

ORL Mag 93

ORGANE OFFICIEL D'EXPRESSION DES **INSTANCES NATIONALES**
DE L'ORL ET DE LA CHIRURGIE CERVICO-FACIALE

SEPTEMBRE 2022

**SPÉCIAL 128^e Congrès
Annuel de la SFORL**

14 > 17 Octobre
Programme - p 9

Palais du Pharo - Marseille



**Forum Pluridisciplinaire en ORL
et Chirurgie de la Face** p 41

à Mexico

du 1^{er} au 8 Décembre 2022

Présidé par

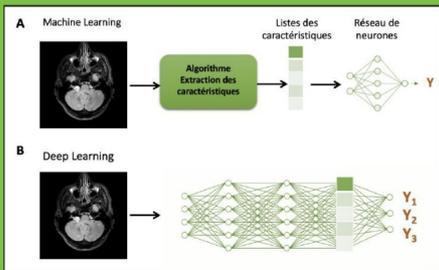
Pr Elie Serrano

Pr Guillaume de Bonnecaze

Dr. M. Alejandro Jiménez Chobillon

**L'Intelligence Artificielle au service
de l'Audiologie Clinique** p 35

Nicolas Wallaert,
Hadrien Jean,
Nihaad Paraouty



L'Intelligence Artificielle au service de l'Audiologie Clinique

Nicolas Wallaert^{1,2}, Hadrien Jean^{1,3}, Nihaad Paraouti^{1,4}

1. iAudiogram, 5 Bis Cours Anatole France, 51100 Reims, France
2. Audioprothésiste D.E., Master Audiologie et Troubles du Langages, Ingénieur en Acoustique, Docteur en Sciences Cognitives (PhD), Membre du Collège National d'Audioprothèse
3. Data scientist, Machine learning scientist, Docteur en Sciences Cognitives (PhD)
4. Translational auditory scientist, Docteur en Sciences Cognitives (PhD)

RÉSUMÉ

La recherche sur l'audition a toujours été à la pointe de l'innovation technologique. Ainsi, l'implant cochléaire, qui rétablit l'audition par stimulation électrique directe du nerf auditif, a été une avancée majeure et reste l'une des prothèses neurales les plus aboutie en termes de performance et de pénétration. Aujourd'hui en France, comme partout dans le monde, nous faisons face à un défi majeur, celui de prendre en charge un nombre croissant de personnes souffrant d'une perte auditive dans des délais raisonnables pour leur offrir des soins auditifs appropriés : stratégies de prévention, prise en charge médicale ou chirurgicale, mise en place de solutions de réhabilitation auditive. Les récentes innovations technologiques dans le domaine de l'*intelligence artificielle* pourraient apporter un élément de réponse concret aux enjeux médicaux, sociétaux et économiques liés à la surdité. Dans cet article, nous décrivons les grandes lignes du machine learning appliqué à la médecine, ainsi que des exemples d'application qu'il pourrait avoir à court terme en audiologie clinique.

Introduction :

Aujourd'hui, l'audiologie clinique et particulièrement le monde ORL en première ligne devra faire face à un défi majeur : répondre aux besoins de soins de santé auditive pour près d'une personne sur 4 qui serait concernée par une déficience auditive, comme le confirme une récente étude française de l'INSERM (Lisan et al., 2022).

En France, malgré d'important progrès sur les dernières années, la perte auditive demeure encore sous diagnostiquée et parfois peu traitée, en dépit des conséquences non négligeables et désormais bien connues : survenue de déficits neuronaux centraux quelque soit l'âge, allant des retards dans l'acquisition du langage chez les enfants, aux troubles neurodégénératifs chez les personnes âgées (e.g., Baltimore Longitudinal Study of Aging (BLSA), la National Health and Nutrition Survey (NHAES) et la Health, Aging and Body Composition study (Health ABC study). Ce problème de santé publique dépassera largement les frontières dans les années à venir. Ainsi, l'OMS confirme que près d'un quart de la population mondiale souffrira d'une perte auditive dû à une surexposition au bruit et à un vieillissement de la population mondiale à l'horizon 2050.

La prise en charge otologique et audiolgologique de ces patients repose sur des procédures exigeantes et chronophages qui ne permettront pas d'adresser la majorité des patients dans des délais raisonnables (Lesica et al; 2021). Au niveau national, la démographie déclinante des ORL, soulignée par le SNORL qui prévoit environ 800 ORL de moins d'ici à 2030 et sa répartition inhomogène au sein du territoire, impose d'avoir une réflexion pour répondre à cet enjeu de santé publique. Au niveau mondial, le problème est colossal : alors que la France compte environ 1 ORL pour 25 000 habitants, les statistiques peuvent atteindre 1 ORL pour 500 000 habitants dans certains pays émergents.

Face à l'ampleur des enjeux et en raison des spécificités locales, la réponse sera probablement multifactorielle et se doit d'être adaptée : délégation de tâches, promotion de la télé-médecine, apport de l'intelligence artificielle (IA), ...

L'intelligence artificielle (IA), bien que pas ou peu utilisée en otologie, pourrait en effet être l'un des éléments de réponses pour améliorer la prise en charge audiolgologique de patients. Elle commence en effet pourtant à avoir un impact généralisé tant en médecine (Chan et al., 2020) que dans notre vie quotidienne. Ainsi, les algorithmes d'IA ont déjà atteint des performances proches de celles de l'homme dans des tâches importantes liées à 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). Alors que les applications de l'IA sont de plus en plus courantes dans d'autres spécialités cliniques, e.g. détection des maladies de la rétine (Ting et al., 2018; Kim et al., 2021) ou encore en imagerie médicale (Hwang et al., 2019; Shen et al., 2021), elles restent rares dans le domaine de l'audition. De façon à favoriser l'acculturation avec l'IA, nous décrivons ici ces principaux principes de fonctionnement, ainsi que les possibilités d'utilisation et d'application qu'elle pourrait avoir dans nos pratiques cliniques.

Le machine learning : la méthode la plus courante utilisée en IA

TAKE HOME MESSAGE : Le machine learning est un domaine d'étude qui consiste à concevoir des algorithmes ou des modèles, qui sont capables d'apprendre à partir d'exemples fournis.

Afin d'expliquer didactiquement les principes de base du machine learning, prenons un chercheur qui s'intéresse au lien entre la perte auditive tonale et l'intelligibilité de la parole.

Pour comprendre la relation entre ces deux mesures, il est possible de représenter graphiquement les pertes auditives moyennes des sujets en abscisse et leurs seuils d'intelligibilité en ordonnée (Figure 1). On remarque qu'une droite de régression permettrait de définir la relation entre ces deux mesures (Figure 1, ligne noire). Cette droite de régression permet également de « généraliser » les résultats. En effet, grâce à l'équation de la droite de régression, le chercheur pourrait « prédire » les seuils d'intelligibilité de personnes uniquement à partir de leur perte auditive moyenne. Ainsi, pour un nouveau sujet, il suffirait alors de mesurer uniquement sa perte auditive moyenne (Figure 1, illustré en rouge, 55 dB HL) pour en déduire son seuil d'intelligibilité, sans avoir à le mesurer (Figure 1, illustré en rouge, 70 dB SPL).

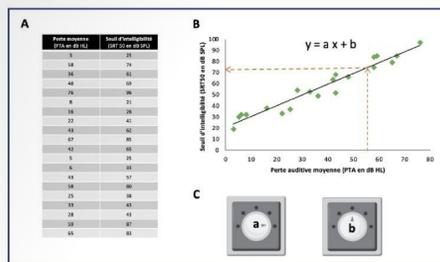


Figure 1 :

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.

Le terme de prédiction, couramment utilisé en IA, ne vise pas nécessairement à prédire un événement futur, mais plutôt à inférer une valeur inconnue. Dans cet exemple, nous avons utilisé les données des sujets pour définir le lien entre la perte auditive moyenne et les seuils d'intelligibilité. Grâce à l'équation définissant le lien entre ces 2 types de mesures, nous pouvons ensuite faire des prédictions de valeurs jusqu'alors inconnues. **Le machine learning repose sur le même principe, celui d'utiliser des algorithmes mathématiques pour définir la relation entre des ensembles de données.**

Schématiquement, pour construire un modèle de machine learning qui permettrait de prédire les seuils d'intelligibilité à partir des pertes auditives, un chercheur en machine learning présenterait les données de perte auditive moyenne et les seuils d'intelligibilité des sujets mesurés à un ordinateur. Puis, le chercheur demanderait à l'ordinateur de déterminer l'algorithme (le modèle) qui capture le plus fidèlement possible la

relation qui existe entre la perte auditive tonale et les seuils d'intelligibilité : c'est la **phase d'apprentissage** du modèle. 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. La 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. Une fois notre algorithme ou modèle entraîné, une phase de test peut ensuite débiter, durant laquelle le modèle peut être utilisé pour prédire des valeurs inconnues. **Cette capacité de prédiction est l'un des objectifs majeurs du machine learning.**

L'IA en pratique clinique avec l'apport des réseaux de neurones

TAKE HOME MESSAGE : Les réseaux de neurones permettent de réaliser une tâche donnée (e.g. aide à l'interprétation d'une imagerie, détection d'incident, surveillance de patients, ...) à partir d'exemples qui ont été caractérisés par des médecins et pour lesquels ils ont identifié des indicateurs clés qui permettent d'aiguiller et de poser leur diagnostic.

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, l'IA utilise, dans le cas présent, de la reconnaissance d'image, qui consiste à créer des algorithmes auxquels on présente des images échographiques en entrée, et dont le but est de prédire en sortie ce que représentent ces images échographiques - en d'autres mots, d'en extraire les informations clés. Les algorithmes doivent ainsi 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**.

TAKE HOME MESSAGE : En effet, les réseaux de neurones sont parfaitement adaptés pour résoudre des problèmes complexes 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 cachées, 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. Un neurone artificiel peut être représenté par une fonction mathématique qui imite grossièrement le fonctionnement physiologique d'un neurone. Schématiquement, chaque neurone artificiel possède de multiples entrées (dendrites) afin de recevoir les signaux électriques d'autres neurones, et comporte également une terminaison principale (axone) qui permet d'envoyer des signaux à d'autres neurones. 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'émettra aucun signal.

La Figure 2 représente un neurone artificiel comprenant plusieurs entrées : x_1, x_2, x_3 allant jusqu'à x_n . Chaque entrée possède un poids et une valeur associée. Le neurone réalise une somme pondérée des entrées qui peut être modifiée par une fonction appelée la fonction d'activation (e.g., une fonction sigmoïde). Cette fonction d'activation permet d'introduire des non-linéarités dans la modélisation des relations complexes entre les entrées et les sorties. Le neurone artificiel peut donc être résumé 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, les entrées elles-mêmes, 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. Ainsi, les paramètres du réseau s'ajustent automatiquement afin de trouver la meilleure combinaison d'algorithmes et de paramètres décrivant le lien entre des ensembles de données lors de la phase d'apprentissage.

Le modèle ainsi entraîné passe ensuite par une phase de validation afin de s'assurer de la qualité des prédictions. De nouvelles données que le modèle n'a jamais vu sont présentées au modèle et les prédictions réalisées par le modèle en sortie sont comparées aux valeurs réelles mesurées en clinique. Cette mesure de **précision du modèle**, c'est-à-dire de sa capacité à prédire les données correctement, est essentielle pour permettre aux chercheurs de déterminer s'il faut arrêter ou poursuivre la phase d'apprentissage. L'un des inconvénients des réseaux de neurones artificiels comparativement à une relation linéaire telle qu'illustrée précédemment, est que les modèles mathématiques obtenus après entraînement peuvent parfois être très complexes et difficilement interprétables. L'autre difficulté lors de l'utilisation de réseaux de neurones artificiels est le très grand nombre de paramètres qu'il convient d'ajuster, en fonction du nombre de couches et de neurones utilisés dans le modèle. Dans certains cas, la phase d'apprentissage peut s'avérer être très longue et peut conduire à des risques d'"over-fitting", c'est-à-dire conduire à des modèles trop parfaits ayant une capacité réduite à prédire des données nouvelles.

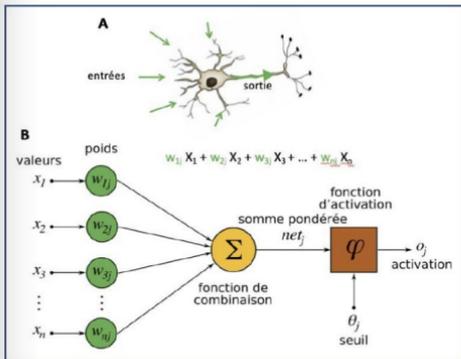


Figure 2 :
 Illustration de la fonction des neurones artificiels en IA.
A. Exemple d'un neurone, représentant des entrées au niveau des dendrites et une sortie sur l'axone.
B. Représentation de la fonction mathématique d'un neurone artificiel au sein d'un réseau de neurones.

Cependant, la résolution de tâches nécessitant un grand nombre de données d'entrée, comme par exemple pour de la reconnaissance d'image, peut s'avérer complexe en utilisant du machine learning, dont les structures des réseaux de neurones restent simples.

Pour comprendre la relation entre ces deux mesures, il est possible de représenter graphiquement les pertes auditives moyennes des sujets en abscisse et leurs seuils d'intelligibilité en ordonnée (Figure 1). On remarque qu'une droite de régression permettrait de définir la relation entre ces deux mesures (Figure 1, ligne noire). Cette droite de régression permet également de « généraliser » les résultats. En effet, grâce à l'équation de la droite de régression, le chercheur pourrait « prédire » les seuils d'intelligibilité de personnes uniquement à partir de leur perte auditive moyenne. Ainsi, pour un nouveau sujet, il suffirait alors de mesurer uniquement sa perte auditive moyenne (Figure 1, illustré en rouge, 55 dB HL pour en déduire son seuil d'intelligibilité, sans avoir à le mesurer (Figure 1, illustré en rouge, 70 dB SPL).

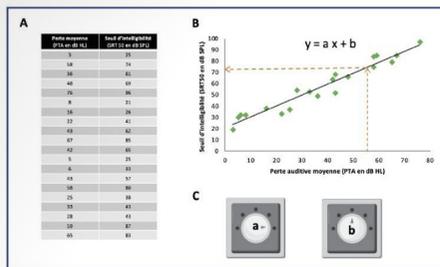


Figure 1 : Illustration schématique du Machine Learning. **A.** Données de perte auditive moyenne (dB HL) et seuils d'intelligibilité (dB SPL). **B.** Représentation graphique des données en A, avec une droite de régression (ligne noire), permettant d'inférer la valeur de seuil d'intelligibilité pour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

Le terme de prédiction, couramment utilisé en IA, ne vise pas nécessairement à prédire un événement futur, mais plutôt à inférer une valeur inconnue. Dans cet exemple, nous avons utilisé les données des sujets pour définir le lien entre la perte auditive moyenne et les seuils d'intelligibilité. Grâce à l'équation définissant le lien entre ces 2 types de mesures, nous pouvons ensuite faire des prédictions de valeurs jusqu'alors inconnues. **Le machine learning repose sur le même principe, celui d'utiliser des algorithmes mathématiques pour définir la relation entre des ensembles de données.**

Schématiquement, pour construire un modèle de machine learning qui permettrait de prédire les seuils d'intelligibilité à partir des pertes auditives, un chercheur en machine learning présenterait les données de perte auditive moyenne et les seuils d'intelligibilité des sujets mesurés à un ordinateur. Puis, le chercheur demanderait à l'ordinateur de déterminer l'algorithme (le modèle) qui capture le plus fidèlement possible la

relation qui existe entre la perte auditive tonale et les seuils d'intelligibilité : c'est la **phase d'apprentissage** du modèle. 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. La 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. Une fois notre algorithme ou modèle entraîné, une phase de test peut ensuite débuter, durant laquelle le modèle peut être utilisé pour prédire des valeurs inconnues. **Cette capacité de prédiction est l'un des objectifs majeurs du machine learning.**

L'IA en pratique clinique avec l'apport des réseaux de neurones

TAKE HOME MESSAGE : Les réseaux de neurones permettent de réaliser une tâche donnée (e.g. aide à l'interprétation d'une imagerie, détection d'incident, surveillance de patients, ...) à partir d'exemples qui ont été caractérisés par des médecins et pour lesquels ils ont identifié des indicateurs clés qui permettent d'aiguiller et de poser leur diagnostic.

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, l'IA utilise, dans le cas présent, de la reconnaissance d'image, qui consiste à créer des algorithmes auxquels on présente des images échographiques en entrée, et dont le but est de prédire en sortie ce que représentent ces images échographiques - en d'autres mots, d'en extraire les informations clés. Les algorithmes doivent ainsi 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**.

TAKE HOME MESSAGE : En effet, les réseaux de neurones sont parfaitement adaptés pour résoudre des problèmes complexes 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 cachées, 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. Un neurone artificiel peut être représenté par une fonction mathématique qui imite grossièrement le fonctionnement physiologique d'un neurone. Schématiquement, chaque neurone artificiel possède de multiples entrées (dendrites) afin de recevoir les signaux électriques d'autres neurones, et comporte également une terminaison principale (axone) qui permet d'envoyer des signaux à d'autres neurones. 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'envoiera aucun signal.

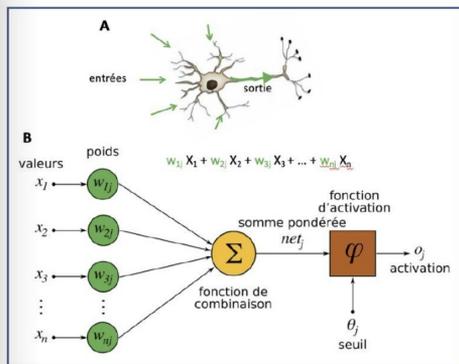


Figure 2 :
 Illustration de la fonction des neurones artificiels en IA.
A. Exemple d'un neurone, représentant des entrées au niveau des dendrites et une sortie sur l'axone.
B. Représentation de la fonction mathématique d'un neurone artificiel au sein d'un réseau de neurones.

La Figure 2 représente un neurone artificiel comprenant plusieurs entrées : x_1, x_2, x_3 allant jusqu'à x_n . Chaque entrée possède un poids et une valeur associée. Le neurone réalise une somme pondérée des entrées qui peut être modifiée par une fonction appelée la fonction d'activation (e.g., une fonction sigmoïde). Cette fonction d'activation permet d'introduire des non-linéarités dans la modélisation des relations complexes entre les entrées et les sorties. Le neurone artificiel peut donc être résumé 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, les entrées elles-mêmes, 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. Ainsi, les paramètres du réseau s'ajustent automatiquement afin de trouver la meilleure combinaison d'algorithmes et de paramètres décrivant le lien entre des ensembles de données lors de la phase d'apprentissage.

Le modèle ainsi entraîné passe ensuite par une phase de validation afin de s'assurer de la qualité des prédictions. De nouvelles données que le modèle n'a jamais vu sont présentées au modèle et les prédictions réalisées par le modèle en sortie sont comparées aux valeurs réelles mesurées en clinique. Cette mesure de **précision du modèle**, c'est-à-dire de sa capacité à prédire les données correctement, est essentielle pour permettre aux chercheurs de déterminer s'il faut arrêter ou poursuivre la phase d'apprentissage. L'un des inconvénients des réseaux de neurones artificiels comparativement à une relation linéaire telle qu'illustrée précédemment, est que les modèles mathématiques obtenus après entraînement peuvent parfois être très complexes et difficilement interprétables. L'autre difficulté lors de l'utilisation de réseaux de neurones artificiels est le très grand nombre de paramètres qu'il convient d'ajuster, en fonction du nombre de couches et de neurones utilisés dans le modèle. Dans certains cas, la phase d'apprentissage peut s'avérer être très longue et peut conduire à des risques d'"over-fitting"; c'est-à-dire conduire à des modèles trop parfaits ayant une capacité réduite à prédire des données nouvelles.

Cependant, la résolution de tâches nécessitant un grand nombre de données d'entrée, comme par exemple pour de la reconnaissance d'image, peut s'avérer complexe en utilisant du machine learning, dont les structures des réseaux de neurones restent simples.

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 essentiel de faire évoluer le monde de l'audiologie clinique 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 de nos patients souffrant de surdité.

Références

- 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.
- 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.
- Lisan, O., Goldberg, M., Lahlou, G., Ozguler, A., Lemonnier, S., Jouven, X., ... & Empana, J. P. (2022). Prevalence of Hearing Loss and Hearing Aid Use Among Adults in France in the CONSTANCES Study. *JAMA Network Open*, 5(6), e2217633-e2217633.
- Livingstone, D., & Chau, J. (2020). Otoscopic diagnosis using computer vision: An automated machine learning approach. *The Laryngoscope*, 130(6), 1408-1413..
- Lorenzi, C., Debrulle, 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 für Medizinische Physik*, 29(2), 102-127.
- Mahomed, F., Swanepoel, D. W., Eikelboom, R. H., & Soer, M. (2013). Validity of automated threshold audiometry: a systematic review and meta-analysis. *Ear and hearing*, 34(6), 745-752.
- Nielsen, M. A. (2015). *Neural networks and deep learning* (Vol. 25). San Francisco, CA, USA: Determination press.
- 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.
- 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.