO ₂ , outil GPUMonitorCallback pour suivre l'utilisation de la VRAM et le pourcentage d'utilisation du GPU.	Niveau 2 - Effets d'usage : Optimisation : Utilisation d'un modèle léger, MobileNetV3, pour automatiser la classification d'images médicales avec une faible consommation énergétique.	L'utilisation du modèle léger MobileNetV3 pour classer des images échographiques atteint 97 % de précision tout en ne consommant que $7,32 \times 10^{-3}$ kWh pour l'entraînement, soit environ une charge de smartphone.	- Impossibilité de mesurer la consommation du GPU dans l'environnement WSL2 utilisé, ce qui limite l'évaluation au CPU et à la RAM. - La tâche est restreinte à une classification binaire sur un seul type d'image (échographie). - L'étude exclut tout le cycle de vie du matériel, se concentrant uniquement sur la phase de

								développement et d'inférence.
LAN et al. (2024)	Article de recherche	Évaluation de modèles d'IA en histopathologie en combinant performance diagnostique et empreinte carbone, notamment pour la classification de cancers et de maladies rénales	Énergie : Demande d'électricité pour l'entraînement et l'inférence. Empreinte carbone : Empreinte carbone calculée en CO ₂ eq intégrée dans le score ESPer. Ressources computationnelles : Nombre de paramètres, temps d'inférence et volume de données traitées.	Entraînement et inférence : Propose le score ESPer qui combine la performance et le carbone opérationnel de ces deux phases. Fabrication du matériel et transport : Mentionnés, mais non inclus dans le score.	Méthode : Développement du score ESPer (<i>Environmentally Sustainable Performance</i>) qui pondère mathématiquement la performance diagnostique par le coût carbone opérationnel. L'étude teste aussi des méthodes comme la simplification du modèle, la quantification et le réglage des hyperparamètres. Outils : Package experiment-impact-tracker 0.1.9, bibliothèques PyTorch 2.1.0 et OpenSlide, serveur Nvidia DGX-1 (Tesla V100)	Niveau 2 - Effets d'usage : Optimisation : Réduction du volume de données analysées, notamment par sous-échantillonnage des tuiles, afin de maintenir une bonne performance avec moins de calcul. Niveau 3 - Impacts structurels : Impact sanitaire indirect : Calcul du coût de mortalité du carbone, c'est-à-dire l'estimation des décès excédentaires liés aux émissions des grands modèles d'IA.	L'étude crée le score ESPer, qui permet d'évaluer la performance diagnostique et l'empreinte carbone opérationnelle d'un modèle. Pour la classification du cancer, l'utilisation de seulement 10 % des tuiles d'une image permet d'obtenir une performance comparable à l'analyse complète de l'image, tout en réduisant fortement la consommation énergétique.	- Centrée sur l'énergie opérationnelle, sans prendre en compte le cycle de vie complet. - L'intensité carbone est calculée sur la base de données historiques régionales plutôt que sur des données de mix énergétique en temps réel - L'efficacité des stratégies de réduction de données identifiées reste dépendante de la tâche et du jeu de données.
NANEKARAN & UKWATTA (2025)	Article de recherche	Méthode d'apprentissage fédéré économe en énergie pour classer le cancer de la prostate à partir d'images IRM.	Énergie : C'est la mesure centrale de l'étude, quantifiée en Watt-heures (Wh). Les auteurs comparent la consommation d'un apprentissage fédéré standard (FedAvg) à leur méthode adaptative. Ils calculent	Prétraitement : Intègre une étape de réduction de dimensionnalité pour harmoniser les données. Entraînement : Se concentre sur l'entraînement décentralisé entre	Méthode : Utilisation de 1500 examens IRM de la prostate venant de 3 institutions. Les auteurs proposent un cadre d'apprentissage fédéré adaptatif utilisant l'algorithme FIPCA (<i>Federated</i>	Niveau 2 - Effets d'usage : Optimisation : Réduction de la dimensionnalité et arrêt précoce pour minimiser l'énergie d'entraînement. Niveau 3 - Impacts structurels :	L'intégration de la PCA incrémentale et de l'arrêt précoce dans un cadre d'apprentissage fédéré a permis de réduire le nombre d'itérations d'échange d'entraînement de 200 à 38. La	- La méthode FIPCA proposée est linéaire, pouvant perdre certaines informations plus complexes utiles au diagnostic. - L'évaluation est limitée à un seul type de pathologie

			aussi la réduction du temps nécessaire pour entraîner le modèle et la réduction du nombre d'itérations d'échange entre les centres participants et le modèle central. Ressources computationnelles : Réduction de la complexité de calcul et de la charge mémoire grâce à la réduction de dimensionnalité et à l'utilisation de mécanismes d'arrêt précoce.	plusieurs centres. Il y a une réduction du nombre d'itérations d'échange entre les centres participants et le modèle central, ce qui limite les transferts de paramètres et la charge réseau. Inférence : Test sur un troisième centre médical qui n'a pas participé à l'entraînement.	<i>Incremental PCA</i>) pour la réduction de dimensionnalité tout en préservant la confidentialité. Outils : Framework Flower, environnement de simulation sur Apple M1 MacBook Pro, et architecture de réseau de neurones à trois couches.	Accès facilité : Facilitation du déploiement dans des institutions aux infrastructures limitées.	consommation d'énergie est alors réduite de 98 % par rapport à l'algorithme standard FedAvg.	(cancer de la prostate). - Étude limitée à un environnement de simulation sur un ordinateur portable, ne reflétant pas les infrastructures hospitalières réelles. - Comparabilité limitée par l'utilisation d'un nombre fixe d'itérations d'échange entre les centres participants et le modèle central dans le protocole FedAvg de base.
ORDOUMPOZA NIS & PAPAKOSTAS (2024)	Article de recherche et de conférence scientifique	L'impact environnemental du réglage fin (<i>fine-tuning</i>) du modèle Google Visual Transformer (ViT) pour l'analyse d'échographies mammaires	Énergie : Consommation sans l'impact de la RAM (kWh) via CodeCarbon. Empreinte carbone : Émissions équivalentes produites par expérience de fine-tuning. Ressources computationnelles : Tailles des modèles ViT, nombre de paramètres, impact de l'utilisation d'un matériel trop puissant pour la tâche.	Développement : Se concentre spécifiquement sur le fine-tuning de modèles pré-entraînés. Mentionne l'installation des bibliothèques et la configuration du serveur, bien que non incluses dans le calcul d'énergie final.	Méthode : Étude basée sur 780 images échographiques de cancer du sein. Recherche expérimentale via quatre expériences : optimisation des hyperparamètres, comparaison de tailles de modèles (ViT-Base, Large, Huge), impact du surdimensionnement matériel (exécution du code sur une carte modeste vs carte très	Niveau 2 - Effets d'usage : Optimisation : Sélection rigoureuse de la taille du modèle pré-entraîné et optimisation manuelle des hyperparamètres.	L'étude montre que chaque expérience de réglage consomme en moyenne 0,18 kWh et génère 0,066 kg CO₂eq. Le réglage du nombre de cycles d'entraînement est l'étape la plus consommatrice, avec 43 % d'émissions en plus par rapport aux autres paramètres. Les auteurs montrent aussi que plus le modèle est grand, plus son empreinte environnementale	- Exclusion de l'énergie de la RAM. - Optimisation des hyperparamètres effectuée manuellement, risquant de manquer des configurations plus économes. - Localisation des serveurs différente selon les expériences, ce qui complique la comparaison des émissions.

					puissante) et choix du fournisseur de serveurs. Outils : Outil CodeCarbon, bibliothèques PyTorch 2.2 et Hugging Face Accelerate, serveurs RunPod et Google Colab		augmente. L'utilisation d'un GPU trop puissant peut augmenter les émissions de 8 % et la puissance consommée de 50 %, même si le calcul est plus rapide. Enfin, la localisation du serveur influence fortement les émissions, avec des variations liées au mix énergétique du pays.	- Comparaison centrée sur le fine-tuning, sans prise en compte du cycle de vie complet du matériel.
PRAJWAL et al. (2025)	Article de recherche empirique	Consommation énergétique des modèles d'IA pour la segmentation d'images médicales, évaluant l'impact de différentes architectures de convolution et de techniques d'optimisation	Énergie : Consommation totale et distribution par composant matériel (kWh). Empreinte carbone : Les émissions sont estimées en combinant la consommation d'énergie mesurée avec les indices d'intensité carbone régionaux. Ressources computationnelles : Complexité algorithmique, accès mémoire et opérations d'entrée/sortie.	Prétraitement : Inclut le chargement, la normalisation et l'extraction de coupes 2D. Entraînement et inférence : Compare les demandes énergétiques de ces deux phases selon différentes architectures de convolution.	Méthode : Évaluation quantitative comparant trois variantes de convolutions (standard, depthwise, group) combinées à des techniques d'optimisation de l'entraînement. Outils : Bibliothèque CodeCarbon pour le suivi CPU/GPU/RAM, framework PyTorch 2.4.0, architecture U-Net 2D.	Niveau 2 - Effets d'usage : Optimisation : Utilisation de convolutions depthwise et de la précision mixte pour réduire la charge GPU. Niveau 3 - Impacts structurels : Hausse des besoins de calcul : Croissance rapide des besoins de calcul en IA, pouvant augmenter la consommation énergétique globale du secteur.	Les convolutions depthwise combinées à la précision mixte sont les plus économes pour l'entraînement (-20,3 % d'énergie). Cependant, pour l'inférence, la convolution standard reste la plus efficace car elle minimise les accès mémoire fragmentés.	- Basée sur une architecture fixe (U-Net) et sur un seul ensemble de données (KiTS19, segmentation des tumeurs rénales) - Les mesures d'énergie sont basées sur une modélisation logicielle (CodeCarbon) et non sur une mesure directe - Les expériences sont réalisées en dehors d'un contexte hospitalier réel, sans tenir compte de l'intégration dans les systèmes d'images médicales utilisés par les

								hôpitaux ni des contraintes liées au traitement simultané de nombreux examens.
RANGANATHAN et al. (2025)	Article de recherche technique	La conception et l'évaluation d'un système d'intelligence artificielle durable pour le triage des radiographies pulmonaires (détection de la pneumonie), comparant une solution conventionnelle basée sur le cloud à une approche utilisant l'apprentissage fédéré et l'informatique en périphérie	Énergie : Dissipation de puissance pour l'entraînement et l'inférence. Empreinte carbone : Émissions estimées basées sur le mix énergétique régional. Ressources computationnelles : Taille du modèle (MB), latence d'inférence, utilisation GPU et dépendance au réseau.	Entraînement : Les auteurs comparent l'énergie nécessaire pour entraîner le modèle de base par rapport au système durable utilisant l'apprentissage fédéré. Inférence : Inclut la quantification de la consommation d'énergie par image, la latence et l'utilisation du GPU. Le volume de données circulant est mesuré. L'étude quantifie la fréquence de mises à jour. Le système durable ne nécessite que 2 cycles de réentraînement complets par an, ce qui réduit la charge de calcul à long terme. Autres étapes citées mais pas calculées : L'acquisition des données, la fin de vie	Méthode : Comparaison entre une solution d'inférence classique sur le Cloud (ResNet50) et une approche durable sur dispositif « Edge » (MobileNetV2 compressé). Outils : Outil CodeCarbon, commande nvidia-smi pour la puissance GPU en temps réel, méthode SHAP pour l'explicabilité, et jeu de données NIH ChestX-ray14.	Niveau 2 - Effets d'usage : Substitution : Inférence sur dispositif Edge remplaçant le Cloud pour éliminer la dépendance au réseau. Niveau 3 - Impacts structurels : Meilleure équité : Amélioration de l'équité démographique.	Un système basé sur le calcul local réduit l'énergie d'inférence de plus de 80 % et l'énergie d'entraînement de 74,5 %.	- Utilisation de scénarios de déploiement simulés sur des périphériques Edge, qui ne capturent pas les complexités réelles de la connectivité réseau intermittente en milieu clinique. - Léger compromis de performance diagnostique lors de la compression. - Absence de comparaison avec le standard de soin humain.

				et l'impact matériel/fabrication.				
SELVAN et al. (2022)	Article de recherche	Quantification de l'empreinte carbone et de la consommation d'énergie liées au développement de modèles d'apprentissage profond pour l'analyse d'imagerie médicale, en utilisant la segmentation d'images (modèle nnU-net) comme cas d'étude et en comparant différents outils de suivi des émissions	Énergie : Elle est mesurée en kilowattheures (kWh), avec distinction entre l'énergie consommée par le GPU et le CPU. Empreinte carbone : Les auteurs cherchent à quantifier les émissions de gaz à effet de serre générées par le développement des modèles. Les résultats sont exprimés en kilogrammes de CO₂ équivalent (kg CO₂eq). L'étude traduit aussi ces émissions en distance parcourue en voiture (km) pour évaluer l'impact carbone. L'impact est évalué en fonction de la région géographique où les serveurs sont situés. L'étude compare l'intensité carbone (gCO₂/kWh) de différentes régions (ex : Danemark vs Estonie vs Monde). Ressources computationnelles : Le temps nécessaire à l'entraînement et à l'inférence est enregistré.	Développement / Sélection du modèle : Cette phase est identifiée comme la plus consommatrice en ressources. Elle consiste à tester plusieurs architectures et hyperparamètres. Entraînement : Il s'agit de la phase où le modèle apprend à partir des données (dans cette étude, des tâches de segmentation d'images 2D, IRM ou volumes 4D). Les auteurs notent que si le temps d'entraînement final est souvent rapporté, il ne représente qu'une partie de l'empreinte totale si l'on ne compte pas les multiples itérations nécessaires durant la sélection. Inférence : N'est pas incluse dans les calculs quantitatifs mais mentionnée comme l'une des phases du cycle de vie.	Méthode : Les auteurs utilisent nnU-Net comme exemple de modèle de segmentation médicale standard, afin d'évaluer la consommation d'énergie et les émissions associées à ce type de pipeline. L'étude compare deux modes d'entraînement pour évaluer les gains d'efficacité : la précision mixte automatique (AMP) (utilisant des formats de données float16) et la pleine précision (float32). Outils : L'article réalise une analyse comparative de quatre outils logiciels de suivi carbone issus de la littérature : MLEC (<i>Machine Learning Emissions Calculator</i>), EIT (<i>Experiment-Impact-Tracker</i>), Carbontracker et CodeCarbon. Les auteurs ont spécifiquement intégré Carbontracker	Niveau 2 - Effets d'usage : Optimisation : Passer de la pleine précision à la précision mixte réduit la charge computationnelle et donc la consommation d'énergie. Optimisation des calculs : Substituer la recherche par grille, très énergivore, par des méthodes plus efficaces comme la recherche aléatoire pour réduire le temps de calcul. Niveau 3 - Impacts structurels : Effet rebond : Les auteurs consacrent une section spécifique à ce risque. Ils avertissent que l'amélioration de l'efficacité (Green AI) ne réduit pas forcément l'impact total, car des méthodes plus économes peuvent augmenter la demande globale et	L'étude a mesuré la consommation d'énergie pour l'entraînement du modèle nnU-net (sur 1000 cycles d'entraînement) pour trois types de tâches de segmentation. Plus l'image est complexe et volumineuse, plus le coût est élevé. La segmentation du cerveau (volumes 4D) est la plus énergivore avec 66,1 kWh consommés. La segmentation du cœur (IRM 3D) consomme 48,9 kWh et la segmentation des noyaux cellulaires consomme 30,2 kWh. L'un des résultats les plus frappants est que l'impact environnemental d'un même calcul varie considérablement selon l'intensité carbone du réseau électrique local. Les émissions en Estonie sont ainsi trois fois plus élevées que celles enregistrées au Danemark pour un travail identique.	- L'étude utilise des estimations statistiques (Carbontracker) basées sur des cycles courts au lieu de réaliser des entraînements complets. - Absence de données d'intensité carbone en temps réel pour la majorité des régions du monde. - Certains logiciels comparés, comme MLEC, ont une vision incomplète de la consommation en omettant l'énergie utilisée par le CPU pour ne mesurer que celle du GPU. - L'étude utilise uniquement nnU-Net comme exemple de pipeline de segmentation, ce qui ne représente pas forcément toutes les autres architectures possibles.

			L'étude met l'accent sur les coûts récurrents liés à la recherche massive d'hyperparamètres, qui est la phase la plus consommatrice en ressources.	Prétraitement et post-traitement : Le cadre utilisé pour l'expérimentation (nnU-net) intègre également de manière automatique les étapes de prétraitement et post-traitement.	dans leurs scripts d'entraînement Pytorch pour suivre et prédire la consommation d'énergie et les émissions de CO ₂ eq.	entraîner une consommation d'énergie encore plus grande.	L'étude démontre que l'utilisation de la précision mixte automatique (AMP), qui fait passer les calculs du format float32 au format float16, réduit systématiquement la consommation d'énergie sans perte notable de performance.	- Périmètre limité à la segmentation d'images. - Configuration matérielle spécifique (GPU RTX 3090).
VAFAEI SADR et al. (2024)	Article de recherche	L'empreinte carbone opérationnelle liée à l'utilisation du deep learning en pathologie numérique pour le diagnostic des cancers du sein et de la prostate.	Énergie : Consommation calculée en temps réel des composants (CPU, GPU, RAM et système de refroidissement de l'ordinateur). Empreinte carbone : Émissions de gaz à effet de serre mesurées en tonnes métriques de CO ₂ eq, calculées pour plusieurs scénarios et extrapolées aux échelles nationale et mondiale. Ressources computationnelles : Nombre de paramètres, nombre de tuiles traitées et scénarios multi-tâches.	Inférence : L'étude se concentre presque exclusivement sur l'utilisation clinique à grande échelle. Acquisition des données : Évalue la consommation électrique liée à la numérisation des lames (scannage). Étapes exclues : La source précise qu'elle ne prend pas en compte l'entraînement (en raison des contraintes réglementaires allemandes) ni la fabrication ou le transport du matériel.	Méthode : Étude de modélisation évaluant quatre scénarios de déploiement (de 1 tâche à multitâche) et trois stratégies d'entrée de données (Image complète, tissus seulement ou régions d'intérêt seulement). Outils : Package experiment-impact-tracker, base de données Electricity Maps, architecture PaLM-540B (pour estimation), et bibliothèques Keras/TensorFlow.	Niveau 2 - Effets d'usage : Optimisation : Analyse des tissus ou des régions d'intérêt uniquement plutôt que de l'image entière pour réduire les émissions de 141 fois. La méthode pathomique est présentée comme une alternative à l'IA conventionnelle, avec un impact carbone 147 fois moindre.	L'étude montre que le choix des données analysées influence fortement l'empreinte carbone. En pathologie numérique, analyser uniquement les tissus plutôt que l'image complète pourrait réduire les émissions jusqu'à 141 fois. L'approche par pathomique est présentée comme beaucoup plus sobre que l'IA conventionnelle multitâche, avec un impact carbone jusqu'à 147 fois plus faible.	- Exclusion de l'étape d'entraînement des modèles pour se conformer à la réglementation allemande sur les dispositifs médicaux. - Exclusion du carbone incorporé, du transport et de la maintenance des infrastructures. - Extrapolations mondiales basées sur des scénarios théoriques faute de données précises sur le volume réel des cas de pathologie à l'échelle internationale.

Article	Type	Objet étudié	Dimensions environnementales	Étapes du cycle de vie	Méthode / Outils	Effets d'usage et impacts structurels	Principaux résultats	Limites
B. Revues, éditoriaux et articles de perspective								
CHAMPENDAL et al. (2025)	Revue de portée	Durabilité environnementale de l'IA appliquée à la radiologie	Énergie : La plus fréquemment abordée. Elle évalue la quantité d'électricité nécessaire pour entraîner ou faire fonctionner un modèle (mesurée en kWh ou Joules). Empreinte carbone : Évaluée dans 6 études, cette dimension mesure le potentiel de réchauffement global via les émissions de gaz à effet de serre (CO₂eq). Ressources informatiques : Cette catégorie (n=9) se concentre sur les aspects techniques du processus. Les métriques sont le temps d'entraînement et d'exécution, le nombre de cycles d'entraînement, les FLOPs, le nombre de paramètres du modèle et le temps d'inférence. Eau : Encore rare (n=2), cette dimension mesure les gallons ou litres d'eau utilisés, pour le refroidissement des	Cycle de vie complet : Cette revue de portée structure les stratégies selon quatre phases : l'infrastructure informatique, l'usage des données, la modélisation/entraînement et l'inférence. Production du matériel : Elle discute de l'extraction des terres rares et du carbone incorporé des GPU et du processeur spécialisé pour l'IA (TPU). Fin de vie : Elle identifie le déclassé et le recyclage des modèles et du matériel comme un manque critique non traité dans la littérature actuelle.	Méthode : Revue de portée structurée selon la méthodologie de l'Institut Joanna Briggs (JBI) et les directives PRISMA. L'analyse utilise le cadre du cycle de vie de Mehlman et al. pour classer les stratégies de durabilité. Outils : Logiciel Rayyan pour le tri des articles, bases de données MEDLINE, Embase, CINAHL et Web of Science.	Niveau 2 – Effets d'usage : Optimisation : Amélioration des flux de travail cliniques et réduction du temps d'occupation des salles. Amélioration de la qualité d'image permettant de diminuer les doses de produit de contraste injectées. Niveau 3 - Impacts structurels : Pression sur les ressources matérielles : Contribution aux déchets électroniques, à la dégradation des terres et à l'extraction de terres rares.	Sur 3 723 articles, seuls 13 traitent spécifiquement de la durabilité de l'IA en radiologie. L'article met surtout en évidence un manque important : la fin de vie du matériel et des données est très peu étudiée. Les stratégies de mitigation identifiées sont les architectures légères, la quantification et l'arrêt précoce.	- Peu d'études originales sur la durabilité de l'IA en radiologie, avec seulement 13 identifiées. - Manque de méthodes standardisées pour présenter les résultats, limitant la comparaison des impacts. - Phase de fin de vie du matériel et des données peu ou pas prise en compte. - Forte variabilité des architectures et des outils de mesure utilisés.

			serveurs ou pour la production d'électricité.					
DIETRICH & HANNEMAN (2025)	Éditorial	Impact environnemental des données utilisées pour développer l'IA en radiologie, avec une comparaison entre données cliniques réelles et données synthétiques.	Énergie : Dimension centrale. Comprend l'énergie utilisée pour préparer les bases de données cliniques, notamment pour les organiser et anonymiser les données, l'utilisation des serveurs hospitaliers et des systèmes basés sur le Cloud, ainsi que l'énergie consommée par les stations de travail haute performance lors de l'annotation manuelle par des experts. Empreinte carbone : Montre que l'estimation de l'empreinte carbone totale d'un projet d'IA en radiologie doit idéalement comptabiliser l'énergie utilisée à chaque étape : acquisition, stockage, annotation, entraînement, validation et inférence. Ressources computationnelles : Les auteurs évaluent l'impact des GPU pour entraîner les algorithmes	Acquisition et préparation des données : La curation, la désidentification (anonymisation) et l'organisation des données. Stockage : Utilisation des serveurs hospitaliers et des systèmes basés sur le Cloud. Annotation : Travail des experts sur des stations de travail à haute puissance. Développement du modèle : Entraînement, validation (évaluation de la fidélité et de la validité clinique du modèle produit), et inférence. Génération de données synthétiques : Entraînement d'un modèle générateur, puis création de nombreuses images annotées avec peu d'énergie supplémentaire.	Méthode : Éditorial proposant une analyse comparative théorique entre les pipelines de données réelles et les pipelines de données synthétiques.	Niveau 2 - Effets d'usage : Optimisation : Approches hybrides pour équilibrer performance clinique et responsabilité environnementale Substitution partielle : Utilisation de données synthétiques pour réduire la dépendance aux données réelles, notamment en limitant les coûts énergétiques liés à la curation et à l'annotation.	Les données réelles demandent beaucoup d'énergie pour la curation, l'annotation et le stockage. Les données synthétiques nécessitent un coût initial élevé pour entraîner le générateur, mais permettent ensuite de produire de nombreuses images annotées avec peu d'énergie supplémentaire.	- Source théorique et conceptuelle, sans mesures expérimentales directes. - L'étude pointe l'absence de méthode standardisée pour quantifier et comparer le coût carbone entre les données réelles et synthétiques. - Difficulté de mesurer de manière cohérente les contributions indirectes, telles que l'activité des développeurs ou la maintenance des infrastructures.

			d'apprentissage profond.					
DOO et al. (2024)	Revue / Article de perspective	Dualité de l'IA à l'intersection de la durabilité environnementale et de la radiologie	Énergie : Consommation des centres de données et de l'infrastructure informatique. Empreinte carbone : Émissions liées au développement et au stockage des données massives. Ressources computationnelles : Complexité des modèles, mémoire utilisée et types de processeurs utilisés. Matériaux : Impacts de la production du matériel et de l'extraction des métaux. Eau : Besoins pour le refroidissement des systèmes.	Développement et utilisation clinique : Analyse les phases d'entraînement, de validation et d'inférence. Stockage et transfert de données : Se concentre sur le stockage massif (Cloud vs On-site) et le transfert de données. Cycle de vie du matériel : Discute du carbone incorporé lié à la fabrication, au transport et à la fin de vie du matériel.	Méthode : Article de perspective synthétisant des estimations publiées sur les émissions de l'IA et proposant une liste d'actions concrètes pour rendre la radiologie plus durable.	Niveau 2 - Effets d'usage : Optimisation : Amélioration de la planification des scanners pour réduire les temps de veille. Réduction des agents de contraste via l'amélioration logicielle du signal. Substitution : Création d'images CT synthétiques à partir de l'IRM pour éviter un examen scanner réel. Induction : Le dépistage opportuniste génère de nouvelles données cliniques à partir d'examens existants et peut élargir les usages de l'imagerie médicale. Niveau 3 - Impacts structurels : Réduction de l'activité médicale inutile : Réduction possible des examens à faible valeur et des procédures redondantes. Collaboration renforcée : L'adoption de l'apprentissage	L'article insiste sur l'ambivalence de l'IA en radiologie. D'un côté, l'entraînement, l'inférence, le stockage et la multiplication des modèles peuvent augmenter les impacts environnementaux. De l'autre, certaines applications peuvent contribuer à une radiologie plus durable, par exemple en optimisant les scanners, en réduisant les examens inutiles ou en améliorant la planification clinique.	- Manque de données d'émissions spécifiques à la radiologie. - Calculs basés sur des estimations publiées pour des modèles de langage généralistes comme GPT-3. - Manque de transparence des fournisseurs de Cloud sur le mix énergétique réel et l'eau pour le refroidissement. - Absence de directives pour sélectionner des logiciels d'IA durables, empêchant une évaluation comparative au moment de l'achat.

						féderé et du partage de code évite que plusieurs institutions ne développent inutilement des modèles identiques. Optimisation logistique et humaine : Une meilleure planification des rendez-vous et du travail via l'IA réduit les émissions liées aux transports, tout en luttant contre le burnout des radiologues. Effet rebond : L'IA peut augmenter le nombre total d'exams en détectant davantage d'anomalies non recherchées, ce qui peut conduire à des exams supplémentaires.		
KOCAK et al. (2025)	Revue pédagogique	Paradoxe de la durabilité de l'IA en radiologie, analysé à travers ses impacts environnementaux, économiques et sociaux.	Énergie : Distingue l'énergie nécessaire pour l'entraînement et pour l'inférence. Empreinte carbone : Mesurée en tonnes de CO₂-eq (équivalent CO₂), elles incluent les émissions directes du matériel et les émissions indirectes	Entrainement et inférence : Analyse les besoins importants en calcul pour optimiser les paramètres et générer des prédictions. Stockage : Centres de données et refroidissement. Fabrication du matériel : Détaille	Méthode : Revue pédagogique analysant le paradoxe de durabilité de l'IA. Les auteurs proposent une approche globale intégrant les dimensions environnementales, économiques et sociales.	Niveau 2 - Effets d'usage : Optimisation : Triage intelligent activant les calculs haute performance uniquement en cas d'anomalie détectée. Auto-planification du personnel par l'IA remplaçant la gestion manuelle.	L'article présente l'IA en radiologie comme un paradoxe environnemental. Elle peut aggraver l'impact environnemental par l'entraînement, l'inférence, le stockage, la consommation d'eau et les déchets électroniques, mais	- Les méthodes actuelles sont inadéquates car elles se focalisent de manière isolée sur le carbone. - Dimensions économiques et sociales insuffisamment intégrées. - Absence de labels écologiques

			liées aux centres de données et au Cloud. Eau : Il s'agit d'une dimension souvent ignorée qui concerne le refroidissement des systèmes de calcul haute performance. La demande mondiale en eau pour l'IA pourrait atteindre 4,2 à 6,6 milliards de mètres cubes d'ici 2027. Déchets électroniques : La nécessité constante de matériel plus puissant entraîne une obsolescence rapide des équipements (GPUs, CPUs) qui sont souvent retirés avant la fin de leur vie opérationnelle. Ressources naturelles : La fabrication du matériel nécessite l'extraction de terres rares et de métaux rares.	l'extraction minière (néodyme, cobalt) et le raffinage. Fin de vie : Traite de l'accumulation des déchets électroniques toxiques (plomb, mercure).		Induction : L'IA peut induire une hausse du nombre d'études d'imagerie par patient. Obsolescence matérielle : Le besoin de puissance pour l'IA force le retrait prématuré de matériel encore fonctionnel. Niveau 3 - Impacts structurels : Effet rebond : Les gains de productivité peuvent entraîner une consommation importante de ressources diagnostiques. Inégalités d'accès : Risque d'inégalités si les modèles ne sont pas adaptés aux contextes locaux ou si l'accès est réservé aux institutions les plus riches.	elle peut aussi améliorer la durabilité en réduisant les examens inutiles, en optimisant l'usage des scanners et en limitant certains produits polluants. Les auteurs insistent aussi sur les enjeux économiques et sociaux, notamment les coûts élevés des logiciels et le risque d'inégalités d'accès. Ils proposent enfin un prototype d'écotabel pour aider les hôpitaux à comparer les outils d'IA en radiologie selon quatre critères environnementaux : la consommation d'énergie, les émissions de CO ₂ , l'utilisation d'eau et la production de déchets.	standardisés pour comparer les outils d'IA en radiologie. - Manque de transparence des vendeurs d'IA sur leurs données d'entraînement et les impacts environnementaux. - Évaluation complète difficile en raison du manque d'informations accessibles.
QUTTAIAH et al. (2025)	Article de recherche	Évaluation et hiérarchisation des impacts environnementaux des solutions de diagnostic médical basées sur l'IA.	Énergie : Quantité d'énergie électrique pour les centres de données et les infrastructures. Empreinte carbone : Bilan carbone des activités liées à l'IA.	Entraînement et déploiement : Analyse les phases de calcul intensif pour les diagnostics médicaux. Cycle de vie du matériel :	Méthode : Approche de décision multicritère intégrant la méthode Fuzzy Best Worst Method (FBWM) pour le poids des facteurs et le DEMATEL pour établir	Niveau 2 - Effets d'usage : Optimisation : Mentionne des méthodes d'entraînement visant à réduire les calculs inutiles et la	L'analyse identifie les déchets électroniques, l'épuisement des ressources naturelles et la consommation d'énergie comme les trois impacts les plus	- Résultat basé sur le jugement subjectif d'un panel d'experts, ce qui peut introduire des biais selon leur domaine de spécialisation

			Matériaux : Épuisement des ressources finies et extraction des minéraux rares. Eau : Usage intensif pour le refroidissement des centres de données. Déchets : Déchets électroniques et augmentation des déchets médicaux.	C'est l'une des sources les plus complètes sur le matériel, intégrant l'extraction des minéraux rares, la fabrication, l'usage et les déchets électroniques. Chaîne d'approvisionnement : Mentionne les émissions liées au transport et à la logistique.	les relations de cause à effet. Outils : Modèle d'optimisation linéaire résolu sous Excel.	consommation de ressources. Induction : Certains processus de diagnostic assistés par IA pourraient augmenter l'utilisation de consommables ou de dispositifs médicaux. Obsolescence : Identifie l'obsolescence rapide du matériel d'IA comme l'un des neuf facteurs environnementaux critiques Niveau 3 - Impacts structurels : Pression sur les ressources matérielles : Mentionne l'épuisement des ressources finies (métaux rares), dégradation des terres et perturbation de la biodiversité par l'activité minière liée au matériel IA.	critiques. L'épuisement des ressources (métaux rares) est identifié comme la cause racine la plus influente sur les autres facteurs.	(gestion, technique, médical). - Pas de mesures physiques directes, mais une hiérarchisation des facteurs. - Comparaison difficile avec les études quantitatives. - Utilisation de données incertaines ou incomplètes, ce qui peut affecter la robustesse finale.
THOMSON et al. (2025)	Revue systématique	Pratiques actuelles d'évaluation de la durabilité environnementale de l'IA en radiologie clinique.	Énergie : Cinq études mesurent l'énergie en joules, watts ou kilowattheures (kWh). Empreinte carbone : 3 études quantifient l'empreinte carbone.	Entrainement : 50 % des études quantitatives (soit 3 études) ont mesuré les impacts environnementaux uniquement durant la phase	Méthode : Revue systématique méthodologique recherchant des études cliniques quantitatives en radiologie discutant	Niveau 2 - Effets d'usage : Optimisation : L'IA comme outil pour réduire la pollution des eaux usées par le gadolinium en	La revue montre que seule une minorité des études cliniques quantifie réellement l'impact environnemental de l'IA en radiologie. Sur 18 études, seulement	- Aucune étude ne compare l'impact environnemental total d'un parcours clinique utilisant l'IA par rapport au standard de soins

			Rapportées en équivalent dioxyde de carbone (CO₂eq). Pollution liée aux produits de contraste : Discussions de quatre études sur la réduction possible du gadolinium dans les eaux usées grâce à l'IA. Dimensions non quantifiées : Eau, extraction et utilisation de minéraux et déchets électroniques.	d'apprentissage des algorithmes. Inférence : Les 50 % restants ont mesuré les impacts durant l'utilisation réelle de l'IA sur des données cliniques.	de la durabilité environnementale. Outils : Directives PRISMA et SWiM, logiciel Covidence pour le tri, et Excel pour l'extraction.	diminuant les doses nécessaires. Niveau 3 - Impacts structurels : Impact des infrastructures numériques : Conséquences croissantes sur les environnements matériels dues au cycle de vie des centres de données.	6 rapportent des mesures quantitatives, principalement limitées à l'énergie et aux émissions de CO₂eq. Les modèles légers apparaissent plus sobres que les modèles de pointe, avec des émissions de carbone réduites en médiane de 7,8 fois et une consommation d'énergie réduite de 3,2 fois. La revue montre aussi que de nombreux impacts importants, comme l'eau, les minéraux rares ou les déchets électroniques, sont encore peu ou pas quantifiés.	traditionnel sans IA. - Grande hétérogénéité des métriques utilisées dans la littérature (joules, watts, kWh). - 75 % des études ne mentionnent la durabilité que de manière superficielle (une seule phrase).
--	--	--	--	---	---	--	---	---

Source : élaboration propre de l'auteure sur la base des articles retenus.

Résumé : Ce mémoire analyse la manière dont l'impact environnemental de l'intelligence artificielle (IA) est évalué dans le domaine de l'imagerie médicale. Alors que l'IA est de plus en plus utilisée pour améliorer la qualité des images, accélérer certains examens et aider au diagnostic, son développement soulève aussi des questions environnementales importantes, notamment en termes de consommation d'énergie, d'émissions de gaz à effet de serre et d'utilisation de ressources matérielles.

Basé sur une revue de littérature critique et méthodologique, ce travail cherche à répondre à la question de recherche suivante : comment l'impact environnemental de l'IA en imagerie médicale est-il évalué dans la littérature scientifique, et quelles en sont les principales limites méthodologiques ? Pour y répondre, les études sélectionnées ont été comparées selon plusieurs critères : dimensions environnementales évaluées, étapes du cycle de vie prises en compte, méthodes et outils utilisés, effets indirects considérés, principaux résultats et limites méthodologiques. L'analyse révèle que les études se concentrent principalement sur la consommation d'énergie et les émissions de CO₂, que peu de travaux ont une perspective de cycle de vie complète et que les effets indirects, comme l'effet rebond, restent rarement intégrés.

Ce mémoire met ainsi en évidence un manque de normalisation des méthodes d'évaluation et montre la nécessité de développer des approches plus globales, harmonisées et multidimensionnelles pour mieux comprendre les impacts environnementaux de l'IA en imagerie médicale.

UNIVERSITÉ CATHOLIQUE DE LOUVAIN
Louvain School of Management

Place des Doyens, 1 bte L2.01.01, 1348 Louvain-la-Neuve
Boulevard Emile Devreux 6, 6000 Charleroi, Belgique
Chaussée de Binche 151, 7000 Mons, Belgique
www.uclouvain.be/lsm