

Mémoire

Selim BRAHIMI

L'intérêt du deep learning dans le diagnostic du  
SAOS

*Sommaire:*

*I Introduction*

*II Principes du deep learning appliqués au SAOS*

*III Mise en application du deep learning grâce à différentes études*

*III-1 Données utilisées*

*III-2 Modèles du deep learning*

*III-3 Performances des modèles diagnostiques*

*IV Discussion*

*IV-1 Avantages*

*IV-2 Limites*

*V Conclusion*

## I Introduction

Le syndrome d'apnées obstructives du sommeil (SAOS) est une pathologie respiratoire fréquente, caractérisée par des épisodes répétés d'obstruction partielle ou complète des voies aériennes supérieures au cours du sommeil. Sa prévalence est estimée entre 10 et 30% (SAOS léger et 5 à 10% qui nécessitent une prise en charge médicalisée) dans la population avec un sex-ratio de 2 à 3 hommes pour 1 femme. Ces épisodes sont responsables de désaturations en oxygène, de micro-éveils répétés et d'une fragmentation du sommeil pouvant avoir des répercussions sur la santé et la qualité de vie. À long terme, les conséquences du SAOS peuvent être: des troubles neurocognitifs, comportementaux, cardiovasculaires ou encore métaboliques. Malheureusement, cette pathologie à risque reste encore sous diagnostiquée.

Pour diagnostiquer le SAOS, la polysomnographie reste le gold standard. Cet examen permet l'enregistrement simultané de nombreux paramètres physiologiques, tels que l'activité cérébrale (EEG), l'activité électro-cardiaque (ECG), la saturation pulsée en oxygène ( $SpO_2$ ) et les paramètres respiratoires (fréquence respiratoire...). Toutefois, sa réalisation nécessite un matériel spécifique, du personnel formé et une interprétation spécialisée. Son coût et sa disponibilité limitée peuvent ainsi retarder l'accès au diagnostic.

Dans ce contexte, le développement de méthodes automatisées d'analyse des signaux physiologiques suscite un intérêt croissant. Parmi elles, le deep learning occupe une place particulière. Cette branche de l'intelligence artificielle est une sous catégorie de l'apprentissage automatique (machine learning) qui utilise des réseaux de neurones artificiels profonds pour apprendre des modèles à partir de bases de données, permettant ainsi aux ordinateurs d'accomplir des tâches complexes. Cette approche de deep learning pourrait permettre d'identifier automatiquement des profils compatibles avec un SAOS.

Au cours des dernières années, plusieurs équipes ont développé des modèles utilisant des données telles que l'ECG, la  $SpO_2$  ou des enregistrements polysomnographiques complets afin d'améliorer le dépistage et le diagnostic du SAOS. Les résultats publiés semblent encourageants, avec des performances parfois proches de celles obtenues lors de l'interprétation spécialisée. Néanmoins, l'utilisation de ces modèles soulève plusieurs questions, notamment concernant leur interprétabilité et leur place dans la pratique clinique.

Face aux difficultés d'accès à la polysomnographie et à l'augmentation des capacités de calcul informatique, les méthodes de deep learning apparaissent aujourd'hui comme une piste intéressante pour simplifier le dépistage du SAOS.

L'objectif de ce mémoire est d'analyser les principales approches de deep learning appliquées au diagnostic du SAOS à partir de données physiologiques. Une attention particulière sera portée aux performances diagnostiques rapportées dans la littérature, notamment la sensibilité et la spécificité des différents modèles, ainsi qu'à leur potentiel d'utilisation en complément de l'expertise clinique.

## II-Principes du deep learning appliqué au SAOS

De nos jours, l'intelligence artificielle est en pleine expansion. Elle correspond à un enjeu économique qui intéresse l'économie, la recherche et la formation et innervant tous les domaines de la société. Il s'agit d'un domaine scientifique dans lequel les outils peuvent être classés lorsqu'ils respectent certains critères.

Pour le parlement européen, l'intelligence artificielle représente tout outil utilisé par une machine afin de reproduire des comportements liés aux humains tels que le raisonnement, la planification et la créativité.

Le machine learning est quant à lui une sous-catégorie de l'intelligence artificielle qui se concentre sur la création de systèmes qui apprennent et s'améliorent à mesure qu'ils intègrent des données.

Les types populaires d'algorithmes de machine Learning incluent:

- les réseaux neuronaux (deep Learning)
- Les arbres de décision
- Le clustering

Parmi ces algorithmes: le deep learning (ou apprentissage profond) est un procédé d'apprentissage automatique utilisant des réseaux de neurones possédant plusieurs couches de neurones cachées. Ces algorithmes possédant de très nombreux paramètres, ils demandent un nombre très important de données afin d'être entraînés (Définition du CNIL).

Le deep learning s'appuie donc sur des algorithmes qui reprennent une architecture neuronale avec pour ambition de reproduire le cerveau humain.

On peut se représenter le réseau de neurones artificiels comme une boîte avec :

- une entrée : les données fournies;
- une sortie : le résultat attendu et
- entre les deux : un réseau neuronal, autrement dit des couches successives de neurones artificiels.

En deep learning, les réseaux de neurones convolutifs (CNN ou ConvNet) sont un type de réseaux de neurones profonds généralement utilisés pour reconnaître des motifs présents dans les images. Ils sont également utilisés pour l'analyse de données spatiales, la vision par ordinateur, le traitement du langage naturel, le traitement du signal et bien plus encore. L'architecture d'un réseau convolutif ressemble au modèle de connectivité des neurones dans le cerveau humain et a été inspirée de l'organisation du cortex visuel. Ce type spécifique de réseau de neurones artificiels tire son nom de l'une des opérations les plus importantes du réseau : la convolution.

Une convolution est une procédure ordonnée dans laquelle deux sources d'information sont entrelacées. Il s'agit d'une opération qui transforme une fonction en quelque chose d'autre. Les convolutions sont utilisées depuis longtemps, notamment dans le traitement des images pour les rendre floues ou plus nettes. Elles permettent également d'effectuer d'autres opérations (par exemple, pour

rehausser les bords et les mettre en relief). Les CNN créent un modèle de connectivité locale entre les neurones des couches adjacentes.

Comme expliqué précédemment l'examen de référence pour le diagnostic du SAOS repose sur l'exploration de la qualité du sommeil et de la vigilance se faisant à l'aide de techniques subjectives (appréciations du patient et de son entourage) et objectives (techniques de laboratoire).

Il n'existe pas de définition unique de la polysomnographie et de la polygraphie. Cependant, la polysomnographie est définie de façon générale comme étant un processus de surveillance et d'enregistrement de plusieurs données physiologiques pendant le sommeil. Le nombre et la nature des données enregistrées sont variables selon la pathologie suspectée mais comprennent habituellement dans une version complète :

- l'électroencéphalogramme (EEG) qui est un enregistrement de l'activité électrique du cerveau par des électrodes placées sur le cuir chevelu. Il permet de classer les stades du sommeil ;
- l'électro-oculogramme (EOG) qui enregistre les mouvements des globes oculaires. Le recueil des différences de potentiel est monoculaire effectué entre deux électrodes de surfaces, l'une placée au canthus interne et l'autre au canthus externe. Cet examen permet de classer les stades du sommeil ;
- l'électromyogramme (EMG) qui enregistre l'activité musculaire. Les électrodes sont placées en général sous le menton et sur les jambes. Cet examen permet de classer les stades du sommeil ;
- l'électrocardiogramme (ECG) qui enregistre l'activité cardiaque avec deux ou trois électrodes sur la poitrine. L'objectif de cet examen est de déterminer s'il y a des perturbations importantes du rythme cardiaque et/ou du rythme associés à des troubles respiratoires ;
- l'effort respiratoire qui sert à déterminer la présence et le type d'apnées du sommeil : la méthode de référence est celle de la pression œsophagienne (Pœso) mais elle est invasive puisqu'elle nécessite la mise en place d'un capteur de pression dans l'œsophage. En routine, des méthodes semi-quantitatives peuvent suffire. La méthode privilégiée alors est la plethysmographie respiratoire par inductance (RIP). Les sangles thoraciques ou abdominales, qu'elles soient à jauge de contrainte au mercure ou à quartz piézo électrique, et la mesure de l'impédance par la technique des oscillations forcées peuvent être utilisés, mais sont sujets à des variations importantes quand le patient change de position de sommeil et peuvent donner des informations trompeuses ;
- le débit respiratoire qui est mesuré à l'aide d'un pneumatographe (gold standard), peu pratique en routine car nécessite l'utilisation d'un masque naso-buccal, ou par mesure de la pression nasale à l'aide d'une canule nasale, non utilisable lorsque la respiration est exclusivement buccale.

L'utilisation de thermocouple (capteurs thermiques) est simple mais elle n'est pas adaptée à la détection d'hypopnées et ne permet pas d'identifier des apnées au cours desquelles se produisent de faibles débits expiratoires sans débit inspiratoire ;

- la pression partielle en gaz carbonique et/ou en oxygène ( $\text{PaCO}_2/\text{PaO}_2$ ) qui permet, grâce à des électrodes transcutanées, d'évaluer les conséquences gazométriques des apnées ;

- la saturation oxyhémoglobinée ( $\text{SaO}_2$ ) par oxymétrie transcutanée qui permet également d'évaluer les conséquences gazométriques des apnées ;
- la position du corps par observation directe ou par utilisation de capteurs à mercure placés sur une sangle ;

- les bruits respiratoires et notamment du ronflement enregistrés au moyen d'un microphone qui permettent d'identifier les anomalies respiratoires au cours du sommeil et également de constater la réussite d'une opération correctrice ;

- l'enregistrement vidéographique du patient qui a pour but de corréler une manifestation clinique à un aspect EEG concomitant.

- la présence ou l'absence de lumière qui est une information importante pour la mesure de la latence d'endormissement (temps entre l'extinction de la lumière et la survenue de la première époque de n'importe quel stade du sommeil).

En France, la définition utilisée est celle de l'Assurance Maladie: « la polysomnographie inclut la réalisation simultanée d'une électroencéphalographie sur une ou deux dérivations, d'une électro-oculographie sur une ou deux dérivations, d'une électromyographie mentonnière sur une dérivation, ainsi que de l'un des enregistrements suivants :

- électroencéphalographie sur au moins 8 dérivations supplémentaires,
- électromyographie sur au moins 2 dérivations supplémentaires,
- paramètres physiologiques cardiorespiratoires (bruits, flux et efforts respiratoires,  $\text{SaO}_2$ , fréquence cardiaque) ».

Malgré leur statut de référence, les méthodes diagnostiques actuelles du SAHOS présentent plusieurs limites structurelles. Dans le cas de la PSG, il persiste un écart notable entre la suspicion clinique d'un trouble du sommeil et l'exploration objective de celui-ci, impliquant un décalage dans le parcours patient et un retard de diagnostic de plusieurs mois, voire années selon les délais d'attente pour réaliser l'examen. Cette situation influe la continuité de la prise en charge et explique que de nombreux patients restent non diagnostiqués ou mal orientés.

Des limites individuelles sont également à noter pour chaque examen d'exploration évoqué (transports, accès aux soins, isolement social...)

Dans ce contexte, le principal défi ne réside pas tant dans la fiabilité des examens que dans la difficulté à identifier précocement les patients à risque et à organiser de manière raisonnée leur orientation vers les spécialistes. Améliorer l'accès aux soins passe ainsi par une rationalisation du parcours diagnostique, reposant sur des

stratégies alternatives de dépistage et de prévention primaire, notamment par l'amélioration des habitudes de sommeil et l'identification précoce de signaux d'alerte.

Des solutions innovantes basées sur l'intelligence artificielle existent déjà et suscitent un intérêt croissant dans ce domaine.

### III- Mise en application du deep learning grâce à différentes études

Le tableau suivant synthétise les principales caractéristiques des articles analysés, avec notamment les signaux physiologiques utilisés, les modèles de deep learning étudiés et les performances diagnostiques rapportées dans les différents articles.

| Article                     | Type d'étude                 | Population /effectif | Signal(s) utilisé(s)                 | Modèle                        | Sensibilité                                    | Spécificité                                    | AUC                |
|-----------------------------|------------------------------|----------------------|--------------------------------------|-------------------------------|------------------------------------------------|------------------------------------------------|--------------------|
| García-Vicente et al., 2026 | Étude pédiatrique            | 3320                 | ECG + SpO <sub>2</sub>               | CNN combiné + stacking + SHAP | 80–96 %                                        | 17,9–98,6 % selon seuil AHI                    | Non renseigné (NR) |
| Zarei et al., 2022          | Étude diagnostique           |                      | ECG 1 dérivation                     | CNN-LSTM                      | 94,41 %                                        | 98,94 %                                        | NR                 |
| Li et al., 2023             | Étude multicentrique         | 50 PSG               | EEG + flux oro-nasal                 | CNN + self-attention          | 83,7 %                                         | 87,3 %                                         | NR                 |
| Erdenebayar et al., 2019    | Étude diagnostique           | 86 patients          | ECG                                  | DNN, CNN, RNN, LSTM, GRU      | jusqu'à 99 %                                   | jusqu'à 99 %                                   | NR                 |
| Covassin et al., 2025       | Étude clinique rétrospective | 11.299 patients      | ECG 12 dérivations                   | Deep CNN                      | 77,0 %                                         | 68,6 %                                         | 0,80               |
| Salari et al., 2022         | Revue systématique           | 48 études            | ECG                                  | ML/DL variés                  | jusqu'à 100 %                                  | jusqu'à 100 %                                  | Non applicable     |
| Mostafa et al., 2019        | Revue systématique           | 21 études            | ECG, SpO <sub>2</sub> , airflow, PSG | DL variés                     | Non applicable                                 | Non applicable                                 | NR                 |
| Gupta et al., 2025          | Étude avec XAI               |                      | ECG 1 dérivation                     | MLP, SVM, GB, LSTM + LIME     | 82,4 %                                         | 89,5 %                                         | NR                 |
| Kilic et al., 2025          | Méta analyse                 | 84 études            | ECG 1 dérivation                     | ML/DL                         | 90,3 % par segment ; 97,7 % par enregistrement | 91,3 % par segment ; 96,9 % par enregistrement | NR                 |
| Setiawan & Lin, 2022        | Étude diagnostique           | 33 sujets            | ECG 1 dérivation                     | EMD + 1D/2D deep CNN          | 94,9 % par segment ; 75,9 % par sujet          | 92,7 % par segment ; 88,7 % par sujet          | NR                 |

### III.1) Données utilisées

Le signal le plus souvent utilisé dans l'ensemble des 10 articles pour détecter le SAOS est l'ECG. Il permet d'observer des effets du SAOS sur le coeur, notamment les changements de rythme.

Dans certaines études, l'ECG est couplé avec la SpO2, ce qui permet de prendre en compte également les conséquences respiratoires des apnées.

D'autres utilisent des signaux issus de la polysomnographie, tels que l'électroencéphalogramme (EEG) ou le flux oro-nasal, afin d'améliorer les performances diagnostiques.

L'utilisation de plusieurs signaux physiologiques semble ainsi offrir une meilleure représentation des mécanismes physiopathologiques du SAOS et permet d'améliorer les performances des modèles de deep learning.

### III.2) Modèles du deep learning

Parmi les dix études présentées dans ce mémoire:

- 7 études utilisent un CNN (seul ou combiné).
- 2 études utilisent un CNN-LSTM.
- 1 étude compare plusieurs architectures (DNN, CNN, RNN, LSTM, GRU).
- 2 études intègrent une approche d'IA explicable (XAI).

L'utilisation des CNN connaît une croissance rapide grâce à leur capacité à identifier automatiquement des motifs locaux distincts au sein d'un signal brut, sans nécessité d'extraction manuelle préalable de paramètres. Ils sont ainsi particulièrement bien adaptés pour reconnaître les signatures spécifiques de l'apnée, telles que les modifications transitoires du rythme cardiaque, les désaturations en oxygène ou les variations du flux respiratoire.

Par ailleurs, les *Long Short-Term Memory (LSTM)*, sous-catégorie des réseaux récurrents, apportent une dimension temporelle essentielle en permettant au modèle de prendre en compte la séquence chronologique des événements physiologiques.

Cette capacité de "mémoire" leur donne un avantage significatif pour analyser l'évolution d'un épisode d'apnée, depuis l'interruption respiratoire jusqu'à la reprise ventilatoire, en intégrant aussi les phases de récupération.

### III.3) Performances des modèles diagnostiques

Dans l'ensemble, les modèles de deep learning présentent des performances diagnostiques élevées pour le dépistage du SAOS. La plupart des études rapportent des sensibilités supérieures à 90 % et des spécificités comprises entre 85 et 99 %, bien que ces résultats varient selon la population étudiée, les signaux physiologiques utilisés et les seuils diagnostiques retenus (sauf Covassin et Al. avec 77% de sensibilité et 68% de spécificité).

Les meilleures performances sont généralement obtenues lorsque plusieurs signaux physiologiques sont combinés, notamment l'ECG et la saturation en oxygène. (Kilic. Et al., Garcia-Vicente et al.). Les approches multimodales permettent en effet de mieux prendre en compte les différentes conséquences physiologiques des épisodes d'apnée.

À l'inverse, les modèles utilisant un seul signal, bien qu'ils restent performants, présentent parfois une légère diminution de leur précision diagnostique (par exemple, l'étude Covassin et al.)

Ces résultats ont des taux élevés de précision, de sensibilité et de spécificité, notamment lors de l'analyse de signaux ECG et SpO<sub>2</sub>, plaçant aujourd'hui le deep learning au cœur des perspectives d'amélioration du dépistage non invasif et automatisé du SAHOS, constituant une stratégie prometteuse de dépistage du SAOS.

### III.4) Résultats

L'étude de Garcia-Vicente et al. nous montre que l'ECG aide à dépister les sujets sains ou avec un SAOS léger tandis que la SpO<sub>2</sub> est plus performante pour les SAOS modérés à sévères.

L'étude de Zarei et al. nous montre que l'association LSTM-CNN améliore significativement les performances diagnostiques par rapport aux méthodes traditionnelles.

L'étude de Li et al. aborde le sujet grâce à l'EEG et le flux respiratoire en nous montrant ainsi une alternative à la polysomnographie.

L'étude de Erdenebayar et al. utilise six modèles de deep Learning et montre leur performance comparé aux études publiées précédemment. (Notamment avec les CNN 1D et les GRU)

L'étude de Covassin et al. montre qu'un ECG standard à 12 dérivations, largement utilisé en pratique clinique, peut constituer une solution simple et peu coûteuse pour le dépistage du SAOS lorsqu'il est associé à un algorithme de machine learning.

L'étude de Salari et al. souligne que les caractéristiques issues de l'analyse de la densité spectrale de puissance (PSD) sont particulièrement pertinentes pour la détection de la pathologie. Parmi les algorithmes évalués, les machines à vecteurs de support (SVM) et les réseaux de neurones obtiennent les meilleures performances.

L'étude de Mostafa et al. montre que les méthodes de deep learning offrent de très bonnes performances pour la détection du SAOS, avec les CNN comme modèles les plus fréquemment utilisées. L'ECG est le signal le plus étudié, mais la SpO<sub>2</sub> et la combinaison de plusieurs signaux peuvent également améliorer les performances diagnostiques.

L'étude de Gupta et al. a permis d'intégrer la méthode LIME, qui permet d'expliquer les décisions de l'algorithme et de renforcer la confiance des cliniciens.

L'étude de Kilic et al. souligne que le machine learning et le deep learning associés avec l'ECG constituent des approches prometteuses pour le dépistage du SAOS.

L'étude de Setiawan et Lin propose un nouvel algorithme de deep learning combinant la décomposition EMD des signaux ECG avec des CNN 1D et 2D pour distinguer les épisodes d'apnée des périodes de respiration normale. Les résultats montrent une très bonne précision, supérieure à celle des approches de référence existantes.

#### IV. Discussion

##### IV.1) Avantages

Tout d'abord, les performances diagnostiques de l'ensemble des 10 études restent élevées (par exemple: 94% de sensibilité et 98% de spécificité pour l'étude Zarei et al., 83% de sensibilité et 87% de spécificité pour l'étude Li et al.).

Ces résultats ont été établis à partir de signaux simples tels que l'ECG ou la SpO2.

Par ailleurs, le deep learning est capable d'apprendre directement à partir des signaux bruts. Il n'est donc pas nécessaire de sélectionner au préalable les caractéristiques à analyser, ce qui permet de simplifier le traitement des données.

Un autre avantage est la possibilité de réduire le nombre de capteurs.

Les études de Zarei et al., de Erdenebay ar et al, de Salari et al. ou encore de Kilic et al. montrent qu'avec seulement un ECG, les performances diagnostiques restent très satisfaisantes.

Cette approche pourrait ainsi limiter le coût, la contrainte et améliorer l'accessibilité comparativement à la polysomnographie.

Ces outils de deep learning offrent des perspectives intéressantes pour le dépistage du SAOS.

##### IV.2) Limites

Concernant les limites directes exposées au cours des études, était évoquée une méconnaissance de la validité externe avec des populations limitées en nombre (l'étude Setiawan & Lin, 2022 menée sur seulement 33 sujets).

Les modèles sont parfois difficilement interprétables et compréhensibles pour l'homme donc moins reproductibles en pratique clinique, ce qui nécessitent des protocoles de validation plus rigoureux et des travaux supplémentaires garantissant l'indépendance des sujets entre les ensembles d'apprentissage et de tests.

Ceci afin d'améliorer la généralisabilité des modèles et de favoriser leur utilisation en pratique clinique (étude de Mostafa)

Pour finir un besoin de diversification des populations et des sujets semble évident ,en cause, l'ipséité de chaque patient qui rend impossible la réalisation d'un unique algorithme pour tous (étude de Kilic)

D'un point de vue plus général:

Sur le plan technologique, l'implémentation de l'intelligence artificielle en santé se heurte encore à plusieurs limites majeures. Tout d'abord, la fiabilité des algorithmes reste étroitement dépendante de la qualité et de la diversité des données utilisées pour leur entraînement ; or, dans la pratique clinique, les données sont souvent hétérogènes, incomplètes ou biaisées, ce qui peut compromettre la robustesse des résultats.

En parallèle, le recours aux modèles d'apprentissage profond (deep learning), bien que performant pour traiter de vastes ensembles de données complexes, pose un problème d'opacité décisionnelle connu sous le nom de « boîte noire ». Comme l'IA peut saisir un nombre de données très largement supérieur à l'intelligence humaine, elle pourrait en inférer des règles plus complexes que ne pourrait saisir l'entendement humain. Les médecins se retrouveraient forcés à suivre les recommandations d'une machine en devant se fier à un raisonnement qu'ils ne comprendraient pas, ce qui va à l'encontre du désir acteur et décideur. Cette absence de transparence constitue un frein à la confiance et à l'acceptabilité de l'IA, notamment pour des décisions cliniques engageant la responsabilité du praticien.

Enfin, ces systèmes nécessitent une mise à jour continue et un recalibrage régulier afin de rester performants face à l'évolution des données et des pratiques médicales, faute de quoi leur précision peut se détériorer avec le temps (concept de data drift). Ces limites rappellent que, malgré leur potentiel, les outils d'IA doivent être considérés comme un soutien décisionnel et non comme un substitut à l'expertise humaine et au raisonnement clinique.

Sur le plan juridique et éthique, bien que l'intelligence artificielle représente un levier prometteur dans le domaine de la santé en générale, son déploiement en pratique clinique pose encore de nombreuses questions éthiques et réglementaires. Sur le plan juridique, le statut de dispositif médical impose des obligations strictes de marquage CE et de démonstration de performance clinique selon le règlement européen (MDR), mais de nombreux outils connectés, notamment les applications et capteurs grand public, demeurent encore dans une zone grise réglementaire lorsqu'ils ne disposent pas de cette certification formelle.

L'IA appliquée aux données de santé implique la collecte massive de données personnelles sensibles, soumise aux exigences strictes du RGPD en Europe. Or, les patients doivent être informés, de manière compréhensible, de l'usage qui sera fait de leurs données, de la manière dont elles seront stockées, traitées et partagées. Le respect du consentement éclairé est donc une condition éthique fondamentale.

De plus, la question de l'anonymisation réelle reste délicate : certaines techniques de croisement de données ou de ré-identification peuvent mettre en péril la confidentialité, même lorsque les informations semblent pseudonymisées.

La question de la responsabilité médico-légale en cas d'erreur persiste : en cas de dommage ou de diagnostic erroné basé sur une recommandation algorithmique, il est encore difficile de déterminer précisément qui du développeur, du fournisseur de l'algorithme ou du praticien est juridiquement responsable, ce qui peut freiner l'adoption de ces technologies. Ces incertitudes rappellent que l'IA doit rester un outil d'aide encadré, sans jamais se substituer au jugement clinique du professionnel de santé.

Enfin, sur le plan éthique, la généralisation d'outils automatiques ne doit pas conduire à une déshumanisation de la relation soignant-patient. Le patient doit rester au centre de la décision, et le professionnel de santé conserver la maîtrise critique et la capacité de remettre en cause les suggestions de l'IA. L'exigence de transparence (Explainable AI) devient ainsi un levier essentiel pour maintenir la confiance.

## V. Conclusion

Bien que le SAOS soit très prévalent et qu'il entraîne des complications métaboliques, cardiovasculaires, neurocognitives et respiratoires, cette pathologie reste encore largement sous-diagnostiquée.

Le gold standard reste encore aujourd'hui la polysomnographie malgré son coût et son manque d'accessibilité.

Dans ce contexte, l'essor de l'intelligence artificielle et des technologies, notamment du deep Learning constitue une véritable perspective pour le dépistage du SAOS.

Néanmoins, cela implique de nombreux défis: enjeux éthiques, juridiques, responsabilité médico-légale, déshumanisation...

Ainsi, ces technologies doivent demeurer un complément à la pratique clinique, où le patient reste au centre du colloque singulier médecin-patient, avec un cadre juridique et éthique.

## Bibliographie:

<https://openclassrooms.com/fr/courses/6417031-objectif-ia-initiez-vous-a-l-intelligence-artificielle/6823506-apprenez-le-deep-learning-ou-l-apprentissage-profond>

<https://www.cnil.fr/fr/definition/apprentissage-profond-deep-learning#:~:text=L'apprentissage profond est un,données afin d'être entraînés.>

<https://www.oracle.com/fr/artificial-intelligence/machine-learning/what-is-machine-learning/>

<https://www.databricks.com/fr/blog/what-is-convolutional-layer>

[https://www.has-sante.fr/jcms/c\\_1761818/fr/evaluation-clinique-et-economique-des-dispositifs-medicaux-et-prestations-associees-pour-prise-en-charge-du-syndrome-d-apnees-hypopnees-obstructives-du-sommeil-sahos](https://www.has-sante.fr/jcms/c_1761818/fr/evaluation-clinique-et-economique-des-dispositifs-medicaux-et-prestations-associees-pour-prise-en-charge-du-syndrome-d-apnees-hypopnees-obstructives-du-sommeil-sahos)

<https://www.ameli.fr/assure/sante/themes/apnee-du-sommeil/comprendre-apnee-sommeil>

## Les 10 articles utilisés:

1. García-Vicente C, Gutiérrez-Tobal GC, Vaquerizo-Villar F, et al. Combined explainable deep learning model to predict pediatric sleep apnea from ECG and SpO<sub>2</sub>.
2. Zarei M, Asl BM. Detection of sleep apnea using deep neural networks and single-lead ECG signals. Biomedical Signal Processing and Control. 2022;72:103352.
3. Li X, et al. Automatic sleep apnea classification using EEG and oro-nasal airflow based on self-attention deep learning. Biomedical Signal Processing and Control. 2023.
4. Erdenebayar U, Kim YJ, Park JU, Joo EY, Lee KJ. Automatic sleep apnea detection using deep learning: A review. Physiological Measurement. 2019;40(7):07TR01.
5. Covassin N, et al. Deep learning-based detection of obstructive sleep apnea using standard 12-lead electrocardiography. Sleep Medicine. 2025.
6. Salari N, et al. Machine learning and deep learning for sleep apnea detection: A systematic review. Sleep Medicine Reviews. 2022.
7. Mostafa SS, Mendonça F, Ravelo-García AG, Morgado-Dias F. A systematic review of detecting sleep apnea using deep learning. Sensors (Basel). 2019
8. Gupta J, Seeja KR. An explainable AI approach towards automatic sleep apnea detection based on ECG signal. Procedia Computer Science. 2025
9. Kilic ME, Arayici ME, Turan OE, Yilancioglu YR, Ozcan EE, Yilmaz MB. Diagnostic accuracy of machine learning algorithms in electrocardiogram-based sleep apnea detection: A systematic review and meta-analysis. Sleep Medicine Reviews. 2025

10. Setiawan F, Lin CW. A deep learning framework for automatic sleep apnea classification based on empirical mode decomposition derived from single-lead electrocardiogram. Life (Basel). 2022