



Revisión

Innovación en sueño

Laura Vigil*, Toni Zapata, Andrea Grau, Marta Bonet, Montserrat Montaña y María Piñar

Unidad Multidisciplinar del Sueño, Servicio de Neumología, Parc Taulí Hospital Universitari, Institut d'Investigació i Innovació Parc Taulí (I3PT-CERCA), Universitat Autònoma de Barcelona, Sabadell, Barcelona, España

INFORMACIÓN DEL ARTÍCULO

Historia del artículo:

Recibido el 27 de septiembre de 2024

Aceptado el 8 de enero de 2025

On-line el 18 enero 2025

Palabras clave:

Inteligencia artificial

Aprendizaje automático

Apnea obstructiva del sueño

R E S U M E N

Los avances en la medicina del sueño han impulsado mejoras significativas en el diagnóstico y tratamiento de trastornos del sueño como la apnea obstructiva del sueño (AOS). Este trastorno afecta a mil millones de personas en todo el mundo, y tradicionalmente el diagnóstico se basa en la polisomnografía (PSG), un método laborioso que requiere personal especializado. Sin embargo, la integración de la inteligencia artificial (IA) en la medicina del sueño ha permitido automatizar el análisis de las fases del sueño y de los eventos respiratorios con alta precisión.

Los algoritmos de aprendizaje automático y las redes neuronales han demostrado ser efectivos en la codificación automática del sueño, con tasas de acierto comparables a las de los expertos humanos. Estos avances permiten mejorar la eficacia de los laboratorios del sueño y personalizar el tratamiento de la AOS. Además, técnicas como el análisis de clústeres se utilizan para identificar patrones sintomáticos y fenotipos, lo que mejora la comprensión de la fisiopatología de la AOS y optimiza el tratamiento con CPAP.

Sin embargo, la implementación de la IA en los hospitales se enfrenta a barreras tecnológicas, éticas y legales. Los desafíos incluyen la calidad de los datos, la privacidad del paciente y la necesidad de personal especializado. A pesar de estos obstáculos, la IA y el Big Data tienen el potencial de transformar la atención médica de los trastornos del sueño, mejorando tanto el diagnóstico como la adherencia al tratamiento, siempre que se superen las barreras regulatorias y culturales.

© 2025 Publicado por Elsevier España, S.L.U. en nombre de Sociedad Española de Neumología y Cirugía Torácica (SEPAR). Este es un artículo Open Access bajo la licencia CC BY-NC-ND (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

Sleep Innovation

A B S T R A C T

Advances in sleep medicine have driven significant improvements in the diagnosis and treatment of sleep disorders such as obstructive sleep apnea (OSA). This disorder affects one billion people worldwide and traditionally, diagnosis is based on polysomnography (PSG), a laborious method that requires specialized personnel. However, the integration of artificial intelligence (AI) in sleep medicine has made it possible to automate the analysis of sleep phases and respiratory events with high accuracy.

Machine learning algorithms and neural networks have proven to be effective in automatic sleep coding, with hit rates comparable to those of human experts. These advances make it possible to improve the efficiency of sleep labs and to personalize OSA treatment. In addition, techniques such as cluster analysis are used to identify symptomatic patterns and phenotypes, which improves understanding of OSA pathophysiology and optimizes CPAP treatment.

However, implementation of AI in hospitals faces technological, ethical, and legal barriers. Challenges include data quality, patient privacy, and the need for specialized personnel. Despite these obstacles, AI and Big Data have the potential to transform medical care for sleep disorders, improving both diagnosis and treatment adherence, provided regulatory and cultural barriers are overcome.

© 2025 Published by Elsevier España, S.L.U. on behalf of Sociedad Española de Neumología y Cirugía Torácica (SEPAR). This is an open access article under the CC BY-NC-ND license (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

Keywords:

Artificial intelligence

Machine learning

Sleep apnea

* Autor para correspondencia.

Correo electrónico: lvigil@tauli.cat (L. Vigil).

✉ @laura7270930915 (L. Vigil)

Avances en sueño

La innovación se define como el proceso de aportar nuevas ideas, métodos, productos, servicios o soluciones que tengan un impacto positivo y un valor significativo. Cuando aplicamos este concepto a la innovación sanitaria, el proceso se realiza con el objetivo de mejorar la prestación de asistencia sanitaria, los resultados para los pacientes y la eficiencia general dentro del sector sanitario.

Aproximadamente mil millones de personas en todo el mundo padecen apnea obstructiva del sueño (AOS), una enfermedad caracterizada por hipoxia intermitente debida a la obstrucción de las vías respiratorias superiores durante el sueño; de ellas, 400 millones presentan una AOS moderada-grave¹.

En la medicina del sueño, desde sus inicios se han buscado métodos que nos permitan encontrar un sistema automatizado de análisis del sueño, ya que el *gold standard* en el diagnóstico continúa siendo la polisomnografía (PSG), una prueba laboriosa que requiere personal especializado para su realización e interpretación y no está al alcance de todos los centros².

El papel de las técnicas de inteligencia artificial (IA) se ha estudiado en distintos aspectos de la medicina, como el diagnóstico, la estratificación del riesgo, la respuesta al tratamiento y la gestión personalizada³. Es por ello que centraremos nuestra revisión en cómo la IA nos puede ayudar en el diagnóstico y el seguimiento de nuestros pacientes con AOS sin olvidar las barreras de las que disponemos en la actualidad para su plena implementación en los hospitales de nuestro territorio.

Diagnóstico

La rápida expansión de la IA en el sueño queda patente en la búsqueda en Pubmed de «Artificial Intelligence» y «polysomnogram», que muestra más de 644 artículos, 390 de ellos (60,5%) publicados en los últimos 5 años.

Como ya se ha comentado previamente, el diagnóstico mediante PSG requiere de un análisis manual exhaustivo para su codificación, por lo que se han desarrollado sistemas basados en la IA para el análisis automático con bastante precisión⁴. En la actualidad se utiliza para la estadificación del sueño, la codificación de eventos respiratorios, la caracterización del insomnio, la predicción del ritmo circadiano a partir de la expresión génica y el fenotipado de la AOS⁵. De hecho, la *Food and Drug Administration* (FDA) ha aprobado varios softwares de codificación automática en los últimos años, como Somnolyzer® (Philips Respironics, Murrysville, PA, EE.UU.) o Noxturnal Software System® (Nox Medical Global, Reykjavik, Islandia).

La mayoría de los dispositivos simplificados que están disponibles en el mercado integran la IA para codificación automática mediante técnicas de aprendizaje automático o *Machine Learning* (ML). El ML es una disciplina dentro de la IA que proporciona a las computadoras la capacidad de aprender mediante el uso de datos, sin ser programadas de un modo explícito. La manera de aprender de las máquinas va a estar estructurada de tres formas distintas: aprendizaje supervisado (para problemas de clasificación y regresión), no supervisado (*clustering*) y por refuerzo. Los métodos de ML con aprendizaje supervisado van a requerir que los datos estén etiquetados para entrenar los modelos de predicción.

En general, muchas de las publicaciones sobre la clasificación del sueño mediante IA han utilizado redes neuronales convolucionales (*convolutional neural networks* [CNN]) o recurrentes, o una combinación de ambas⁶.

Las redes neuronales son un tipo de ML que intenta imitar el comportamiento de las neuronas en el cerebro. La ventaja principal de las redes neuronales es que aprenden solas y no se ven influenciadas por el conocimiento humano, pero, por el contrario,

necesitan elevadas cantidades de datos para su entrenamiento. En este sentido, las CNN han aumentado su popularidad en los últimos años debido a que requieren un mínimo preprocesado y se adaptan bien a datos de series temporales, como las señales de la PSG⁷.

Uno de los primeros estudios en utilizar redes neuronales fue descrito por Schaltenbrand et al.⁸ en 1996. En este estudio, la puntuación automática de 61.949 épocas correspondientes a 60 sujetos, mediante un modelo de red neuronal, mostró un nivel de acuerdo comparable al de los expertos humanos, con un 82,3% de concordancia entre el modelo y los expertos, y un 87,5% de concordancia entre los propios expertos. Esta precisión mejoró hasta el 90% cuando se introdujo la supervisión de expertos para las épocas desconocidas o ambiguas.

En los últimos años, las redes neuronales se han usado en la codificación de la estadificación del sueño en pacientes con AOS, epilepsia, respiración de Cheyne-Stokes o en la enfermedad de Parkinson^{9,10}. Algunos de los estudios se han centrado en el análisis de los husos de sueño y el análisis espectral de las fases del sueño para su estadificación y otros se han enfocado en la integración de eventos cardiorrespiratorios para diagnosticar trastornos respiratorios asociados al sueño o en la señal del ronquido^{11,12}.

En la [tabla 1](#) se exponen los estudios más recientes en los que se han usado algoritmos de ML para la codificación de las fases del sueño y de la parte respiratoria.

Actualmente hay una clara evidencia de que el índice de apneas no refleja todas las características de la AOS, ni su etiología (endotipo) ni sus características clínicas (fenotipo)²⁵. Los hallazgos más característicos de la PSG, junto con los datos clínicos, se han utilizado para estimar la colapsabilidad de la vía aérea superior y el umbral de despertar usando modelos asistidos mediante IA²⁶. La determinación del endotipo de la AOS mediante PSG se considera cada vez más importante en nuestro campo, y existe un interés creciente por hacer que los algoritmos de determinación del endotipo de la AOS sean accesibles, baratos y, en última instancia, escalables^{27,28}.

En este sentido, los métodos de aprendizaje no supervisado, como el análisis de clústeres, se centran en descubrir patrones emergentes dentro de los datos, agrupando a los sujetos en categorías homogéneas en base a asociaciones únicas entre las características de los sujetos. Esto se consigue evaluando la similitud (o disimilitud) entre los sujetos mediante métricas como la correlación o la distancia, basadas en los rasgos utilizados para caracterizar a cada individuo. Lo ideal es que los miembros de cada clúster sean lo más parecidos posible entre sí y lo más diferentes posible de los de otros clústeres.

Debido a la heterogeneidad de la AOS, el análisis de clústeres se ha aplicado a la sintomatología de los pacientes, características de la PSG o respuesta al tratamiento con presión continua positiva sobre la vía aérea (CPAP)²⁹. Un resumen de los principales estudios se puede consultar en la [tabla 2](#).

El primer estudio en ese sentido fue realizado por Ye et al.³⁴, quienes en la Cohorte Islandesa de Apnea del Sueño de 822 pacientes (predominantemente hombres) identificaron tres grupos de pacientes, lo que confirmó que la somnolencia abarcaba solo una parte del espectro sintomático de la AOS. El grupo «Excesivamente somnoliento» (prevalencia del 42%), con puntuaciones más altas en la escala de somnolencia de Epworth, dormirse de manera involuntaria y conducir con somnolencia, coincidía con el grupo «AOS clásica» y comprendía a los pacientes más jóvenes. Otros grupos se etiquetaron como «Sueño alterado» (33%), caracterizado predominantemente por síntomas relacionados con el insomnio, sueño agitado y despertares con ahogo (*choking*), y «Mínimamente sintomático» (25%), compuesto por los pacientes de más edad y los más reparados al despertar, con ronquidos molestos para el cónyuge y episodios de apnea nocturna como síntomas más frecuentes.

Tabla 1
Principales características y resultados de los estudios más recientes que han utilizado técnicas de ML en el diagnóstico de la AOS

Estudio	Año	Características	Algoritmo ML	Precisión
Mosquera-López et al. ¹³	2019	Sensores de presión en la cama	AD y regresión lineal	0,743
Wang et al. ¹⁴	2019	Intervalo RR de ECG de una derivación	LeNet-5, MLP-NN, KNN, RL, SVM	0,941
Chang et al. ¹⁵	2020	Saturación, ECG y acelerómetro torácico	LSTM-NN	0,893
Ma et al. ¹⁶	2020	Saturación arterial oxígeno	SVM	0,941
Chang et al. ¹⁷	2020	ECG de una derivación	Deep CNN	0,847
Álvarez et al. ¹⁸	2020	Análisis de oximetría, registros de flujo	Regresión, SVM	0,958
Hajipour et al. ¹⁹	2020	Sonidos respiratorios traqueales diurnos	RF	0,793
Li et al. ²⁰	2020	Múltiples bioseñales	SVM con Linear kernel	0,952
Mashrur et al. ²¹	2021	ECG de una derivación	CNN	0,944
Bricout et al. ²²	2021	PSG	Boosted tree	0,89
Kuan et al. ²³	2022	Edad, sexo e índice de masa corporal	RL y Redes neuronales	0,763 y 0,764
Park P et al. ²⁴	2023	Variabilidad de la frecuencia cardíaca, edad, sexo e índice de masa corporal	RL, RF, SVM y TW-MLP	0,72

AD: árboles de decisión; CNN: convolutional neural network; KNN: *K-nearest neighbor*; LR: regresión logística; LSTM-NN: *long short-term memory-Neural Network*; MLP-NN: *multilayer perceptron neural network*; RF: *Random Forest*; SVM: *Support Vector Machine*; TW-MLP: *Time window-Multilayer perceptron*.

Tabla 2
Principales características y resultados de los estudios más recientes que han utilizado técnicas de aprendizaje no supervisado en la caracterización de la AOS

Estudio/año	Rasgo fenotípico	Clústeres	Algoritmo ML
Nakayama et al. ³⁰ , 2019	PSG, duración media de los eventos, saturación de oxígeno mínima, ratio de despertares e IAH	1. AOS hipersevero, hipoxémico, obeso 2. AOS severo, no hipoxémico, duración prolongada de los eventos, no obeso 3. AOS severo, duración corta evento, sobrepeso, apnea central	Clúster jerárquico y <i>K-means</i>
Mazzoti et al. ³¹ , 2019	Síntomas, Epworth	1. Sueño alterado, síntomas insomnio 2. Mínimo sintomático 3. Excesiva somnolencia: sueño al conducir 4. Moderada somnolencia: roncador, siesta	<i>Latent Class Analysis</i>
Jaffuel et al. ³² , 2020	Edad, sexo, índice de masa corporal, poligrafía respiratoria o PSG, IAH obstructivo, IAH central, uso previo de CPAP, tratamiento con servoventilación, cardiopatía y reducción fracción eyección ventrículo izquierdo	1. Cluster 1: hombres, tratamiento previo con CPAP, cardiopatía, obesidad 2. Cluster 2: hombres, no tratamiento previo con CPAP, sobrepeso, predominio apnea central, cardiopatía 3. Cluster 3: hombres, obesidad, jóvenes, predominio apnea central 4. Cluster 4: mujeres, tratamiento previo con CPAP, obesidad, edad avanzada 5. Cluster 5: hombres, predominio apnea obstructiva, fracción eyección reducida, cardiopatía y edad < 70 años	<i>K-means</i>
Chen et al. ³³ , 2023	TAC vía aérea superior, PSG, IAH	1. IAH alterado 2. IAH no empeorado	Clúster automático (<i>Schwarz's Bayesian</i>)

Otros autores, como Mazzotti et al.³¹ y Kim et al.³⁵, detectaron grupos similares en poblaciones con AOS, con diferencias en la prevalencia que probablemente reflejen una mayor frecuencia de pacientes menos sintomáticos en estas muestras. Es importante incluir a este tipo de pacientes en los estudios, ya que los poco sintomáticos tardan más en diagnosticarse. Los síntomas en estos grupos no coinciden con el índice de apnea-hipopnea (IAH), y el Epworth solo captura una parte del espectro de los fenotipos. Además, según Mazzotti et al.³¹, es importante tener en cuenta las diferentes consecuencias cardiovasculares en función del clúster al que se pertenece.

Tratamiento

El tratamiento eficaz de la AOS es un objetivo crucial debido a su impacto en la calidad de vida y a las conocidas consecuencias cardiovasculares y neurocognitivas de la enfermedad. Dentro del abanico de posibles tratamientos de la AOS se encuentra la CPAP, que constituye un tratamiento eficaz para reducir la gravedad de la AOS, y continúa siendo el tratamiento de elección en muchos de estos pacientes³⁶. Con el fin de alcanzar los objetivos del tratamiento es fundamental el ajuste adecuado de la presión y el control del cumplimiento del tratamiento con CPAP, ya que su efectividad va a depender de la correcta adhesión al mismo².

En general, el no cumplimiento del tratamiento con CPAP es elevado (29%-83%) en los pacientes con AOS³⁷. La IA puede mejorar la tasa de éxito global del tratamiento de la AOS mediante la elección del tratamiento más eficaz para cada paciente³⁸ mediante algoritmos de ML que permiten el análisis de características genéticas de los pacientes con AOS³⁹ o el uso de biomarcadores relacionados con la gravedad de la enfermedad⁴⁰. La IA puede ayudar a predecir el cumplimiento del tratamiento con CPAP en pacientes con AOS y alertar a los médicos para que realicen intervenciones tempranas utilizando técnicas de ML con sistemas de monitorización inteligente⁴¹. Un estudio analizó las tendencias de adhesión a la CPAP durante 20 años y descubrió que la tasa de no adhesión se situaba en torno al 34%⁴², pero esta revisión data del 2016, donde la telemonitorización no estaba tan disponible como en la actualidad, ya que su implantación ha supuesto un cambio en el manejo de los pacientes con AOS, como veremos más adelante, mediante técnicas de análisis de los datos con Big Data. Babbín et al.⁴³ emplearon datos longitudinales de uso de CPAP para identificar patrones de adherencia mediante el análisis de series temporales individuales combinado con el *clustering*. Entre 161 pacientes con IAH ≥ 5 tratados con CPAP en un ensayo clínico, los investigadores identificaron cuatro subgrupos de adhesión: «Grandes usuarios», «Buenos usuarios», «Usuarios bajos» y «Declinadores lentos».

Si tenemos en cuenta un análisis no supervisado en relación con el tratamiento con CPAP, Gagnadoux et al.⁴⁴ describieron cinco grupos, que incluían una «AOS femenina» caracterizada por el insomnio, una «AOS leve sintomática» con poca somnolencia, pero con síntomas nocturnos y de insomnio, y una «AOS comórbida» formada por pacientes de edad avanzada. Estos tres grupos presentaron tasas significativamente más bajas de éxito de la CPAP (OR: 0,36-0,66) que los pacientes del grupo de «AOS grave», más jóvenes y con mayor somnolencia (Epworth > 10).

En nuestro país, en una población de 72.217 pacientes tratados con CPAP, utilizando 30 diagnósticos de una base de datos administrativa, Turino et al.⁴⁵ identificaron seis clústeres de comorbilidad. Se detectó un subgrupo de pacientes con asma, predominantemente femenino, que presentaban tasas de hospitalización más elevadas que los grupos con comorbilidades mínimas o musculoesqueléticas. Además, un grupo con cáncer y otro con enfermedades cardiovasculares (por ejemplo, insuficiencia cardíaca, ictus), ambos de mayor edad y con asociaciones previamente descritas con la hipoxemia en la AOS⁴⁶, presentaban las tasas más elevadas de mortalidad y de uso de recursos sanitarios.

Otras aplicaciones de la IA en el sueño

Un uso importante de la IA más allá del diagnóstico y del tratamiento de trastornos del sueño es su aplicación en la salud de la población, haciendo hincapié en la relación entre el sueño alterado y la morbilidad. De ahí que se hayan desarrollado aplicaciones basadas en la IA en el campo de la hipersomnia diurna asociada a narcolepsia, insomnio, trastornos del ritmo circadiano, trastornos de conducta del sueño o trastornos del movimiento durante el sueño⁴⁷.

La IA también confiere la capacidad de realizar investigaciones escalables, como ponen de manifiesto los más de 11 millones de noches de actividad de los dispositivos portátiles (relojes inteligentes como el Sony SmartBand (el SmartBand Talk [SWR30] y el SmartBand 2 [SWR12]) que caracterizan la duración del sueño y los datos de sincronización por edad y sexo⁴⁸. Recientemente la FDA también ha aprobado los relojes Samsung Galaxy y el Apple Watch Series 10 para el cribado de la apnea del sueño. Otro *wearable* disponible para el diagnóstico es AcuPebble SA100, que ha demostrado su validez para el diagnóstico de AOS frente a la poligrafía respiratoria⁴⁹.

Los algoritmos de IA por sí solos no permitirán definir por completo el papel del sueño en la salud y la enfermedad, por lo que es probable que se requiera un enfoque combinado de análisis avanzados, sensores innovadores y mediciones del sueño tanto dentro como fuera del laboratorio.

El proyecto *Sleep and Obstructive Sleep Apnoea Monitoring with Non-Invasive Applications* (SOMNIA) contribuye a este objetivo, ya que, además de registrar las señales habituales, se registran simultáneamente sensores que no se suelen monitorizar como parte de la PSG, como la monitorización de la presión supraesternal, la electromiografía multielectrodo del diafragma, la acelerometría y la fotopletismografía óptica llevadas en la muñeca y los sensores integrados en el colchón. Por lo tanto, además de proporcionar una fuente de datos que puede ser analizada con algoritmos de aprendizaje automático para proporcionar nuevos conocimientos a partir de los datos típicamente registrados en la PSG, los nuevos sensores pueden demostrar su utilidad, y algunos son incluso adaptables para uso ambulatorio⁴⁹.

Nos quedaría hacer un apunte sobre el Big Data y su relación con el sueño⁵⁰. Disponemos de un acúmulo de información que proviene de registros clínicos hospitalarios, de dispositivos *wearables* de los pacientes, así como de medidas objetivas del tratamiento con CPAP en pacientes que están telemonitorizados⁵¹. El Big Data se

describe habitualmente con las 5 V de Volumen, Velocidad, Variedad, Veracidad y Valor, en referencia a la cantidad masiva de datos, su velocidad de adquisición, la diversidad y heterogeneidad de las fuentes de datos, pero con incertidumbre en cuanto a la calidad de los datos y el potencial de valorización.

Un estudio real de adhesión a la CPAP a corto plazo de 2,6 millones de pacientes, utilizando técnicas de Big Data, informó que el 75% de los pacientes cumplían la definición de adhesión del Centro de Servicios de Medicare y Medicaid de Estados Unidos a los 3 meses, con una mediana de uso de CPAP de 5,1 horas por noche⁵².

Barreras para la implantación de la IA

Podemos dividir las barreras en tecnológicas, de los datos y sesgos, regulatorias, recursos humanos, educación y cultura⁵³.

- **Tecnológicas.** Aunque ya se ha comentado que las redes neurales son útiles en la medicina del sueño, no hay que olvidar el concepto caja negra de los algoritmos que se utilizan, ya que en muchas ocasiones no queda claro su método de aprendizaje. Tener que trabajar con enormes cantidades de datos implica acceso rápido a los datos, en diferentes formatos y con errores e imperfecciones, y todo en un entorno seguro exento de ataques de terceros, por lo que será importante trabajar con infraestructuras que nos prevengan de ciberataques.
- **Datos y sesgos.** Tener que trabajar y compartir datos médicos ha de generar la confianza en el entorno sanitario para ser capaz de superar la resistencia a unir fuerzas. En cuanto a los sesgos en nuestras bases de datos, la mayoría de los algoritmos han sido creados con elevadas prevalencias de AOS. Lo ideal para comprobar que los modelos funcionan sería probarlos con poblaciones con baja prevalencia de AOS.
- **Reto legal y ético.** Este es un reto relacionado con la protección de datos personales que requiere soluciones que garanticen la seguridad. Lo más importante es la privacidad del paciente, por lo que se ha propuesto utilizar datos abiertos anonimizados para evitar identificar de manera personal a los pacientes. En ese sentido, en Europa disponemos del Reglamento de IA de la Unión Europea⁵⁴, también conocido como Ley de Inteligencia Artificial, que fue aprobada en mayo de 2024. En Estados Unidos no existe actualmente una regulación federal específica para la IA comparable a la europea. Sin embargo, hay varias iniciativas en desarrollo y regulaciones en áreas relacionadas con el uso ético y seguro de la IA. En un futuro inmediato será muy importante trasladar el debate sobre la ética en IA a todos los implicados (pacientes, usuarios, administraciones...).
- **Recursos humanos.** Se necesita personal para desarrollar y mantener los sistemas de IA, así como personal experto que sea capaz de formar y educar a la población en estos temas⁵⁵.
- **Educación y cultura.** Se necesitaría implementar educación en IA en el currículo de las facultades de Medicina. La IA nos aboca a un cambio en nuestra cultura médica, en que la relación médico-paciente no puede verse sustituida por un algoritmo, que carece de compasión y de empatía⁵⁶.

Desafíos y líneas futuras

Uno de los mayores retos es crear grandes conjuntos de datos de entrenamiento con una calidad óptima, pero la limitación para ellos reside en el acceso a la información, que es imprescindible para que estos sistemas funcionen correctamente, así como la protección de nuestros datos de ciberataques de terceros.

Con múltiples empresas comerciales que desarrollan algoritmos aprobados por la FDA, existe la necesidad de estandarizar los algoritmos comerciales mediante la certificación por parte de

un organismo regulador acreditado y personal entrenado que sea capaz de valorar el algoritmo desde todas las perspectivas. Aunque la aprobación de la FDA garantiza la seguridad de uso de los algoritmos, no asegura su validez clínica. Un punto por destacar es la explicabilidad de los algoritmos, que deben ser entendibles y reproducibles, por lo que en la actualidad se trabaja en ese sentido en los modelos llamados de «caja blanca» que puedan ser comprendidos por todos los usuarios⁵⁷.

Existe una necesidad acuciante de ensayos de investigación a mayor escala que puedan corroborar las medidas generadas por algoritmos automáticos con resultados clínicamente significativos⁵⁸.

Es necesario integrar los datos obtenidos a través de la tecnología «ómica» (transcriptómica, proteómica, metabolómica) con los datos sanitarios y demográficos tradicionales y los datos derivados de la polisomnografía⁵⁹.

Además, dado que muchos programas requieren subir los datos del sueño a servidores externos, es necesario garantizar la seguridad de la información sanitaria protegida. Las cuestiones relativas a los sesgos y a las disparidades sanitarias requieren una evaluación continua para evitar desigualdades⁶⁰.

Conclusiones

La IA ha revolucionado el campo de la medicina del sueño, particularmente en el diagnóstico y el tratamiento de la AOS. La aplicación de técnicas como el ML y las redes neuronales ha permitido avances significativos en la automatización del análisis del sueño, reduciendo la dependencia de la intervención humana y mejorando la eficiencia diagnóstica.

Los estudios recientes demuestran que la telemonitorización y el análisis de grandes volúmenes de datos han mejorado la adhesión al tratamiento con CPAP. La IA, además, se ha utilizado con éxito para identificar patrones de adhesión y predecir qué pacientes pueden tener dificultades para seguir el tratamiento, lo que permite intervenciones tempranas para mejorar los resultados.

A pesar de los avances, persisten barreras significativas para la plena implementación de la IA en el campo del sueño. Estas incluyen retos tecnológicos, problemas de datos y sesgos, consideraciones legales y éticas, y la falta de personal capacitado. Además, la heterogeneidad de la AOS dificulta la creación de algoritmos completamente eficaces que puedan aplicarse de forma generalizada.

Para maximizar el potencial de la IA en el tratamiento de los trastornos del sueño será esencial integrar datos de diversas fuentes, junto con datos tradicionales de salud. Además, se requiere una mayor estandarización de los algoritmos utilizados para garantizar su validez clínica y su seguridad en la práctica real.

Financiación

La presente investigación no ha recibido ayudas específicas provenientes de agencias del sector público, sector comercial o entidades sin ánimo de lucro.

Contribuciones de los autores

Laura Vigil se ha encargado de la redacción del texto y ha realizado la preparación del manuscrito para su publicación.

Toni Zapata y Andrea Grau se han encargado de realización de las tablas del manuscrito.

Marta Bonet, Montserrat Montaña y María Piñar han realizado la búsqueda bibliográfica del manuscrito con la supervisión de Laura Vigil.

Todos los autores han leído la versión que se presenta y han dado su aprobación definitiva.

Conflictos de intereses

Los autores declaran no tener conflictos de intereses.

Bibliografía

- Benjafield AV, Ayas NT, Eastwood PR, Heinzer R, Ip MSM, Morrell MJ, et al. Estimation of the global prevalence and burden of obstructive sleep apnoea: A literature-based analysis. *Lancet Respir Med*. 2019;7:687–98. [http://dx.doi.org/10.1016/S2213-2600\(19\)30198-5](http://dx.doi.org/10.1016/S2213-2600(19)30198-5). PMID: 31300334.
- Mediano O, González Mangado N, Montserrat JM, Luz Alonso-Álvarez M, Almen-dros I, Alonso-Fernández A, et al. Documento internacional de consenso sobre apnea obstructiva del sueño. *Arch Bronconeumol*. 2022;58:52–68.
- Goldstein CA, Berry RB, Kent DT, Kristo DA, Seixas AA, Redline S, et al. Artificial intelligence in sleep medicine: An American Academy of Sleep Medicine position statement. *J Clin Sleep Med*. 2020;16:605–7.
- Bazoukis G, Bollepalli SC, Chung CT, Li X, Tse G, Bartley BL, et al. Application of artificial intelligence in the diagnosis of sleep apnea. *J Clin Sleep Med*. 2023;19:1337–63.
- De Chazal P, Sutherland K, Cistulli PA. Advanced polysomnographic analysis for OSA: A pathway to personalized management? *Respirology*. 2020;25:251–8. <http://dx.doi.org/10.1111/resp.13564>.
- Fiorillo L, Puiatti A, Papandrea M, Ratti P-L, Favaro P, Roth C, et al. Automated sleep scoring: A review of the latest approaches. *Sleep Med Rev*. 2019;48:101204. <http://dx.doi.org/10.1016/j.smrv.2019.07.007>.
- Bandyopadhyay A, Goldstein C. Clinical applications of artificial intelligence in sleep medicine: A sleep clinician's perspective. *Sleep Breath*. 2023;27:39–55. <http://dx.doi.org/10.1007/s11325-022-02592-4>.
- Schaltenbrand N, Lengelle R, Toussaint M, Luthringer R, Carelli G, Jacqmin A, et al. Sleep stage scoring using the neural network model: Comparison between visual and automatic analysis in normal subjects and patients. *Sleep*. 1996;19:26–35.
- El-Solh AA, Mador MJ, Ten-Brock E, Shucard DW, Abul-Khoudoud M, Grant BJ. Validity of neural network in sleep apnea. *Sleep*. 1999;22:105–11.
- Almazaydeh L, Elleithy K, Faezipour M. Obstructive sleep apnea detection using SVM-based classification of ECG signal features. *Annu Int Conf IEEE Eng Med Biol Soc*. 2012;2012:4938–41.
- Redmond SJ, Heneghan C. Cardiorespiratory-based sleep staging in subjects with obstructive sleep apnea. *IEEE Trans Biomed Eng*. 2006;53:485–96.
- Willemsen T, van Deun D, Verhaert V, Vandekerckhove M, Exadaktylos V, Verbraecken J, et al. An evaluation of cardiorespiratory and movement features with respect to sleep-stage classification. *IEEE J Biomed Health Inform*. 2014;18:661–9.
- Mosquera-Lopez C, Leitschuh J, Condon J, Hagen CC, Rajhbeharrysingh U, Hanks C, et al. Design and evaluation of a non-contact-bed-mounted sensing device for automated-in-home detection of obstructive sleep apnea: A pilot study. *Biosensors (Basel)*. 2019;9:90.
- Wang T, Lu C, Shen G, Hong F. Sleep apnea detection from a single-lead ECG signal with automatic feature-extraction through a modified LeNet-5 convolutional neural network. *PeerJ*. 2019;7:e7731. <http://dx.doi.org/10.7717/peerj.7731>.
- Chang HC, Wu HT, Huang PC, Ma HP, Lo YL, Huang YH. Portable sleep apnea syndrome screening and event detection using long short-term memory recurrent neural network. *Sensors (Basel)*. 2020;20:6067.
- Ma B, Wu Z, Li S, Huang Y, Kasukurthi M, Lin J, et al. Development of a support vector machine learning and smart phone Internet of Things-based architecture for real-time sleep apnea diagnosis. *BMC Med Inform Decis Mak*. 2020;20 Suppl 14:298.
- Chang HY, Yeh CY, Lee CT, Lin CC. A sleep apnea detection system based on a one-dimensional deep convolution neural network model using single-lead electrocardiogram. *Sensors (Basel)*. 2020;20:4157.
- Álvarez D, Cerezo-Hernández A, Crespo A, Gutiérrez-Tobal G, Vaquerizo-Villar F, Barroso-García V, et al. A machine learning-based test for adult sleep apnoea screening at home using oximetry and airflow. *Sci Rep*. 2020;10:5332.
- Hajipour F, Jozani MJ, Moussavi Z. A comparison of regularized logistic regression and random forest machine learning models for daytime diagnosis of obstructive sleep apnea. *Med Biol Eng Comput*. 2020;58:2517–29.
- Li X, Ling SH, Su S. A hybrid feature selection and extraction methods for sleep apnea detection using bio-signals. *Sensors (Basel)*. 2020;20:4323.
- Mashrur FR, Islam MS, Saha DK, Islam SMR, Moni MA. SCNN: scalogram-based convolutional neural network to detect obstructive sleep apnea using single-lead electrocardiogram signals. *Comput Biol Med*. 2021;134:104532.
- Bricout A, Fontcave-Jallon J, Pépin JL, Guméry PY. Accelerometry-derived respiratory index estimating apnea-hypopnea index for sleep apnea screening. *Comput Methods Programs Biomed*. 2021;207:106209. <http://dx.doi.org/10.1016/j.cmpb.2021.106209>.
- Kuan YC, Hong CT, Chen PC, Liu WT, Chung CC. Logistic regression and artificial neural network-based simple predicting models for obstructive sleep apnea by age, sex, and body mass index. *Math Biosci Eng*. 2022;19:11409–21. <http://dx.doi.org/10.3934/mbe.2022532>. PMID: 36124597.
- Park P, Kim JW. A classifying model of obstructive sleep apnea based on heart rate variability in a large Korean population. *J Korean Med Sci*. 2023;38:e49. <http://dx.doi.org/10.3346/jkms.2023.38.e49>. PMID: 36808544; PMCID: PMC9941018.

25. Edwards BA, Redline S, Sands SA, Owens RL. More than the sum of the respiratory events: Personalized medicine approaches for obstructive sleep apnea. *Am J Respir Crit Care Med*. 2019;200:691–703.
26. Dutta R, Delaney G, Toson B, Jordan AS, White DP, Wellman A, et al. A novel model to estimate key obstructive sleep apnea endotypes from standard polysomnography and clinical data and their contribution to obstructive sleep apnea severity. *Ann Am Thorac Soc*. 2021;18:656–67.
27. Ma E-Y, Kim J-W, Lee Y, Cho S-W, Kim H, Kim JK. Combined unsupervised-supervised machine learning for phenotyping complex diseases with its application to obstructive sleep apnea. *Sci Rep*. 2021;11:1–15.
28. Finnsson E, Ólafsdóttir GH, Loftsdóttir DL, Jónsson S, Helgadóttir H, Ágústsson JS, et al. A scalable method of determining physiological endotypes of sleep apnea from a polysomnographic sleep study. *Sleep*. 2021;44:zsaa168.
29. Zinchuk A, Yaggi HK. Phenotypic subtypes of OSA. A challenge and opportunity for precision medicine. *Chest*. 2020;157:403–20. <http://dx.doi.org/10.1016/j.chest.2019.09.002>.
30. Nakayama H, Kobayashi M, Tsuike S, Yanagihara M, Inoue Y. Obstructive sleep apnea phenotypes in men based on characteristics of respiratory events during polysomnography. *Sleep Breath*. 2019;23:1087–94. <http://dx.doi.org/10.1007/s11325-019-01785-8>.
31. Mazzotti DR, Keenan BT, Lim DC, Gottlieb DJ, Kim J, Pack AI. Symptom subtypes of obstructive sleep apnea predict incidence of cardiovascular outcomes. *Am J Respir Crit Care Med*. 2019;200:493–506.
32. Jaffuel D, Rabec C, Philippe C, Mallet JP, Georges M, Redolfi S, et al. Patterns of adaptive servo-ventilation settings in a real-life multicenter study: Pay attention to volume! Adaptive servo-ventilation settings in real-life conditions. *Respir Res*. 2020;21:243. <http://dx.doi.org/10.1186/s12931-020-01509-7>. PMID: 32957983; PMCID: PMC7507637.
33. Chen H, Emami E, Kauffmann C, Rompré P, Almeida F, Schmittbuhl M, et al. Airway phenotypes and nocturnal wearing of dentures in elders with sleep apnea. *J Dent Res*. 2023;102:263–9. <http://dx.doi.org/10.1177/00220345221133278>. PMID: 36333889.
34. Ye L, Pien GW, Ratcliffe SJ, Björnsdóttir E, Arnardóttir ES, Pack AI, et al. The different clinical faces of obstructive sleep apnoea: A cluster analysis. *Eur Respir J*. 2014;44:1600–7.
35. Kim J, Keenan BT, Lim DC, Lee SK, Pack AI, Shin C. Symptom based subgroups of Koreans with obstructive sleep apnea. *J Clin Sleep Med*. 2018;14:437–43. <http://dx.doi.org/10.1186/s40463-023-00621-0>. PMID: 36747273.
36. Weaver TE, Mancini C, Maislin G, Cater J, Staley B, Landis JR, et al. Continuous positive airway pressure treatment of sleepy patients with milder obstructive sleep apnea: Results of the CPAP Apnea Trial North American Program (CATNAP) randomized clinical trial. *Am J Respir Crit Care Med*. 2012;186:677–83.
37. Sawyer AM, Gooneratne NS, Marcus CL, Ofer D, Richards KC, Weaver TE. A systematic review of CPAP adherence across age groups: Clinical and empiric insights for developing CPAP adherence interventions. *Sleep Med Rev*. 2011;15:343–56. <http://dx.doi.org/10.1016/j.smrv.2011.01.003>. PMID: 21652236.
38. Brennan HL, Kirby SD. The role of artificial intelligence in the treatment of obstructive sleep apnea. *J Otolaryngol Head Neck Surg*. 2023;52:7. <http://dx.doi.org/10.1186/s40463-023-00621-0>. PMID: 36747273.
39. Zhu J, Sanford LD, Ren R, Zhang Y, Tang X. Multiple machine learning methods reveal key biomarkers of obstructive sleep apnea and continuous positive airway pressure treatment. *Front Genet*. 2022;13:927545. <http://dx.doi.org/10.3389/fgene.2022.927545>.
40. Cederberg KLJ, Hanif U, Peris Sempere V, Hédou J, Leary EB, Schneider LD, et al. Proteomic biomarkers of the apnea hypopnea index and obstructive sleep apnea: Insights into the pathophysiology of presence, severity, and treatment response. *Int J Mol Sci*. 2022;23:7983. <http://dx.doi.org/10.3390/ijms23147983>.
41. Scioscia G, Tondo P, Foschino Barbaro MP, Sabato R, Gallo C, Maci F, et al. Machine learning-based prediction of adherence to continuous positive airway pressure (CPAP) in obstructive sleep apnea (OSA). *Inform Health Soc Care*. 2022;47:274–82. <http://dx.doi.org/10.1080/17538157.2021.1990300>. PMID: 34748437.
42. Rotenberg BW, Murariu D, Pang KP. Trends in CPAP adherence over twenty years of data collection: A flattened curve. *J Otolaryngol Head Neck Surg*. 2016;45:43. <http://dx.doi.org/10.1186/s40463-016-0156-0>. PMID: 27542595.
43. Babbitt SF, Velicer WF, Aloia MS, Kushida CA. Identifying longitudinal patterns for individuals and subgroups: An example with adherence to treatment for obstructive sleep apnea. *Multivariate Behav Res*. 2015;50:91–108.
44. Gagnadoux F, le Vaillant M, Paris A, Pigeanne T, Leclair-Visonneau L, Bizieux-Thaminy A, et al. Relationship between OSA clinical phenotypes and CPAP treatment outcomes. *Chest*. 2016;149:288–90.
45. Turino C, Bertran S, Gavalda R, Teixidó I, Woehrle H, Rué M, et al. Characterization of the CPAP treated patient population in Catalonia. *PLoS One*. 2017;12:e0185191. <http://dx.doi.org/10.1371/journal.pone.0185191>.
46. Campos-Rodríguez F, Martínez-García MA, Martínez M, Duran-Cantolla J, Peña Mde L, Masdeu MJ, et al. Association between obstructive sleep apnea and cancer incidence in a large multicenter Spanish cohort. *Am J Respir Crit Care Med*. 2013;187:99–105.
47. Goldstein CA, Berry RB, Kent DT, Kristo DA, Seixas AA, Redline S, et al. Artificial intelligence in sleep medicine: Background and implications for clinicians. *J Clin Sleep Med*. 2020;16:609–18. <http://dx.doi.org/10.5664/jcsm.8388>.
48. Jonasdóttir SS, Minor K, Lehmann S. Gender differences in nighttime sleep patterns and variability across the adult lifespan: A global-scale wearables study. *Sleep*. 2021;44. <http://dx.doi.org/10.1093/sleep/zsaa169>.
49. Devani N, Pramono RXA, Imtiaz SA, Bowyer S, Rodriguez-Villegas E, Mandal S. Accuracy and usability of AcuPebble SA100 for automated diagnosis of obstructive sleep apnoea in the home environment setting: An evaluation study. *BMJ Open*. 2021;11:e046803. <http://dx.doi.org/10.1136/bmjopen-2020-046803>.
50. Van Gilst MM, van Dijk JP, Krijn R, Hoondert B, Fonseca P, van Sloun RJG, et al. Protocol of the SOMNIA project an observational study to create a neurophysiological database for advanced clinical sleep monitoring. *BMJ Open*. 2019;9:e030996.
51. Pépin JL, Bailly S, Tamisier R. Big Data in sleep apnoea: Opportunities and challenges. *Respirology*. 2020;25:486–94. <http://dx.doi.org/10.1111/resp.13669>.
52. Montserrat Canal JM, Suárez-Girón M, Egea C, Embid C, Matute-Villacis M, Martínez LM, et al. Posicionamiento de la Sociedad Española de Neumología y Cirugía Torácica en el uso de la telemedicina en los trastornos respiratorios del sueño y ventilación mecánica. *Arch Bronconeumol*. 2021;57:281–90.
53. Cistulli PA, Armitstead J, Pepin JL, Woehrle H, Nunez CM, Benjafield A, et al. Short-term CPAP adherence in obstructive sleep apnea: A big data analysis using real world data. *Sleep Med*. 2019;59:114–6.
54. Brennan HL, Kirby SD. Barriers of artificial intelligence implementation in the diagnosis of obstructive sleep apnea. *J Otolaryngol Head Neck Surg*. 2022;51:16. <http://dx.doi.org/10.1186/s40463-022-00566-w>.
55. Ley de IA de la UE: primera normativa sobre inteligencia artificial. (Reglamento [UE] 2024/1689) [consultado 19 Jun 2024]. Disponible en: <https://www.europarl.europa.eu/topics/es/article/20230601STO93804/ley-de-ia-de-la-ue-primera-normativa-sobre-inteligencia-artificial>
56. Racine E, Boehlen W, Sample M. Healthcare uses of artificial intelligence: Challenges and opportunities for growth. *Health Manage Forum*. 2019;32:272–5.
57. Petitgand C, Motulsky A, Denis J-L, Régis C. Investigating the barriers to physician adoption of an artificial intelligence-based decision support system in emergency care: An interpretative qualitative study. *Stud Health Technol Inform*. 2020;270:1001–5.
58. Barredo Arrieta A, Díaz-Rodríguez N, del Ser J, Bénéto A, Tabik S, Barbado A, et al. Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*. 2020;58:82–115. <http://dx.doi.org/10.1016/j.inffus.2019.12.012>.
59. Verma RK, Dhillon G, Grewal H, Prasad V, Munjal RS, Sharma P, et al. Artificial intelligence in sleep medicine: Present and future. *World J Clin Cases*. 2023;11:8106–10.
60. Redline S, Purcell SM. Sleep and Big Data: Harnessing data, technology, and analytics for monitoring sleep and improving diagnostics, prediction, and interventions — an era for Sleep-Omics? *Sleep*. 2021;44:zsab107.