



Thèse

2023

Open Access

This version of the publication is provided by the author(s) and made available in accordance with the copyright holder(s).

Intelligence Artificielle en Imagerie Neurovasculaire

Hofmeister, Jérémy

How to cite

HOFMEISTER, Jérémy. Intelligence Artificielle en Imagerie Neurovasculaire. 2023. doi:
10.13097/archive-ouverte/unige:169761

This publication URL: <https://archive-ouverte.unige.ch//unige:169761>

Publication DOI: [10.13097/archive-ouverte/unige:169761](https://doi.org/10.13097/archive-ouverte/unige:169761)



Section de Médecine Clinique
Département de Radiologie et d'Informatique
Médicale, Service de Radiologie

Thèse préparée sous la direction des Professeurs Dimitri VAN DE VILLE et Xavier MONTET

" Intelligence Artificielle en Imagerie Neurovasculaire "

Thèse
présentée à la Faculté de Médecine
de l'Université de Genève
pour obtenir le grade de Docteur en médecine
par

Jeremy HOFMEISTER

de
Hermance (GE) et Winterthur (ZH)

Thèse n° 11170

Genève
2023

Remerciements

J'ai commencé cette thèse il y a plusieurs années, grâce à Dimitri Van De Ville et Xavier Montet, qui ont accepté de superviser mes recherches sur l'intelligence artificielle (IA) en imagerie médicale pendant mon internat en radiologie. En poursuivant ma formation en neuroradiologie interventionnelle, j'ai eu l'occasion de continuer à travailler avec Dimitri et Xavier, qui m'ont aidé à appliquer mes recherches en IA à l'imagerie neurovasculaire. Ensemble, nous avons mené plusieurs études portant sur le rôle de l'IA dans la détection et le diagnostic de maladies sur des images radiologiques et sur les aspects " non interprétatifs " de l'IA pour améliorer la qualité ou la reproductibilité des images médicales. Dans cette thèse, j'ai voulu retracer le chemin qui m'a conduit à découvrir le rôle de l'IA en radiologie, puis ses applications en imagerie neurovasculaire. J'ai également voulu mettre en avant les collaborations multidisciplinaires qui m'ont permis de mieux comprendre l'importance de la discussion entre médecins et scientifiques pour l'émergence de questions et de réponses pertinentes pour le développement de notre domaine, l'imagerie clinique.

Je tiens à remercier Dimitri Van De Ville pour m'avoir accompagné pendant de nombreuses années dans mon parcours scientifique, d'abord à travers mon mémoire de master sur l'IRM fonctionnelle et maintenant à travers la supervision de mon doctorat en médecine. Je tiens à le remercier pour son soutien et son enthousiasme à partager sa passion et son expertise dans le traitement des images médicale, ce qui m'a permis de mieux comprendre le potentiel derrière les images que j'utilise quotidiennement pour traiter les patients.

Je tiens également à remercier Xavier Montet pour m'avoir accompagné dans les activités cliniques et de recherche tout au long de mon internat en radiologie et pour m'avoir soutenu dans l'avancement de nos projets de recherche. Je tiens à le remercier pour avoir partagé sa passion pour la recherche translationnelle et ses idées sur la façon dont les médecins et les scientifiques peuvent travailler ensemble pour faire progresser notre domaine clinique et la prise en charge de nos patients.

Je remercie également mes collègues de neuroradiologie interventionnelle aux HUG, Paolo, Gianmarco et Andrea, pour m'avoir permis de poursuivre ma formation clinique tout en appliquant et en étendant mes travaux de recherche en IA au domaine de l'imagerie diagnostique et thérapeutique des maladies neurovasculaires. Je remercie également mes

collègues de notre groupe de recherche à Campus Biotech pour m'avoir permis de découvrir de nouvelles perspectives sur la prise en charge des pathologies neurovasculaires, principalement grâce à la robotique.

Enfin, je tiens à remercier ma famille, mes parents, et mes frères, qui ont toujours encouragé mon développement, principalement par des discussions enrichissantes et par leur appel à vulgariser et à mieux transmettre le rationnel de mes différents projets.

Genève, le 27 January 2023 (version initiale)

Jeremy Hofmeister

Genève, le 27 février 2023 (version corrigée)

A handwritten signature in dark blue ink, consisting of several fluid, connected strokes. The signature is positioned to the right of the text 'Genève, le 27 février 2023 (version corrigée)'. It starts with a long diagonal stroke from the bottom left, followed by a loop, then a series of smaller loops and a final horizontal stroke extending to the right.

Résumé (français)

L'intelligence artificielle joue un rôle croissant dans l'imagerie diagnostique et thérapeutique des maladies neurovasculaires. Nous reverrons ici la portée et l'histoire de l'IA et ses applications récentes et potentielles en imagerie neurovasculaire, en traitant des pathologies les plus courantes. Nous verrons comment les modèles d'IA contribuent au diagnostic en imagerie neurovasculaire, et comment ils présentent un potentiel intéressant pour l'imagerie quantitative. Nous verrons également comment ils élargissent le potentiel des images en fournissant des informations invisibles à l'œil humain. Nous verrons que le rôle de l'IA ne se limite pas au diagnostic, mais s'applique à toutes les étapes du workflow en imagerie, y compris les aspects "non interprétatifs". Enfin, nous discuterons des implications, limites et biais de l'IA en imagerie neurovasculaire, en rappelant que son champ d'application en médecine est actuellement étroit et essentiellement utile pour répondre à des applications spécifiques.

Résumé (anglais)

Artificial intelligence is becoming increasingly important in the diagnostic and therapeutic imaging of neurovascular disease. Here we will review the scope and history of AI and its applications in neurovascular imaging, addressing recent and potential developments for the most common pathologies. We will see how AI models contribute to the detection and diagnosis in neurovascular imaging and how they hold exciting possibilities for quantitative imaging. We will also see how they extend the potential of images by providing information invisible to the human eye. We will see that the role of AI is not limited to diagnosis but applies to all stages of the imaging workflow, including "non-interpretive" aspects. Finally, we will discuss the implications, limitations, and biases of AI in neurovascular imaging, reminding that the scope of AI models in healthcare is currently narrow and essentially useful to address a specific application.

Table des Matières

REMERCIEMENTS.....	2
RÉSUMÉ (FRANÇAIS).....	4
RÉSUMÉ (ANGLAIS).....	4
INTELLIGENCE ARTIFICIELLE.....	6
DEFINITION DE L'IA.....	7
PORTÉE ET FORMES D'IA.....	8
HISTOIRE DE L'IA.....	9
Box 1 – Événements choisis dans l'histoire de l'IA.....	10
HISTOIRE DE L'IA EN MÉDECINE.....	14
IA EN NEUROIMAGERIE CLINIQUE.....	16
Box 3 – Concepts principaux en IA.....	18
MALADIES NEUROVASCULAIRES.....	22
DEFINITION DES MALADIES NEUROVASCULAIRES.....	22
IMAGERIE DIAGNOSTIQUE DES MALADIES NEUROVASCULAIRES.....	23
Box 4 – Techniques imageries neurovasculaires.....	25
IMAGERIE THÉRAPEUTIQUE DES MALADIES NEUROVASCULAIRES.....	27
IA & IMAGERIE NEUROVASCULAIRE.....	29
ANATOMIE NEUROVASCULAIRE.....	29
AVC ISCHÉMIQUE AIGU.....	32
<i>Imagerie diagnostique de l'AVC.....</i>	34
<i>Traitement de l'AVC.....</i>	35
<i>Athéromatose carotido-vertébrale.....</i>	36
HÉMORRAGIE CÉRÉBRALE.....	37
<i>Diagnostique de l'HIC.....</i>	38
<i>Anévrismes cérébraux.....</i>	39
<i>Malformations vasculaires.....</i>	41
PATHOLOGIES VEINEUSES CÉRÉBRALES.....	43
PERSPECTIVES.....	44
CONCLUSION.....	46
RÉFÉRENCES.....	46
APPENDIX.....	55
1. Generative adversarial networks Improve the reproducibility and discriminative power of radiomic features.....	55
2. nnUNet for unified cerebral artery segmentation on 3DRA, CTA and TOF-MRI.....	56
3. CTA to 3DRA using generative adversarial networks.....	57
4. Clot-based radiomics predict a mechanical thrombectomy strategy for successful recanalization in acute ischemic stroke.....	58
5. Cerebral aneurysm segmentation and quantitative measurement on TOF-MRI.....	59

Intelligence Artificielle

Qui a imaginé le premier les concepts d'intelligence artificielle et de systèmes autonomes capables d'accomplir des tâches normalement réservées aux humains ? Bien que le terme "intelligence artificielle" ait été inventé dans la seconde moitié du XXe siècle et que les premières applications concrètes de machines automatiques remontent à la fin du Moyen Âge et à la Renaissance, l'idée de créer une vie artificielle semble avoir été envisagée bien avant que la technologie ne rende de telles réalisations possibles.¹⁻³ Historiquement, de nombreux inventeurs ont rêvé de créer des machines pensantes, et ce désir remonte à l'époque de la Grèce antique.

Franc-tireur parmi les autres dieux de la mythologie grecque, Héphaïstos est le dieu du feu, de la forge, de la métallurgie et des volcans. Il fabriquait des armes, des armures et des équipements spéciaux pour d'autres dieux et héros, ou des objets d'une extrême beauté, d'une conception ingénieuse et d'un savoir-faire sublime. Dans une scène de l'Iliade, alors que Thétis visite la forge d'Héphaïstos, elle observe quelque chose d'étonnant : Héphaïstos est assisté d'une équipe d'automates féminins qu'il a créé artificiellement et qui se déplacent et pensent par eux-mêmes.

*"Héphaïstos quitta son soufflet, prit à la main un lourd bâton et se dirigea vers le seuil de la porte en boitant. Et pour soutenir leur maître, ses assistants se déplacèrent. Ils sont dorés et ressemblent à des jeunes femmes vivantes. Il y a de l'intelligence dans leur cœur, de la parole et de la force, et ils ont appris des dieux immortels comment faire les choses. Ils agissent avec agilité pour soutenir leur maître."*⁴

Ces assistants d'or créés par Héphaïstos sont non seulement spontanément mobiles, mais ils anticipent et répondent à ses besoins. Et ils sont dotés de caractéristiques humaines indiscernables de la réalité : conscience, intelligence, apprentissage, raison et parole. De nombreux historiens pensent que ce mythe des vierges d'or d'Héphaïstos et d'autres mythes antiques qui envisagent des moyens d'imiter, d'augmenter et de transcender la vie naturelle préfigurent les notions modernes de machines contrôlées par une forme d'intelligence artificielle.^{5,6} Dans ces récits, les automates et autres machines créées par des dieux jouent déjà un rôle en aidant ou en assistant les dieux ou les humains. Ils peuvent également menacer une civilisation et remettre en question le sens de l'être humain en

repoussant les limites de ce que les humains peuvent créer, comme dans le mythe de Pandore, une femme créée par les dieux pour punir l'humanité d'avoir accepté la technologie divine du feu volée par un Titan. Ces mêmes questions persisteront dans les débats historiques sur l'intelligence artificielle, même dans ses applications pratiques, qui se développent dans de nombreux domaines en ce début de XXI^e siècle.⁷

Dans ma thèse, je définirai brièvement l'intelligence artificielle (IA), ses perspectives historiques, et sa portée pour comprendre ses applications et développements récents en imagerie neurovasculaire. Nous passerons ensuite en revue les perspectives que l'IA ouvre dans la prise en charge des pathologies neurovasculaires les plus courantes. Cet ouvrage se veut lisible à la fois par un lectorat de médecins neurovasculaires désireux d'en savoir plus sur l'IA, et par un public de chercheurs et développeurs en IA qui souhaitent faire le lien entre les applications récentes de l'IA et les perspectives de l'IA en imagerie neurovasculaire.

Definition de l'IA

Le terme "intelligence artificielle" a été proposé au cours du Dartmouth Summer Research Project on Artificial Intelligence, qui s'est tenu pendant l'été 1956, et est considéré comme l'événement fondateur du domaine académique de l'IA.⁸ L'IA est un domaine qui implique la création de machines "intelligentes" capables d'effectuer des tâches qui requièrent normalement une intelligence humaine. En d'autres termes, il s'agit de la capacité d'une machine à imiter ou à reproduire les fonctions cognitives de l'esprit humain.

Qu'est-ce que l'intelligence ?

L'intelligence humaine n'est pas un trait unique, mais une combinaison de capacités cognitives complexes et de conscience de soi. Grâce à l'intelligence, les humains possèdent les capacités cognitives nécessaires pour percevoir, apprendre, comprendre, se souvenir, raisonner, innover, prendre des décisions et communiquer.

Plus d'un siècle avant la construction des premiers ordinateurs, lors de la conception d'outils programmables, les gens se demandaient s'ils pourraient un jour devenir intelligents.³ Après la Seconde Guerre mondiale, alors qu'il travaillait sur l'un des premiers ordinateurs, Alan Turing a apporté une contribution décisive au débat sur la possibilité de l'intelligence artificielle. Dans un article publié en 1950, il pose la question de savoir si les machines peuvent penser et propose un test utilisant un jeu d'imitation pour y répondre.⁹ Il postule

que si une machine peut imiter les réponses humaines lors d'une interaction avec un humain au point que ce dernier ne peut pas dire s'il interagit avec un autre humain ou un ordinateur, alors elle possède une intelligence artificielle. Bien que ce test, appelé plus tard le "test de Turing", soit imparfait, il fournit un point de référence pour qu'une machine puisse être considérée comme ayant une intelligence artificielle.¹⁰

Portée et formes d'IA

Quel type d'intelligence une machine peut-elle développer ?

Dans sa forme la plus simple, l'IA est un domaine qui associe l'informatique à des ensembles de données complexes pour résoudre des problèmes. Elle est mise en œuvre par le développement d'algorithmes et de modèles statistiques qui permettent aux ordinateurs de traiter et d'analyser de grandes quantités de données pour percevoir, apprendre, mémoriser, raisonner, prendre des décisions et faire des prédictions. Plusieurs types d'IA sont définis soit par leurs capacités, soit par leurs fonctionnalités (figure 1).

Lorsque l'IA est définie par ses capacités, on dit qu'elle est soit étroite (*narrow*), soit générale (*general*), soit super-intelligente, selon ses capacités et le caractère généralisable de son "intelligence".^{11,12} L'IA étroite est capable d'effectuer une tâche spécifique et dédiée. Il s'agit de la forme d'IA la plus courante et la plus disponible aujourd'hui. Cela concerne par exemple, un outil d'IA qui diagnostiquerait certaines pathologies sur une image médicale. L'IA générale peut effectuer n'importe quelle tâche intellectuelle avec l'efficacité d'un humain. La super IA est un niveau d'intelligence auquel les machines peuvent surpasser l'intelligence humaine et effectuer n'importe quelle tâche mieux que les humains.

Si l'IA est définie par sa fonctionnalité, elle peut être divisée en quatre types : les machines réactives (*reactive machines*), la mémoire limitée (*limited memory*), la théorie de l'esprit (*theory of mind*) ou la conscience de soi (*self-awareness*).⁶ Les machines réactives sont le type d'IA le plus basique et consistent en des outils qui réagissent à un input selon un modèle précédent afin de produire un output. Là encore, il s'agirait d'un outil d'IA qui diagnostiquerait certaines pathologies prédéfinies sur une image médicale. Les machines à mémoire limitée sont des systèmes dotés d'une capacité de mémoire à court terme qui leur permet de produire un output en fonction d'inputs rencontrés dans une situation donnée. Un exemple serait une voiture autonome qui adapte sa conduite à l'environnement. Les

systèmes dotés d'une théorie de l'esprit seraient capables de comprendre les émotions et les croyances humaines, et auraient la capacité d'interagir socialement avec les humains. Ce type d'IA fait l'objet de nombreuses recherches et ses applications en sont encore à leurs débuts. Enfin, les systèmes d'IA conscients d'eux-mêmes seraient superintelligents et auraient leur propre conscience et leurs propres émotions. Ce type d'IA reste pour l'instant un concept théorique.

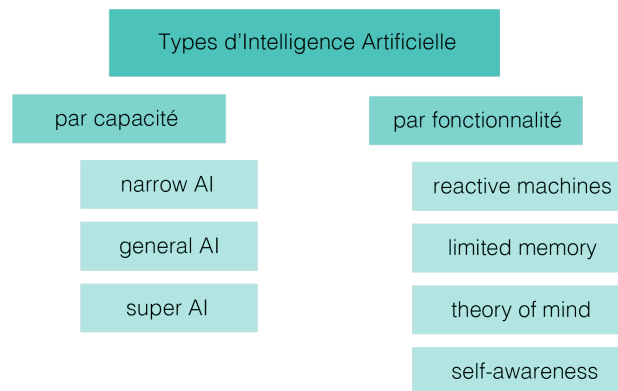


Figure 1 : Types d'intelligence artificielle, défini soit par leur capacités, soit par leur fonctionnalité.

Histoire de l'IA

Le concept d'IA a une longue histoire, qui commence dans l'Antiquité avec des mythes et des légendes sur des êtres intelligents créés par des dieux ou des artisans ingénieux. Les origines de l'IA moderne remontent aux efforts des philosophes qui ont cherché à comprendre le processus de pensée humain comme une série d'opérations symboliques. Ces travaux ont finalement abouti à la création, dans les années 1940, d'ordinateurs numériques programmables, basés sur les principes du raisonnement mathématique. L'existence de ces ordinateurs a amené certains scientifiques à discuter de la possibilité de créer un cerveau artificiel.¹³

L'étude de l'IA en tant que discipline universitaire a débuté en 1956, mais ses origines remontent aux années 1950, lorsque des chercheurs ont commencé à explorer la possibilité de créer des machines capables d'effectuer des tâches nécessitant une intelligence de type humain, comme l'apprentissage, la résolution de problèmes et la prise de décision.^{8,10} L'IA a connu plusieurs cycles d'engouement et de financement, suivis de déceptions et d'une réduction des financements (appelés "hivers de l'IA"), puis d'un renouveau avec de nouvelles approches et de nouveaux succès.¹⁴⁻¹⁶ Aujourd'hui, l'IA et ses sous-domaines les plus

populaires, comme le deep learning, ont fait des progrès considérables et sont utilisés dans de nombreux domaines, notamment le traitement du langage naturel, la reconnaissance d'images et de la parole, et les véhicules à conduite autonome.¹⁷

Box 1 – Événements choisis dans l'histoire de l'IA

Avant le 20e siècle

Antiquité Les concepts de créatures artificielles et

intelligentes ont été introduits dans les mythes grecs, comme Héphaïstos et Pygmalion.

~250 BC L'inventeur grec Ctésibius crée le premier système autorégulateur, appelé *Clepsydra* ("voleur d'eau"), pour remplir automatiquement le récipient utilisé dans les horloges à eau.

19e Charles Babbage et Ada Lovelace ont imaginé l'un des premiers ordinateurs mécaniques (*Analytical Engine*), qui n'a cependant jamais été construit.

Les idées de l'interaction entre humains et machines artificielles ont été développées dans des essais et des fictions, comme dans *Frankenstein* de Mary Shelley et " Darwin among the Machines " de Samuel Butler."

1900-40s

1913 Le livre "Principia Mathematica" de Bertrand Russell et Alfred North Whitehead révolutionne le domaine de la logique.

1915 Leonardo Torres y Quevedo met au point une machine d'échecs automatique (*El Ajedrecista*).

1928-29 Le premier robot (*Gakutensoku*) est développé par le biologiste japonais Makoto Nishimura.

1939 Un ordinateur numérique programmable (l'ordinateur *Atanasoff Berry*) capable de résoudre simultanément plusieurs équations linéaires est mis au point à l'*Iowa State University*.

1939-45 Les premiers ordinateurs modernes ont été développés pour le décodage pendant la Seconde Guerre mondiale (tels que Z3, ENIAC et Colossus).

1943 Walter Pitts et Warren McCulloch étudient des réseaux idéalisés de neurones artificiels et la

manière dont ils peuvent exécuter des fonctions logiques simples. Leurs travaux ont posé les bases de ce que l'on appellera plus tard les réseaux neuronaux.

1945 John von Neumann et Oskar Morgenstern introduisent la théorie des jeux, qui devient essentielle au progrès de l'intelligence artificielle. Vannevar Bush publie un article ("As We May Think") dans lequel il expose une vision du futur dans laquelle les ordinateurs assisteraient les humains et la façon dont la technologie jouerait un rôle dans les tâches humaines.

1950-56: La naissance de l'intelligence artificielle

Dans les années 1950, lorsque les ordinateurs numériques ont été introduits, les scientifiques ont réalisé que les machines capables de traiter des nombres pouvaient également traiter des symboles, ce qui laissait entrevoir la possibilité que la manipulation de symboles soit au cœur de la pensée humaine. Cela a marqué une nouvelle approche de la création de machines pensantes.

1949-51 Les premiers programmes d'IA sont développés par Christopher Strachey (jeu de dames) et Dietrich Prinz (jeu d'échecs) et exécutés sur la machine Ferranti Mark 1 à l'université de Manchester. Au milieu des années 50 et au début des années 60, Arthur Samuel a également écrit un programme de jeu de dames capable de rivaliser avec un joueur amateur.

1950 Alan Turing publie le concept du "*Imitation Game*", connu plus tard sous le nom de "test de Turing", qui présente une méthode permettant de mesurer la capacité d'une machine à penser comme un être humain. Cet article a fait date dans l'histoire

- de l'IA, car il explore l'idée de créer des machines capables de simuler un comportement intelligent de niveau humain.
- Isaac Asimov publie ses "Trois lois de la robotique".
- 1951 Marvey Minsky et Dean Edmonds construisent la première machine à réseau neuronal (SNARC).
- 1955 Allen Newell et Herbert A. Simon (avec l'aide de J.C Shaw) créent le "Logic Theorist", un programme capable de prouver 38 des 52 premiers théorèmes des Principia Mathematica de Russell et Whitehead. Il a également découvert des preuves nouvelles et efficaces pour certains d'entre eux.
- 1956 Le Dartmouth Summer Research Project on Artificial Intelligence (DSRPAI) est organisé par John McCarthy, Marvin Minsky, Claude Shannon et Nathan Rochester. C'est la première fois que le terme "intelligence artificielle" est introduit et défini comme "la science et l'ingénierie de la fabrication de machines intelligentes".
- 1956-74: L'IA symbolique**
- À la suite du workshop de Dartmouth de 1956, les chercheurs ont réalisé des progrès remarquables dans la création de programmes d'IA capables de comportements intelligents, comme la résolution d'équations algébriques, la démonstration de théorèmes géométriques et même la communication en anglais. Malgré le scepticisme de certains, les chercheurs étaient positifs quant au potentiel de l'IA et pensaient qu'une machine totalement intelligente pourrait être construite en quelques décennies. Cela a conduit des organisations gouvernementales telles que la DARPA à investir massivement dans la recherche sur l'IA.*
- 1958 Lisp, un langage de programmation toujours utilisé dans la recherche sur l'IA, est développé au MIT par McCarthy.
- 1959 Arthur Samuel invente le terme " machine learning " en développant un programme informatique capable de rivaliser avec des joueurs d'échecs humains.
- 1961 Le premier bras robotique industriel capable de suivre une série de commandes prédéfinies (Unimate) est introduit sur la chaîne de montage de General Motors pour automatiser le processus de fonderie sous pression.
- 1964-65 Joseph Weizenbaum crée ELIZA, un chatbot qui utilise le traitement du langage naturel et la correspondance de modèles pour simuler une conversation humaine en anglais. Eliza a ouvert la voie aux futurs chatbots et a comblé le fossé entre les humains et les machines, même s'il n'avait pas la capacité d'apprendre par l'interaction.
- 1966-72 Shakey, créé par l'Institut de recherche de Stanford, est le premier robot mobile capable d'effectuer des actions complexes et d'interpréter des instructions, ce qui en fait une réalisation historique dans les domaines de l'IA et de la robotique. Le projet combinait les domaines de l'intelligence artificielle, de la navigation et de la vision par ordinateur. Il a été surnommé "la première personne électronique".
- 1968 Le film de science-fiction "2001 : L'Odysée de l'espace", réalisé par Stanley Kubrick, introduit l'idée de machines dotées d'IA auprès d'un large public grâce à sa représentation de HAL, un ordinateur doté d'intelligence artificielle qui contrôle le vaisseau spatial à propulsion nucléaire Discovery One.
- 1969 La publication de "Perceptrons" par Marvin Minsky et Seymour Papert expose les limites de la structure à deux couches de type "feed-forward" des réseaux neuronaux, ce qui entraîne une diminution du financement et de la confiance dans le domaine, connue sous le nom de premier "hiver de l'IA". Malgré ce revers, les progrès de l'IA se sont poursuivis au cours de cette période.
- 1974-80 : First AI winter**
- Au cours des années 1970, le domaine de l'IA a fait l'objet de critiques et d'une baisse de financement en raison d'attentes irréalistes et de difficultés à résoudre des problèmes complexes tels que la puissance de traitement limitée des ordinateurs, l'intractabilité, l'explosion combinatoire, la nécessité de connaissances et de raisonnements fondés sur*

le bon sens, le paradoxe de Moravec et les problèmes de cadre et de qualification. Malgré ces difficultés, la recherche dans des domaines tels que la programmation logique et le raisonnement fondé sur le bon sens s'est poursuivie.

1978 Le ministère japonais du commerce international et de l'industrie a lancé le projet de système informatique de cinquième génération dans le but de réaliser une percée significative dans la technologie informatique et de donner au Japon un avantage concurrentiel. Doté d'un budget de 850 millions de dollars, le projet visait à créer des ordinateurs capables d'effectuer des tâches similaires à celles des humains, comme le traitement du langage naturel, l'interprétation et l'analyse d'images. Ce projet était une réponse à l'hiver de l'IA aux États-Unis et un effort pour réaliser le "rêve de l'IA" et développer une technologie d'IA avancée.

1979 Le Stanford Cart, un robot mobile équipé d'un téléviseur et d'une télécommande, est mis au point et démontre sa capacité à se déplacer dans une pièce remplie de chaises sans intervention humaine pendant environ 5 heures. Il s'agit de l'un des premiers exemples de véhicules autonomes.

1980-87: Première résurgence de l'IA

Dans les années 1980, les entreprises ont commencé à adopter des systèmes experts, des programmes d'IA qui utilisent les connaissances d'experts pour répondre à des questions ou résoudre des problèmes, ce qui a conduit à mettre l'accent sur la recherche en IA basée sur les connaissances. Le gouvernement japonais a également investi massivement dans l'IA par le biais du projet de système informatique de cinquième génération. Le connexionnisme, qui utilise les réseaux neuronaux, connaît un renouveau avec les travaux de John Hopfield sur les réseaux de Hopfield et la popularisation par les informaticiens Geoffrey Hinton et David Rumelhart de la backpropagation pour la formation des réseaux neuronaux, ce qui permet une résurgence du domaine.

1980 Première conférence nationale de l'American Association for Artificial Intelligence (AAAI) organisée à Stanford.

1986 Le projet NAVLAB de l'université Carnegie Mellon, dirigé par Ernst Dickmanns, met au point le premier véhicule autonome, une camionnette Mercedes-Benz équipée de capteurs et de caméras. Le véhicule était capable de rouler à une vitesse allant jusqu'à 55 mph sur des routes désertes, marquant ainsi une étape importante dans le domaine des voitures sans conducteur.

1987-93 : Deuxième hiver de l'IA

Le deuxième hiver de l'IA s'est produit à la fin des années 1980 et au début des années 1990 pour plusieurs raisons, notamment l'échec des systèmes experts, qui avaient été largement adoptés par les entreprises mais n'ont pas tenu leur promesse de connaissances et de raisonnement généralisés au niveau des experts. Le manque de puissance de calcul et d'algorithmes efficaces pour former des réseaux neuronaux a également joué un rôle dans le déclin du financement et de l'intérêt pour l'IA. Le battage médiatique excessif des capacités de l'IA a suscité des attentes irréalistes et des déceptions, ce qui a entraîné un déclin du financement de la recherche en IA et une période de stagnation relative dans ce domaine.

1988 Judea Pearl introduit les réseaux bayésiens dans sa publication "Probabilistic Reasoning in Intelligent Systems". Ces mathématiques sont devenues des algorithmes clés pour l'inférence dans des modèles de probabilité complexes. L'impact de ces travaux sur l'IA a été considérable et ils continuent d'être largement utilisés dans les applications d'apprentissage automatique et d'IA.

Fin 80s Yann LeCun et ses collègues d'AT&T Bell Labs, ont développé des réseaux neuronaux convolutifs pour des tâches de reconnaissance d'images, notamment la reconnaissance de chiffres manuscrits (MNIST).

1993-2011: Deuxième résurgence de l'IA

1995	Richard Wallace développe A.L.I.C.E (Artificial Linguistic Internet Computer Entity) qui s'inspire d'ELIZA de Joseph Weizenbaum. Cependant, A.L.I.C.E inclut l'utilisation d'un échantillon de données en langage naturel, ce qui le distingue d'ELIZA.	2007	ImageNet, une grande base de données d'images annotées, est rendue publique pour faire avancer la recherche sur les logiciels de reconnaissance d'objets.
1997	Jürgen Schmidhuber et Sepp Hochreiter développent l'architecture LSTM (Long Short-Term Memory), un type de réseau neuronal récurrent (Recurrent Neural Network) qui est désormais largement utilisé pour les tâches de reconnaissance de la parole et de l'écriture.	2011	Watson d'IBM, un ordinateur capable de répondre à des questions en langage naturel, bat les anciens champions de Jeopardy ! Ken Jennings et Brad Rutter. Apple lance Siri, un assistant personnel à commande vocale pour ses utilisateurs, qui utilise une interface en langage naturel pour comprendre et répondre aux commandes vocales.
1997	Deep Blue, l'ordinateur d'IBM jouant aux échecs, bat le champion du monde en titre et grand maître Gary Kasparov, marquant ainsi la première fois qu'un programme informatique bat un champion du monde en titre.	2012	Alex Krizhevsky et Ilya Sutskever développent une nouvelle architecture de réseau neuronal profond appelée "réseaux neuronaux convolutifs" (<i>Convolutional Neural Networks</i>) qui améliore considérablement la précision de la reconnaissance d'images. Cette nouvelle approche, appelée AlexNet, a remporté le concours ImageNet Large Scale Visual Recognition Challenge avec un taux d'erreur de 15,3 % dans le top 5. Cette percée a suscité un regain d'intérêt pour le domaine de l'IA et a servi de preuve de concept pour l'utilisation de l'apprentissage profond dans d'autres domaines tels que la reconnaissance vocale et le traitement du langage naturel.
1999	Sony lance AIBO, un robot à intelligence artificielle conçu pour apprendre par l'interaction avec son environnement et capable de comprendre plus de 100 commandes vocales.	2014	Microsoft et Amazon lancent également leurs propres assistants personnels, respectivement Cortana et Alexa.
2001	Sortie du film de science-fiction <i>A.I. "Artificial Intelligence"</i> de Steven Spielberg, qui met en scène un androïde enfantin programmé pour aimer.		Les réseaux adversariaux génératifs (<i>Generative Adversarial Networks</i>) ont été introduits par Ian Goodfellow et ses collègues, pour générer de nouvelles données inédites qui ressemblent à un ensemble de données d'entraînement donné.
2002	iRobot lance le Roomba, un aspirateur autonome capable de naviguer et d'éviter les obstacles.		
2004	Les rovers d'exploration robotisés de la NASA, <i>Spirit</i> et <i>Opportunity</i> , ont réussi à naviguer sur la surface de Mars sans intervention humaine.		

Since 2006-12: L'essor du Deep Learning

Grâce aux progrès de la puissance de calcul et à la disponibilité de grands ensembles de données, le deep learning et les réseaux neuronaux se sont imposés comme l'approche principale dans la recherche sur l'IA, ce qui a permis des avancées significatives dans la reconnaissance des images et de la parole.

2006	Geoffrey Hinton et ses collègues ont présenté les <i>Deep Belief Networks</i> , qui sont un type de modèle de deep learning non supervisé.	2015-17	AlphaGo de Google DeepMind, un programme de jeu de go alimenté par l'IA, bat plusieurs joueurs de go professionnels, dont le champion européen Fan Hui (2015), le champion coréen Lee Sedol (2016) et le numéro 1 mondial Ke Jie (2017), lors d'une série de matchs.
------	--	---------	--

References:

Buchanan BG. A (Very) Brief History of Artificial Intelligence. *AI Magazine* 2005.

Delipetrev B, Tsinaraki C, Kostic U. Historical Evolution of Artificial Intelligence. Luxembourg: Publications Office of the European Union 2020.

Haenlein M, Kaplan A. A brief history of artificial intelligence: On the past, present, and future of artificial intelligence. *Calif Manage Rev* 2019.

McCorduck P. *Machines Who Think: A Personal Inquiry into the History and Prospects of Artificial Intelligence*. AK Peters, Ltd. 2004.

McCorduck P, Minsky M, Selfridge O. History of artificial intelligence. *IJCAI* 1977.

Moor J. The Dartmouth College Artificial Intelligence Conference: The Next Fifty Years. *AI Magazine* 2006.

Russell SJ, Norvig P. *Artificial intelligence: a modern approach* (4th edition). Pearson 2019.

Histoire de l'IA en médecine

L'utilisation de l'intelligence artificielle en médecine remonte à la fin des années 1950 et au début des années 1960, lorsqu'elle a été appliquée pour la première fois à la prise de décision médicale.¹⁸ Au cours des décennies qui ont suivi, l'IA a été utilisée dans diverses applications médicales, notamment le diagnostic, la planification des traitements et la découverte de médicaments.¹⁹⁻²¹ L'un des premiers exemples d'IA en médecine a été le développement de MYCIN, un programme informatique conçu pour faciliter le diagnostic et le traitement des infections. MYCIN utilisait des techniques d'intelligence artificielle telles que les systèmes experts et le traitement du langage naturel pour analyser les données des patients et formuler des recommandations de traitement fondées sur des connaissances spécialisées et un système de règles.²²

Au fil des années, l'IA a été utilisée dans de nombreuses disciplines médicales, notamment la radiologie, la pathologie, la médecine clinique et l'oncologie, grâce au développement de nouveaux algorithmes d'IA capables de traiter différents types de données, comme des images ou du texte non structuré.^{23,24} Depuis 2018, les premiers programmes informatiques utilisant l'IA ont été approuvés par la FDA pour une utilisation clinique.^{25,26} La grande majorité de ces outils d'IA actuellement développés et utilisés par les médecins sont des IA étroites et des machines réactives, avec des algorithmes capables d'effectuer une tâche spécifique et prédéfinie en réponse à un input donné. Cependant, l'IA est un élément clé de la médecine personnalisée couplée au big data, car elle a le potentiel de faciliter la prise de décision médicale individualisée pour un patient sur la base d'une grande quantité de données qu'un humain seul ne pourrait pas traiter.^{27,28}

Box 2 - Événements choisis dans l'histoire de l'IA en médecine

1959 Robert Ledley et Lee Lusted publient dans la revue *Science* un article historique sur le rôle potentiel des ordinateurs dans le raisonnement médical,

lançant ainsi le domaine de l'informatique médicale.

1964 Eliza, le tout premier chatbot, est un outil

conversationnel qui recrée la conversation entre

	un psychothérapeute et un patient, en appliquant l'intelligence artificielle et les systèmes à base de règles à l'interaction entre les patients et leurs soignants.		quatre composants principaux : les données du patient, le référentiel de connaissances de la maladie (représentant une mémoire à long terme), l'intersection des données du patient et du référentiel de connaissances (représentant une mémoire à court terme), et un programme superviseur pour filtrer les connaissances et agir sur les données du patient.
1965	Projet DENDRAL à l'université de Stanford, par le pionnier de l'IA, Edward Feigenbaum, et le lauréat du prix Nobel, Joshua Lederberg. Les approches basées sur des règles et des listes d'hypothèses utilisées dans le système ont permis d'identifier des molécules organiques inconnues en analysant leurs données de spectrométrie de masse.		
1971	Saul Amarel fonde The Research Resource on Computers in Biomedicine à la Rutgers University afin de développer un cadre informatique pour la recherche dans les sciences biomédicales.		
1972-92	Creation du <i>Stanford University Medical Experimental – Artificial Intelligence in Medicine</i> (SUMEX-AIM) laboratory. L'idée était d'exploiter les capacités de calcul de l'ordinateur à temps partagé PDP-10, nouvellement introduit à l'époque, et de soutenir la recherche AIM de divers groupes à Stanford, à l'université Rutgers, au MIT et à l'université de Pittsburgh.	1978	Development du modèle CASNET (<i>Causal Associational NETWORK</i>) pour la consultation dans le domaine du glaucome. Le modèle CASNET est un réseau causal-associatif composé de trois programmes distincts : la construction du modèle, la consultation, et une base de données créée et maintenue par les collaborateurs. Ce modèle pouvait appliquer des informations sur la maladie à des patients individuels et fournir aux médecins des conseils sur la gestion des patients.
		1986	Développement de <i>DXplain</i> , un système d'aide à la décision créant un diagnostic différentiel sur la base des symptômes saisis, avec des descriptions détaillées des maladies et des références supplémentaires.
1972	Développement de <i>Internist-1</i> , un système contenant une base de connaissances des relations causales et taxonomiques entre les résultats cliniques et les hypothèses de diagnostic, et utilisant un puissant algorithme de classement pour parvenir à des diagnostics.	1980s	Les systèmes de diagnostic assisté par ordinateur (<i>Computer-Aided Diagnosis</i>) basés sur l'IA ont commencé à être utilisés en radiologie pour aider les radiologues à identifier des modèles dans les images médicales qui indiquent des conditions particulières.
1976	Développement de <i>MYCIN</i> , un système expert à base de règles pour l'assistance au traitement des maladies infectieuses fournissant une liste de pathogènes bactériens potentiels et recommandant des options de traitement antibiotique ajustées de manière appropriée au poids corporel du patient, sur la base des informations sur le patient saisies par les médecins et d'une base de connaissances d'environ 600 règles.	1990s	La technologie de traitement du langage naturel (<i>Natural Language Processing</i>) basée sur l'IA a été appliquée pour la première fois aux dossiers médicaux, permettant aux ordinateurs de comprendre et d'extraire des informations pertinentes des dossiers médicaux en texte libre.
		1995	Premier algorithme utilisant des réseaux de neurones pour l'aide au diagnostic en pathologie approuvé par la FDA (<i>PAPNET Testing System</i>).
1976	Développement du système <i>Present Illness Program</i> (PIP), un outil de diagnostic précoce dans l'évaluation des patients souffrant d'œdèmes, avec	2000s	La découverte et le développement de médicaments basés sur l'IA ont commencé à être utilisés pour analyser de grandes quantités de données provenant d'essais cliniques et de la

	littérature scientifique afin d'identifier de nouveaux candidats médicaments et de prédire leur sécurité et leur efficacité.	2020	Google DeepMind a utilisé l'IA pour résoudre le "problème du pliage des protéines", un grand défi qui existe depuis plus de cinquante ans - et prédire la structure tridimensionnelle d'une protéine à partir de sa séquence d'acides aminés.
2010s	Les systèmes robotisés alimentés par l'IA ont commencé à être utilisés en chirurgie et dans d'autres procédures médicales, notamment pour manipuler et trier les instruments médicaux et pour aider à contrôler les bras robotisés pendant les opérations.	2020	La FDA approuve le premier outil d'aide à l'interprétation de mamographies basée sur l'IA pour identifier les cancers mammaires.
2010	La FDA approuve le premier outil d'aide au diagnostic utilisant le machine learning (<i>Pathwork Tissue of Origin Test Kit-FFPE</i>).	2021	La FDA approuve le premier outil d'aide à l'interprétation de CT basée sur l'IA pour identifier les cancers pulmonaires.
2013	IBM Watson a été déployé au <i>Memorial Sloan Kettering Cancer Centre</i> pour aider à la gestion des patients oncologiques et à la recherche d'un traitement spécifique basé sur la littérature scientifique.		
2016	La FDA a approuvé le premier dispositif médical alimenté par deep learning pour le diagnostic par imagerie médicale (<i>Arterys Cardio DL</i>).		

Références:

- Benjamins S, Dhunoo P, Meskó B. The state of artificial intelligence-based FDA-approved medical devices and algorithms: an online database. *npj Digital Medicine*. 2020.
- Harrington SG, Johnson MK. The FDA and Artificial Intelligence in Radiology: Defining New Boundaries. *J. Am. Coll. Radiol.* 2019.
- Harvey HB, Gowda V. How the FDA Regulates AI. *Acad. Radiol.* 2020.
- Hosny A, Parmar C, Quackenbush J, et al. Artificial intelligence in radiology. *Nat. Rev. Cancer*. 2018.
- Kaul V, Enslin S, Gross SA. History of artificial intelligence in medicine. *Gastrointest. Endosc.* 2020.
- Muthukrishnan N, Maleki F, Ovens K, et al. Brief History of Artificial Intelligence. *Neuroimaging Clin. N. Am.* 2020.
- Toosi A, Bottino AG, Saboury B, et al. A Brief History of AI: How to Prevent Another Winter (A Critical Review). *PET Clin.* 2021.
- Yu KH, Beam AL, Kohane IS. Artificial intelligence in healthcare. *Nat. Biomed. Eng.* 2018.

IA en neuroimagerie clinique

Ces dernières années, l'intérêt des chercheurs et des cliniciens pour l'application de l'IA à l'imagerie médicale a connu une croissance exponentielle, comme le montre le nombre croissant d'articles scientifiques publiés dans ce domaine (figure 2).^{16,29-33} Cet intérêt a été rendu possible par l'accessibilité accrue des méthodes d'IA, les progrès techniques dans leur mise en œuvre et le partage des connaissances théoriques et des données cliniques nécessaires à leur développement.

La neuroradiologie est la sous-spécialité la plus représentée dans les travaux sur l'IA en radiologie, avec environ un tiers de tous ces articles. Cela peut être dû à plusieurs facteurs qui étaient déjà présents avant l'avènement de l'IA : (i) il existait une importante communauté de recherche multidisciplinaire et une sensibilité à la recherche quantitative en neuro-imagerie ; (ii) il existait de nombreux datasets partagés propices à l'entraînement des algorithmes d'IA ; (iii) les données de neuro-imagerie clinique sont bien adaptées aux tâches d'apprentissage automatique et sont archivées de manière standardisée.

Les premiers algorithmes d'IA en neuroradiologie ont été utilisés pour identifier des anomalies, diagnostiquer des pathologies ou prédire les outcomes de patients.³⁴⁻³⁸ Ces algorithmes sont essentiellement de type IA *narrow* et sont utilisés pour répondre à une tâche bien définie. Ils sont principalement basés sur un domaine de l'IA appelé machine learning ou l'un de ses sous-domaines, le deep learning, qui permet à un algorithme d'apprendre à partir d'exemples. Un algorithme est entraîné sur un ensemble de données et effectue ensuite des prédictions sur de nouveaux cas sans être explicitement programmé pour le faire. Il existe plusieurs types d'apprentissage automatique, selon la structure des données et l'objectif de la tâche : l'apprentissage supervisé, l'apprentissage non supervisé, l'apprentissage semi-supervisé et l'apprentissage par renforcement (Box. 3).

Plus récemment, de nouvelles méthodes d'IA ont été utilisées pour améliorer d'autres parties du flux de travail en neuroradiologie : optimisation du choix du protocole d'imagerie et de son paramétrage, amélioration de l'acquisition, de la reconstruction ou du post-traitement des images.^{39,40} Ces applications de l'IA au-delà du diagnostic ou du pronostic, également appelées " non interprétatives ", ont été rendues possibles par les progrès de l'IA en général, et de machine learning et de deep learning en particulier,^{41,42} et par l'application à la neuroradiologie de ces avancées issues d'autres domaines scientifiques et techniques. Par exemple, nous avons développé un modèle d'apprentissage profond basé sur un algorithme de Generative Adversarial Network (GAN) pour harmoniser la texture des images médicales afin d'améliorer la reproductibilité des analyses quantitatives utilisant cette texture (Annexe 1, publié dans la revue *Radiology Artificial Intelligence*).⁴³ Dans ce projet, j'ai travaillé avec un collègue ingénieur de l'EPFL pour construire plusieurs datasets d'imagerie clinique aux HUG afin de développer un réseau neuronal qui traduit la texture entre différents types d'images. Nous avons ainsi réussi à harmoniser la texture d'images provenant de différents fabricants et améliorer la reproductibilité de leur analyse quantitative.

Les algorithmes d'apprentissage profond tels que les réseaux neuronaux convolutifs (convolutional neural networks, CNN) sont particulièrement intéressants pour traiter le grand volume d'images associées aux pathologies neurovasculaires.⁴⁴⁻⁴⁷ Cependant, contrairement au concept attrayant de l'application de l'IA à l'imagerie et à la croissance exponentielle de la recherche, l'adoption d'algorithmes d'IA dans des contextes cliniques reste lente.^{29,30} Ici, nous passerons en revue les applications actuelles de l'IA et les développements récents en

imagerie neurovasculaire. Nous passerons également en revue les principales pathologies neurovasculaires et les perspectives qu'ouvre l'IA dans leur prise en charge.

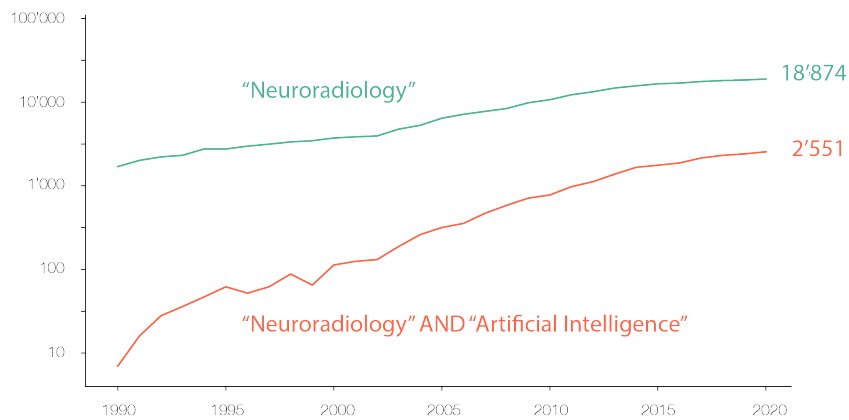


Figure 2 : Nombre d'articles scientifiques indexés sur PubMed pour les termes "Neuroradiology" et "Neuroradiology AND Artificial Intelligence". Remarquez l'axe des y logarithmique.

Box 3 – Concepts principaux en IA

Intelligence artificielle: L'intelligence artificielle (IA) est le développement de systèmes informatiques capables d'effectuer des tâches qui requièrent généralement l'intelligence humaine, comme l'apprentissage et le raisonnement. Il s'agit d'un domaine aux multiples facettes qui englobe diverses disciplines, notamment l'informatique, les mathématiques, l'ingénierie, les neurosciences, la psychologie et la philosophie. Bien qu'elle ait été établie en tant que discipline universitaire dans la seconde moitié du 20^e siècle, le concept d'IA trouve ses racines dans la philosophie et la littérature antiques.

Algorithme: Un algorithme est une procédure définie ou un ensemble d'étapes pour résoudre un problème ou accomplir une tâche. Il prend un input, effectue une série d'opérations et produit un output. Les algorithmes peuvent être représentés sous diverses formes, telles que le langage naturel, le pseudocode ou le langage de programmation, et sont souvent utilisés pour expliquer le fonctionnement des programmes informatiques. Ils peuvent différer en termes de complexité, de caractère aléatoire et de capacité d'apprentissage, et peuvent être exécutés aussi bien par des

humains que par des machines. Par exemple, une recette de cuisine est un algorithme qui peut être exécuté par un humain, tandis qu'un programme informatique de reconnaissance d'images est un algorithme exécuté par une machine.

Computer Science (informatique): L'informatique implique l'utilisation de modèles mathématiques et formels pour comprendre le calcul et pour concevoir et analyser des algorithmes et des systèmes. Elle englobe la compréhension théorique du calcul, de l'information, des algorithmes et de l'automatisation, ainsi que des approches pratiques pour concevoir et mettre en œuvre du hardware et des softwares. Il s'agit d'un domaine multidisciplinaire, qui a des liens avec d'autres domaines tels que les mathématiques, l'ingénierie, la physique, la psychologie ou même la philosophie.

Texture Analysis: En traitement d'images, l'analyse de texture est une technique utilisée pour extraire des informations sur la distribution spatiale de l'intensité, de la couleur ou d'autres caractéristiques d'une image. Elle est utilisée pour quantifier l'aspect visuel d'une image de

manière reproductible. Ces mesures sont ensuite utilisées pour créer un vecteur de caractéristiques de texture qui peut être utilisé pour diverses tâches d'analyse d'images telles que la classification, la segmentation et le recalage d'images. En imagerie médicale, l'analyse de texture est utilisée pour extraire des informations sur la distribution spatiale de l'intensité dans une image, et elle peut être utilisée pour améliorer le diagnostic, le traitement et le pronostic d'une maladie. Diverses mesures sont utilisées pour quantifier la texture d'une image, telles que les Gray-level co-occurrence matrix (GLCM), Gray Level Run Length Matrix (GLRLM), Gray Level Size Zone (GLSZM), Neighbouring Gray Tone Difference Matrix (NGTDM), Gray Level Dependence Matrix (GLDM), Local Binary Patterns (LBP) o Wavelet Transform.

Radiomics: La radiomics est un domaine émergent qui combine l'utilisation de l'imagerie médicale et d'autres variables biomédicales avec des techniques avancées de data science et de machine learning. Elle implique l'extraction d'un large éventail de caractéristiques quantitatives et reproductibles à partir d'images médicales, notamment la forme, la texture, l'intensité et les informations spatiales. Ces caractéristiques sont utilisées en combinaison avec des techniques de science des données et de machine learning pour améliorer le diagnostic, la planification du traitement et les résultats pour les patients. Elle a été initialement utilisée pour améliorer le diagnostic et le pronostic de divers types de cancer, mais son application dans des domaines non oncologiques de l'imagerie médicale est en pleine expansion.

Statistiques: La statistique est la branche des mathématiques qui recueille, analyse, interprète et organise les données. Elle fournit un cadre pour comprendre et faire des déductions sur les modèles et les relations sous-jacents des données. Elle est utilisée pour identifier des tendances et des modèles, et pour tirer des conclusions sur une population à partir d'un échantillon plus petit. Les statistiques peuvent être divisées en deux branches principales :

- Les **statistiques descriptive** traitent de la collecte, de l'organisation et de la présentation des données. Elle

est utilisée pour résumer et décrire les principales caractéristiques d'un ensemble de données. Les méthodes de la statistique descriptive comprennent les mesures de tendance centrale (moyenne, médiane, mode), les mesures de dispersion (variance, écart-type) et les mesures de distribution (histogrammes, box plots).

- Les **statistiques inférentielles** consiste à faire des prédictions et à tirer des conclusions sur une population à partir d'un échantillon. Elle est utilisée pour faire des inférences sur une population à partir des données d'un échantillon. Les méthodes de la statistique inférentielle comprennent l'estimation, le test d'hypothèse et l'inférence statistique.

En général, la statistique descriptive est utilisée pour résumer et décrire les principales caractéristiques d'un ensemble de données et la statistique inférentielle est utilisée pour faire des prédictions et tirer des conclusions sur une population à partir d'un échantillon. Un autre domaine lié aux statistiques et à l'ingénierie, le statistical learning (ou **machine learning**), est utilisé pour faire des prédictions et comprendre les relations entre différentes variables. Il concerne le développement et l'application de modèles statistiques et est utilisé pour faire des prédictions et comprendre les relations entre différentes variables. Les méthodes de machine learning comprennent la régression linéaire et non linéaire, les decision trees, les random forests, les support vector machines et les réseaux neuronaux, parmi de nombreux autres algorithmes.

Machine Learning: Le machine learning (ML) est une branche de l'intelligence artificielle qui se concentre sur la création d'algorithmes et de modèles statistiques permettant aux systèmes d'améliorer leurs performances avec l'expérience, sans instructions explicites. Il permet aux ordinateurs d'apprendre à partir de données, de découvrir des modèles et de prendre des décisions avec une supervision humaine minimale. Elle est largement utilisée dans diverses applications telles que la reconnaissance d'images, le traitement du langage naturel, la reconnaissance vocale, les systèmes autonomes, les véhicules et les robots. Le ML peut être classé en différents

types, chacun d'entre eux ayant une approche différente pour apprendre des données et faire des prédictions :

- **Supervised learning:** un type de ML où le modèle est formé sur des données étiquetées, et le but est de prédire la sortie pour de nouvelles données non vues. Les exemples incluent la régression linéaire, la régression logistique et les support vector machines.
- **Unsupervised learning:** un type de ML où le modèle est formé sur des données non étiquetées, et le but est de trouver des modèles ou des relations dans les données. Les exemples incluent le regroupement, la réduction de la dimensionnalité et la détection des anomalies.
- **Semi-supervised learning:** un type de ML qui combine les techniques supervisées et non supervisées : un modèle est entraîné sur un mélange de données étiquetées et non étiquetées.
- **Reinforcement learning:** un type de ML où le modèle apprend à prendre des décisions en interagissant avec un environnement et en recevant des récompenses ou des punitions.

Artificial Neural Network: Un artificial neural network (ANN) est un type d'algorithme d'apprentissage automatique qui s'inspire de l'organisation du cerveau humain. Il est composé d'un grand nombre de "neurones" artificiels interconnectés qui travaillent ensemble pour effectuer une tâche spécifique. Un ANN se compose généralement de couches de neurones interconnectés, qui reçoivent des entrées, les traitent et les transmettent à la couche suivante pour prédire une sortie sur la base d'entrées données. Chaque neurone applique des transformations mathématiques à l'entrée qu'il reçoit, comme une somme pondérée et une fonction d'activation, avant de transmettre l'entrée transformée à la couche suivante. Les connexions entre les neurones sont représentées par des poids, qui sont ajustés pendant le processus d'apprentissage afin de minimiser l'erreur entre la sortie prédite et la sortie réelle. Les ANN peuvent avoir diverses architectures adaptées à des tâches spécifiques telles que la reconnaissance d'images et de la parole, le traitement du langage naturel et la prise de décision dans les systèmes autonomes. Ils constituent la base du deep learning.

Deep Learning: Les modèles de Deep Learning sont un type de réseaux neuronaux artificiels qui possèdent plusieurs couches de "neurones" artificiels interconnectés qui traitent les informations pour apprendre et prendre des décisions de manière autonome. Ces modèles sont entraînés sur de grandes quantités de données afin d'ajuster les paramètres du modèle pour minimiser l'erreur entre l'output prédit et l'output réel. Ils englobent diverses architectures, telles que les réseaux neuronaux convolutifs pour le traitement des images, les réseaux neuronaux récurrents pour les séries temporelles, la parole et le traitement du langage naturel, ainsi que les modèles d'apprentissage par renforcement pour les robots et les véhicules autonomes. L'apprentissage profond est un sous-domaine de l'apprentissage automatique (Figure 3).

Recurrent Neural Networks: Les recurrent Neural Networks (RNN) sont un type de réseau neuronal artificiel spécialisé dans le traitement de données séquentielles, telles que les séries temporelles, la parole ou le langage naturel. Ils sont largement utilisés pour des tâches comme le traitement du langage naturel, la reconnaissance vocale, la traduction automatique, la prédiction de séries temporelles, et même dans des domaines créatifs comme la musique et la création artistique. Les RNN ont la capacité de "se souvenir" des entrées passées, ce qui leur permet d'utiliser ces informations pour informer la sortie actuelle, cette caractéristique est ce qui les rend "récurrents". La structure des RNN est une série de "neurones" interconnectés qui traitent l'information de manière séquentielle : chaque neurone reçoit un input du neurone précédent, la traite et la transmet au neurone suivant. Les RNN peuvent traiter une séquence d'entrées une par une, et la sortie de chaque neurone dépend des inputs précédents, ce qui permet au réseau de "mémoriser" les inputs précédents.

Convolutional Neural Networks: Les convolutional Neural Networks (CNN) sont un type de réseau neuronal artificiel spécifiquement conçu pour le traitement des images et des vidéos. Ils sont dits "convolutifs" car ils utilisent l'opération mathématique de la convolution pour extraire des caractéristiques de plus en plus complexes des images. La structure des CNN est composée de plusieurs couches, dont

des couches convolutionnelles, des couches de mise en commun et des couches entièrement connectées :

- Les couches convolutionnelles (*convolutional layers*) appliquent un ensemble de filtres (ou noyaux) à l'image d'entrée, qui extraient des caractéristiques telles que les bords, les textures et les motifs.
- Les *pooling layers* réduisent les dimensions spatiales des cartes de caractéristiques tout en préservant les informations importantes.
- Les *fully-connected layers* classent l'image en fonction des caractéristiques extraites.

L'une des principales caractéristiques des CNN est leur capacité à extraire automatiquement des caractéristiques par un processus connu sous le nom d'apprentissage de caractéristiques ou de représentation. Ces caractéristiques peuvent ensuite être utilisées pour la classification ou d'autres tâches, telles que la classification d'images, la détection d'objets, la reconnaissance faciale et l'analyse vidéo, et se sont avérées très efficaces dans ces domaines.

U-Net: Les U-Nets sont une architecture populaire de CNN qui est couramment utilisée pour la segmentation d'images. Ils ont une architecture symétrique en forme de "U", composée d'un encodeur sur le côté gauche et d'un décodeur sur le côté droit. L'encodeur extrait les caractéristiques de l'image d'entrée, tandis que le décodeur génère une image de sortie segmentée. L'encodeur et le décodeur sont reliés par des connexions de saut, ce qui permet au décodeur de combiner des caractéristiques de haut niveau et de bas niveau provenant de l'encodeur. Les U-Nets présentent plusieurs avantages par rapport aux autres architectures CNN pour les tâches de segmentation d'images, comme une grande précision et une facilité d'apprentissage, ce qui les rend adaptés à l'analyse des images médicales et aux petits ensembles de données.

Autoencoders: Les autoencoders sont une architecture de réseau neuronal utilisée pour l'apprentissage non supervisé. Ils sont composés d'un encodeur et d'un décodeur qui travaillent ensemble pour apprendre une représentation condensée des données d'entrée, appelée "encodage". L'objectif de l'auto-codeur est d'apprendre une

représentation des données d'entrée qui capture les caractéristiques les plus cruciales tout en écartant le bruit ou les informations sans importance. L'encodeur fait correspondre les données d'entrée à une représentation de dimension inférieure, en utilisant généralement une série de transformations linéaires et non linéaires. Le décodeur retranscrit la représentation codée dans l'espace de données d'origine. Pour ce faire, le réseau est entraîné à reconstruire les données d'entrée à partir de la représentation codée. Le réseau est entraîné à minimiser la différence entre les données d'entrée et les données reconstruites, ce qui encourage le réseau à apprendre une représentation compacte et informative de l'entrée. Les autoencoders sont utilisés pour diverses tâches, telles que la réduction de la dimensionnalité, le denoising des données, la génération d'images et de paroles, la détection d'anomalies, etc. Il existe différents types d'autoencoders, tels que les autoencoders variationnels qui peuvent être utilisés pour des tâches génératives.

Generative Adversarial Network: Les generative Adversarial Network (**GAN**) sont un type d'algorithme de deep learning non supervisé utilisé pour générer de nouveaux exemples de données nouvelles. Ils se composent d'un réseau générateur et d'un réseau discriminateur :

- Le réseau générateur prend une entrée aléatoire et produit un échantillon de la distribution de données cible.
- Le réseau discriminateur prend un échantillon de la distribution de données cible (réel ou généré) et tente de le classer comme réel ou faux.

Les réseaux du générateur et du discriminateur sont entraînés ensemble de manière contradictoire : le générateur essaie de créer des échantillons qui peuvent tromper le discriminateur, et le discriminateur essaie d'identifier correctement si un échantillon est réel ou faux. Au fur et à mesure de l'entraînement, le générateur s'améliore dans la création d'échantillons réalistes et le discriminateur s'améliore dans l'identification des faux échantillons, ce qui permet au générateur de produire des échantillons très réalistes. Les GAN sont appliqués dans diverses tâches telles que la synthèse d'images, la traduction

d'images, et sont connus pour leur capacité à produire des images, des vidéos et du son très réalistes.

Les **cycle GANs** sont un type de GAN qui peut être utilisé pour les tâches de traduction d'image à image. Ils reposent sur l'idée que la sortie générée par le réseau générateur doit pouvoir être retransformée en entrée originale à l'aide d'un réseau générateur inverse. Ils se composent de deux réseaux générateurs (G et F) et de deux réseaux discriminateurs (Dx et Dy). Ils sont entraînés ensemble de manière contradictoire, comme les GAN. Mais en plus, la *cycle consistency loss* est également utilisée pour s'assurer

que les images générées peuvent être retransformées en l'entrée originale en utilisant le réseau générateur inverse. Les cycle GANs ont été utilisés pour diverses tâches de traduction d'image à image, telles que le transfert de style, la super-résolution et la transfiguration d'objets.

Références:

- Gillies R, Kinahan P, Hricak H. Radiomics: Images are more than pictures, they are data. *Radiology* 2016.
- Goodfellow IJ, Bengio Y, Courville A. Deep Learning. *MIT Press* 2016.
- Russell SJ, Norvig P. Artificial intelligence : a modern approach (4th edition). *Pearson* 2019
- Zhu JY, Park T, Isola P, et al. Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks. *Proceedings of the IEEE International Conference on Computer Vision*, 2017.




Figure 3 : L'intelligence artificielles et ses sous-domaines les plus fréquemment utilisés en neuroimagerie clinique.

Maladies neurovasculaires

Definition des maladies neurovasculaires

Les maladies neurovasculaires affectent le système vasculaire du cerveau et de la moelle épinière. Elles comprennent toute anomalie des vaisseaux sanguins du système nerveux central (SNC), y compris l'ensemble du réseau vasculaire. Le réseau vasculaire cérébral comprend le système artériel, qui transporte le sang du cœur vers le SNC ; le système capillaire, qui permet l'échange d'oxygène et de nutriments entre le sang et le tissu cérébral ; et le système veineux, qui ramène le sang du SNC vers le cœur.

Les pathologies neurovasculaires peuvent être d'étiologie ischémique ou hémorragique. Dans le cas d'une ischémie cérébrale, il y a une réduction du flux sanguin vers le SNC, soit en raison d'un rétrécissement des vaisseaux (sténose), soit en raison de l'obstruction d'un vaisseau par

un caillot sur la paroi du vaisseau (thrombose) ou d'un caillot provenant d'un autre vaisseau (embolie).⁴⁸ Les cellules cérébrales risquent alors fortement d'être endommagées temporairement ou définitivement par une diminution de leur apport en oxygène et en nutriments. Dans le cas d'une hémorragie cérébrale, il existe une anomalie dans la paroi du vaisseau sanguin qui provoque sa rupture, ce qui entraîne une hémorragie intracrânienne.⁴⁹⁻
⁵¹ Cela entraîne également un risque de lésions cérébrales irréversibles dues à une mauvaise irrigation sanguine du tissu cérébral. L'hémorragie cérébrale peut être causée par des malformations vasculaires (par exemple, des anévrismes, des malformations artérioveineuses, des fistules artérioveineuses ou des cavernomes), des parois vasculaires fragiles ou endommagées (par exemple, en cas d'hémorragie hypertensive, d'angiopathie amyloïde, ou de tumeurs) ou un traumatisme entraînant une hémorragie. L'ischémie cérébrale aiguë et l'hémorragie intracrânienne doivent être diagnostiquées et traitées rapidement pour limiter les lésions cérébrales irréversibles, qui peuvent entraîner un handicap grave, voire la mort. Les maladies neurovasculaires peuvent être causées en partie par divers facteurs connus, notamment des causes génétiques, des facteurs de risque liés au mode de vie ou d'autres maladies. Les symptômes de la maladie neurovasculaire sont liés au dysfonctionnement des cellules neurales à la suite d'une ischémie ou d'une hémorragie cérébrale. Selon la zone du cerveau touchée, ces symptômes peuvent prendre de nombreuses formes, notamment des troubles moteurs, sensoriels, cognitifs, de la parole, de la vision, de l'équilibre, des céphalées, des crises d'épilepsie et même une perte de conscience. Le traitement d'une maladie neurovasculaire peut inclure des médicaments, des changements de mode de vie, de l'exercice/de la rééducation, voire des procédures invasives telles que la chirurgie ou les traitements endovasculaires. On distingue le traitement préventif, qui vise à réduire le risque d'atteinte neurovasculaire, et le traitement d'urgence ou de semi-urgence, qui consiste à traiter la maladie elle-même dans sa phase aiguë afin d'en réduire les conséquences.

Imagerie diagnostique des maladies neurovasculaires

Les maladies neurovasculaires sont suspectées et diagnostiquées sur la base de l'histoire et du statu clinique du patient, ainsi que des tests biologiques et de l'imagerie cérébrale.

L'imagerie cérébrale diagnostique joue un rôle important dans la confirmation de la maladie


neurovasculaire et a connu de nombreuses avancées majeures au cours des dernières décennies.

Depuis le développement clinique de modalités d'imagerie cérébrale non invasives telles que le CT au début des années 1970 et l'IRM à la fin de la même décennie, de nombreuses évolutions techniques ont permis de mieux visualiser les vaisseaux ainsi que la viabilité et la fonctionnalité du tissu cérébral. Le CT et l'IRM sont des outils radiologiques qui permettent une imagerie non invasive du corps humain en utilisant soit des rayons X, soit un champ magnétique élevé. En paramétrant ces appareils, nous pouvons obtenir des images du corps humain centrées sur la pathologie que nous souhaitons visualiser. L'imagerie 3D par CT et IRM nous permet de visualiser l'anatomie artérielle et veineuse et de détecter rapidement de nombreuses pathologies neurovasculaires. L'imagerie CT ou IRM en 4 dimensions (3 dimensions spatiales et 1 dimension temporelle) permet l'imagerie dynamique des vaisseaux cérébraux ou la quantification de l'apport sanguin au cerveau, ou perfusion cérébrale, fournissant ainsi une évaluation de la réversibilité des lésions cérébrales causées par une ischémie aiguë.^{48,52} D'autres techniques d'imagerie cérébrale, comme l'IRM de diffusion, peuvent également visualiser les phénomènes tissulaires causés par les lésions neurovasculaires, comme l'œdème cytotoxique causé par le dysfonctionnement cellulaire dans l'ischémie cérébrale.

Les techniques d'imagerie neurovasculaire invasives, comme l'angiographie cérébrale, existent depuis bien plus longtemps que le CT ou l'IRM. Lors d'une angiographie cérébrale, un cathéter est inséré de manière minimalement invasive dans une artère ou une veine, puis guidé dans les vaisseaux de la tête et du cou.⁵³ Des radiographies ou radioscopiques sont ensuite prises pendant qu'un produit de contraste est injecté pour visualiser les artères et les veines cérébrales. Grâce à des progrès techniques progressifs depuis la fin des années 1990, il est également possible, d'obtenir des images angiographiques en 3D et, ces dernières années, même en 4D, qui permettent une excellente étude de la vascularisation cérébrale et la planification d'interventions neurovasculaires.⁵⁴⁻⁵⁷ L'angiographie cérébrale est pratiquée depuis la première moitié du 20^e siècle et était un outil important dans le diagnostic de certaines maladies neurovasculaires avant l'avènement du CT et de l'IRM. Elle a depuis été supplantée par ces modalités d'imagerie non invasives, mais joue toujours un rôle important dans le diagnostic de certaines pathologies neurovasculaires.⁵⁸

Box 4 – Techniques imageries neurovasculaires

CT : La tomographie assistée par ordinateur (*Computed Tomography*, CT) est une technique d'imagerie médicale non invasive qui utilise des rayons X pour créer des images détaillées en coupe du corps. Le processus d'imagerie implique la rotation d'une source de rayons X autour du corps et la capture de plusieurs signaux de rayons X sous différents angles, afin que le détecteur enregistre la quantité de rayons X absorbés (ou atténués) par le corps. Le signal est ensuite reconstruit par un ordinateur pour créer des images 2D, 3D ou 4D du corps. Il est possible d'obtenir des images natives du cerveau (*Non-Contrast CT*, NCCT) ou, en injectant un agent de contraste intravasculaire, d'obtenir des images 3D des artères (*Angio-CT*, CTA), des veines (*Phlebo-CT*) ou du tissu cérébral (*Contrast-Enhanced CT*, CECT), ou des images 4D (3 dimensions spatiales et 1 dimension temporelle) de la perfusion cérébrale (CT perfusion, CTP).



NCCT cérébral (en haut à gauche), CTA (en bas à gauche) et CTP (cartes colorées à droite) d'un patient présentant un accident vasculaire cérébral ischémique aigu, dans le plan axial.


IRM : L'imagerie par résonance magnétique (**IRM**) est une technique d'imagerie non invasive qui utilise un champ magnétique et des ondes radio pour créer des images du cerveau. L'IRM mesure le signal des protons présents dans un tissu (principalement sous forme d'hydrogène H⁺ dans l'eau H₂O) en mesurant la réponse à une variation locale du champ magnétique afin de déduire différentes propriétés du tissu. En induisant volontairement des changements dans le champ magnétique à l'aide d'ondes radiofréquences et en

faisant varier certains paramètres, on obtient des images de "pondération" différente montrant différentes caractéristiques tissulaires d'un même organe. Il est également possible d'effectuer des types d'imagerie plus avancés pour déduire le comportement ou la composition chimique des régions du cerveau, tels que :

- L'imagerie pondérée par la diffusion (*Diffusion Weighted Imaging*, **DWI**): cette technique mesure la diffusion des molécules d'eau dans le cerveau. Cette diffusion peut être libre dans toutes les directions de l'espace (isotrope) ou contrainte dans une direction spécifique (anisotrope). La "quantité" de diffusion et sa direction peuvent être utilisées pour mesurer les caractéristiques des tissus, comme les différents types d'œdème dans le tissu cérébral (cytotoxique ou vasogénique) ou la direction de diffusion préférée (en DTI).
- Imagerie par tenseur de diffusion (*Diffusion Tensor Imaging*, **DTI**): cette technique utilise la diffusion anisotrope des molécules d'eau pour créer des images de la structure et des trajets de la substance blanche du cerveau.
- L'IRM Time-of-Flight (**IRM-TOF**): l'IRM-TOF mesure le mouvement du sang dans les vaisseaux, en mesurant comment le sang "se déplace" dans l'espace, et est souvent utilisée pour créer des images détaillées des artères cérébrales.
- Arterial Spin Labelling (**ASL**): Cette technique utilise la magnétisation naturelle du sang dans le corps pour mesurer le flux sanguin dans le cerveau, sans avoir à injecter de produit de contraste. Elle peut être utilisée pour mesurer la perfusion cérébrale, par exemple en cas d'AVC ischémique aigu ou de tumeur cérébrale.
- Imagerie par résonance magnétique fonctionnelle (*Functional Magnetic Resonance Imaging*, **fMRI**): cette technique mesure les changements du flux sanguin dans différentes zones du cerveau, par le biais des changements de l'oxygénation du sang (ou effet BOLD), afin de déduire l'activité cérébrale. Elle peut également être utilisée pour quantifier la


vasoréactivité des vaisseaux cérébraux en mesurant les changements du flux sanguin après l'administration de CO₂.

- Spectroscopie par résonance magnétique (*Magnetic Resonance Spectroscopy, MRS*): Cette technique mesure la composition chimique de différentes zones du cerveau, en identifiant et en quantifiant le signal unique produit par différentes molécules (p.ex. marqueurs métaboliques, lactate, acides aminés, neurotransmetteurs, etc).



IRM du cerveau, montrant l'imagerie DWI, pondérée en T2 et pondérée en susceptibilité d'un patient 1 jour après son traitement endovasculaire d'un accident vasculaire cérébral ischémique aigu, dans le plan axial.

Angiographie : L'angiographie, également appelée artériographie cérébrale, est une technique d'imagerie médicale invasive qui utilise des rayons X pour produire des images des vaisseaux sanguins du cerveau. Les images radiographiques sont acquises pendant qu'un produit de contraste est injecté dans un vaisseau spécifique à l'aide d'un cathéter, afin de visualiser le flux dans les vaisseaux sanguins (artères et veines). L'angiographie par soustraction numérique (*Digital Subtraction Angiography, DSA*) est une forme spécialisée d'angiographie produisant des images 2D des vaisseaux uniquement, où le fond est soustrait pour permettre une visualisation plus claire des vaisseaux sanguins. L'angiographie rotationnelle 3D (*3D rotational angiography, 3DRA*) est une autre forme spécialisée d'angiographie où la machine tourne autour du patient pendant que le produit de contraste est injecté dans un vaisseau, afin de créer des images 3D détaillées des vaisseaux sanguins. Les images sont proches de celles obtenues par CTA ou phlébo-CT, mais avec une bien meilleure résolution spatiale et en contraste.



Images DSA frontale (colonne de gauche) et latérale (colonne de droite) d'un patient souffrant d'un AVC ischémique aigu, avant (rangée supérieure) et après (rangée inférieure) le traitement endovasculaire par thrombectomie mécanique.

Échographie: L'échographie par ultrasons (**US**) est une technique d'imagerie médicale non invasive qui utilise des ondes sonores pour créer des images du corps. Les ondes ultrasonores sont émises par un appareil portable appelé transducteur, qui est placé à la surface de la peau. Elles se propagent dans le corps et rebondissent sur les organes et les tissus internes. Les ondes ultrasonores qui reviennent sont ensuite captées par le transducteur et converties en images qui sont affichées sur un moniteur. L'échographie Doppler est une forme spécialisée d'imagerie ultrasonore qui utilise l'effet Doppler pour mesurer le flux sanguin et la vitesse du sang dans les vaisseaux sanguins. Il s'agit d'un outil de diagnostic non invasif qui peut être utilisé pour évaluer la morphologie et le flux sanguin dans les principaux vaisseaux du corps. En imagerie neurovasculaire, elle est utilisée pour mesurer le débit et la taille des artères carotides, vertébrales et intracrâniennes, afin de détecter les sténoses ou autres pathologies vasculaires.

PET and SPECT: La tomographie par émission de positons (*Positron Emission Tomography, PET*) et la tomographie par émission monophotonique (*Single-Photon Emission Computed Tomography, SPECT*) sont des techniques d'imagerie de médecine nucléaire qui utilisent des matériaux radioactifs pour créer une image du cerveau et mesurer son activité ou la distribution de radiotraceurs

spécifiques. Les radiotraceurs sont des molécules radioactives dont la forme moléculaire spécifique imite la fonction de molécules naturelles (p. ex. glucose, choline, tau, neurotransmetteurs, etc.). Lorsqu'ils sont administrés à un patient, ils se comportent de la même manière que les

molécules naturelles et montrent ainsi comment ces molécules se distribuent dans le corps.

Références:

Byrne J. *Tutorials in Endovascular Neurosurgery and Interventional Neuroradiology*. Springer 2017.
Runge V. *Imaging of Cerebrovascular Disease*. Thieme 2016.
Takahashi S. *Neurovascular Imaging*. Springer 2010.

Imagerie thérapeutique des maladies neurovasculaires

Depuis la fin du 20^e siècle, l'angiographie cérébrale a progressivement gagné une place importante dans l'arsenal thérapeutique des maladies neurovasculaires. Les interventions endovasculaires guidées par angiographie sont utilisées pour traiter un nombre croissant de maladies neurovasculaires. Au cours d'une intervention endovasculaire dans les vaisseaux cérébraux, un ou plusieurs cathéters sont dirigés dans les vaisseaux extra et intracrâniens sous guidage par imagerie.⁵³ Cela permet de traiter les pathologies neurovasculaires de façon minimalement invasive, à l'aide de dispositifs endovasculaires, de manière préventive ou en cas d'urgence, sans devoir recourir à une procédure chirurgicale plus invasive.

Au cours des deux dernières décennies, les traitements endovasculaires sont devenus la pierre angulaire de nombreuses pathologies neurovasculaires ischémiques et hémorragiques grâce aux progrès majeurs des modalités de traitement et des dispositifs endovasculaires. Plusieurs essais cliniques randomisés ont démontré que le traitement endovasculaire guidé par l'image est une référence dans le traitement de l'accident vasculaire cérébral ischémique aigu⁵⁹⁻⁶⁴ ou des anévrismes cérébraux rompus.⁶⁵⁻⁶⁷ D'autres traitements endovasculaires d'urgence, de semi-urgence et préventifs sont également réalisés pour de nombreuses autres pathologies neurovasculaires.

L'amélioration des techniques d'imagerie cérébrale est également un facteur important dans l'évolution de la prise en charge des pathologies neurovasculaires, qu'elles soient endovasculaires ou non. Ces progrès comprennent l'imagerie diagnostique par IRM, CT ou angiographie avant, pendant ou après le traitement, ainsi que l'imagerie thérapeutique pour guider le traitement. Ces progrès de l'imagerie diagnostique et thérapeutique ont permis d'améliorer la visualisation de l'anatomie et de la pathologie neurovasculaire, ce qui permet d'améliorer leur diagnostic, prise en charge et suivi. Ces progrès reposent sur des méthodes

de traitement du signal qui, jusqu'à récemment, étaient entièrement constituées de modèles algorithmiques définis et codés par des ingénieurs.

Cependant, le traitement du signal en imagerie biomédicale a été enrichi par les récents progrès de l'IA, qui ont permis le développement d'algorithmes plus flexibles et adaptables sans être explicitement programmés pour effectuer une tâche. Cela a ouvert de nouvelles perspectives sur les outils d'imagerie disponibles et leur impact sur le diagnostic, le traitement et le suivi des maladies neurovasculaires.⁶⁸⁻⁷⁰



Figure 4 : Workflow diagnostique et thérapeutique dans le traitement de l'AVC ischémique aigu. **A)** Triage préhospitalier et hospitalier pour orienter le patient suspecté d'AIS vers une imagerie diagnostique. **B)** Confirmation par imagerie du diagnostic de l'AVC (par CT ou IRM) et sélection des patients pouvant bénéficier d'un traitement pharmacologique et endovasculaire. **C)** Thrombectomie mécanique pour les patient atteints d'AVC à l'aide de l'angiographie et de dispositifs endovasculaires tels que le stent retriever et les cathéters de thromboaspiration. **D)** imagerie de suivi pour évaluer l'étendue des lésions cérébrales ischémiques et identifier la cause de l'AVC afin de cibler la prévention secondaire et les plans de réadaptation.

Dans la prochaine section de cette thèse, nous allons examiner comment l'IA est utilisée dans le diagnostic, le traitement et le suivi des pathologies neurovasculaires les plus courantes. Pour chaque pathologie, nous verrons quelles applications d'IA sont actuellement disponibles en clinique, lesquelles font l'objet de recherches académiques, et quelles perspectives l'IA ouvre dans leur prise en charge. Nous verrons tout d'abord comment l'IA a permis d'améliorer les outils de diagnostic et les indications thérapeutiques de l'ischémie cérébrale, comme l'accident vasculaire cérébral ischémique aigu et les pathologies chroniques carotido-vertébrales (figure 4). Nous aborderons ensuite les applications actuelles et potentielles de l'IA dans la gestion des pathologies cérébrales hémorragiques telles que l'hémorragie intracrânienne, les anévrismes cérébraux, les malformations artérioveineuses (MAV), les

fistules artérioveineuses (FAV) et les cavernomes. Nous traiterons finalement brièvement du potentiel de l'IA dans la prise en charge des pathologies veineuses du SNC. Étant donné la faible incidence des troubles neurovasculaires de la moelle épinière et le manque de publications scientifiques impliquant l'IA dans leur prise en charge, nous ne les aborderons pas dans le présent travail. Enfin, nous concluons en discutant des limites actuelles de l'utilisation clinique de l'IA et de ses biais potentiels.

IA & imagerie neurovasculaire

Anatomie neurovasculaire

Le SNC se compose de deux organes étroitement liés : le cerveau et la moelle épinière.⁵⁸ Ils sont enveloppés et protégés par trois couches de méninges et encastrés dans deux structures osseuses : le crâne et la colonne vertébrale. Le cerveau se compose du cortex cérébral, des structures sous-corticales, du tronc cérébral et du cervelet, tandis que la moelle épinière s'étend du tronc cérébral vers le bas dans le canal vertébral. L'anatomie vasculaire du SNC suit celle des autres organes, avec un réseau d'artères partant de l'aorte et devenant progressivement plus petites pour distribuer le sang à un système capillaire.⁷¹ Ce système capillaire est composé de petits vaisseaux qui permettent l'échange d'oxygène et de nutriments avec le cerveau. Après cet échange, le sang retourne au cœur par des veines de plus en plus grosses, puis s'enrichit en nutriments et en oxygène pour être acheminé vers les différents organes.⁷² Différents types de variations anatomiques et de pathologies peuvent apparaître le long de ce réseau vasculaire.

La capacité de visualiser la vascularisation cérébrale à l'aide des techniques d'imagerie médicale actuelles a permis de diagnostiquer et de traiter un nombre croissant de maladies neurovasculaires. En routine clinique, les médecins utilisent des techniques d'imagerie non invasives telles que l'IRM, le CT ou l'échographie par ultrasons (US) pour visualiser les artères et les veines du cou et du cerveau. Ils ont parfois recours à des techniques d'imagerie invasives, comme l'angiographie cérébrale, pour un diagnostic spécialisé ou un traitement endovasculaire.

La bonne visualisation des veines et des artères cérébrales permet un diagnostic rapide et précis des maladies neurovasculaires, notamment grâce à leur reconstruction 3D basée sur des modèles de vaisseaux segmentés. Pour une analyse visuelle efficace de la vascularisation

de la tête et du cou, la reconstruction d'image est généralement effectuée manuellement ou semi-automatiquement par un spécialiste, ce qui prend beaucoup de temps dans un contexte clinique.^{73,74} Récemment, l'IA a été utilisée en recherche pour segmenter automatiquement les vaisseaux cérébraux sur une CTA ou une TOF-MRI, en se focalisant principalement sur les artères cérébrales principales.⁷⁵⁻⁷⁹ La segmentation des artères cérébrales par des algorithmes de deep learning obtient d'excellents résultats comparés à la segmentation manuelle par des humains, avec une réduction drastique du temps de traitement. Il a été rapporté qu'il est même possible de reconstituer le système artériel et veineux cérébral de manière fiable et rapide en utilisant des CNN entraînés sur des CTA en 4D.⁸⁰ L'amélioration de la visualisation 3D de la vascularisation et la distinction entre les veines et les artères cérébrales permettraient d'en faciliter l'analyse par les neuroradiologues et ainsi la détection de pathologies subtiles difficiles à diagnostiquer avec des reconstructions conventionnelles. Nous avons également développé un ensemble de réseaux neuronaux basé sur un nnUNet⁸¹ qui permet la segmentation des artères extra et intracrâniennes indépendamment de la modalité d'imagerie (Annexe 2 et Figure 5). Dans ce projet, j'ai segmenté manuellement des artères cérébrales sur un jeu de données de différentes modalités d'imagerie (200 CTA, 200 TOF-MRI et 200 3DRA) et développé un ensemble de réseaux de deep learning entraînés à segmenter automatiquement les artères cérébrales indépendamment de la modalité d'imagerie. Bien que la validation sur un ensemble de données indépendant et externe soit encore en cours, nous avons observé des résultats similaires à ceux rapportés dans la littérature, avec d'excellentes performances de segmentation via l'IA par rapport à un neuroradiologue sur l'IRM et l'angiographie 3D, et une segmentation encore meilleure sur les CTA. L'un des avantages de cette méthode de segmentation d'ensemble est qu'elle est indépendante de la modalité d'imagerie et semble mieux se généraliser entre différents types d'images, notamment le CT.

Plusieurs groupes ont développé des modèles d'IA pour améliorer la qualité des images acquises par CT, IRM, US et même angiographie cérébrale. Des algorithmes de deep learning ont été utilisés pour améliorer la reconstruction des images CT, IRM, US ou angiographiques. Ils permettent une meilleure résolution spatiale (ou "super-résolution") et de contraste des structures cérébrales,^{82,83} ou permettent une acquisition, une reconstruction et une réduction rapide des artefacts.⁸⁴⁻⁸⁷ Ils ont également été développés pour raccourcir les protocoles d'acquisition et de reconstruction d'images,^{88,89} ou pour réduire la dose de

radiation^{90,91} et la quantité de produit de contraste.⁹² Ces outils sont de plus en plus souvent implémentés directement dans les appareils d'imagerie par les différents fabricants, en permettant une diffusion rapide.




Figure 5 : Segmentation des artères à l'aide du réseau nnUNet. La segmentation automatique utilisant un ensemble d'algorithmes de deep learning permet de reconstruire et de visualiser rapidement les artères cérébrales sur des modèles 3D. Un ensemble d'UNets est entraîné à segmenter les artères cérébrales sur CTA, TOF-MRI et 3DRA. Cet algorithme d'ensembling est ensuite utilisé comme base pour segmenter plusieurs pathologies neurovasculaires, telles que les anévrismes cérébraux.

Bien que des outils aient été développés pour améliorer la résolution spatiale et de contraste des images, celle-ci varie fortement entre les différentes techniques d'imagerie. Par conséquent, la visualisation des petits vaisseaux et des détails anatomiques fins est excellente avec certaines modalités d'imagerie, mais plus difficile avec d'autres, malgré l'utilisation d'outils de reconstruction spécifiques à chaque technique d'imagerie. Par exemple, l'angiographie fournit la meilleure visualisation des artères et des veines cérébrales en routine clinique, en particulier avec la visualisation des artères en 3D grâce à l'angiographie rotationnelle (3DRA), mais présente l'inconvénient d'être un examen invasif.

La CTA ou l'IRM-TOF permettent également de visualiser les vaisseaux en 3D et ont l'avantage d'être non invasives, mais offrent moins de détails fins. Nous avons donc cherché à utiliser l'IA pour améliorer la résolution spatiale des CTAs afin de mieux visualiser les détails fins des artères cérébrales et de leurs pathologies. À cette fin, j'ai d'abord construit un ensemble de 50 paires de CTA et de 3DRA provenant des 50 mêmes patients. Ensuite, j'ai développé un GAN basé sur un modèle vox2vox⁹³ pour convertir les CTA à faible résolution spatiale ($\sim 0,8 \text{ mm}^3$) en 3DRA à meilleure résolution ($\sim 0,2 \text{ mm}^3$). Les GAN sont des réseaux neuronaux qui apprennent à imiter tout type de distribution de données et peuvent transformer une image d'un domaine source en un domaine cible.^{94,95} Ils peuvent générer une nouvelle image à partir d'une image source afin de correspondre aux caractéristiques spécifiques d'une image cible. Un type spécifique de GAN, appelé GAN de cycle, a été développé pour traduire la texture au niveau de l'image.⁹⁶ Enfin, nous avons entraîné un GAN de cycle à traduire les CTA en 3DRA et vice versa (Annexe 3). Cela nous a permis d'obtenir des images de CTAs avec une bien meilleure résolution spatiale, passant de $0,8 \text{ mm}^3$ voxels à $\sim 0,2 \text{ mm}^3$. Cette amélioration peut permettre une meilleure visualisation des artères cérébrales et de leurs pathologies sur les CTA, sans qu'il soit nécessaire de recourir à un examen invasif tel que l'artériographie cérébrale pour obtenir la 3DRA. Toutefois, l'impact de ces techniques d'amélioration de l'image sur la prise en charge des patients atteints de maladies neurovasculaires doit être étudié plus en détail.

AVC ischémique aigu

L'accident vasculaire cérébral (AVC) est l'une des principales causes de décès et de handicap dans le monde. Un diagnostic et un traitement précoces sont essentiels pour réduire la mortalité et la morbidité. Les accidents vasculaires cérébraux peuvent être classés en deux grandes catégories : les accidents ischémiques et les accidents hémorragiques. L'accident ischémique aigu (AIS) est causé par une interruption de la circulation sanguine cérébrale entraînant des lésions cérébrales graves et représente environ 71 % de tous les accidents vasculaires cérébraux dans le monde. L'incidence mondiale des AVC ischémiques était de 9,5 millions (en 2016) et a causé 2,7 millions de décès (en 2017).⁴⁸

La plupart des AIS sont d'origine thromboembolique : un caillot provenant principalement d'une plaque athéromateuse dans une grande artère ou causé par une maladie cardiaque migre jusqu'au cerveau et occlut une grande, moyenne ou petite artère cérébrale. La gravité

des symptômes de l'AVC dépend de l'étendue de la région du cerveau touchée par l'ischémie, mais aussi du rôle fonctionnel de cette région. Par exemple, l'occlusion d'une grosse artère cérébrale entraîne généralement des symptômes plus invalidants que l'occlusion distale d'une artère moyenne ou petite, car la zone d'ischémie est plus étendue. Cependant, si la zone est petite mais fonctionnellement très importante, les symptômes peuvent également être très invalidants. Parmi les autres causes d'AVC, citons les maladies des petits vaisseaux ou, plus rarement, la dissection artérielle, la vascularite, la persistance d'un foramen ovale patent avec embolie paradoxale et les troubles hématologiques. L'identification correcte de la cause de l'AVC est importante car elle peut guider les stratégies de traitement pour prévenir les récurrences.

Plusieurs facteurs de risque modifiables et non modifiables augmentent la probabilité d'un AVC. Les facteurs de risque non modifiables pour les AVC comprennent l'âge, le sexe et les facteurs génétiques. Plusieurs facteurs de risque modifiables ont été identifiés, notamment l'hypertension artérielle, la sédentarité, l'obésité, les habitudes alimentaires, le tabagisme, les causes cardiaques (telles que la fibrillation auriculaire et les antécédents de crise cardiaque), la consommation élevée d'alcool ou le diabète. La réduction de ces facteurs de risque modifiables avant ou après un accident ischémique cérébral constitue donc un élément important de la prévention (primaire ou secondaire) de l'AVC.

Le traitement des AVC vise à obtenir une recanalisation rapide de l'artère occluse pour reperfuser le cerveau et limiter les lésions cérébrales, réduisant ainsi la mortalité et la morbidité. Cette prise en charge aiguë repose sur un traitement pharmacologique par thrombolyse intraveineuse et un traitement endovasculaire par thrombectomie mécanique, qui doivent être réalisés le plus rapidement possible. Pour maximiser les bénéfices des thérapies de reperfusion cérébrale, il est essentiel d'améliorer le système de soins afin de réduire les délais de traitement. Cela inclut l'identification rapide des patients suspects d'AVC, à la fois en dehors et à l'arrivée à l'hôpital, suivie d'un diagnostic rapide par imagerie cérébrale et d'une orientation vers le traitement de reperfusion cérébrale d'urgence le plus approprié.

Ces dernières années, l'IA a ouvert de nouvelles possibilités à différentes étapes du workflow de prise en charge des AIS.^{41,97-100} Les algorithmes d'IA peuvent être utilisés pour détecter les patients atteints d'AVC à partir d'images médicales telles que le CT ou l'IRM. Ils peuvent également être utilisés pour analyser les données des patients afin d'identifier les facteurs de

risque d'AVC, ce qui permet aux professionnels de la santé de prendre des mesures préventives avant qu'un AVC ne se produise.⁹⁹ Ils peuvent même aider à la rééducation post-AVC en fournissant des pronostics et des plans de réadaptation adaptés aux besoins de chaque patient.¹⁰¹⁻¹⁰⁵

Nous nous concentrerons ici sur les progrès récents de la neuro-imagerie vasculaire de l'AVC ischémique aigu en utilisant l'IA. Nous verrons comment l'IA aide au diagnostic de l'AVC et à la localisation de l'artère occluse, mais aussi comment elle pourrait aider à traiter les patients plus efficacement en fournissant des recommandations sur la stratégie de traitement personnalisée pour chaque patient.

Imagerie diagnostique de l'AVC

Les algorithmes de deep learning sont performants dans le diagnostic des occlusions de grosses artères cérébrales, à la fois via des algorithmes open source et des logiciels commerciaux.^{100,106-109} Le deep learning s'est également avéré efficace dans le calcul automatique de scores ou la reconstruction quantitative d'images pour guider la prise en charge aiguë de l'AVC ischémique. Par exemple, l'apprentissage profond a permis de calculer automatiquement un score ASPECT, qui quantifie l'étendue des lésions cérébrales dans l'AVC et peut guider le traitement endovasculaire.¹¹⁰⁻¹¹² Il peut également segmenter automatiquement les lésions ischémiques sur l'IRM de diffusion.¹¹³ Il s'est également avéré utile pour le traitement automatisé de l'imagerie de perfusion cérébrale (CTP) afin de définir la zone du cerveau présentant des lésions irréversibles (core ischémique) et la zone présentant des lésions réversibles (pénombre).¹¹⁴⁻¹¹⁶ Les outils de recherche et commerciaux ont montré de bonnes performances dans le calcul automatique du score ASPECT, ainsi que du core et de la pénombre, en utilisant l'imagerie de perfusion cérébrale.

De nombreuses avancées dans l'utilisation de l'IA en imagerie de l'AVC ont été facilitées par des collaborations entre des groupes de recherche clinique et technique, ainsi que par le partage d'ensembles de données publiques ou l'organisation de défis. Par exemple, le défi ISLES (Ischemic Stroke Lesion Segmentation) est organisé depuis 2015, et fournit un dataset annuel pour le développement de modèles d'IA pour la segmentation de lésions cérébrales ischémiques sur IRM et pour permettre une comparaison directe des résultats entre différents groupes.¹¹⁷⁻¹¹⁹ Ce type de défi a été développé pour d'autres pathologies neurovasculaires, comme la détection d'hémorragies intracrâniennes sur CT, la segmentation

et la stratification du risque des anévrismes cérébraux, ou la détection et la segmentation de plaques athéromateuses carotidiennes. Nombre de ces défis sont disponibles en ligne, par exemple sur <https://grand-challenge.org/>.

Enfin, des outils plus avancés pour visualiser les artères cérébrales et même le caillot sont en cours de développement dans la recherche et semblent avoir un avenir prometteur pour aider au traitement endovasculaire de l'accident vasculaire cérébral ischémique. Un modèle de deep learning s'est avéré capable de segmenter de manière fiable le caillot occluant une grosse artère cérébrale, permettant une meilleure visualisation et un traitement endovasculaire potentiellement plus efficace.¹²⁰ Cependant, l'impact de cet outil sur l'efficacité du traitement endovasculaire doit être étudié en clinique, et une collaboration impliquant notre groupe a été mise en place pour l'évaluer.

Traitement de l'AVC

Le but du traitement de l'AVC est de recanaliser rapidement l'artère cérébrale occluse afin de limiter les dommages irréversibles causés par l'ischémie cérébrale. La cible de ce traitement est donc le caillot obstruant l'artère, qui peut être détruit soit pharmacologiquement (lyse intraveineuse), soit mécaniquement (thrombectomie mécanique). Le choix du traitement est actuellement basé sur le temps écoulé depuis l'apparition des symptômes de l'AVC, la réversibilité de la lésion ischémique telle que définie par la CTP ou l'IRM, et l'accessibilité du caillot en cas de thrombectomie mécanique. En outre, il existe plusieurs techniques de thrombectomie mécanique utilisant différents dispositifs intravasculaires, tels que des stents retrievers ou des cathéters d'aspiration, et aucun outil n'est actuellement disponible pour sélectionner la meilleure stratégie de traitement endovasculaire.

Il a été suggéré que l'analyse de la texture du caillot visible sur le CT pourrait fournir des informations pour sélectionner la meilleure stratégie de traitement. Qiu et al (2019) ont pu utiliser la texture du caillot et un algorithme d'apprentissage automatique pour prédire quels patients bénéficieraient d'une recanalisation artérielle par lyse intraveineuse en cas d'AVC.¹²¹ En utilisant une approche similaire, nous avons également pu prédire la meilleure stratégie de thrombectomie mécanique et sa difficulté à l'aide d'un algorithme d'apprentissage machine entraîné à distinguer différentes caractéristiques de texture du caillot (Annexe 4 et Figure 6, publié dans la revue *Stroke*).¹²² Dans ce projet, j'ai développé deux algorithmes de machine learning entraînés à prédire la stratégie la plus efficace pour retirer un caillot

occluant une artère chez les patients souffrant d'AIS. En collaboration avec des collègues neuroradiologues, nous avons ensuite validé ce modèle sur une cohorte prospective de patients. D'autres études ont par la suite reproduit nos résultats^{123,124} et ont même établi un lien entre la texture du caillot et sa composition histopathologique.^{125,126} Nous avons récemment passé en revue le rôle de l'imagerie des caillots par CT et IRM et avons souligné que, bien qu'aucune de ces techniques ne soit actuellement approuvée pour un usage clinique, elles ont un potentiel important pour améliorer et personnaliser la prise en charge de l'AVC ischémique aigu.¹²⁷

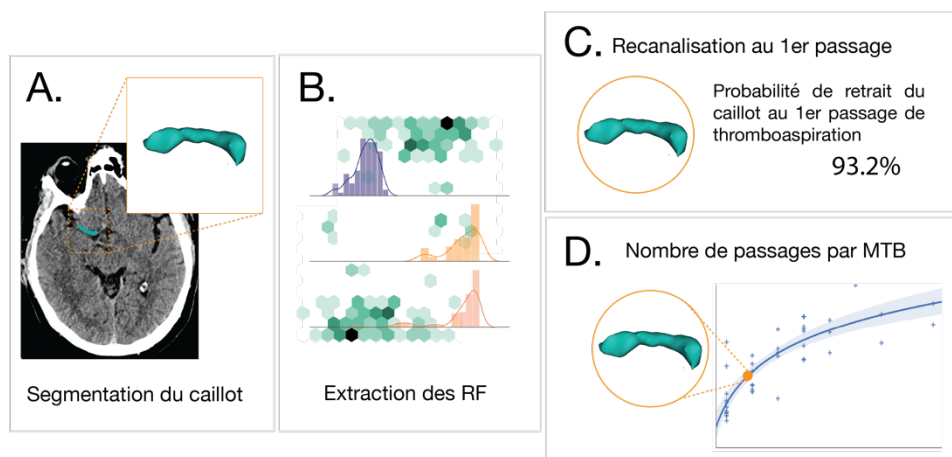


Figure 6 : L'analyse radiomics des caillots prédit la meilleure stratégie de thrombectomie mécanique pour une recanalisation complète dans l'AVC ischémique aigu. **A)** Segmentation manuelle du caillot sur un NCCT. **B)** Extraction des features radiomics (RF) à l'aide de la librairie open-source pyradiomics. **C)** Prédiction de la recanalisation de premier passage par machine learning. **D)** Prédiction du nombre total de passages nécessaires pour recanaliser l'artère par machine learning. Figure adaptée de Hofmeister et al.¹²²

Athéromatose carotido-vertébrale

L'athéromatose est une maladie de la paroi artérielle caractérisée par une accumulation pariétale de cholestérol, accompagnée de calcium et de composants inflammatoires.¹²⁸ Celle-ci peut évoluer vers une sténose ou une obstruction de l'artère et provoquer un AVC ischémique lorsqu'elle se produit dans les artères alimentant le cerveau, comme l'artère carotide interne. Le traitement des plaques athéromateuses dans l'artère carotide interne vise donc à prévenir l'accident vasculaire cérébral ischémique et consiste en un traitement médicamenteux, une intervention chirurgicale ou une procédure endovasculaire.^{129,130} Les

guidelines internationales se basent actuellement sur le degré de sténose artérielle, sa progression et ses symptômes pour identifier les patients qui bénéficieront d'un traitement préventif par chirurgie ou pose de stent endovasculaire de la sténose carotidienne.¹³¹ L'application des méthodes d'IA à l'étude des pathologies carotidiennes a considérablement progressé ces dernières années, permettant non seulement la mesure automatisée de la sténose carotidienne, mais aussi une meilleure identification des caractéristiques de vulnérabilité de la plaque.^{132,133} Par exemple, des études ont montré qu'il est possible de calculer automatiquement des marqueurs échographiques de la vulnérabilité des plaques d'athérome, tels que le "complexe intima-media".¹³⁴ Il a également été proposé de stratifier le risque d'AVC par une analyse quantitative des plaques d'athérome dans les artères carotides en couplant des algorithmes de machine learning à l'analyse de la texture des images échographiques. Bien qu'elle soit moins étudiée que pour l'échographie, l'application des méthodes d'IA au CT présente également un potentiel intéressant. Par exemple, il a été rapporté que des algorithmes de machine learning entraînés sur des données radiomics extraites de CT peuvent être utiles pour distinguer les plaques athéromateuses symptomatiques des plaques asymptomatiques, ou les plaques athéromateuses des thrombus flottants.^{135,136} Toutefois, bien que l'IA ait un potentiel intéressant pour comprendre et identifier le risque d'AVC en présence de plaques athéromateuses carotidiennes et puisse avoir des implications pour la prise en charge préventive des patients, ce domaine reste moins étudié que celui de la prise en charge des AVC ischémiques aigus discuté ci-dessus.

Hémorragie cérébrale

L'hémorragie intracrânienne (HIC) est un type de saignement qui se produit à l'intérieur du crâne. Elle peut être causée par une variété de conditions, traumatiques ou non traumatiques. Elle présente plusieurs sous-types en fonction de la localisation anatomique du saignement et comprend quatre grands types d'hémorragie : épidurale, sous-durale, sous-arachnoïdienne et intra-parenchymateuse. Chaque type d'hémorragie résulte d'étiologies différentes, et ses caractéristiques cliniques, son pronostic et son issue sont variables.^{51,137,138} L'HIC est principalement diagnostiquée par l'imagerie cérébrale, qui identifie la localisation anatomique de l'hémorragie et, dans la plupart des cas, sa cause.^{49,139,140} La cause la plus

fréquente de l'HIC est le traumatisme. En l'absence de traumatisme, l'hémorragie intracrânienne peut être associée à des maladies ou malformations vasculaires, à l'hypertension ou à d'autres pathologies cellulaires ou moléculaires des vaisseaux et du parenchyme cérébral adjacent. De nombreuses malformations vasculaires cérébrales, telles que les anévrismes, les MAVs ou les FAVs, peuvent être traitées de manière préventive si elles sont diagnostiquées avant la survenue d'une hémorragie.

Nous passerons ici en revue les progrès récents de l'imagerie neurovasculaire utilisant l'IA dans le diagnostic, le traitement, le pronostic ou la prévention des hémorragies intracrâniennes.

Diagnostic de l'HIC

La détection de l'HIC est généralement effectuée par CT en urgence. L'automatisation de la détection de l'HIC au CT a été l'une des premières applications de l'IA dans la recherche et en milieu clinique et a été largement développée ces dernières années. Les algorithmes de deep learning ont été développés comme outil de détection des hémorragies sur CT dans les cas traumatiques et non traumatiques. Ils peuvent même distinguer les différents types d'hémorragies, comme les hémorragies épidurales, sous-durales, sous-arachnoïdiennes et intraparenchymateuses. Ces capacités d'analyse tomодensitométrique rapide et automatisée ont été proposées pour améliorer la rapidité de la prise en charge des patients dans les cas où l'accès aux neuroradiologues experts est limité.

Des outils d'IA pour la détection automatisée des HIC ont été développés par de nombreux groupes de recherche et plusieurs entreprises commerciales. Il existe en effet actuellement plusieurs solutions commerciales approuvées qui effectuent cette détection et s'intègrent aux systèmes de radiologie des hôpitaux. De nombreux articles récents ont montré que ces systèmes commerciaux ont une bonne performance diagnostique, bien qu'ils puissent augmenter légèrement le nombre de faux positifs (c'est-à-dire que l'IA identifie une HIC en l'absence d'HIC).¹⁴¹⁻¹⁴⁶ Cependant, plusieurs auteurs soulignent que lorsqu'ils sont utilisés dans des hôpitaux ayant accès à des neuroradiologues experts, l'amélioration résultant de l'utilisation de l'IA est marginale et difficile à mesurer.^{142,147} Ainsi, son utilité a été démontrée principalement lorsque les radiologues experts sont plus difficiles d'accès ou lorsque leur charge de travail est très élevée, deux situations qui entraînent davantage d'erreurs ou de retards dans le diagnostic.

Le développement d'algorithmes de détection d'HIC a été grandement accéléré par le partage d'ensembles de données publics et l'organisation de défis pour comparer les solutions proposées, comme le *2019 RSNA Intracranial Hemorrhage Detection Challenge* hébergé sur Kaggle ou le *2022 Intracranial Hemorrhage Segmentation Challenge on Non-Contrast Head CT* hébergé sur <https://grand-challenge.org/>.¹⁴⁸

La grande quantité d'algorithmes d'IA commerciaux et non commerciaux pour la détection des HIC est principalement basée sur des réseaux de neurones de type CNN. Qu'ils soient développés par des sociétés commerciales ou des équipes de recherche académiques, ils montrent de bonnes performances dans la détection des hémorragies et la classification du type d'hémorragie.¹⁴⁹ Plusieurs d'entre eux ont également été entraînés à détecter des résultats associés, tels que l'effet de masse intracrânienne associé à l'HIC.¹⁵⁰ Enfin, certains de ces algorithmes ont été entraînés à segmenter l'HIC afin de calculer son volume ou son évolution d'une image à l'autre.^{151–153} Des études récentes suggèrent même que l'analyse de paramètres d'image avancés tels que la texture (ou radiomics) pourrait prédire d'autres caractéristiques telles que l'évolution, l'étiologie ou l'outcome clinique des patients.^{154–157} Cependant, cela nécessitera une validation rigoureuse avant d'être introduit dans la pratique clinique de routine.

L'une des principales limites de ces diagnostics utilisant l'IA est que la distinction entre les différentes causes d'HIC est actuellement limitée aux plus courantes et n'inclut pas les causes plus rares et souvent plus difficiles à diagnostiquer, comme l'angiopathie amyloïde ou la vasculite. En outre, les performances de l'IA sont généralement proches de celles des neuroradiologues, ce qui la rend très utile dans les cas où les ressources spécialisées sont limitées. Un développement futur de l'IA dans la gestion de l'HIC pourrait être l'extension des capacités diagnostiques de l'imagerie cérébrale pour permettre l'identification de causes rares, l'évolution, les stratégies thérapeutiques et l'outcome clinique.

Anévrismes cérébraux

Un anévrisme cérébral se développe sur un point de faiblesse dans la paroi d'une artère intracrânienne où se développe une bulle. Ces anévrismes peuvent se produire dans n'importe quelle artère du cerveau, mais ils apparaissent le plus souvent dans les grosses artères situées à la base du cerveau.¹⁵⁸ Le principal risque des anévrismes est leur rupture, qui peut provoquer une hémorragie intracrânienne et est associée à une mortalité et une morbidité

élevées.¹⁵⁹ Les anévrismes sont souvent asymptomatiques avant leur rupture et peuvent être découverts fortuitement lors d'une imagerie cérébrale. Lorsqu'un anévrisme intracrânien est découvert fortuitement, un suivi par imagerie cérébrale ou un traitement préventif par voie endovasculaire ou chirurgicale peut être recommandé en fonction de son risque de rupture. Plusieurs scores ont été développés au cours des dernières décennies pour évaluer ce risque de rupture d'un anévrisme, en fonction de sa taille, de sa localisation et de sa morphologie, ainsi que des caractéristiques cliniques, des données démographiques et des facteurs de risque du patient.¹⁶⁰ Les anévrismes surviennent chez 2 à 3 % de la population, mais seule une minorité d'entre eux présente un risque élevé de rupture. Les anévrismes peuvent être causés par un certain nombre de facteurs, notamment des anomalies vasculaires congénitales ou des facteurs génétiques. Ils sont associés à un certain nombre de facteurs de risque modifiables et non modifiables, tels que le tabagisme, l'hypertension artérielle et des antécédents familiaux d'anévrisme cérébral.

Ces dernières années, l'IA a été utilisée dans la gestion des anévrismes cérébraux pour détecter, localiser et caractériser les anévrismes cérébraux. Plusieurs solutions commerciales et académiques ont montré de bonnes performances dans le diagnostic des anévrismes intracrâniens sur CT ou IRM, y compris dans des populations cliniques.¹⁶¹⁻¹⁶⁴ Cependant, l'utilité de la détection automatisée des anévrismes dépend toujours de la disponibilité de ressources neuroradiologues expertes, comme dans le cas des AVC ischémiques ou des HIC. Les algorithmes de deep learning, qui utilisent actuellement principalement l'architecture UNet, permettent également une bonne segmentation des anévrismes intracrâniens.^{165,166} Nous avons également développé un modèle unifié de segmentation d'anévrisme en utilisant l'apprentissage par transfert à partir d'un modèle précédemment formé pour segmenter les artères intracrâniennes et entraîné sur un jeu de données public (annexe 5 et figure 7).¹⁶⁷ Dans ce projet, j'ai adapté un modèle de deep learning pour segmenter les anévrismes cérébraux sur un dataset public et développé un algorithme qui calcule automatiquement les caractéristiques morphologiques de cet anévrisme, comme sa taille. Nous avons ensuite évalué ces mesures automatiques et constaté que ses performances sont comparables à la segmentation et à la mesure des anévrismes par un neuroradiologue expert. Cela pourrait faciliter leur suivi et éviter aux neuroradiologues de devoir mesurer manuellement chaque anévrisme pour détecter un éventuel changement morphologique.

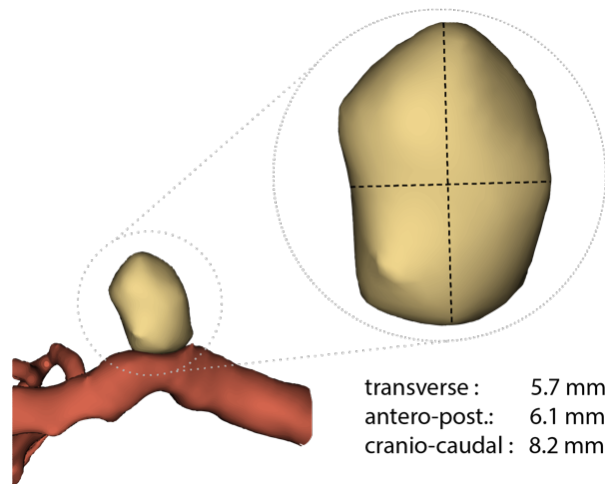


Figure 7 : Segmentation d'anévrisme cérébral et caractérisation morphologique automatique à l'aide du deep learning.

Les algorithmes d'IA peuvent également être utilisés pour prédire le risque de rupture et guider les décisions de traitement, comme le choix entre une intervention préventive ou une surveillance conservatrice de l'anévrisme.^{168–171} Un certain nombre de ces algorithmes de prédiction de rupture ont utilisé des modèles de machine learning entraînés sur des paramètres radiomics ou des modèles de deep learning entraînés directement sur les images. Bien qu'ils présentent un potentiel intéressant et permettent une prise en charge personnalisée de chaque patient, ils nécessitent une validation plus poussée avant de pouvoir être utilisés en routine clinique.

Enfin, l'IA peut contribuer à optimiser la planification des procédures endovasculaires en aidant à la sélection du dispositif endovasculaire et de sa taille afin de réduire le risque de complications et d'améliorer les résultats pour le patient.¹⁷² Des algorithmes, y compris commerciaux, ont été développés pour segmenter les anévrismes et les artères adjacentes afin de simuler par ordinateur le placement de différents dispositifs endovasculaires pour traiter un anévrisme. Les outils d'IA peuvent également aider à la gestion chirurgicale des anévrismes en facilitant la visualisation préopératoire ou peropératoire, notamment par l'utilisation de la réalité augmentée.

Malformations vasculaires

Les malformations vasculaires cérébrales sont des connexions ou des clusters anormaux de vaisseaux sanguins dans le cerveau. Elles peuvent prendre plusieurs formes, dont certaines

peuvent nécessiter un suivi ou un traitement, notamment les MAVs, les FAVs ou les malformations cavernueuses.

Les MAV se caractérisent par des connexions anormales entre les artères et les veines du cerveau.^{173,174} Le sang court-circuite le lit capillaire normal et passe directement des artères aux veines à travers un nidus de vaisseaux anormaux. Cela peut conduire à une augmentation de la pression dans le nidus et les veines, entraînant une hémorragie intracrânienne ou des symptômes tels que des maux de tête, des crises d'épilepsie ou des déficits neurologiques focaux. Les MAV sont classées en fonction de leur risque de traitement chirurgical, et leur prise en charge dépend du fait qu'elles soient rompues et hémorragiques ou non rompues.¹⁷⁵ Les MAV rompues sont traitées par voie chirurgicale, radiochirurgicale, endovasculaire ou par une combinaison de ces méthodes. Le traitement des MAV non rompues repose sur les mêmes modalités, mais il est plus controversé et son bénéfice n'a pas été clairement prouvé par des études cliniques prospectives et randomisées.

Les FAV sont également caractérisées par des connexions anormales entre les artères et les veines dures ou (moins fréquemment) piales.¹⁷⁶ Le sang contourne ainsi le lit capillaire normal et passe directement des artères aux veines, mais avec une connexion directe sans nidus. Cela peut entraîner une augmentation de la pression dans les veines dures, ce qui peut provoquer une hémorragie ou des symptômes tels que des acouphènes pulsatiles, des céphalées, des déficits neurologiques focaux ou un déclin cognitif. Le traitement des FAV est basé sur le risque de rupture et d'hémorragie ou sur l'impact des symptômes qu'elles provoquent, et il peut être endovasculaire ou chirurgical.^{177,178}

Les malformations cavernueuses sont caractérisées par des groupes de vaisseaux sanguins dilatés à paroi mince (capillaires) dans le cerveau ou la moelle épinière.^{179,180} Elles sont courantes et souvent asymptomatiques, mais dans de rares cas, elles peuvent saigner ou provoquer des symptômes tels que des crises, des maux de tête ou des déficits neurologiques focaux. Dans les rares cas où un traitement est indiqué, il est principalement chirurgical ou radiochirurgical.

Ces malformations neurovasculaires ont fait l'objet de très peu de recherches utilisant l'IA, en partie parce qu'elles sont moins fréquentes et moins traitées que les AVC ischémiques ou les anévrismes cérébraux. Cependant, les reconstructions angiographiques 3D basées sur l'IA se sont avérées être une méthode fiable pour visualiser les MAVs et les FAVs et peuvent constituer une méthode de post-traitement prometteuse pour aider à leur diagnostic. Dans

le cas des MAVs, des outils d'IA ont été développés pour guider le traitement par radiochirurgie et limiter ses complications en délimitant mieux la zone à traiter¹⁸¹ ou en prédisant les résultats et les complications possibles après le traitement.^{182,183} Des auteurs ont également utilisé des algorithmes de machine learning pour prédire le résultat et les complications du traitement endovasculaire des MAVs cérébrales, ce qui pourrait permettre d'individualiser ce traitement selon certaines caractéristiques pour chaque patient.¹⁸⁴ Enfin, l'IA a été utilisée dans quelques applications pour la prise en charge des cavernomes, notamment leur caractérisation par IRM ou par pathologie, et leur visualisation peropératoire pour guider les neurochirurgiens grâce à la réalité augmentée.¹⁸⁵

Bien que l'utilisation de l'IA dans la gestion des MAVs, des FAVs et des cavernomes soit moins avancée que dans d'autres maladies neurovasculaires, son potentiel reste intéressant, notamment pour identifier les patients qui bénéficieront d'un traitement et guider ce traitement à l'aide d'outils d'imagerie 3D et multiparamétriques. Cela nécessitera toutefois une meilleure coordination multicentrique pour partager des datasets afin d'entraîner des modèles de machine learning ou de deep learning, car ces pathologies sont beaucoup moins fréquentes que les AVC et les anévrismes.

Pathologies veineuses cérébrales

Les pathologies veineuses cérébrales constituent un ensemble de maladies qui affectent les veines cérébrales et comprennent la thrombose veineuse cérébrale (TVC), les anomalies du développement veineux, les sténoses veineuses ou les anomalies de la paroi veineuse (diverticule, déhiscence, etc.).¹⁸⁶⁻¹⁸⁸ Selon leur nature, leur taille et leur localisation, ces pathologies peuvent être asymptomatiques ou provoquer des symptômes tels que des céphalées, des crises d'épilepsie, des acouphènes pulsatiles ou des déficits neurologiques focaux, voire entraîner une HIC. Ces pathologies veineuses cérébrales sont souvent diagnostiquées à l'aide de techniques d'imagerie telles que le CT ou l'IRM ou, dans de rares cas, l'angiographie cérébrale.

L'IA n'a pas été étudiée de manière approfondie dans les pathologies veineuses cérébrales, mais son potentiel est intéressant. Par exemple, elle a été utilisée pour diagnostiquer la thrombose veineuse périphérique (c'est-à-dire principalement dans les membres inférieurs) ou pour prédire ses séquelles chroniques.¹⁸⁹⁻¹⁹³ La thrombose veineuse est une condition

dans laquelle un caillot de sang se forme dans le système veineux. Lorsque cela se produit dans les veines cérébrales, des symptômes tels que des maux de tête, des déficits neurologiques ou des hémorragies peuvent survenir et entraîner des séquelles à long terme.¹⁸⁶ Le traitement de la TVC est principalement basé sur l'anticoagulation, et les indications du traitement endovasculaire ne sont pas bien établies. L'IA pourrait donc aider à identifier la meilleure approche thérapeutique pour les patients souffrant de TVC afin de limiter le risque d'hémorragie ou le développement de séquelles telles que les sténose ou les FAVs.¹⁹⁴

Perspectives

Dans cette thèse, nous avons passé en revue les applications et développements actuels de l'IA dans l'imagerie des maladies neurovasculaire, aussi bien lorsqu'elle est utilisée pour leur diagnostic que pour leur traitement. Nous avons vu que l'IA est utile pour la détection et la caractérisation des maladies neurovasculaires par imagerie cérébrale, et qu'elle a un potentiel intéressant pour fournir des informations pertinentes pour leur diagnostic, leur traitement et leur pronostic, même lorsque ces informations sont invisibles pour l'œil humain expert. Nous avons également vu que l'IA a un potentiel au-delà de l'interprétation des images, comme l'amélioration de la qualité et de la vitesse d'acquisition, ou la réduction de la dose de radiation ou de l'utilisation d'un agent de contraste. Cependant, il est important de rappeler que l'utilisation clinique de l'IA est encore strictement réglementée, et malgré l'enthousiasme de la communauté scientifique, l'IA reste soumise à plusieurs limitations et biais potentiels.¹⁹⁵ Ces limitations sont de plusieurs types en imagerie clinique et peuvent être liées aux données utilisées pour entraîner les algorithmes, aux algorithmes eux-mêmes, à la compréhension scientifique de la maladie, ainsi qu'aux questions éthiques et juridiques liées à leur utilisation.

Les algorithmes d'IA nécessitent de grandes quantités de données pour s'entraîner, mais la disponibilité des données médicales peut être limitée, en particulier pour les maladies ou traitements rares. La qualité des données utilisées pour entraîner les algorithmes d'IA est essentielle à leur performance, mais les données utilisées en médecine peuvent être incomplètes, incohérentes, inexactes ou non représentatives d'une population entière.¹⁹⁶⁻¹⁹⁸ Par exemple, des biais liés au genre ou à la race ont été signalés en raison de la faible

représentation des minorités (dans le monde occidental).^{199–201} En outre, le labelling des données utilisées dans les tâches de classification est principalement effectué par des humains et pas nécessairement par des experts, alors même qu'en médecine les experts ne soient pas toujours en mesure de fournir un diagnostic parfait (ou *gold-standard*). Enfin, si les datasets d'entraînement sont trop sélectionnées et peu variées, cela soulève des inquiétudes quant à la généralisation des prédictions lorsqu'un algorithme est utilisé dans un environnement différent, parfois sans même le savoir. Le soin apporté à la création de datasets d'entraînement représentatifs, variés et correctement labellisés est donc un élément essentiel du développement de l'IA en imagerie neurovasculaire.⁶⁹

Les algorithmes d'IA deviennent de plus en plus puissants, mais aussi très complexes, avec des niveaux de calcul difficiles à comprendre, même pour les experts humains.

L'interprétabilité et la transparence du "raisonnement" et des prédictions de l'IA sont donc difficiles à apprécier pour les humains, ce qui peut conduire à un faible niveau de compréhension des erreurs qu'une machine peut commettre.^{202,203} Ces questions d'interprétabilité et de responsabilité font actuellement l'objet de recherches théoriques et appliquées, avec des propositions pour que les modèles d'IA produisent des outputs visuels ou des références de leur "raisonnement".²⁰⁴

Les algorithmes d'IA peuvent aider à identifier des patterns dans les données biomédicales et à faire des prédictions, mais ils sont actuellement limités à une forme d'IA étroite et ne sont pas capables d'une compréhension globale de la physiopathologie ou des concepts généraux de la biologie et de la physique.²⁰⁵ Par conséquent, leur développement est conçu pour répondre à des questions spécifiques et est actuellement supervisé par des humains qui peuvent ou non être des experts dans un domaine médical. Une collaboration efficace entre les cliniciens experts qui peuvent formuler des questions pertinentes et les ingénieurs qui peuvent fournir des réponses techniques à ces questions est donc essentielle au développement d'outils d'IA adaptés à une prise en charge sûre et efficace des patients. La collaboration entre les domaines cliniques et techniques, mais aussi le respect des principes éthiques et du cadre réglementaire, seront donc importants pour le bon usage de l'IA en imagerie neurovasculaire, mais aussi dans les autres domaines de la médecine.

Conclusion

En conclusion, nous avons abordé l'histoire et la portée de l'IA, ainsi que ses applications actuelles les plus populaires en imagerie neurovasculaire, afin d'offrir à un lectorat de médecins la possibilité d'en savoir plus sur les développements récents et potentiels que l'IA a à offrir. Nous avons également passé en revue les maladies neurovasculaires les plus courantes, de leur diagnostic à leur traitement, afin de fournir à un lectorat de chercheurs et d'ingénieurs une perspective sur les possibilités offertes par l'IA dans leur prise en charge. Ce faisant, nous avons tenté de combler le fossé entre les domaines de la médecine et de l'ingénierie pour comprendre les applications actuelles de l'IA en neuroimagerie, son potentiel, mais aussi ses limites actuelles dans la prise en charge des maladies neurovasculaires.

Références

- 1 P McCorduck, M Minsky, OG Selfridge HS. History of artificial intelligence. *IJCAI* 1977;:951–4.
- 2 Buchanan BG. A (Very) Brief History of Artificial Intelligence. 2005. doi:10.1609/AIMAG.V26I4.1848
- 3 McCorduck P. *Machines Who Think: A Personal Inquiry into the History and Prospects of Artificial Intelligence*. A K Peters, Ltd. 2004.
- 4 Homer, Lattimore (transl.) R. *Iliad*. Chicago & London: 1951.
- 5 Sparkes B. *The red and the black.: Studies in Greek pottery*. London and New York: 1996.
- 6 David W. Tandy. *Warriors Into Traders: The Power of the Market in Early Greece*. Berkeley: : University of California Press 1997.
- 7 Brynjolfsson E, Mitchell T. What can machine learning do? Workforce implications: Profound change is coming, but roles for humans remain. *Science (80-)*. 2017;358:1530–4. doi:10.1126/science.aap8062
- 8 Moor J. The Dartmouth College Artificial Intelligence Conference: The Next Fifty Years. *AI Mag* 2006;27:87. doi:10.1609/AIMAG.V27I4.1911
- 9 Turing A. Computing Machinery and Intelligence. *Mind* 1950;59:433–60. doi:10.1093/mind/LIX.236.433
- 10 Epstein R. Can Machines Think? The Quest for the Thinking ComputerComputers Try to Fool Humans at theFirst Annual Loebner Prize CompetitionHeld at The Computer Museum, Boston. *AI Mag* 1992;13:81–81. doi:10.1609/AIMAG.V13I2.993
- 11 Russell SJ, Norvig P. *Artificial intelligence : a modern approach (4th edition)*. Pearson 2019.
- 12 Goodfellow IJ, Bengio Y, Courville A. *Deep Learning*. Cambridge, MA, USA: : MIT Press 2016.
- 13 Haenlein M, Kaplan A. A brief history of artificial intelligence: On the past, present, and future of artificial intelligence. *Calif Manage Rev* 2019;61:5–14. doi:10.1177/0008125619864925
- 14 Toosi A, Bottino AG, Saboury B, et al. A Brief History of AI: How to Prevent Another Winter (A Critical Review). *PET Clin*. 2021;16:449–69. doi:10.1016/j.cpet.2021.07.001
- 15 Delipetrev B, Tsinaraki C, Kostic U. *Historical Evolution of Artificial Intelligence*. Luxembourg: : Publications Office of the European Union 2020. doi:10.2760/801580
- 16 Muthukrishnan N, Maleki F, Ovens K, et al. Brief History of Artificial Intelligence. *Neuroimaging Clin. N. Am*. 2020;30:393–9. doi:10.1016/j.nic.2020.07.004
- 17 Lecun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015;521:436–44. doi:10.1038/nature14539
- 18 Ledley RS, Lusted LB. Reasoning foundations of medical diagnosis. *Science (80-)* 1959;130:9–21. doi:10.1126/science.130.3366.9
- 19 Yu KH, Beam AL, Kohane IS. Artificial intelligence in healthcare. *Nat. Biomed. Eng*. 2018;2:719–31.

- doi:10.1038/s41551-018-0305-z
- 20 Gelman M. Computers in medicine - The office setting. *West J Med* 1985;142:230–4.
- 21 Kahn CE. Inteffigence in Radiology: Decision Support Systems. *Radiographics* 1994;14:849–61. <https://pubs.rsna.org/doi/pdf/10.1148/radiographics.14.4.7938772>
- 22 Yu VL, Fagan LM, Wraith SM, *et al.* Antimicrobial Selection by a Computer: A Blinded Evaluation by Infectious Diseases Experts. *JAMA J Am Med Assoc* 1979;242:1279–82. doi:10.1001/jama.1979.03300120033020
- 23 Kaul V, Enslin S, Gross SA. History of artificial intelligence in medicine. *Gastrointest. Endosc.* 2020;92:807–12. doi:10.1016/j.gie.2020.06.040
- 24 Hosny A, Parmar C, Quackenbush J, *et al.* Artificial intelligence in radiology. *Nat. Rev. Cancer.* 2018;18:500–10. doi:10.1038/s41568-018-0016-5
- 25 Harrington SG, Johnson MK. The FDA and Artificial Intelligence in Radiology: Defining New Boundaries. *J. Am. Coll. Radiol.* 2019;16:743–4. doi:10.1016/j.jacr.2018.09.057
- 26 Harvey HB, Gowda V. How the FDA Regulates AI. *Acad. Radiol.* 2020;27:58–61. doi:10.1016/j.acra.2019.09.017
- 27 Esteve A, Robicquet A, Ramsundar B, *et al.* A guide to deep learning in healthcare. *Nat. Med.* 2019;25:24–9. doi:10.1038/s41591-018-0316-z
- 28 Higgins D, Madai VI. From Bit to Bedside: A Practical Framework for Artificial Intelligence Product Development in Healthcare. *Adv Intell Syst* 2020;2:2000052. doi:10.1002/aisy.202000052
- 29 Recht MP, Dewey M, Dreyer K, *et al.* Integrating artificial intelligence into the clinical practice of radiology: challenges and recommendations. *Eur Radiol* 2020;30:3576–84. doi:10.1007/s00330-020-06672-5
- 30 Allen B, Seltzer SE, Langlotz CP, *et al.* A Road Map for Translational Research on Artificial Intelligence in Medical Imaging: From the 2018 National Institutes of Health/RSNA/ACR/The Academy Workshop. *J Am Coll Radiol* 2019;16:1179–89. doi:10.1016/j.jacr.2019.04.014
- 31 Chang PJ. Moving artificial intelligence from feasible to real: Time to drill for gas and build roads. *Radiology.* 2020;294:432–3. doi:10.1148/radiol.2019192527
- 32 Bluemke DA. Radiology in 2018: Are you working with AI or being replaced by AI? *Radiology.* 2018;287:365–6. doi:10.1148/radiol.2018184007
- 33 Jha S, Cook T. Artificial Intelligence in Radiology—The State of the Future. *Acad. Radiol.* 2020;27:1–2. doi:10.1016/j.acra.2019.11.003
- 34 Olthof AW, van Ooijen PMA, Rezazade Mehrizi MH. Promises of artificial intelligence in neuroradiology: a systematic technographic review. *Neuroradiology* 2020;62:1265–78. doi:10.1007/s00234-020-02424-w
- 35 Zaharchuk G, Gong E, Wintermark M, *et al.* Deep learning in neuroradiology. *Am. J. Neuroradiol.* 2018;39:1776–84. doi:10.3174/ajnr.A5543
- 36 Yao AD, Cheng DL, Pan I, *et al.* Deep Learning in Neuroradiology: A Systematic Review of Current Algorithms and Approaches for the New Wave of Imaging Technology. *Radiol Artif Intell* 2020;2:e190026. doi:10.1148/ryai.2020190026
- 37 Kaka H, Zhang E, Khan N. Artificial Intelligence and Deep Learning in Neuroradiology: Exploring the New Frontier. *Can. Assoc. Radiol. J.* 2021;72:35–44. doi:10.1177/0846537120954293
- 38 Nenning K-H, Langs G. Machine learning in neuroimaging: from research to clinical practice. *Radiol (Heidelberg, Ger)* 2022;62:1. doi:10.1007/S00117-022-01051-1
- 39 Richardson ML, Garwood ER, Lee Y, *et al.* Noninterpretive Uses of Artificial Intelligence in Radiology. *Acad Radiol* 2021;28:1225–35. doi:10.1016/j.acra.2020.01.012
- 40 Sreekumari A, Shanbhag D, Yeo D, *et al.* A deep learning-based approach to reduce rescan and recall rates in clinical MRI examinations. *Am J Neuroradiol* 2019;40:217–23. doi:10.3174/ajnr.A5926
- 41 Lakhani P, Prater AB, Hutson RK, *et al.* Machine Learning in Radiology: Applications Beyond Image Interpretation. *J Am Coll Radiol* 2018;15:350–9. doi:10.1016/j.jacr.2017.09.044
- 42 Richardson ML, Garwood ER, Lee Y, *et al.* Noninterpretive Uses of Artificial Intelligence in Radiology. *Acad Radiol* Published Online First: 2020. doi:10.1016/j.acra.2020.01.012
- 43 Marcadent S, Hofmeister J, Preti MG, *et al.* Generative Adversarial Networks Improve the Reproducibility and Discriminative Power of Radiomic Features. *Radiol Artif Intell* 2020;2:e190035.
- 44 Yao AD, Cheng DL, Pan I, *et al.* Deep Learning in Neuroradiology: A Systematic Review of Current Algorithms and Approaches for the New Wave of Imaging Technology. *Radiol Artif Intell* 2020;2:e190026. doi:10.1148/ryai.2020190026
- 45 Duong MT, Rauschecker AM, Mohan S. Diverse Applications of Artificial Intelligence in Neuroradiology. *Neuroimaging Clin. N. Am.* 2020;30:505–16. doi:10.1016/j.nic.2020.07.003
- 46 Olthof AW, van Ooijen PMA, Rezazade Mehrizi MH. Promises of artificial intelligence in neuroradiology: a systematic technographic review. *Neuroradiology* 2020;62:1265–78.

- doi:10.1007/s00234-020-02424-w
- 47 Kaka H, Zhang E, Khan N. Artificial Intelligence and Deep Learning in Neuroradiology: Exploring the New Frontier. *Can. Assoc. Radiol. J.* 2021;72:35–44. doi:10.1177/0846537120954293
- 48 Campbell BCV, De Silva DA, Macleod MR, *et al.* Ischaemic stroke. *Nat Rev Dis Prim* 2019;5. doi:10.1038/s41572-019-0118-8
- 49 Keep RF, Hua Y, Xi G. Intracerebral haemorrhage: mechanisms of injury and therapeutic targets. *Lancet Neurol* 2012;11:720–31. doi:10.1016/s1474-4422(12)70104-7
- 50 Qureshi AI, Mendelow AD, Hanley DF. Intracerebral haemorrhage. *Lancet* 2009;373:1632–44. doi:10.1016/s0140-6736(09)60371-8
- 51 Caceres JA, Goldstein JN. Intracranial Hemorrhage. *Emerg Med Clin North Am* 2012;30:771–94. doi:10.1016/j.emc.2012.06.003
- 52 Kortman HGJ, Smit EJ, Oei MTH, *et al.* 4D-CTA in neurovascular disease: A review. *Am J Neuroradiol* 2015;36:1026–33. doi:10.3174/ajnr.A4162
- 53 Byrne JV. Tutorials in Endovascular Neurosurgery and Interventional Neuroradiology. 2017. doi:10.1007/978-3-319-54835-7
- 54 Ruedinger KL, Schafer S, Speidel MA, *et al.* 4D-DSA: development and current neurovascular applications. *AJNR Am J Neuroradiol* 2021;42:214–20. doi:10.3174/ajnr.a6860
- 55 Kortman HGJ, Smit EJ, Oei MTH, *et al.* 4D-CTA in Neurovascular Disease: A Review. *AJNR Am J Neuroradiol* 2015;36:1026. doi:10.3174/AJNR.A4162
- 56 Davis B, Royalty K, Kowarschik M, *et al.* 4D digital subtraction angiography: Implementation and demonstration of feasibility. *Am J Neuroradiol* 2013;34:1914–21. doi:10.3174/AJNR.A3529
- 57 Lang S, Göllitz P, Struffert T, *et al.* 4D DSA for dynamic visualization of cerebral vasculature: A single-center experience in 26 cases. *Am J Neuroradiol* 2017;38:1169–76. doi:10.3174/AJNR.A5161
- 58 Takahashi S. *Neurovascular Imaging*. Berlin Heidelberg London New York: : Springer 2010. doi:10.1007/978-1-84882-134-7
- 59 Berkhemer OA, Fransen PSS, Beumer D, *et al.* A randomized trial of intraarterial treatment for acute ischemic stroke. *N Engl J Med* 2015;372:11–20. doi:10.1056/NEJMoa1411587
- 60 Saver JL, Goyal M, Bonafe A, *et al.* Stent-retriever thrombectomy after intravenous t-PA vs. t-PA alone in stroke. *N Engl J Med* 2015;372:2285–95. doi:10.1056/NEJMoa1415061
- 61 Goyal M, Demchuk AM, Menon BK, *et al.* Randomized assessment of rapid endovascular treatment of ischemic stroke. *N Engl J Med* 2015;372:1019–30. doi:10.1056/NEJMoa1414905
- 62 Campbell BCV, Mitchell PJ, Kleinig TJ, *et al.* Endovascular therapy for ischemic stroke with perfusion-imaging selection. *N Engl J Med* 2015;372:1009–18. doi:10.1056/NEJMoa1414792
- 63 Jovin TG, Chamorro A, Cobo E, *et al.* Thrombectomy within 8 hours after symptom onset in ischemic stroke. *N Engl J Med* 2015;372:2296–306. doi:10.1056/NEJMoa1503780
- 64 S Román SL, Blasco J, K Menon CB, *et al.* Imaging features and safety and efficacy of endovascular stroke treatment: a meta-analysis of individual patient-level data. 2018. www.thelancet.com/neurology
- 65 Molyneux AJ, Kerr RS, Yu LM, *et al.* International Subarachnoid Aneurysm Trial (ISAT) of neurosurgical clipping versus endovascular coiling in 2143 patients with ruptured intracranial aneurysms: A randomised comparison of effects on survival, dependency, seizures, rebleeding, subgroups, and aneurysm occlusion. *Lancet* 2005;366:809–17. doi:10.1016/S0140-6736(05)67214-5
- 66 Molyneux AJ, Birks J, Clarke A, *et al.* The durability of endovascular coiling versus neurosurgical clipping of ruptured cerebral aneurysms: 18 year follow-up of the UK cohort of the International Subarachnoid Aneurysm Trial (ISAT). *Lancet* 2015;385:691–7. doi:10.1016/S0140-6736(14)60975-2
- 67 Molyneux A, Kerr R, Stratton I, *et al.* International Subarachnoid Aneurysm Trial (ISAT) of neurosurgical clipping versus endovascular coiling in 2143 patients with ruptured intracranial aneurysms: A randomised trial. *Lancet* 2002;360:1267–74. doi:10.1016/S0140-6736(02)11314-6
- 68 Iezzi R, Goldberg SN, Merlino B, *et al.* Artificial Intelligence in Interventional Radiology: A Literature Review and Future Perspectives. *J Oncol* 2019;2019:6153041. doi:10.1155/2019/6153041
- 69 Sailer AM, Tiplaldi MA, Krokidis M. AI in Interventional Radiology: There is Momentum for High-Quality Data Registries. *Cardiovasc. Intervent. Radiol.* 2019;42:1208–9. doi:10.1007/s00270-019-02249-y
- 70 Meek RD, Lungren MP, Gichoya JW. Machine Learning for the Interventional Radiologist. *Am J Roentgenol* 2019;213:782–4. doi:10.2214/AJR.19.21527
- 71 Byrne JV. Cranial Arterial Anatomy. *Tutorials Endovasc Neurosurg Interv Neuroradiol* 2017;:27–55. doi:10.1007/978-3-319-54835-7_2

- 72 Agid R, Shelef I, Scott JN, *et al.* Imaging of the Intracranial Venous System. *Neurologist* 2008;14:12–22. doi:10.1097/NRL.0b013e318157f791
- 73 Zhao F, Chen Y, Hou Y, *et al.* Segmentation of blood vessels using rule-based and machine-learning-based methods: a review. *Multimed Syst* 2019;25:109–18. doi:10.1007/s00530-017-0580-7
- 74 Goni MR, Ruhaiyem NIR, Mustapha M, *et al.* Brain vessel segmentation using deep learning - A review. *IEEE Access* Published Online First: 2022. doi:10.1109/ACCESS.2022.3214987
- 75 Livne M, Rieger J, Aydin OU, *et al.* A U-Net deep learning framework for high performance vessel segmentation in patients with cerebrovascular disease. *Front Neurosci* 2019;13:97. doi:10.3389/fnins.2019.00097
- 76 Hilbert A, Madai VI, Akay EM, *et al.* BRAVE-NET: Fully Automated Arterial Brain Vessel Segmentation in Patients With Cerebrovascular Disease. *Front Artif Intell* 2020;3. doi:10.3389/FRAI.2020.552258
- 77 Subramaniam P, Kossen T, Ritter K, *et al.* Generating 3D TOF-MRA volumes and segmentation labels using generative adversarial networks. *Med Image Anal* 2022;78. doi:10.1016/J.MEDIA.2022.102396
- 78 Fu F, Wei J, Zhang M, *et al.* Rapid vessel segmentation and reconstruction of head and neck angiograms using 3D convolutional neural network. *Nat Commun* 2020;11. doi:10.1038/S41467-020-18606-2
- 79 Patel TR, Pinter N, Sarayi SMMJ, *et al.* Automated Cerebral Vessel Segmentation of Magnetic Resonance Imaging in Patients with Intracranial Atherosclerotic Diseases. *Proc Annu Int Conf IEEE Eng Med Biol Soc EMBS* 2021;:3920–3. doi:10.1109/EMBC46164.2021.9630626
- 80 Meijis M, Pegge SAH, Vos MHE, *et al.* Cerebral Artery and Vein Segmentation in Four-dimensional CT Angiography Using Convolutional Neural Networks. *Radiol Artif Intell* 2020;2:1–9. doi:10.1148/Ryai.2020190178
- 81 Isensee F, Jaeger PF, Kohl SAA, *et al.* nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. *Nat Methods* 2020 182 2020;18:203–11. doi:10.1038/s41592-020-01008-z
- 82 Bashir SMA, Wang Y, Khan M, *et al.* A Comprehensive Review of Deep Learning-based Single Image Super-resolution. *PeerJ Comput Sci* 2021;7:1–56. doi:10.48550/arxiv.2102.09351
- 83 Dong C, Loy CC, He K, *et al.* Image Super-Resolution Using Deep Convolutional Networks. *IEEE Trans Pattern Anal Mach Intell* 2016;38:295–307. doi:10.1109/TPAMI.2015.2439281
- 84 Mardani M, Gong E, Cheng JY, *et al.* Deep generative adversarial neural networks for compressive sensing MRI. *IEEE Trans Med Imaging* 2019;38:167–79. doi:10.1109/TMI.2018.2858752
- 85 Vey BL, Gichoya JW, Prater A, *et al.* The Role of Generative Adversarial Networks in Radiation Reduction and Artifact Correction in Medical Imaging. *J Am Coll Radiol* 2019;16:1273–8. doi:10.1016/j.jacr.2019.05.040
- 86 Johnson PM, Drangova M. Conditional generative adversarial network for 3D rigid-body motion correction in MRI. *Magn Reson Med* 2019;82:901–10. doi:10.1002/mrm.27772
- 87 Hu Z, Jiang C, Sun F, *et al.* Artifact correction in low-dose dental CT imaging using Wasserstein generative adversarial networks. *Med Phys* 2019;46:1686–96. doi:10.1002/mp.13415
- 88 Yoon J, Gong E, Chatnuntawech I, *et al.* Quantitative susceptibility mapping using deep neural network: QSMnet. *Neuroimage* 2018;179:199–206. doi:10.1016/J.NEUROIMAGE.2018.06.030
- 89 Kim KH, Choi SH, Park SH. Improving arterial spin labeling by using deep learning. *Radiology* 2018;287:658–66. doi:10.1148/RADIOL.2017171154
- 90 Chen H, Zhang Y, Zhang W, *et al.* aLow-dose CT via convolutional neural network. *Biomed Opt Express* 2017;8:679. doi:10.1364/BOE.8.000679
- 91 Xiao Y, Liu P, Liang Y, *et al.* STIR-net: Deep spatial-temporal image restoration net for radiation reduction in CT perfusion. *Front Neurol* 2019;10. doi:10.3389/FNEUR.2019.00647
- 92 Gong E, Pauly JM, Wintermark M, *et al.* Deep learning enables reduced gadolinium dose for contrast-enhanced brain MRI. *J Magn Reson Imaging* 2018;48:330–40. doi:10.1002/jmri.25970
- 93 Cirillo MD, Abramian D, Eklund A. Vox2Vox: 3D-GAN for Brain Tumour Segmentation. In: *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. Springer Science and Business Media Deutschland GmbH 2021. 274–84. doi:10.1007/978-3-030-72084-1_25
- 94 Erickson BJ, Cai J. Magician’s Corner: 5. Generative Adversarial Networks. *Radiol Artif Intell* 2020;2:e190215. doi:10.1148/ryai.2020190215
- 95 Yi X, Walia E, Babyn P. Generative Adversarial Network in Medical Imaging: A Review. *Med Image Anal* 2018;58. doi:10.1016/j.media.2019.101552
- 96 Zhu JY, Park T, Isola P, *et al.* Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks. In:

- Proceedings of the IEEE International Conference on Computer Vision*. Institute of Electrical and Electronics Engineers Inc. 2017. 2242–51. doi:10.1109/ICCV.2017.244
- 97 Mouridsen K, Thurner P, Zaharchuk G. Artificial Intelligence Applications in Stroke. *Stroke* 2020;51:2573–9. doi:10.1161/STROKEAHA.119.027479
- 98 Leslie-Mazwi TM, Lev MH. Towards artificial intelligence for clinical stroke care. *Nat Rev Neurol* 2019 161 2019;16:5–6. doi:10.1038/s41582-019-0287-9
- 99 Bivard A, Churilov L, Parsons M. Artificial intelligence for decision support in acute stroke — current roles and potential. *Nat Rev Neurol* 2020 1610 2020;16:575–85. doi:10.1038/s41582-020-0390-y
- 100 Murray NM, Unberath M, Hager GD, et al. Artificial intelligence to diagnose ischemic stroke and identify large vessel occlusions: A systematic review. *J Neurointerv Surg*. 2020;12:156–64. doi:10.1136/neurintsurg-2019-015135
- 101 Hamann J, Herzog L, Wehrli C, et al. Machine-learning-based outcome prediction in stroke patients with middle cerebral artery-M1 occlusions and early thrombectomy. *Eur J Neurol* 2021;28:1234–43. doi:10.1111/ene.14651
- 102 Brugnara G, Neuberger U, Mahmutoglu MA, et al. Multimodal Predictive Modeling of Endovascular Treatment Outcome for Acute Ischemic Stroke Using Machine-Learning. *Stroke* 2020;:3541–51. doi:10.1161/STROKEAHA.120.030287
- 103 Bentley P, Ganesalingam J, Carlton Jones AL, et al. Prediction of stroke thrombolysis outcome using CT brain machine learning. *NeuroImage Clin* 2014;4:635–40. doi:10.1016/J.NICL.2014.02.003
- 104 Bacchi S, Zerner T, Oakden-Rayner L, et al. Deep Learning in the Prediction of Ischaemic Stroke Thrombolysis Functional Outcomes: A Pilot Study. *Acad Radiol* 2020;27:e19–23. doi:10.1016/J.ACRA.2019.03.015
- 105 Nishi H, Oishi N, Ishii A, et al. Deep Learning-Derived High-Level Neuroimaging Features Predict Clinical Outcomes for Large Vessel Occlusion. *Stroke* 2020;:1484–92. doi:10.1161/STROKEAHA.119.028101
- 106 Shlobin NA, Baig AA, Waqas M, et al. Artificial Intelligence for Large-Vessel Occlusion Stroke: A Systematic Review. *World Neurosurg*. 2022;159:207–220.e1. doi:10.1016/j.wneu.2021.12.004
- 107 Olive-Gadea M, Crespo C, Granes C, et al. Deep Learning Based Software to Identify Large Vessel Occlusion on Noncontrast Computed Tomography. *Stroke* 2020;:3133–7. doi:10.1161/STROKEAHA.120.030326
- 108 Stib MT, Vasquez J, Dong MP, et al. Detecting large vessel occlusion at multiphase CT angiography by using a deep convolutional neural network. *Radiology* 2020;297:640–9. doi:10.1148/radiol.2020200334
- 109 Amukotuwa SA, Straka M, Smith H, et al. Automated detection of intracranial large vessel occlusions on computed tomography angiography a single center experience. *Stroke* 2019;50:2790–8. doi:10.1161/STROKEAHA.119.026259
- 110 Guberina N, Dietrich U, Radbruch A, et al. Detection of early infarction signs with machine learning-based diagnosis by means of the Alberta Stroke Program Early CT score (ASPECTS) in the clinical routine. *Neuroradiology* 2018;60:889–901. doi:10.1007/S00234-018-2066-5
- 111 Nagel S, Sinha D, Day D, et al. e-ASPECTS software is non-inferior to neuroradiologists in applying the ASPECT score to computed tomography scans of acute ischemic stroke patients. *Int J Stroke* 2017;12:615–22. doi:10.1177/1747493016681020
- 112 Neuhaus A, Seyedsaadat SM, Mihal D, et al. Region-specific agreement in ASPECTS estimation between neuroradiologists and e-ASPECTS software. *J Neurointerv Surg* 2020;12:720–3. doi:10.1136/neurintsurg-2019-015442
- 113 Chen L, Bentley P, Rueckert D. Fully automatic acute ischemic lesion segmentation in DWI using convolutional neural networks. *NeuroImage Clin* 2017;15:633–43. doi:10.1016/J.NICL.2017.06.016
- 114 Wang K, Shou Q, Ma SJ, et al. Deep Learning Detection of Penumbra Tissue on Arterial Spin Labeling in Stroke. *Stroke* 2020;:489–97. doi:10.1161/STROKEAHA.119.027457
- 115 Meier R, Lux P, Jung S, et al. Neural network-derived perfusion maps for the assessment of lesions in patients with acute ischemic stroke. *Radiol Artif Intell* 2019;1. doi:10.1148/ryai.2019190019
- 116 Stier N, Vincent N, Liebeskind D, et al. Deep learning of tissue fate features in acute ischemic stroke. *Proc - 2015 IEEE Int Conf Bioinform Biomed BIBM 2015* 2015;:1316–21. doi:10.1109/BIBM.2015.7359869
- 117 Winzeck S, Hakim A, McKinley R, et al. ISLES 2016 and 2017-benchmarking ischemic stroke lesion outcome prediction based on multispectral MRI. *Front Neurol* 2018;9:679. doi:10.3389/FNEUR.2018.00679/BIBTEX
- 118 Maier O, Menze BH, von der Gablentz J, et al. ISLES 2015 - A public evaluation benchmark for ischemic stroke lesion segmentation from multispectral MRI. *Med Image Anal* 2017;35:250–69. doi:10.1016/J.MEDIA.2016.07.009
- 119 Petzsche MRH, de la Rosa E, Hanning U, et al. ISLES 2022: A multi-center magnetic resonance imaging stroke lesion segmentation dataset. *Sci Data* 2022 91 2022;9:1–9.

- doi:10.1038/s41597-022-01875-5
- 120 Mojtahedi M, Kappelhof M, Ponomareva E, *et al.* Fully Automated Thrombus Segmentation on CT Images of Patients with Acute Ischemic Stroke. *Diagnostics* 2022;12. doi:10.3390/DIAGNOSTICS12030698
- 121 Qiu W, Kuang H, Nair J, *et al.* Radiomics-based intracranial thrombus features on CT and CTA predict recanalization with intravenous alteplase in patients with acute ischemic stroke. *Am J Neuroradiol* 2019;40:39–44. doi:10.3174/ajnr.A5918
- 122 Hofmeister J, Bernava G, Rosi A, *et al.* Clot-Based Radiomics Predict a Mechanical Thrombectomy Strategy for Successful Recanalization in Acute Ischemic Stroke. *Stroke* 2020;51:2488–94. doi:10.1161/STROKEAHA.120.030334
- 123 Voorst H van, Bruggeman AAE, Yang W, *et al.* Thrombus radiomics in patients with anterior circulation acute ischemic stroke undergoing endovascular treatment. *J Neurointerv Surg* 2022;0:1–7. doi:10.1136/JNIS-2022-019085
- 124 Li L, Li M, Chen Z, *et al.* Prognostic value of radiomics-based hyperdense middle cerebral artery sign for patients with acute ischemic stroke after thrombectomy strategy. *Front Neurol* 2023;13:3023. doi:10.3389/fneur.2022.1037204
- 125 Patel TR, Waqas M, Fricano S, *et al.* Clot organization on histology is associated with radiomics features that predict treatment outcomes from mechanical thrombectomy. In: Tomaszewski JE, Ward AD, eds. *Medical Imaging 2021: Digital Pathology*. SPIE 2021. 18. doi:10.1117/12.2581130
- 126 Hanning U, Sporns PB, Psychogios MN, *et al.* Imaging-based prediction of histological clot composition from admission CT imaging. *J Neurointerv Surg* Published Online First: 2021. doi:10.1136/neurintsurg-2020-016774
- 127 Dumitriu LaGrange D, Hofmeister J, Rosi A, *et al.* Predictive value of clot imaging in acute ischemic stroke: A systematic review of artificial intelligence and conventional studies. *Neurosci Informatics* 2023;3:100114. doi:10.1016/j.neuri.2022.100114
- 128 Libby P, Buring JE, Badimon L, *et al.* Atherosclerosis. *Nat Rev Dis Prim* 2019;5. doi:10.1038/s41572-019-0106-z
- 129 Krist AH, Davidson KW, Mangione CM, *et al.* Screening for Asymptomatic Carotid Artery Stenosis: US Preventive Services Task Force Recommendation Statement. *JAMA - J Am Med Assoc* 2021;325:476–81. doi:10.1001/jama.2020.26988
- 130 Saba L, Saam T, Jäger HR, *et al.* Imaging biomarkers of vulnerable carotid plaques for stroke risk prediction and their potential clinical implications. *Lancet Neurol* 2019;18:559–72. doi:10.1016/S1474-4422(19)30035-3
- 131 Bonati LH, Kakkos S, Berkefeld J, *et al.* European Stroke Organisation guideline on endarterectomy and stenting for carotid artery stenosis. *Eur Stroke J* 2021;6:I–XLVII. doi:10.1177/23969873211012121
- 132 Porcu M, Cau R, Suri JS, *et al.* Artificial Intelligence- and Radiomics-Based Evaluation of Carotid Artery Disease. In: *Artificial Intelligence in Cardiothoracic Imaging*. Humana, Cham 2022. 513–23. doi:10.1007/978-3-030-92087-6_48
- 133 Sharma AM, Gupta A, Kumar PK, *et al.* A Review on Carotid Ultrasound Atherosclerotic Tissue Characterization and Stroke Risk Stratification in Machine Learning Framework. *Curr Atheroscler Rep* 2015;17:1–13. doi:10.1007/S11883-015-0529-2/TABLES/2
- 134 Biswas M, Saba L, Chakrabarty S, *et al.* Two-stage artificial intelligence model for jointly measurement of atherosclerotic wall thickness and plaque burden in carotid ultrasound: A screening tool for cardiovascular/stroke risk assessment. *Comput Biol Med* 2020;123:103847. doi:10.1016/J.COMPBIOMED.2020.103847
- 135 Acharya UR, Sree SV, Mookiah MRK, *et al.* Computed tomography carotid wall plaque characterization using a combination of discrete wavelet transform and texture features: A pilot study. <http://dx.doi.org/10.1177/0954411913480622> 2013;227:643–54. doi:10.1177/0954411913480622
- 136 Thornhill RE, Lum C, Jaber A, *et al.* Can shape analysis differentiate free-floating internal carotid artery thrombus from atherosclerotic plaque in patients evaluated with CTA for stroke or transient ischemic attack? *Acad Radiol* 2014;21:345–54. doi:10.1016/j.acra.2013.11.011
- 137 Qureshi AI, Mendelow AD, Hanley DF. Intracerebral haemorrhage. *Lancet* 2009;373:1632–44. doi:10.1016/S0140-6736(09)60371-8
- 138 Inder TE, Perlman JM, Volpe JJ. Intracranial Hemorrhage. *Volpe's Neurol Newborn* 2022;;593-622.e7. doi:10.1016/B978-0-323-42876-7.00022-3
- 139 Freeman WD, Aguilar MI. Intracranial hemorrhage: diagnosis and management. *Neurol Clin* 2012;30:211–40. doi:10.1016/J.NCL.2011.09.002
- 140 de Oliveira Manoel AL, Goffi A, Zampieri FG, *et al.* The critical care management of spontaneous intracranial hemorrhage: a contemporary review. *Crit Care* 2016;20:1–29. doi:10.1186/S13054-016-1432-0
- 141 Rava RA, Seymour SE, LaQue ME, *et al.* Assessment of an Artificial Intelligence Algorithm for Detection of Intracranial Hemorrhage. *World Neurosurg* 2021;150:e209–17. doi:10.1016/j.wneu.2021.02.134

- 142 Ginat DT. Analysis of head CT scans flagged by deep learning software for acute intracranial hemorrhage. *Neuroradiology* 2020;62:335–40. doi:10.1007/s00234-019-02330-w
- 143 Yeo M, Tahayori B, Kok HK, *et al.* Review of deep learning algorithms for the automatic detection of intracranial hemorrhages on computed tomography head imaging. *J. Neurointerv. Surg.* 2021;13:369–77. doi:10.1136/neurintsurg-2020-017099
- 144 Zia A, Fletcher C, Bigwood S, *et al.* Retrospective analysis and prospective validation of an AI-based software for intracranial haemorrhage detection at a high-volume trauma centre. *Sci Rep* 2022;12:19885. doi:10.1038/s41598-022-24504-y
- 145 Kundisch A, Hönning A, Mutze S, *et al.* Deep learning algorithm in detecting intracranial hemorrhages on emergency computed tomographies. *PLoS One* 2021;16:e0260560. doi:10.1371/journal.pone.0260560
- 146 McLouth J, Elstrott S, Chaibi Y, *et al.* Validation of a Deep Learning Tool in the Detection of Intracranial Hemorrhage and Large Vessel Occlusion. *Front Neurol* 2021;12. doi:10.3389/fneur.2021.656112
- 147 Voter AF, Meram E, Garrett JW, *et al.* Diagnostic Accuracy and Failure Mode Analysis of a Deep Learning Algorithm for the Detection of Intracranial Hemorrhage. *J Am Coll Radiol* 2021;18:1143–52. doi:10.1016/j.jacr.2021.03.005
- 148 Flanders AE, Prevedello LM, Shih G, *et al.* Construction of a Machine Learning Dataset through Collaboration: The RSNA 2019 Brain CT Hemorrhage Challenge. *Radiol Artif Intell* 2020;2:e190211. doi:10.1148/ryai.2020190211
- 149 Yeo M, Tahayori B, Kok HK, *et al.* Review of deep learning algorithms for the automatic detection of intracranial hemorrhages on computed tomography head imaging. *J Neurointerv Surg* 2021;13:369–78. doi:10.1136/NEURINTSURG-2020-017099
- 150 Chilamkurthy S, Ghosh R, Tanamala S, *et al.* Deep learning algorithms for detection of critical findings in head CT scans: a retrospective study. *Lancet* 2018;392:2388–96.
- 151 Islam M, Sanghani P, See AAQ, *et al.* ICHNet: Intracerebral hemorrhage (ICH) segmentation using deep learning. *Lect Notes Comput Sci (including Subser Lect Notes Artif Intell Lect Notes Bioinformatics)* 2019;11383 LNCS:456–63. doi:10.1007/978-3-030-11723-8_46/TABLES/2
- 152 Sharrock MF, Mould WA, Ali H, *et al.* 3D Deep Neural Network Segmentation of Intracerebral Hemorrhage: Development and Validation for Clinical Trials. *Neuroinformatics* 2021;19:403–15. doi:10.1007/S12021-020-09493-5/FIGURES/7
- 153 Mansour RF, Aljehane NO. An optimal segmentation with deep learning based inception network model for intracranial hemorrhage diagnosis. *Neural Comput Appl* 2021;33:13831–43. doi:10.1007/S00521-021-06020-8/FIGURES/11
- 154 Xie H, Ma S, Wang X, *et al.* Noncontrast computer tomography-based radiomics model for predicting intracerebral hemorrhage expansion: preliminary findings and comparison with conventional radiological model. *Eur Radiol* 2019 301 2019;30:87–98. doi:10.1007/S00330-019-06378-3
- 155 Xia X, Ren Q, Cui J, *et al.* Radiomics for predicting revised hematoma expansion with the inclusion of intraventricular hemorrhage growth in patients with supratentorial spontaneous intraparenchymal hematomas. *Ann Transl Med* 2022;10. doi:10.21037/ATM-21-6158
- 156 Yang Q, Sun J, Guo Y, *et al.* Radiomics Features on Computed Tomography Combined With Clinical-Radiological Factors Predicting Progressive Hemorrhage of Cerebral Contusion. *Front Neurol* 2022;13:839784. doi:10.3389/FNEUR.2022.839784
- 157 Shih Y-J, Liu Y-L, Chen J-H, *et al.* Prediction of Intraparenchymal Hemorrhage Progression and Neurologic Outcome in Traumatic Brain Injury Patients Using Radiomics Score and Clinical Parameters. *Diagnostics* 2022, Vol 12, Page 1677 2022;12:1677. doi:10.3390/DIAGNOSTICS12071677
- 158 Xu Z, Rui YN, Hagan JP, *et al.* Intracranial Aneurysms: Pathology, Genetics, and Molecular Mechanisms. *NeuroMolecular Med.* 2019;21:325–43. doi:10.1007/s12017-019-08537-7
- 159 Texakalidis P, Sweid A, Mouchtouris N, *et al.* Aneurysm Formation, Growth, and Rupture: The Biology and Physics of Cerebral Aneurysms. *World Neurosurg.* 2019;130:277–84. doi:10.1016/j.wneu.2019.07.093
- 160 Toth G, Cerejo R. Intracranial aneurysms: Review of current science and management. *Vasc. Med. (United Kingdom).* 2018;23:276–88. doi:10.1177/1358863X18754693
- 161 Faron A, Sijben R, Teichert N, *et al.* Deep learning-based detection of intracranial aneurysms in 3D TOF-MRA. *Am J Neuroradiol* 2019;40:25–32. doi:10.3174/AJNR.A5911
- 162 Ueda D, Yamamoto A, Nishimori M, *et al.* Deep learning for MR angiography: Automated detection of cerebral aneurysms. *Radiology* 2019;290:187–94. doi:10.1148/RADIOL.2018180901
- 163 Sohn B, Park KY, Choi J, *et al.* Deep learning-based software improves clinicians' detection sensitivity of aneurysms on

- brain TOF-MRA. *Am J Neuroradiol* 2021;42:1769–75. doi:10.3174/AJNR.A7242
- 164 Lang S, Hoelter P, Schmidt M, *et al.* Artificial intelligence-based 3D angiography for visualization of complex cerebrovascular pathologies. *Am J Neuroradiol* 2021;42:1722–68. doi:10.3174/ajnr.A7252
- 165 Shahzad R, Pennig L, Goertz L, *et al.* Fully automated detection and segmentation of intracranial aneurysms in subarachnoid hemorrhage on CTA using deep learning. *Sci Rep* 2020;10. doi:10.1038/S41598-020-78384-1
- 166 Patel TR, Paliwal N, Jaiswal P, *et al.* Multi-resolution CNN for brain vessel segmentation from cerebrovascular images of intracranial aneurysm: a comparison of U-Net and DeepMedic. 2020;:101. doi:10.1117/12.2549761
- 167 Timmins KM, van der Schaaf IC, Bennink E, *et al.* Comparing methods of detecting and segmenting unruptured intracranial aneurysms on TOF-MRAS: The ADAM challenge. *Neuroimage* 2021;238:118216. doi:10.1016/j.neuroimage.2021.118216
- 168 Lauric A, Ludwig CG, Malek AM. Enhanced Radiomics for Prediction of Rupture Status in Cerebral Aneurysms. *World Neurosurg* 2022;159:e8–22. doi:10.1016/J.WNEU.2021.11.038
- 169 Alwalid O, Long X, Xie M, *et al.* CT Angiography-Based Radiomics for Classification of Intracranial Aneurysm Rupture. *Front Neurol* 2021;12:95. doi:10.3389/FNEUR.2021.619864/BIBTEX
- 170 Ou C, Chong W, Duan CZ, *et al.* A preliminary investigation of radiomics differences between ruptured and unruptured intracranial aneurysms. *Eur Radiol* 2021;31:2716–25. doi:10.1007/S00330-020-07325-3/TABLES/3
- 171 Ludwig CG, Lauric A, Malek JA, *et al.* Performance of Radiomics derived morphological features for prediction of aneurysm rupture status. *J Neurointerv Surg* 2021;13:755–61. doi:10.1136/NEURINTSURG-2020-016808
- 172 Nabaei M. Cerebral aneurysm evolution modeling from microstructural computational models to machine learning: A review. *Comput Biol Chem* 2022;98:107676. doi:10.1016/J.COMPBIOLCHEM.2022.107676
- 173 Friedlander RM. Clinical practice. Arteriovenous malformations of the brain. *N Engl J Med* 2007;356:2704–12. doi:10.1056/NEJMCP067192
- 174 Bazil MJ, Shigematsu T, Berenstein A, *et al.* Modern Brain Arteriovenous Malformation Models: A Review. *Stroke Vasc Interv Neurol* 2022;2. doi:10.1161/svin.121.000335
- 175 Chen CJ, Ding D, Derdeyn CP, *et al.* Brain arteriovenous malformations: A review of natural history, pathobiology, and interventions. *Neurology*. 2020;95:917–27. doi:10.1212/WNL.0000000000010968
- 176 Reynolds MR, Lanzino G, Zipfel GJ. Intracranial Dural Arteriovenous Fistulae. *Stroke* 2017;48:1424–31. doi:10.1161/STROKEAHA.116.012784/-/DC1
- 177 Miller TR, Gandhi D. Intracranial Dural Arteriovenous Fistulae: Clinical Presentation and Management Strategies. *Stroke*. 2015;46:2017–25. doi:10.1161/STROKEAHA.115.008228
- 178 Bhatia KD, Lee H, Kortman H, *et al.* Endovascular Management of Intracranial Dural AVFs: Transvenous Approach. *Am J Neuroradiol* 2022;43:510–6. doi:10.3174/AJNR.A7300
- 179 Snellings DA, Hong CC, Ren AA, *et al.* Cerebral Cavernous Malformation: From Mechanism to Therapy. *Circ. Res.* 2021;129:195–215. doi:10.1161/CIRCRESAHA.121.318174
- 180 Dammann P, Santos AN, Wan XY, *et al.* Cavernous Malformations: Updates in Surgical Management and Biology. *Neurosurg. Clin. N. Am.* 2022;33:449–60. doi:10.1016/j.nec.2022.05.001
- 181 Peng SJ, Lee C chia, Wu HM, *et al.* Fully automated tissue segmentation of the prescription isodose region delineated through the Gamma knife plan for cerebral arteriovenous malformation (AVM) using fuzzy C-means (FCM) clustering. *NeuroImage Clin* 2019;21:101608. doi:10.1016/j.nicl.2018.11.018
- 182 Jiao Y, Zhang J, Yang X, *et al.* Artificial Intelligence-Assisted Evaluation of the Spatial Relationship between Brain Arteriovenous Malformations and the Corticospinal Tract to Predict Postsurgical Motor Defects. *AJNR Am J Neuroradiol* 2023;44:17–25. doi:10.3174/ajnr.A7735
- 183 Oermann EK, Rubinsteyn A, Ding D, *et al.* Using a Machine Learning Approach to Predict Outcomes after Radiosurgery for Cerebral Arteriovenous Malformations. *Sci Rep* 2016;6:1–12. doi:10.1038/srep21161
- 184 Asadi H, Kok HK, Looby S, *et al.* Outcomes and Complications After Endovascular Treatment of Brain Arteriovenous Malformations: A Prognostication Attempt Using Artificial Intelligence. *World Neurosurg* 2016;96:562-569.e1. doi:10.1016/j.wneu.2016.09.086
- 185 Hendricks BK, Rumalla K, Benner D, *et al.* Cavernous Malformations and Artificial Intelligence: Machine Learning Applications. *Neurosurg. Clin. N. Am.* 2022;33:461–7. doi:10.1016/j.nec.2022.05.007
- 186 Ropper AH, Klein JP. Cerebral Venous Thrombosis. *NEJM* 2021;385:59–64. doi:10.1056/NEJMRA2106545
- 187 Hufnagle JJ, Tadi P. *Neuroanatomy, Brain Veins*. StatPearls

- Publishing 2020.
<http://www.ncbi.nlm.nih.gov/pubmed/31536212> (accessed 27 Jan 2023).
- 188 Aoki R, Srivatanakul K. Developmental venous anomaly: Benign or not benign. *Neurol Med Chir (Tokyo)* 2016;56:534–43. doi:10.2176/nmc.ra.2016-0030
- 189 Yu T, Shen R, You G, *et al.* Machine learning-based prediction of the post-thrombotic syndrome: Model development and validation study. *Front Cardiovasc Med* 2022;9:2611. doi:10.3389/fcvm.2022.990788
- 190 Contreras-Luján EE, García-Guerrero EE, López-Bonilla OR, *et al.* Evaluation of Machine Learning Algorithms for Early Diagnosis of Deep Venous Thrombosis. *Math Comput Appl* 2022;27:24. doi:10.3390/mca27020024
- 191 Ryan L, Mataraso S, Siefkas A, *et al.* A Machine Learning Approach to Predict Deep Venous Thrombosis Among Hospitalized Patients. *Clin Appl Thromb* 2021;27. doi:10.1177/1076029621991185
- 192 Wang Q, Yuan L, Ding X, *et al.* Prediction and Diagnosis of Venous Thromboembolism Using Artificial Intelligence Approaches: A Systematic Review and Meta-Analysis. *Clin Appl Thromb* 2021;27. doi:10.1177/10760296211021162
- 193 Challenges of Artificial Intelligence Models in Thrombosis. <https://www.medscape.com/viewarticle/983713> (accessed 14 Jan 2023).
- 194 Mishra A, Ashraf MZ. Using Artificial Intelligence to Manage Thrombosis Research, Diagnosis, and Clinical Management. *Semin Thromb Hemost* 2020;46:410–8. doi:10.1055/S-0039-1697949
- 195 Chen JH, Asch SM. Machine Learning and Prediction in Medicine — Beyond the Peak of Inflated Expectations. *N Engl J Med* 2017;376:2507–9. doi:10.1056/nejmp1702071
- 196 Larrazabal AJ, Nieto N, Peterson V, *et al.* Gender imbalance in medical imaging datasets produces biased classifiers for computer-aided diagnosis. *Proc Natl Acad Sci USA* 2020;117:12592–4. doi:10.1073/pnas.1919012117
- 197 Chen IY, Joshi S, Ghassemi M. Treating health disparities with artificial intelligence. *Nat Med* 2020;26:16–7. doi:10.1038/s41591-019-0649-2
- 198 Char DS, Shah NH, Magnus D. Implementing machine learning in health care: addressing ethical challenges. *NEJM* 2018;378:981–3. doi:10.1056/nejmp1714229
- 199 Vyas DA, Eisenstein LG, Jones DS. Hidden in plain sight: reconsidering the use of race correction in clinical algorithms. *N Engl J Med* 2020;383:874–82. doi:10.1056/nejmms2004740
- 200 Seyyed-Kalantari L, Zhang H, McDermott MBA, *et al.* Underdiagnosis bias of artificial intelligence algorithms applied to chest radiographs in under-served patient populations. *Nat Med* 2021 2712 2021;27:2176–82. doi:10.1038/s41591-021-01595-0
- 201 Obermeyer Z, Powers B, Vogeli C, *et al.* Dissecting racial bias in an algorithm used to manage the health of populations. *Science (80-)* 2019;366:447–53. doi:10.1126/science.aax2342
- 202 Tjoa E, Guan C. A survey on explainable artificial intelligence (XAI): toward medical XAI. *IEEE Trans Neural Netw Learn Syst* 2020;32:4793–813. doi:10.1109/tnnls.2020.3027314
- 203 Reyes M, Meier R, Pereira S, *et al.* On the Interpretability of Artificial Intelligence in Radiology: Challenges and Opportunities. *Radiol Artif Intell* 2020;2:e190043. doi:10.1148/ryai.2020190043
- 204 Saporta A, Gui X, Agrawal A, *et al.* Benchmarking saliency methods for chest X-ray interpretation. *Nat Mach Intell* 2022 410 2022;4:867–78. doi:10.1038/s42256-022-00536-x
- 205 Krenn M, Pollice R, Guo SY, *et al.* On scientific understanding with artificial intelligence. *Nat Rev Phys* 2022 2022;;1–9. doi:10.1038/s42254-022-00518-3

Appendix

1. *Generative adversarial networks Improve the reproducibility and discriminative power of radiomic features*

This research has been published on 27 May 2020 by Marcadent, Hofmeister* et al. in Radiology: Artificial Intelligence (vol. 2(3)). <https://doi.org/10.1148/ryai.2020190035>*

** Marcadent and Hofmeister contributed equally to this work. The article was covered by an invited commentary by Philip O. Alderson, in Radiology: Artificial Intelligence (vol. 2(3)). <https://doi.org/10.1148/ryai.2020200068>*

Rationale

Radiomics is a promising method for quantitative analysis of radiological images, but its potential can be limited by a weak reproducibility of the results when images are acquired on different machines or with different acquisition parameters. Here, we evaluated the contribution of a generative adversarial network (GAN) to improve the inter-manufacturer reproducibility of radiomics features by performing an image texture transfer between two different manufacturers.

Methods

We retrospectively developed a cycle GAN to translate texture information from chest radiographs (CXRs) acquired by one manufacturer (Siemens) to chest radiographs acquired by another manufacturer (Philips), thereby generating false chest radiographs with different textures. We then prospectively evaluated the ability of this texture translation GAN cycle to reduce inter-manufacturer variability of RFs extracted from lung parenchyma on normal and pathological images, as well as its ability to fool several machine learning classifiers and radiologists who were asked to identify the manufacturer of the CXRs.

Results

The radiomics features extracted from CXRs after texture translation by Cycle-GAN (false chest radiographs) reduced the inter-manufacturer variability. This inter-manufacturer texture translation also fooled machine learning classifiers and even experienced radiologists who identified the false CXRs as belonging to a target manufacturer class.

Perspective

Cycle-GAN has improved the inter-manufacturer reproducibility of radiomics analysis and its ability to identify patients with cardiothoracic pathology. This deep learning approach has not yet been applied to 3D imaging such as CT or MRI, but has interesting potential for texture adaptation of medical images.

2. *nnUNet for unified cerebral artery segmentation on 3DRA, CTA and TOF-MRI*

Rationale

Segmentation of cerebral arteries on CTA, TOF-MRI or 3DRA and their visualization in 3D allows neuroradiologists to better analyze and detect neurovascular diseases. Many groups have used deep learning models to automatically segment cerebral arteries on TOF-MRI, CTA and 3DRA with promising results. However, these models have only been able to segment cerebral arteries on one imaging modality, which limits comparisons when a patient undergoes different imaging modalities during his follow-up. Furthermore, a segmentation algorithm that incorporates different imaging modalities with different spatial and contrast resolutions could improve the quality of segmentation compared to an algorithm that uses only one imaging modality, especially when its spatial resolution is lower. We developed a unified deep learning model to segment cerebral arteries from CTA, TOF-MRI, and 3DRA to evaluate whether it improves the segmentation quality of the different imaging modalities.

Methods

We developed a deep learning model based on a two-step ensembling of multiple neural networks. In a first step, a CNN recognizes the type of imaging (CTA, TOF-MRI or 3DRA) and then preprocesses these images (realignment, resampling and normalization). In a second step, two nnUNet⁸¹ segment the cerebral arteries in parallel: (i) one trained specifically on one imaging modality (either CTA, TOF-MRI or 3DRA) and (ii) the other trained on all imaging modalities simultaneously. The segmentations are finally ensembled to create a unified representation of the cerebral arteries. This deep learning model was trained using a 5-fold cross-validation technique on an internal HUG dataset containing 200 CTA, 200 TOF-MRI and 200 3DRA whose arteries had been manually segmented by an expert neuroradiologist.

Results

Segmentation metrics derived from 5-fold cross-validation show that this unified nnUNet provides better segmentation of cerebral arteries on 3DRA and TOF-MRI than on CTA (Dice similarity coefficient, *DSC*: 3DRA: 0.91, TOF-MRI: 0.88, CTA: 0.81). However, it allows a better segmentation of CTAs compared to a segmentation with a nnUNet trained only on CTAs (*DSC*: 0.81 versus 0.73).

Perspective

The development of a multicenter validation dataset is underway to compare our unified segmentation model with a segmentation performed only with the nnUNet specific to each imaging modality. Using transfer learning, we are also applying this pre-trained network as a basis for re-training in the segmentation of different neurovascular pathologies (e.g. cerebral aneurysms, malformations, etc.).

3. CTA to 3DRA using generative adversarial networks

Rationale

Spatial and contrast resolution varies between imaging modalities, and the higher the resolution, the more accurate the diagnosis. For example, these resolutions are better with 3DRA than with CTA, but 3DRA has the disadvantage of being a less accessible and invasive imaging modality. Therefore, we sought to use AI to improve the spatial resolution of angio-CT to better visualize fine details of cerebral arteries and their pathologies.

Methods

We developed a GAN model to convert CTA with low spatial resolution ($\sim 0.8 \text{ mm}^3$) to 3DRA with better resolution ($\sim 0.2 \text{ mm}^3$) by adapting a vox2vox algorithm⁹³. We trained this model on a dataset of 50 pairs of CTA and 3DRA from the same 50 patients, after coregistration of both volumes (3DRA are usually performed on one side of the brain at a time). The task of the model was to translate CTAs into 3DRAs and vice versa, in order to obtain images of CTAs with much better spatial resolution, going from 0.8 mm^3 voxels to $\sim 0.2 \text{ mm}^3$. We used a small validation dataset of 10 patients to obtain a quantitative evaluation of the performance of our model.

Results

Reconstruction metrics derived from the validation dataset show that this vox2vox is accurate in translating texture between 3DRA and CTA (Structural Similarity Index Measure, *SSIM*: 0.91), thus allowing better spatial and contrast resolution of CTAs, which may allow better visualization of cerebral arteries on CTA without the need for an invasive examination such as cerebral arteriography to obtain 3DRA. However, qualitative evaluation by a neuroradiologist is required to ensure proper visualization of cerebrovascular pathology on these modified CTAs.

Perspective

The development of a multicenter validation dataset is underway to qualitatively and quantitatively assess the enhancement of spatial and contrast resolution of CTAs by the GAN model.

4. *Clot-based radiomics predict a mechanical thrombectomy strategy for successful recanalization in acute ischemic stroke*

*This research has been published on 20 July 2020 by Hofmeister et al. in Stroke (51:2488–2494).
<https://doi.org/10.1161/STROKEAHA.120.030334>*

Rationale

Several mechanical thrombectomy (MTB) strategies are available to treat patients with acute ischemic stroke, including thromboaspiration, stent retrieval, or a combination of both. However, there is no quantitative method to select the best strategy for a given patient. Therefore, we developed a radiomics model using features extracted from clots on NCCTs to predict (i) which patients will achieve recanalization on the first pass of thromboaspiration and (ii) how many passes with an MTB device are required for successful recanalization.

Methods

We developed two machine learning models after extracting 1485 radiomic features of manually segmented clots on NCCTs from a retrospective training cohort (n=109): a first model to predict recanalization on the first attempt with thromboaspiration and a second model to predict the total number of passes with MTB devices for complete recanalization (mTICI 3). The performance of these two models was then evaluated in a prospective validation cohort (n=47).

Results

A small subset of radiomic features (n=9) predicted which clots could be removed on the first attempt of recanalization by thromboaspiration (*ROC-AUC*: 0.88). The same subset of radiomic features predicted the total number of passes required for complete recanalization (explained variance: 0.70; mean square error: 0.76; Pearson correlation coefficient: 0.73; $p < 0.05$).

Perspective

The radiomic signature of the clot predicts its response to mechanical thrombectomy treatment in acute ischemic stroke. Quantitative analysis of the clot on preinterventional imaging could thus provide information on the best endovascular treatment strategy.

5. Cerebral aneurysm segmentation and quantitative measurement on TOF-MRI

Rationale

Quantitative analysis of unruptured cerebral aneurysms, including size, volume, and morphology, enables their appropriate management between follow-up or preventive intervention. We developed a deep learning model to automatically segment intracranial arteries and aneurysms on TOF-MRI to calculate quantitative measures relevant for their management in an automated and reproducible manner.

Methods

We used a transfer learning method to retrain our unified intracranial artery segmentation model to segment cerebral aneurysms in addition to healthy arteries. We used the ADAM dataset, which is derived from an unruptured intracranial aneurysm detection and segmentation challenge.¹⁶⁷ The aneurysm segmentation label was available for N patients on TOF-MRI, and we semi-automatically labeled the arteries in each of these images (labeling by our unified segmentation model, followed by manual correction by a neuroradiologist). We then retrained our unified network using 5-fold cross-validation and automatically calculated the shape parameters (size, volume, sphericity, etc.) of the segmented aneurysms using an open-source Python library (pyradiomics). Finally, we compared the automatically calculated maximum aneurysm diameter with that measured by an experienced neuroradiologist.

Results

Segmentation metrics derived from 5-fold cross-validation show that our network maintains a good segmentation of intracranial arteries while allowing a good segmentation of intracranial aneurysms (*DCS*: 0.82). The automated calculation of the maximum diameter of each aneurysm is also close to that performed by an expert neuroradiologist (concordance correlation coefficient: 0.94).

Perspective

An external validation dataset of manual segmentation by two neuroradiologists is under development to evaluate the performance of segmentation and automation of quantification of aneurysm size and shape parameters on TOF-MRI images.