

REVUE SCIENTIFIQUE ET TECHNIQUE

LA REVUE
DU COLLÈGE
NATIONAL
D'AUDIO-
PROTHÈSE

Les Cahiers de
l'Audition

BIMESTRIEL

Septembre / Octobre 2022 - Vol 35 - N°5 / WWW.COLLEGE-NAT-AUDIO.FR

MÉTIER ET TECHNIQUE
EXPLOITER LE FORMIDABLE
OUTIL QU'EST L'INTELLIGENCE
ARTIFICIELLE POUR AMÉLIORER
LES SOINS ET LA PRISE EN CHARGE
AUDIOLOGIQUE

**ANALYSE DE DONNÉES
CLINIQUES**
ANALYSE DES DONNÉES
COLLECTÉES LORS D'UNE ÉTUDE
OBSERVATIONNELLE MENÉE CHEZ
DES ADULTES, AVEC LE TEST VRB

**REVUE DE LITTÉRATURE
SCIENTIFIQUE ET MÉDICALE**
ACOUPHÈNES :
VERS UNE SOLUTION
THÉRAPEUTIQUE NON-INVASIVE

IMPLANT COCHLÉAIRE
CAS CLINIQUE

PIÈGES LORS DU REPÉRAGE, DIAGNOSTIC,
APPAREILLAGE ET IMPLANTATION COCHLÉAIRE
EN CAS DE SURDITÉ ÉVOLUTIVE DISSYMÉTRIQUE
LIÉE À UNE INFECTION CMV

EPU 2021
COMMUNICATIONS

VEILLE TECHNIQUE INNOVATIONS DES INDUSTRIELS



Auteurs

Nicolas Wallaert¹

Audioprothésiste D.E.,
Ingénieur, Docteur en
Sciences Cognitives,
Membre du Collège
National d'Audioprothèse

Hadrien Jean¹

Data scientist, Machine
learning scientist, Docteur
en Sciences Cognitives

Nihaad Parouty¹

Translational auditory
scientist, Docteur en Sciences
Cognitives

¹. iAudiogram, 5 Bis Cours Anatole
France, 51100 Reims, France

EXPLOITER LE FORMIDABLE OUTIL QU'EST L'INTELLIGENCE ARTIFICIELLE POUR AMÉLIORER LES SOINS ET LA PRISE EN CHARGE AUDIOLOGIQUE

La recherche sur l'audition a toujours été à la pointe de l'innovation technologique. Aujourd'hui en France, comme partout dans le monde, nous faisons face à un défi croissant : les personnes souffrant d'une perte auditive et demandeuse d'une prise en charge audiolinguistique augmente. La question d'un diagnostic médical des troubles auditifs dans des délais raisonnables constitue un véritable enjeu de santé publique. Les récentes avancées de l'intelligence artificielle (IA) pourraient apporter une solution concrète aux enjeux médicaux, sociétaux et économiques liés à la surdit .

Mots clés :

AUDIOLOGIE, DEEP LEARNING, INTELLIGENCE ARTIFICIELLE, MACHINE LEARNING, RÉSEAU DE NEURONES ARTIFICIELS

Abr viation : INTELLIGENCE ARTIFICIELLE (IA)

La recherche sur l'audition a toujours  t    la pointe de l'innovation technologique. Les appareils auditifs ont ouvert la voie   la miniaturisation de l' lectronique num rique (Levitt, 2007) et au progr s technologique et algorithmique. Pour sa part, l'implant cochl aire, a  t  une avanc e majeure et reste la proth se neurale la plus aboutie en termes de performance et de p n tration (Zeng et al., 2008).

Aujourd'hui en France, comme partout dans le monde, nous faisons face   un d fi croissant : les personnes souffrant d'une perte auditive et demandeuse d'une prise en charge audiolinguistique augmente. La question d'un diagnostic m dical des troubles auditifs dans des d lais raisonnables constitue un v ritable enjeu de sant  publique, de fa on   pouvoir proposer une prise en charge audiolinguistique adapt e pour  viter les cons quences parfois irr versibles induite par la perte auditive.

Toutefois, alors que l'on pr voit une augmentation massive du nombre de personnes souffrant de perte auditive dans les ann es   venir (surexposition au bruit,  volution d mographique, ...), le nombre de sp cialistes ORL va sensiblement diminuer :  ge moyen des praticiens en activit  en France d'environ 55 ans, non remplacement de d parts en retraite, le Syndicat National des M decins sp cialis s en ORL et chirurgie Cervico-Faciale (SNORL) table sur une diminution significative du nombre de praticien (- 800 ORL en moins d'ici 2030).

Au niveau mondial, le probl me constituera l'un des enjeux de sant  majeur du XXI me si cle : d'apr s les derni res projections de l'OMS, d'ici   2050, plus de 700 millions de personnes dans

le monde (soit une personne sur dix) seront malentendantes. Pourtant, la surdit  reste actuellement largement sous diagnostiqu e et sous trait e, entra nant des d ficits neuronaux centraux quelque soit l' ge du patient: retards dans l'acquisition du langage chez les enfants, troubles neurod g n ratifs chez les personnes  g es.

Les r centes avanc es de l'*intelligence artificielle* (IA) pourraient apporter une solution concr te aux enjeux m dicaux, soci taux et  conomiques li s   la surdit . Ainsi, les algorithmes et mod les math matiques bas s sur l'IA ont parfois d j  atteint des performances comparables   celles de l'homme dans des t ches importantes li es   l'audition, telles que la reconnaissance automatique de la parole (Automatic Speech Recognition, ASR: Hinton et al., 2012; Yu and Deng, 2015) et le traitement du langage naturel (Deng and Liu, 2018; Devlin et al., 2018). De plus, l'IA commence  galement   avoir un impact croissant en m decine : r alisation de t ches chronophages, aide au diagnostic, ... (Chan et al., 2020). Alors que ces techniques sont de plus en plus courantes dans diff rents contextes cliniques, notamment pour la d tection des maladies de la r tine (Ting et al., 2018 ; Kim et al., 2021) et dans le domaine de l'imagerie m dicale (Hwang et al., 2019 ; Shen et al., 2021), elles restent que tr s peu utilis es dans le domaine de l'audition. De fa on   favoriser l'acculturation avec l'IA, nous d crivons ici ces principaux principes de fonctionnement, ainsi que les possibilit s d'utilisation qu'elle pourrait avoir pour cr er de nouvelles applications cliniques.

LE MACHINE LEARNING, UN SOUS DOMAINE DE L'IA

L'essor de l'IA débute dans les années 90, notamment par le développement d'un sous domaine de l'IA, que l'on appelle le machine learning. Le machine learning est un domaine d'étude qui consiste à concevoir des algorithmes, appelés parfois modèles, qui sont capables d'apprendre à partir d'exemples.

Afin d'expliquer didactiquement les principes de base du machine learning, prenons le cas d'un audioprothésiste qui s'intéresserait au lien entre la perte auditive tonale et l'intelligibilité de ses patients. Pour comprendre la relation entre ces grandeurs, il est possible de représenter graphiquement les pertes auditives moyennes d'un l'ensemble de patients en abscisse ainsi et que leurs seuils d'intelligibilité en ordonnée (Figure 1).

Le praticien remarque donc aisément que les données semblent relativement alignées et qu'il peut alors tracer une droite de régression (Figure 1, ligne noire). Cette droite de régression permet de généraliser les résultats. En effet, grâce à l'équation de la droite, l'audiologiste pourrait « prédire » les seuils d'intelligibilité de nouveaux patients à partir de leur perte auditive moyenne. Ainsi, pour un nouveau patient, il suffirait alors de mesurer la perte auditive moyenne (Figure 1, illustré en rouge, 55 dB HL) et de déduire à partir de cette perte moyenne, le seuil d'intelligibilité estimé du patient, sans avoir à le mesurer (Figure 1, illustré en rouge, 70 dB SPL).

Le terme de prédiction, couramment utilisé en IA, ne vise pas nécessairement à prédire un événement futur, mais plutôt à inférer une valeur inconnue. En résumé, dans l'exemple précédent, nous avons utilisé des données réelles (des mesures individuelles) pour définir la relation qui peut exister entre ces différents ensembles de données afin de pouvoir faire des prédictions de valeurs jusqu'alors inconnues. Le machine

learning repose sur le même principe, sauf que l'on utilise ici des algorithmes mathématiques pour en déduire la relation entre les variables.

Si nous reprenons l'exemple précédent pour construire grâce au machine learning un modèle qui permettrait de prédire l'intelligibilité du patient à partir de sa perte auditive tonale, l'ordinateur (avec l'aide du data scientist !) devra déterminer l'algorithme qui capture le plus fidèlement la relation qui existe entre la perte auditive tonale et les seuils d'intelligibilité.

Dans le cas présent, l'ordinateur déterminera d'abord la nature de la relation entre les données, e.g. une relation linéaire (du type $y = ax+b$) ou non linéaire. Dans le cas d'une relation linéaire, il déterminera ensuite les valeurs exactes de pente (a) et d'ordonnée à l'origine (b) qui correspondent le mieux avec l'ensemble des données. En d'autres mots, les deux paramètres a et b de la droite peuvent être représentés par deux 'boutons' que l'ordinateur ajuste jusqu'à trouver la meilleure combinaison possible entre les deux boutons. Une fois l'ajustement terminé, les positions ou valeurs des 2 boutons (a et b) ne changent plus. Une fois l'équation de droite connue, l'algorithme peut être utilisé pour prédire des valeurs inconnues de seuils d'intelligibilité à partir de nouvelles mesures de perte auditive tonale.

QU'EST CE QUE L'APPRENTISSAGE AUTOMATISÉ ?

En machine learning, cette phase d'ajustement des paramètres durant laquelle l'ordinateur essaie toutes les combinaisons possibles permettant d'expliquer le lien entre les valeurs est appelée *phase d'apprentissage*. Cette phase d'apprentissage s'arrête quand l'ordinateur trouve la combinaison optimale, c'est-à-dire les paramètres qui expliquent au mieux la relation entre les données.

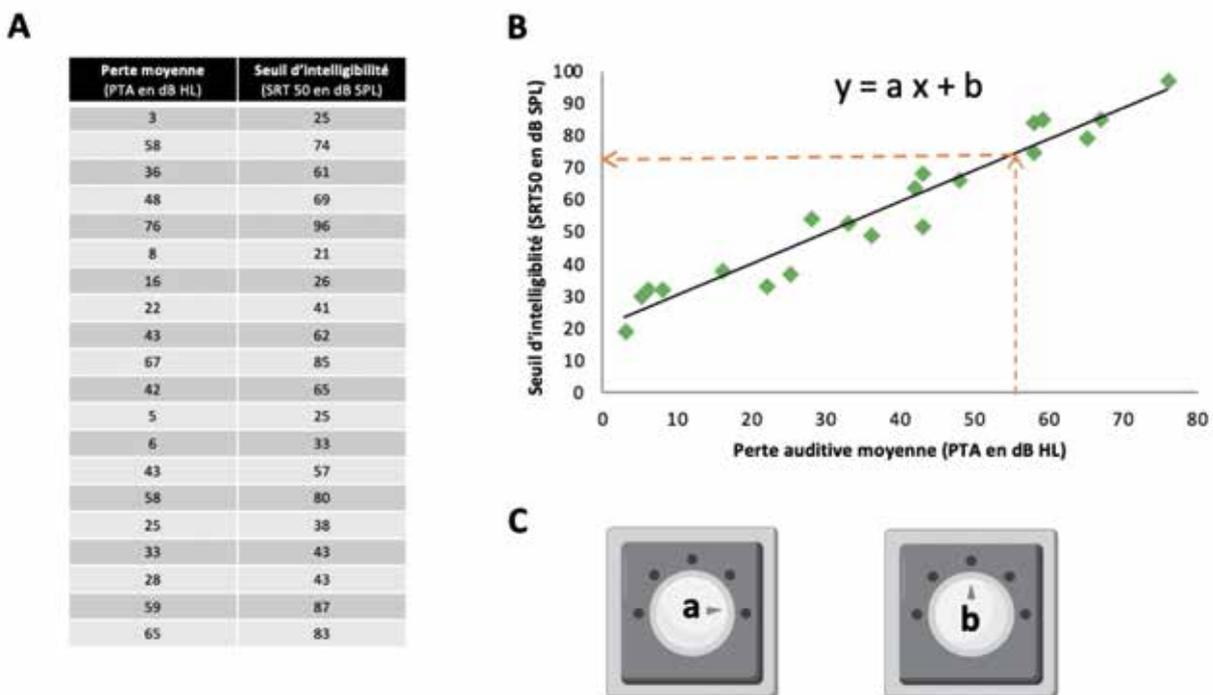


Figure 1 : Illustration schématique du Machine Learning. A. Données de perte auditive moyenne (dB HL) et seuils d'intelligibilité (dB SPL). B. Représentation graphique des données en A, avec une droite de régression (ligne noire), permettant d'inférer la valeur de seuil d'intelligibilité pour une perte auditive moyenne de 55 dB HL (ligne pointillée rouge). C. Représentations de l'ajustement des valeurs des variables, a et b figurant dans l'équation de la droite de régression en B.

Une fois notre modèle entraîné, ce dernier peut être utilisé pour prédire des mesures inconnues. Cette capacité de prédiction est l'un des objectifs majeurs du machine learning.

Le machine learning permet donc de trouver les relations mathématiques complexes qui existent entre différentes grandeurs et données afin d'effectuer des prédictions les plus précises possible.

En pratique, le machine learning est bien évidemment utilisé principalement pour résoudre des problèmes complexes, très éloignés de notre exemple simpliste. Afin d'illustrer la complexité que peut revêtir le machine learning, nous allons exposer différents exemples d'application de l'IA dans le domaine médical. Ces dernières années, les radiologues ont testé l'apport du machine learning en imagerie médicale, par exemple pour l'identification du cancer du sein en échographie (Shen et al., 2021). En effet, l'interprétation de l'échographie mammaire demeure une tâche difficile nécessitant une certaine expertise car les radiologues doivent évaluer les images échographiques à l'aide de différentes caractéristiques qui varient considérablement d'un patient à l'autre: la taille, la forme, la marge, l'échogénicité, les caractéristiques acoustiques postérieures et l'orientation des lésions. Au final, les radiologues doivent déterminer si les résultats de l'imagerie sont bénins, s'ils nécessitent une imagerie de suivi à court terme ou si une biopsie est nécessaire en raison d'une suspicion de malignité. Ces recommandations varient considérablement en fonction du radiologue et peuvent parfois mener à des décisions incorrectes. Les résultats de l'étude menée à l'hôpital universitaire de New York (NYU Langone Health) soulignent qu'avec l'aide de l'IA, les radiologues réduisent leur taux de faux positifs de 37,3%, tout en conservant le même niveau de sensibilité. L'IA permet en effet d'améliorer la précision, la cohérence et l'efficacité du diagnostic. Mais comment ça marche ?

En fait, dans ce cas précis, l'IA utilise la reconnaissance d'image qui consiste à créer des algorithmes auxquels on présente en entrée des images, et dont le but est de prédire en sortie ce que représentent les images. Les algorithmes doivent être capable

de prendre en compte de nombreuses données d'entrées, et surtout de capturer les relations complexes qui existent entre les entrées et les sorties. C'est là qu'interviennent les réseaux de neurones artificiels.

LE MACHINE LEARNING UTILISE LA PUISSANCE COMPUTATIONNELLE DES RÉSEAUX DE NEURONES ARTIFICIELS

Les réseaux de neurones sont parfaitement adaptés pour résoudre ce genre de problème complexe car ils sont capables d'apprendre et de modéliser les relations complexes entre les entrées et les sorties, pour permettre de faire des généralisations et des prédictions, de révéler des relations cachés, ainsi que de modéliser des données très volatiles ou des événements rares.

Le nom et la structure des réseaux de neurones sont inspirés du fonctionnement du cerveau humain, et imitent la façon dont les neurones biologiques se comportent les uns par rapport aux autres. Un neurone artificiel est une fonction mathématique qui imite schématiquement le fonctionnement physiologique d'un vrai neurone. Chaque neurone artificiel a de multiples entrées (équivalent des dendrites) afin de recevoir les signaux électriques d'autres neurones qui lui sont connectés, et possède également une terminaison principale (équivalent de l'axone) qui lui permet d'envoyer un signal à d'autres neurones (en sortie). Le neurone artificiel réalise ainsi une opération binaire : i) si les signaux d'entrée sont supérieurs à une valeur déterminée, appelée valeur seuil, le neurone va envoyer un signal électrique en sortie ; ii) si les signaux d'entrée ne dépassent pas la valeur seuil spécifiée, le neurone va rester au repos, et n'enverra aucun signal le long de son axone.

Afin d'illustrer cela, imaginons un neurone artificiel qui comprendrait plusieurs entrées : x_1, x_2, x_3 allant jusqu'à x_n (Figure 2). Chaque entrée possède un poids et une valeur associée. Le neurone réalise ensuite la somme pondérée de ses entrées, en fonction des poids et des entrées du neurone. Cette somme pondérée peut être modifiée par une fonction que l'on appelle fonction d'activation (par exemple, une fonction sigmoïde). Cette fonction d'activation peut permettre d'introduire des non-linéarités pour la modélisation de relations complexes entre les entrées et les sorties. Le neurone artificiel peut donc être résumé schématiquement par une fonction mathématique comprenant de nombreuses données d'entrées et dont le but est de prendre une décision binaire en sortie. Cette fonction mathématique peut être ajustée en modifiant le poids des entrées et la valeur de seuil spécifiée.

La difficulté, c'est qu'un seul et unique neurone ne suffit pas pour rendre compte de relations complexes. Aussi, comme dans un cerveau humain, il est possible d'associer les neurones artificiels pour créer des réseaux neuronaux, également appelés réseaux neuronaux artificiels (ANN; Nielsen, 2015). Un réseau de neurones artificiels est constitué de couches de neurones - une ou plusieurs couches d'entrée, de sortie, ainsi que des couches intermédiaires. Le réseau contient alors autant de valeurs de poids et de seuils que de neurones individuels. Les réseaux de neurones artificiels sont très polyvalents et peuvent s'adapter à différents types d'entrées et de sorties. Leur principe de fonctionnement est similaire à l'exemple précédent, de l'audiologiste qui présente des données d'entrées à un ordinateur. Les paramètres du réseau (poids et seuils) s'ajustent automatiquement pour trouver la meilleure combinaison d'algorithmes et de paramètres pour permettre de décrire le lien entre les données lors d'une phase appelée phase d'apprentissage.

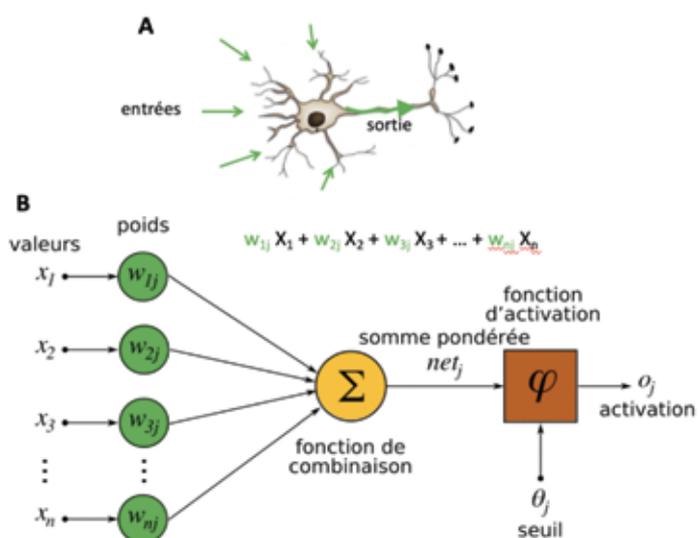


Figure 2 : Illustration du fonctionnement des neurones artificiels en IA. A. Exemple d'un neurone physiologique, représentant des entrées au niveau des dendrites et une sortie sur l'axone. B. Représentation de la fonction mathématique d'un neurone artificiel, qui peut être intégré au sein d'un réseau de neurones.

Le modèle ainsi créé est ensuite testé afin de s'assurer de la qualité des prédictions. De nouvelles données que le modèle n'a jamais vues sont présentées au modèle et les prédictions réalisées par le modèle en sortie sont comparées aux valeurs réelles. Cette mesure de la précision du modèle, c'est-à-dire de sa capacité à prédire les données réelles, est essentielle pour permettre aux chercheurs de déterminer s'il faut arrêter ou continuer la phase d'apprentissage (phase de 'training'). L'un des inconvénients des réseaux de neurones artificiels comparativement à une relation linéaire telle qu'illustrée dans l'exemple précédent, est que les modèles mathématiques obtenus après entraînement peuvent parfois être très complexes... et donc difficilement interprétables.

Une autre difficulté que les chercheurs et data scientists rencontrent fréquemment lors de l'utilisation de réseaux de neurones artificiels est le très grand nombre de paramètres qu'il convient d'ajuster (dépendant du nombre de neurones individuels et du nombre de couches présentes dans le modèle). La phase d'apprentissage peut s'avérer être très longue... et parfois l'entraînement du modèle est impossible lorsque le modèle contient un trop grand nombre de paramètres et de couches de neurones. En effet, plus on a de neurones dans les couches intermédiaires, plus le réseau est a priori polyvalent et puissant. Toutefois, plus il devient compliqué à entraîner et plus l'ajustement des paramètres est complexe. De plus, le grand nombre de paramètres fait qu'il a tendance à représenter les données de manière trop parfaite ("over fitting"), ce qui induit une capacité réduite à prédire des données nouvelles et diminue la précision du modèle. En pratique, les chercheurs se limitent souvent en machine learning à des structures ou architectures simples, avec par exemple 3 couches de neurones seulement : une couche d'entrée, une couche intermédiaire et une couche de sortie.

Cependant, la résolution de tâches nécessitant un grand nombre de données d'entrée telle que la reconnaissance d'image peut s'avérer complexe en utilisant du machine learning, dont les structures restent simples. Par exemple, si l'on souhaite créer un algorithme capable de détecter un neurinome de l'acoustique à partir d'une IRM cérébrale, l'entrée du réseau de neurone (image de l'IRM) peut contenir des milliers de pixels. Cela fait alors autant d'entrées dans le réseau, ce qui complexifie fortement le modèle et rend l'apprentissage extrêmement difficile. En d'autres mots, un modèle de machine learning traditionnel ne peut avoir en entrée l'intégralité des images brutes d'une IRM car le modèle serait trop compliqué à entraîner.

Une technique usuelle utilisée par les chercheurs pour résoudre la problématique précédente repose sur la réalisation d'une étape intermédiaire, au cours de laquelle les caractéristiques essentielles de l'image sont extraites. Ces « caractéristiques intermédiaires », c'est-à-dire les informations clés de l'image, visent à extraire les principaux éléments distinctifs de la pathologie recherchée, telle que le ferait un radiologue dans notre exemple précédent (Figure 3).

Pour la détection du neurinome de l'acoustique, les radiologues se basent sur certaines caractéristiques clés, notamment le diamètre du nerf auditif, la prise de contraste après injection de gadolinium, la comparaison de l'imagerie des deux angles pontocérébelleux.

La solution en machine learning classique pour faire de la reconnaissance d'image est d'extraire des caractéristiques clés de l'image en faisant ce qu'on appelle une abstraction de l'image. Ces caractéristiques sont ensuite fournies aux réseaux de neurones artificiels. Cela permet de réduire considérablement le nombre d'entrées fournies au réseau, et rend alors la phase d'apprentissage possible.

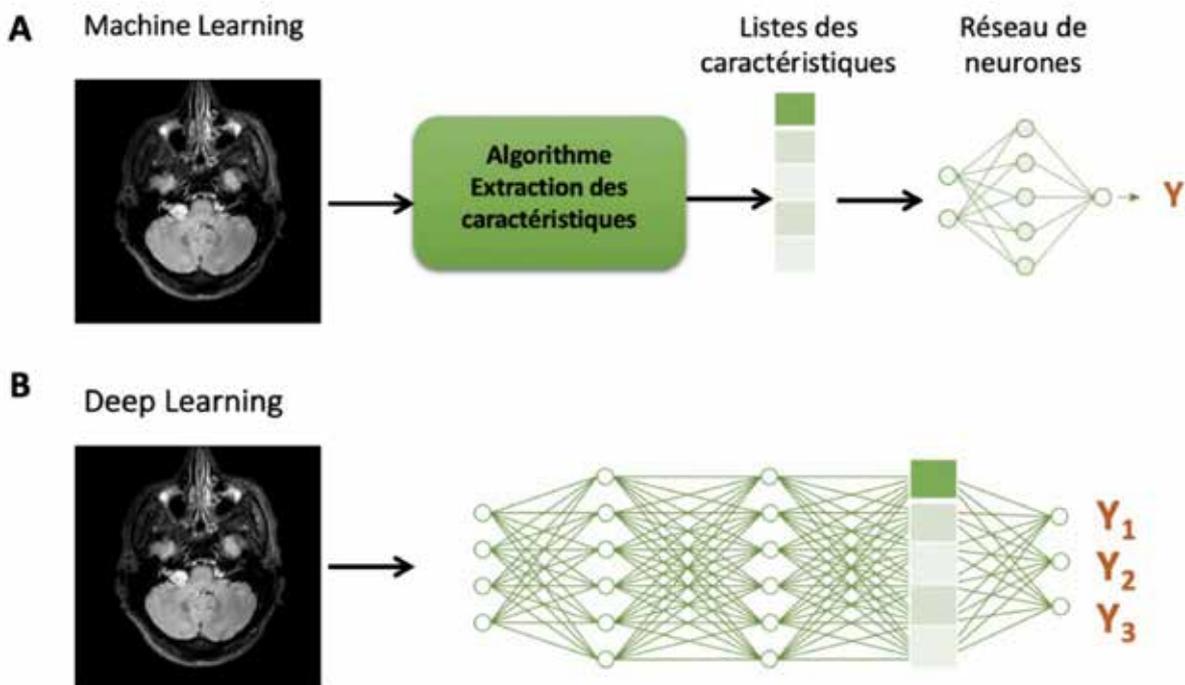


Figure 3 : Illustration des réseaux de neurones artificiels. A. Illustration du modèle de machine learning pour la reconnaissance d'image, avec une étape intermédiaire, celle d'abstraction de l'image. B. Illustration du modèle de deep learning pour la reconnaissance d'image avec de nombreuses couches de neurones artificiels.

Cette étape intermédiaire est cruciale car elle impacte directement la qualité du modèle que l'on va obtenir et donc influe directement sur sa précision. Ainsi, pour obtenir un réseau fiable et précis, cette abstraction doit être faite par un expert - une personne qui extrait et/ou annote les informations clés de l'image, avant de les fournir au réseau. C'est donc cet expert qui réalise une grande partie du travail 'd'intelligence'. Par conséquent, le modèle est entraîné sur un petit ensemble de données composées de plusieurs centaines ou milliers d'images, annotés manuellement par des experts du domaine.

Toutefois, cette réduction de l'information initiale, en plus du travail titanesque qu'elle représente pour l'extraction des caractéristiques essentielles, peut poser différents problèmes :

- i) les modèles entraînés ainsi pourraient ne pas être capables d'interpréter correctement les caractéristiques parfois très diverses des images observées dans la pratique clinique ;
- ii) la variabilité d'annotation entre les experts peut conduire à des erreurs du modèles ;
- iii) la diminution générale de l'information fournie au réseau peuvent conduire à des modèles imprécis.

LE DEEP LEARNING S'AFFRANCHIT DES PROBLÉMATIQUES OBSERVÉES EN MACHINE LEARNING

Le *deep learning* - modèle d'apprentissage profond avec des réseaux neuronaux profonds (deep neural networks, DNN, Figure 3; Bengio et al., 2017) a été créé pour pallier aux problèmes rencontrés en machine learning. L'idée ambitieuse du deep learning est de sauter cette étape intermédiaire d'extraction des caractéristiques essentielles à partir des données brutes. Alors pourquoi le deep learning réussit-il là où le machine learning échoue ?

Après la phase d'apprentissage, des chercheurs ont montré qu'avec des réseaux neuronaux profonds en deep learning, certaines couches du réseau contiennent de façon surprenante les caractéristiques essentielles, c'est-à-dire tous les éléments clés de l'image qui peuvent être nécessaires pour permettre de la reconnaître (Jang et Cho, 2019). En effet, le modèle créé lui-même cette phase d'extraction des caractéristiques intermédiaires. Dans le cas de l'exemple de détection d'un neurinome de l'acoustique, cela signifie en fait que l'on n'a plus besoin de fournir « manuellement » au modèle les informations qui permettent à l'expert du domaine d'identifier la présence d'un neurinome (localisation, prise de contraste éventuelle, caractéristiques morphologiques, ...).

La grande question est pourquoi le deep learning, qui nécessite d'entraîner un réseau comprenant de nombreuses couches de neurones et de nombreuses entrées, fonctionnerait-il aujourd'hui ?

Plusieurs raisons peuvent l'expliquer :

- i) la puissance de calcul des GPU et des cartes graphiques a considérablement augmenté, permettant de résoudre des problèmes sensiblement plus complexes.
- ii) les architectures des réseaux de neurones ont également grandement progressé, et la compréhension des mécanismes impliqués dans le fonctionnement des réseaux neuronaux du cerveau s'est améliorée.

- iii) la quantité de données disponibles pour l'entraînement des modèles s'est considérablement accrue.

En pratique, les modèles de deep learning, contrairement à l'humain, nécessitent un très grand nombre d'exemples (des centaines de milliers, voir des millions) afin d'apprendre à réaliser une tâche donnée pour pouvoir faire des prédictions correctes.

Dans l'exemple de détection du neurinome de l'acoustique, il faudrait donc disposer d'une base de données conséquente, contenant les IRM de milliers de patients, qui auraient été préalablement classifiées. Lorsque toutes ces données sont fournies à un algorithme de deep learning, le modèle extrait lui-même automatiquement les caractéristiques essentielles qui font qu'un neurinome de l'acoustique est un neurinome de l'acoustique. Après entraînement de ce réseau, comprenant parfois plus d'une centaine de couches et plusieurs millions de neurones, le modèle va être capable de définir les paramètres, ainsi que la relation

mathématique qui existe entre les pixels des images fournies en entrée et la catégorie 'neurinome de l'acoustique' en sortie. Ainsi, le modèle pourra guider les radiologues en fournissant une information sur la présence potentielle ou non d'un neurinome de l'acoustique. Les dernières performances de l'IA obtenue grâce au deep learning pour l'interprétation d'images échographie et radiographiques sont maintenant assez spectaculaires (sensibilité de 99,5%; Suzuki, 2017; Lundervold et Lundervold, 2019).

COMPLÉMENTARITÉ ESSENTIELLE ENTRE LES PROFESSIONNELS DE SANTÉ ET L'INTELLIGENCE ARTIFICIELLE

L'intelligence artificielle commence à être communément utilisée pour la réhabilitation auditive par les fabricants d'aides auditives (e.g., Werminghaus et al., 2022). Dans les années à venir, l'IA pourrait également fluidifier le parcours patient, en modifiant sensiblement les pratiques cliniques actuelles au sein des cabinets d'ORL et d'audioprothésiste.

En otologie et en audiologie clinique, les modèles d'IA sont de plus en plus présents dans des revues scientifiques, sous forme d'algorithmes permettant de réaliser des examens audiologiques et ou audiométriques de façon automatisée (e.g., Mahomed et al., 2013; Cox and de Vries, 2015; Song et al., 2015; 2017; Schlittenlacher et al., 2018; Barbour et al., 2019). L'IA peut en effet beaucoup apporter au monde de l'audition, et permettre :

- i) une amélioration considérable de la précision et la répétabilité des explorations fonctionnelles auditives,
- ii) une démocratisation des examens audiologiques complémentaires développés en recherche fondamentale afin d'améliorer le phénotypage du patient, et sa prise en charge (mesures de perception binaurale, ou de perception de modulations - indices clés pour la compréhension de la parole; Lorenzi et al., 2006; 2009; Paraouty et al., 2016; 2018; Wallaert et al., 2016; 2017; 2018).

L'IA appliquée à la médecine est une technologie qui peut potentiellement sembler disruptive. Toutefois, une bonne compréhension de la part des praticiens des principes de base et des mécanismes computationnels impliqués dans la création des réseaux de neurones profonds est fondamentale pour permettre une utilisation raisonnée et éthique en pratique

« L'INTELLIGENCE ARTIFICIELLE COMMENCE À ÊTRE COMMUNÉMENT UTILISÉE POUR la réhabilitation auditive par les fabricants d'aides auditives. » »

clinique. Aujourd'hui, il est nécessaire d'avoir une réflexion approfondie sur l'utilisation de ces réseaux de neurones profonds en incluant les chercheurs, les professionnels de santé, ainsi que pouvoirs publics.

Un récent article scientifique (Hwang et al., 2019) a comparé les performances d'un algorithme d'IA de lecture de radiographies thoraciques aux performances d'une quinzaine de médecins. Les résultats suggèrent que les performances des radiologues sont très bonnes mais celles des radiologues associés à l'IA sont quant à elles excellentes. Ces résultats renforcent l'idée de complémentarité entre les professionnels de santé et les méthodes d'IA. L'utilisation raisonnée des algorithmes d'IA, main dans la main avec les professionnels de santé, devient par ailleurs aujourd'hui indispensable pour améliorer la qualité des soins et transformer notre système de santé, notamment dans un contexte où le temps médical est précieux... et limité.

Pour mettre en œuvre avec succès les nouvelles solutions d'IA en pratique clinique, les professionnels de santé doivent non seulement avoir une compréhension de cette nouvelle technologie mais également connaître ses limites.

En outre, les outils et algorithmes offerts par l'IA doivent être associés à des mesures de performance rigoureuses, à un suivi continu, à un retour d'information et à une responsabilisation de tous les acteurs du domaine afin de garantir le succès de l'IA en clinique (Larson et Boland, 2019). La protection des données de patients est aujourd'hui plus que jamais primordiale car l'utilisation et le stockage de ces données font partie intégrante de ces nouvelles technologies. Enfin, malgré les avantages majeurs offerts par l'utilisation de l'IA dans le domaine médical, il est important de rappeler la possibilité d'erreur des modèles d'IA. Même si cette possibilité est parfois plus faible comparativement à la possibilité d'erreur humaine (e.g. fatigue, inattention, ...), il est toutefois crucial de rester vigilant et de ne pas se conformer aveuglément aux résultats fournis par une IA.

En résumé, l'IA appliquée de façon raisonnée et éthique à la médecine va permettre aujourd'hui d'améliorer la précision des diagnostics des patients, de diminuer la variabilité des recommandations de suivi et de traitement, et de diminuer les coûts des soins en libérant du temps médical pour les praticiens.

Dans le domaine de l'otologie et l'audiologie clinique, les solutions concrètes apportées par l'IA permettront d'adresser le nombre croissant de nouveaux patients. Aujourd'hui, les soins de santé auditive ne peuvent que difficilement continuer à reposer sur des procédures chronophages, et des mesures partielles des capacités auditives. Il est donc capital de faire évoluer le monde de l'audiologie vers un avenir où l'IA apportera un soutien essentiel à la vérification d'hypothèses, au développement de thérapies nouvelles et proactives, pour améliorer la prise en charge des patients souffrant de surdit .

R F RENCES

- Chan, H. P., Samala, R. K., Hadjiiski, L. M., & Zhou, C. (2020). Deep learning in medical image analysis. *Deep Learning in Medical Image Analysis*, 3-21.
- Deng, L., & Liu, Y. (Eds.). (2018). *Deep learning in natural language processing*. Springer.
- Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2018). Bert: Pre-training of deep bidirectional transformers for language understanding. *arXiv preprint arXiv:1810.04805*.
- Hinton, G., Deng, L., Yu, D., Dahl, G. E., Mohamed, A. R., Jaitly, N., ... & Kingsbury, B. (2012). Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. *IEEE Signal processing magazine*, 29(6), 82-97.

- Hwang, E. J., Park, S., Jin, K. N., Im Kim, J., Choi, S. Y., Lee, J. H., ... & Park, C. M. (2019). Development and validation of a deep learning-based automated detection algorithm for major thoracic diseases on chest radiographs. *JAMA network open*, 2(3), e191095-e191095.
- Bengio, Y., Goodfellow, I., & Courville, A. (2017). *Deep learning* (Vol. 1). Cambridge, MA, USA: MIT press.
- Jang, H. J., & Cho, K. O. (2019). Applications of deep learning for the analysis of medical data. *Archives of pharmaceutical research*, 42(6), 492-504.
- Kim, K. M., Heo, T. Y., Kim, A., Kim, J., Han, K. J., Yun, J., & Min, J. K. (2021). Development of a fundus image-based deep learning diagnostic tool for various retinal diseases. *Journal of Personalized Medicine*, 11(5), 321.
- Larson, D. B., & Boland, G. W. (2019). Imaging quality control in the era of artificial intelligence. *Journal of the American College of Radiology*, 16(9), 1259-1266.
- Lesica, N. A., Mehta, N., Manjaly, J. G., Deng, L., Wilson, B. S., & Zeng, F. G. (2021). Harnessing the power of artificial intelligence to transform hearing healthcare and research. *Nature Machine Intelligence*, 3(10), 840-849.
- Levitt, H. (2007). A historical perspective on digital hearing aids: how digital technology has changed modern hearing aids. *Trends in amplification*, 11(1), 7-24.
- Lorenzi, C., Debruille, L., Garnier, S., Fleuriot, P., & Moore, B. C. (2009). Abnormal processing of temporal fine structure in speech for frequencies where absolute thresholds are normal. *The Journal of the Acoustical Society of America*, 125(1), 27-30.
- Lorenzi, C., Gilbert, G., Carn, H., Garnier, S., & Moore, B. C. (2006). Speech perception problems of the hearing impaired reflect inability to use temporal fine structure. *Proceedings of the National Academy of Sciences*, 103(49), 18866-18869.
- Lundervold, A. S., & Lundervold, A. (2019). An overview of deep learning in medical imaging focusing on MRI. *Zeitschrift f r Medizinische Physik*, 29(2), 102-127.
- Nielsen, M. A. (2015). *Neural networks and deep learning* (Vol. 25). San Francisco, CA, USA: Determination press.
- Paraouty, N., Ewert, S. D., Wallaert, N., & Lorenzi, C. (2016). Interactions between amplitude modulation and frequency modulation processing: Effects of age and hearing loss. *The Journal of the Acoustical Society of America*, 140(1), 121-131.
- Paraouty, N., Stasiak, A., Lorenzi, C., Varnet, L., & Winter, I. M. (2018). Dual coding of frequency modulation in the ventral cochlear nucleus. *Journal of Neuroscience*, 38(17), 4123-4137.
- Shen, Y., Shamout, F. E., Oliver, J. R., Witowski, J., Kannan, K., Park, J., ... & Geras, K. J. (2021). Artificial intelligence system reduces false-positive findings in the interpretation of breast ultrasound exams. *Nature communications*, 12(1), 1-13.
- Suzuki, K. (2017). Overview of deep learning in medical imaging. *Radiological physics and technology*, 10(3), 257-273.
- Ting, D. S., Liu, Y., Burlina, P., Xu, X., Bressler, N. M., & Wong, T. Y. (2018). AI for medical imaging goes deep. *Nature medicine*, 24(5), 539-540.
- Yu, D., & Deng, L. (2016). *Automatic speech recognition* (Vol. 1). Berlin: Springer.
- Zeng, F. G., Rebscher, S., Harrison, W., Sun, X., & Feng, H. (2008). Cochlear implants: system design, integration and evaluation. *IEEE Rev Biomed Eng.* 2008; 1 (1): 115-42. PMID: 19946565.
- Wallaert, N., Moore, B. C., & Lorenzi, C. (2016). Comparing the effects of age on amplitude modulation and frequency modulation detection. *The Journal of the Acoustical Society of America*, 139(6), 3088-3096.
- Wallaert, N., Moore, B. C., Ewert, S. D., & Lorenzi, C. (2017). Sensorineural hearing loss enhances auditory sensitivity and temporal integration for amplitude modulation. *The Journal of the Acoustical Society of America*, 141(2), 971-980.
- Wallaert, N., Varnet, L., Moore, B. C., & Lorenzi, C. (2018). Sensorineural hearing loss impairs sensitivity but spares temporal integration for detection of frequency modulation. *The Journal of the Acoustical Society of America*, 144(2), 720-733.
- Werminghaus, M., Schatton, D., Thyson, S., Gnadlinger, F., Schr der, M., Richter, J., & Klenzner, T. (2022). How artificial intelligence can be used in hearing therapy-Adaptive Difficulty Adjustment in Digital Auditory Training. *Laryngo-Rhino-Otologie*, 101(S 02).