Monografía AMORL Nº 18
Junio 2026

ASOCIACIÓN MADRILEÑA DE OTORRINOLARINGOLOGÍA

INTELIGENCIA ARTIFICIAL EN ORL: DE LOS FUNDAMENTOS A LA PRÁCTICA CLÍNICA



Carlos Carazo Casas
Andrea López Salcedo
Jose Davín Escobar
Ignacio Alcalá Rueda

www.amorl.es

Monografía AMORL Nº 18
Junio 2026

Monografía AMORL Nº 1 2012/11:
PET-TAC en tumores de cabeza y cuello.

Monografía AMORL Nº 2 2013/06:
Consenso para el diagnóstico y tratamiento de la otitis seromucosa infantil.

Monografía AMORL Nº 3 2014/06:
Cirugía de fosa nasal y senos paranasales: indicaciones de abordaje externo y endoscópico.

Monografía AMORL Nº 4 2014/12:
Indicaciones de TC y RM en ORL, coste efectividad.

Monografía AMORL Nº 5 2015/06:
El otorrinolaringólogo ante el profesional de la voz.

Monografía AMORL Nº 6 2015/09:
Manejo del nódulo tiroideo. Evidencias y recomendaciones.

Monografía AMORL Nº 7 2016/09:
Tumor primario de origen desconocido cervical.

Monografía AMORL Nº 8 2017/05:
Disfagia orofaríngea: conceptos y conocimientos necesarios para el especialista de ORL.

Monografía AMORL Nº 9 2018/01:
Pérdida del sentido del olfato: del conocimiento al diagnóstico y manejo del problema.

Monografía AMORL Nº 10 2019/06:
El acúfeno.

Monografía AMORL Nº 11 2023:
Somnoscopia (Drug Induced Sleep Endoscopy o DISE).

Monografía AMORL Nº 12 2023:
TransOral Robotic Surgery (TORS).

Monografía AMORL Nº 13 2024:
VPH en otorrinolaringología.

Monografía AMORL Nº 14 2024:
Rinosinusitis crónica con poliposis. Guía práctica actualizada.

Monografía AMORL Nº 15 2025:
Introducción a la cirugía endoscópica de oído.

Monografía AMORL Nº 16 2025:
Vértigo Posicional Paroxístico Benigno.

Monografía AMORL Nº 17 2026:
Perforaciones septales nasales.

Editora
Asociación Madrileña de Otorrinolaringología

Coordinadores
Carlos Carazo Casas, Andrea López Salcedo, Jose Davín Escobar, Ignacio Alcalá Rueda

Autores

Álvaro Borque Sanz. Servicio de Otorrinolaringología, Hospital Universitario Ramón y Cajal

Álvaro Sánchez Barrueco. Unidad de Glándulas Salivales y Sialoendoscopia.
Servicio de Otorrinolaringología, Hospital Universitario Fundación Jiménez Díaz y Hospital Universitario General de Villalba

Alex Ramírez Rosa. Servicio de Otorrinolaringología y Cirugía de Cabeza y Cuello,
Hospital Universitario Puerta de Hierro Majadahonda

Alejandro Pozuelo Moreno. Servicio de Otorrinolaringología, Hospital Infanta Sofía

Alfonso Campos González. Servicio de Otorrinolaringología, Hospital Fundación Jiménez Díaz

Alfonso Santamaría Gadea. Servicio de Otorrinolaringología, Hospital Universitario Ramón y Cajal

Andrea López Salcedo. Servicio de Otorrinolaringología, Hospital Infanta Sofía

Asier Blanco Goñi. Servicio de Otorrinolaringología, Hospital Fundación Jiménez Díaz

Blanca Martínez Cabrera. Servicio de Otorrinolaringología, Hospital Universitario La Paz

Carlos Carazo Casas. Servicio de Otorrinolaringología y Cirugía de Cabeza y Cuello,
Hospital Universitario Ramón y Cajal

Carlos Franco Fente. Servicio de Otorrinolaringología, Hospital Infanta Sofía

Carlos Ruiz Escudero. Servicio de Otorrinolaringología, Hospital Universitario Quirónsalud

Carmen Vallés Rodríguez. Servicio de Otorrinolaringología, Hospital Infanta Sofía

Coloma Grau Van Laak. Servicio de Otorrinolaringología, Hospital Universitario La Paz

Cristóbal Fernández Manzano. Servicio de Otorrinolaringología, Hospital Universitario Quirónsalud,
Servicio de Otorrinolaringología, Hospital del Escorial

Francisco Javier Hernández Calvín. Servicio de Otorrinolaringología, Hospital Universitario Quirónsalud

Gustavo Eisenberg Plaza. Servicio de Otorrinolaringología y Cirugía de Cabeza y Cuello,
Hospital Universitario Ramón y Cajal

Hernán López-Tello. Servicio de Otorrinolaringología, Hospital Universitario Rey Juan Carlos

Ignacio Alcalá Rueda. Servicio de Otorrinolaringología, Hospital Universitario General de Villalba.
Red SanitarIA, Servicio de Otorrinolaringología, Hospital Universitario Fundación Jiménez Díaz

Inés Eugenia Purroy Ortega. Servicio de Otorrinolaringología, Hospital Universitario Clínico San Carlos

Isabel Fernández Rastrilla. Servicio de Otorrinolaringología, Hospital Universitario Rey Juan Carlos

Isabel García López. Servicio de Otorrinolaringología, Hospital Universitario La Paz

Isidora Rettig Infante. Servicio de Otorrinolaringología, Hospital Infanta Sofía

Irene Oliver Laguna. Servicio de Otorrinolaringología, Hospital Infanta Sofía

Iván Muerte Moreno. Servicio de Otorrinolaringología, Hospital Universitario Clínico San Carlos

Javier Morales Domínguez. Servicio de Otorrinolaringología, Hospital Fundación Jiménez Díaz

Jesús Gimeno Hernández. Servicio de Otorrinolaringología, Unidad de Rinología, Olfato y Base de Cráneo Anterior, Hospital Clínico San Carlos

José Granell. Servicio de Otorrinolaringología. Hospital Universitario Rey Juan Carlos, Servicio de Otorrinolaringología, Cirugía de Cabeza y Cuello y Audiología, Hospital HLA Universitario Moncloa, Universidad Europea

José Miguel Villacampa Aubá. Unidad de Glándulas Salivales y Sialoendoscopia. Servicio de Otorrinolaringología. Hospital Universitario Fundación Jiménez Díaz y Hospital Universitario General de Villalba

Juan José Ocaña Domínguez. Servicio de Otorrinolaringología. Hospital Blua Sanitas Valdebebas

José Antonio Davín Escobar. Red SanitarIA

Marta Maroto de Pablo. Servicio de Otorrinolaringología y Cirugía de Cabeza y Cuello, Hospital Universitario Puerta de Hierro

Marta Morato Galán. Servicio de Otorrinolaringología, Hospital Universitario Quirónsalud

Manuel Gómez Serrano. Servicio de Otorrinolaringología y Cirugía de Cabeza y Cuello, Hospital Universitario Puerta de Hierro

M.ª del Mar Martínez Ruiz-Coello. Servicio de Otorrinolaringología, Unidad de Rinología, Olfato y Base de Cráneo Anterior, Hospital Clínico San Carlos

Mar Domínguez Fernández. Servicio de Otorrinolaringología y Cirugía de Cabeza y Cuello, Hospital Universitario Ramón y Cajal

Nazaret Benítez Lobón. Servicio de Otorrinolaringología. Hospital Infanta Sofía

Pilar Benavent Marín. Unidad de Glándulas Salivales y Sialoendoscopia. Servicio de Otorrinolaringología. Hospital Universitario Fundación Jiménez Díaz y Hospital Universitario General de Villalba

Pablo Sarrió Solera. Servicio de Otorrinolaringología, Unidad de Rinología, Olfato y Base de Cráneo Anterior, Hospital Clínico San Carlos

Raimundo Gutiérrez Fonseca. Servicio de Otorrinolaringología, Hospital Universitario Rey Juan Carlos, Otorrinolaringología, Hospital Ruber Internacional

Rubén Polo López. Servicio de Otorrinolaringología. Hospital Universitario Ramón y Cajal

Teresa Rivera Schmitz. Servicio de Otorrinolaringología. Hospital Universitario La Paz

Tomás Delgado Sánchez. Servicio de Otorrinolaringología. Hospital Universitario Clínico San Carlos

Virginia Ruiz San José. Unidad de Glándulas Salivales y Sialoendoscopia. Servicio de Otorrinolaringología, Hospital Universitario Fundación Jiménez Díaz y Hospital Universitario General de Villalba

Índice

1. Introducción 7
2. Fundamentos y modalidades de IA aplicadas a ORL 10
3. IA generativa en la práctica otorrinolaringológica 15
4. Inteligencia artificial y robótica quirúrgica en ORL 21
5. Aplicaciones actuales de la inteligencia artificial en otología 26
6. Aplicaciones en otoneurología 32
7. Aplicaciones en cirugía de cabeza y cuello 36
8. Aplicaciones de la IA en el análisis acústico de la voz 41
9. Aplicaciones en patología glandular salivar 46
10. Aplicaciones de la IA en el síndrome de apnea del sueño 51
11. Aplicaciones en rinología 57
12. Aplicaciones en cirugía plástica facial y reconstructiva 61
13. Aplicación de la IA en ORL infantil 67
14. Aplicaciones de la inteligencia artificial en investigación sanitaria 71
15. Ética y gobernanza de la IA en ORL 77
16. Inteligencia artificial en la gestión y optimización de los flujos clínicos en hospitales terciarios (consulta, hospital y quirófano) 82
17. Conclusiones 87

1

Introducción

Julio Mayol, MD, PhD[1].
1. Director Científico. Instituto de Investigación Sanitaria San Carlos (IdISSC), Madrid

Autor de correspondencia: Julio Mayol
Instituto de Investigación Sanitaria San Carlos (IdISSC).
Hospital Clínico San Carlos. Calle del Profesor Martín Lagos, s/n, 28040 Madrid
Correo electrónico: julio.mayol@salud.madrid.org

INTRODUCCIÓN

Hace treinta años, cuando empezaba mi formación quirúrgica, la idea de que un algoritmo interpretara una imagen médica, redactara un informe clínico o asistiera en la toma de decisiones intraoperatorias habría sonado a ciencia ficción. Hoy ninguna de esas cosas lo es. Algunas ya funcionan, otras están cerca de hacerlo y muchas necesitan todavía un largo camino de validación antes de incorporarse a la asistencia real. Distinguir unas de otras es el objetivo de esta monografía.

La inteligencia artificial (IA) no es ajena a lo que hacemos los médicos. En el fondo, la medicina siempre ha consistido en reconocer patrones. Un cirujano identifica una variante anatómica. Un otorrinolaringólogo diferencia un nistagmo central de uno periférico. Un radiólogo detecta una ocupación sutil en un seno paranasal. La IA no aporta una capacidad nueva. Aporta una escala y una velocidad de procesamiento que el cerebro humano no alcanza[1]. La pregunta no es si esta tecnología llegará a nuestra especialidad. Ya ha llegado. La pregunta es si sabremos evaluarla con criterio, integrarla con prudencia y exigirle la misma evidencia que a cualquier otra intervención.

LA OTORRINOLARINGOLOGÍA COMO TERRENO FÉRTIL

No todas las especialidades están igual de preparadas para incorporar la IA. La Otorrinolaringología sí lo está, y por razones que van más allá de la moda tecnológica. Trabajamos de forma intensiva con imágenes: otoscopia, endoscopia nasal y laríngea, tomografía de senos paranasales y de hueso temporal. Esas imágenes generan datos estructurados, reproducibles y abundantes, justo lo que los algoritmos de aprendizaje profundo necesitan para entrenarse[2]. Trabajamos también con señales acústicas, la voz, la audición, los potenciales evocados, que se prestan a un análisis cuantitativo antes dependiente de la interpretación subjetiva del explorador. Y operamos en espacios anatómicos complejos, donde la robótica quirúrgica ya ha demostrado su utilidad y donde la integración de IA es la evolución natural.

Hay otra razón, menos glamurosa y más urgente. La presión asistencial sobre los servicios de Otorrinolaringología en el sistema público es enorme. Consultas saturadas, listas de espera crecientes, carga administrativa desproporcionada. En ese contexto, las aplicaciones que reciben menos atención mediática, la programación inteligente de agendas, la documentación automatizada, el triaje de derivaciones desde atención primaria, pueden tener un impacto más inmediato que el algoritmo diagnóstico más sofisticado[3].

ENTRE EL ENTUSIASMO Y LA CAUTELA

Quien lea la literatura reciente sobre IA en Otorrinolaringología encontrará métricas impresionantes: sensibilidades superiores al 90 por ciento, áreas bajo la curva cercanas a 1, precisiones que igualan o superan al especialista experimentado. Conviene leer esas cifras con la misma precaución que un ensayo clínico en fase II. La mayoría de esos modelos se evaluaron en el mismo centro donde se entrenaron, con poblaciones seleccionadas y protocolos de imagen homogéneos. Al

trasladarlos a otro hospital, con otro equipo, otra población y otra forma de trabajar, el rendimiento suele caer. Es el *domain shift*, probablemente el obstáculo más subestimado en la traslación de la IA a la clínica[4].

No se trata de desacreditar lo conseguido, sino de ser honestos sobre lo que falta. Y lo que falta, casi siempre, son estudios prospectivos, multicéntricos, con validación externa y con medidas de resultado que importen al paciente: no solo si el algoritmo acierta, sino si ese acierto cambia el pronóstico, reduce la morbilidad o mejora la calidad de vida. Mientras tanto, conviene no confundir un buen resultado técnico con una herramienta clínicamente recomendable[5].

A esto se añade el marco regulatorio. El Reglamento Europeo de Inteligencia Artificial (AI Act), en vigor desde 2024, clasifica las aplicaciones sanitarias como de alto riesgo y exige transparencia, trazabilidad y supervisión humana[6]. Las directrices de la OMS sobre IA y modelos de lenguaje extenso subrayan la necesidad de gobernanza a lo largo de todo el ciclo de vida del producto[7]. Para el especialista que quiera incorporar estas herramientas, conocer este marco no es opcional. Es parte de la responsabilidad profesional.

LO QUE EL LECTOR ENCONTRARÁ EN ESTAS PÁGINAS

Esta monografía se organiza en diecisiete capítulos con una lógica deliberada. Los tres primeros establecen los cimientos: fundamentos técnicos de la IA, IA generativa aplicada a la práctica diaria y robótica quirúrgica inteligente. El cuarto aborda el análisis acústico de la voz, una aplicación transversal que conecta laringología, foniatría y biomarcadores digitales.

Los capítulos del 4 al 13 recorren la especialidad subespecialidad a subespecialidad: otología, otoneurología, cirugía de cabeza y cuello, patología glandular salivar, apnea del sueño, rinología, cirugía plástica facial y Otorrinolaringología pediátrica. No son revisiones teóricas. Están escritos por equipos que trabajan activamente en esas áreas y que conocen de primera mano sus posibilidades y sus límites.

Los cuatro capítulos finales abordan dimensiones transversales que atraviesan toda la especialidad. La IA como herramienta de investigación, desde la extracción automática de variables hasta la generación de datos sintéticos. El marco ético y de gobernanza, con sus cuestiones de sesgo, consentimiento algorítmico y responsabilidad legal. La optimización de flujos clínicos, donde quizá resida el retorno más inmediato para el profesional y para el sistema. Y unas conclusiones que no pretenden cerrar el debate, sino dar criterios para mantenerlo vivo.

LAS PREGUNTAS QUE NO CADUCAN

Escribir sobre IA en 2026 tiene algo de paradoja. Parte de lo que aquí se describe habrá cambiado antes de que el texto llegue al lector. Los ciclos de innovación se miden en semanas, no en años, y un modelo que hoy representa el estado del arte puede haber quedado superado cuando esta monografía se presente en las Jornadas de la Asociación Madrileña de Otorrinolaringología.

Por eso lo que más valor tiene no es el catálogo de herramientas, sino las preguntas que debemos hacernos ante cualquiera de ellas. ¿Se ha validado externamente? ¿Funciona en mi población? ¿Se integra en lo que ya hago o me obliga a duplicar trabajo? ¿Quién responde si falla? ¿Mejora algo que al paciente le importe? Esas preguntas no caducan con la siguiente versión del modelo. Son el núcleo de la alfabetización digital que necesitamos[8,9].

La Asociación Madrileña de Otorrinolaringología ha decidido dedicar su monografía anual a un tema que no es una subespecialidad clínica, sino una competencia que las afecta a todas. Esa decisión dice mucho sobre hacia dónde mira esta comunidad. La IA no va a sustituir al otorrinolaringólogo. Pero el otorrinolaringólogo que sepa evaluarla con criterio, usarla con prudencia y mantener siempre la decisión final como responsabilidad propia estará mejor preparado para lo que viene[10,11]. Estas páginas aspiran a contribuir a ese objetivo.

CONFLICTO DE INTERESES

El autor declara no tener conflictos de interés.

FINANCIACIÓN

No se recibió financiación para la elaboración de este capítulo.

BIBLIOGRAFÍA

1. Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. Nat Med. 2019;25(1):44-56.
2. Crowson MG, Ranisau J, Eskander A, et al. A contemporary review of machine learning in otolaryngology-head and neck surgery. Laryngoscope. 2020;130(1):45-51.
3. Davenport T, Kalakota R. The potential for artificial intelligence in healthcare. Future Healthc J. 2019;6(2):94-98.
4. Burmeister JR, Dimock E, Haupert M, Zazay I. Bridging the AI implementation gap in otolaryngology: a clinical commentary. Digit Health. 2025;11:20552076251396981.
5. Kelly CJ, Karthikesalingam A, Suleyman M, Corrado G, King D. Key challenges for delivering clinical impact with artificial intelligence. BMC Med. 2019;17(1):195.
6. Regulation (EU) 2024/1689 of the European Parliament and of the Council of 13 June 2024 laying down harmonised rules on artificial intelligence (AI Act). Official Journal of the European Union. OJ L, 12.7.2024.
7. World Health Organization. Ethics and governance of artificial intelligence for health: guidance on large multi-modal models. Geneva: WHO; 2024.
8. Collins GS, Moons KGM, Dhiman P, et al. TRIPOD+AI statement: updated guidance for reporting clinical prediction models that use regression or machine learning methods. BMJ. 2024;385:e078378.
9. Lekadir K, Frangi AF, Porras AR, et al. FUTURE-AI: international consensus guideline for trustworthy and deployable artificial intelligence in healthcare. BMJ. 2025;388:e081554.
10. Ayoub NF, Rameau A, Brenner MJ, et al. American Academy of Otolaryngology-Head and Neck Surgery (AAO-HNS) Report on Artificial Intelligence. Otolaryngol Head Neck Surg. 2025;172(2):734-743.
11. Rajpurkar P, Chen E, Banerjee O, Topol EJ. AI in health and medicine. Nat Med. 2022;28(1):31-38.

2

Fundamentos y modalidades de IA aplicadas a ORL

Jose Antonio Davín Escobar[1], Ignacio Alcalá Rueda[1,2]
1. Red SanitarIA
2. Hospital Universitario Fundación Jiménez Díaz

INTRODUCCIÓN: LA NUEVA ERA DIGITAL EN LA CONSULTA DE ORL

¿Qué es exactamente la Inteligencia Artificial? Desmitificando el concepto para el clínico

En nuestra práctica diaria como otorrinolaringólogos, tomamos decisiones complejas integrando la historia clínica, la exploración física y pruebas complementarias. La Inteligencia Artificial (IA) es, en términos generales, un concepto que describe a los sistemas informáticos o software diseñados para emular precisamente esta inteligencia y comportamiento humano[1]. A diferencia del *software* médico tradicional que funciona como una calculadora con reglas rígidas ("si A, entonces B"), la IA moderna tiene la capacidad de procesar enormes cantidades de datos, descubrir patrones complejos e inferir respuestas de forma autónoma[2]. Para nosotros, esto significa pasar de utilizar la tecnología como un mero instrumento de visualización (como un endoscopio) a tener un "asistente" capaz de analizar esa imagen y sugerir diagnósticos.

Breve evolución: de los sistemas basados en reglas inflexibles al auge de los datos médicos

La IA no es un invento de esta década; su historia ha estado marcada por ciclos de gran optimismo y profundos estancamientos. El término "inteligencia artificial" nació en 1956 durante la Conferencia de Dartmouth, dando inicio a un primer auge que pronto se frenó por las limitaciones técnicas de la época[1].

En los años 80 vivimos un segundo auge gracias a los llamados sistemas expertos (como MYCIN), diseñados para ayudar en decisiones médicas basándose en reglas lógicas introducidas manualmente por humanos[1]. Su fracaso radicó en que no podían actualizar su conocimiento por sí solos ni manejar la incertidumbre intrínseca de la biología humana.

Actualmente, desde finales de la década de los 2000, nos encontramos en el tercer gran auge, el cual ha transformado la medicina. Este salto ha sido posible gracias a tres pilares: el aumento de la potencia computacional, la digitalización masiva de nuestras historias clínicas e imágenes (*Big Data*), y la invención del Aprendizaje Profundo (*deep learning*)[1].

LA JERARQUÍA DE LA IA: ENTENDIENDO LOS FUNDAMENTOS TECNOLÓGICOS

Para entender la literatura técnica actual sin perdernos, resulta muy útil visualizar la tecnología como una muñeca rusa (Matrioska), donde los conceptos más potentes y específicos se encuentran anidados dentro de los más amplios.

Inteligencia Artificial (IA)

Como se ha comentado anteriormente, la IA en su definición más amplia es la capa más externa y abarca cualquier técnica o algoritmo que intente replicar la cognición humana en una máquina[3]. Engloba desde los algoritmos más arcaicos hasta los modelos generativos actuales.

Machine Learning (ML) o Aprendizaje Automático

Es la siguiente muñeca. El *machine learning* permite a las computadoras aprender a partir de la experiencia, en lugar de requerir que un programador escriba líneas de código para cada posible escenario clínico. En este subcampo, el sistema mejora su rendimiento en

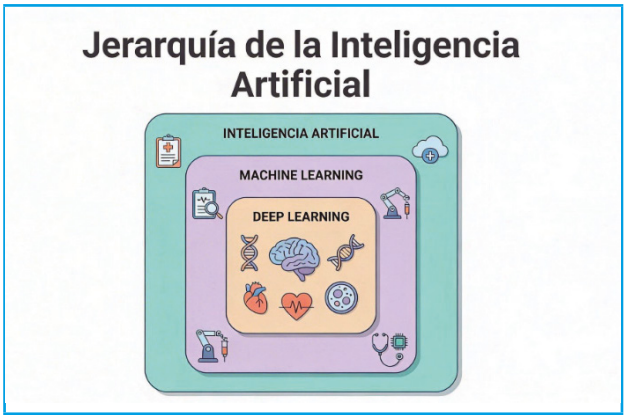


Figura 1. La jerarquía tecnológica. La Inteligencia Artificial es el concepto global que intenta replicar la cognición humana. El *machine learning* aprende a partir de la experiencia con datos estructurados, y el *deep learning* utiliza redes neuronales multicapa para procesar datos complejos y "crudos", como imágenes tomográficas o voz, sin necesidad de que el profesional extraiga variables manualmente[3,4].

una tarea médica a medida que acumula más datos (experiencia).

Deep Learning (DL) o Aprendizaje Profundo

En el núcleo de la Matrioska encontramos el *deep learning*. Esta es la tecnología que nos ha permitido lograr avances sin precedentes en ORL, ya que utiliza redes neuronales artificiales compuestas por múltiples capas, inspiradas en la estructura de nuestro cerebro. Mientras que el ML clásico requiere que extraigamos manualmente las variables (por ejemplo, midiendo el diámetro de un tumor), el DL puede procesar datos complejos y "crudos", como imágenes tomográficas o grabaciones de voz, aprendiendo automáticamente las representaciones jerárquicas y anatómicas sin intervención humana[4].

PARADIGMAS DE APRENDIZAJE: ¿CÓMO LE ENSEÑAMOS A LA MÁQUINA?

Al igual que formamos a nuestros residentes, debemos "entrenar" a los algoritmos. Dependiendo del tipo de datos médicos que tengamos, utilizamos tres paradigmas principales.

Aprendizaje Supervisado

Es el método estándar en la investigación actual[5]. Funciona entregando al algoritmo un conjunto de datos (entradas) junto con sus diagnósticos correctos (etiquetas o salidas)[3]. Por ejemplo, le mostramos miles de imágenes de otoscopia previamente etiquetadas por otólogos como "oído sano" o "colesteatoma". El algoritmo ajusta repetidamente sus conexiones matemáticas para reducir el error hasta que es capaz de predecir con exactitud el diagnóstico en una imagen que nunca ha visto.

Aprendizaje No Supervisado

En este enfoque, proporcionamos al algoritmo datos médicos "crudos" sin ninguna etiqueta ni diagnóstico predefinido. La tarea de la IA es encontrar patrones

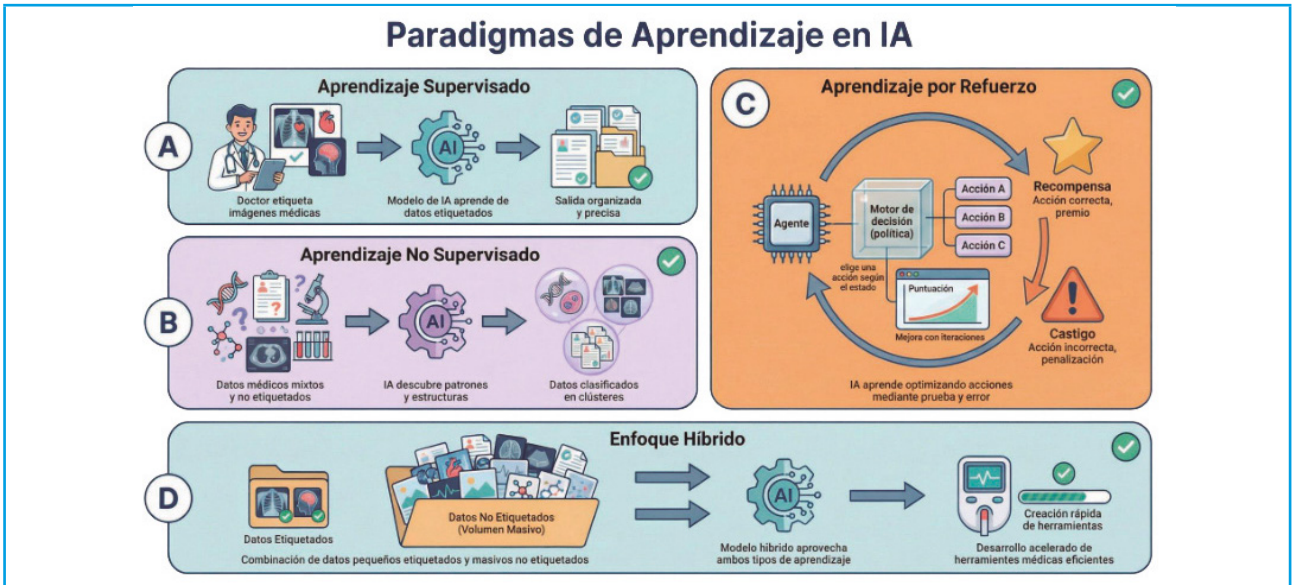


Figura 2. Paradigmas de aprendizaje automático en Otorrinolaringología. (A) Aprendizaje Supervisado: el algoritmo se entrena con un conjunto de datos (entradas) que incluyen el diagnóstico correcto (etiquetas) proporcionado por el especialista. (B) Aprendizaje No Supervisado: la IA recibe datos "crudos" sin diagnóstico predefinido y su tarea es descubrir patrones ocultos de forma autónoma, ideal para el clustering o agrupación de fenotipos. (C) Aprendizaje por Refuerzo: el modelo aprende mediante ensayo y error, recibiendo "recompensas" o "castigos" en función de si sus decisiones mejoran o empeoran un escenario clínico. (D) Enfoques Híbridos (Semi-supervisado): combinan una pequeña porción de datos etiquetados manualmente con una vasta cantidad de datos sin etiquetar, optimizando el tiempo clínico y acelerando el desarrollo de la herramienta[1,3].

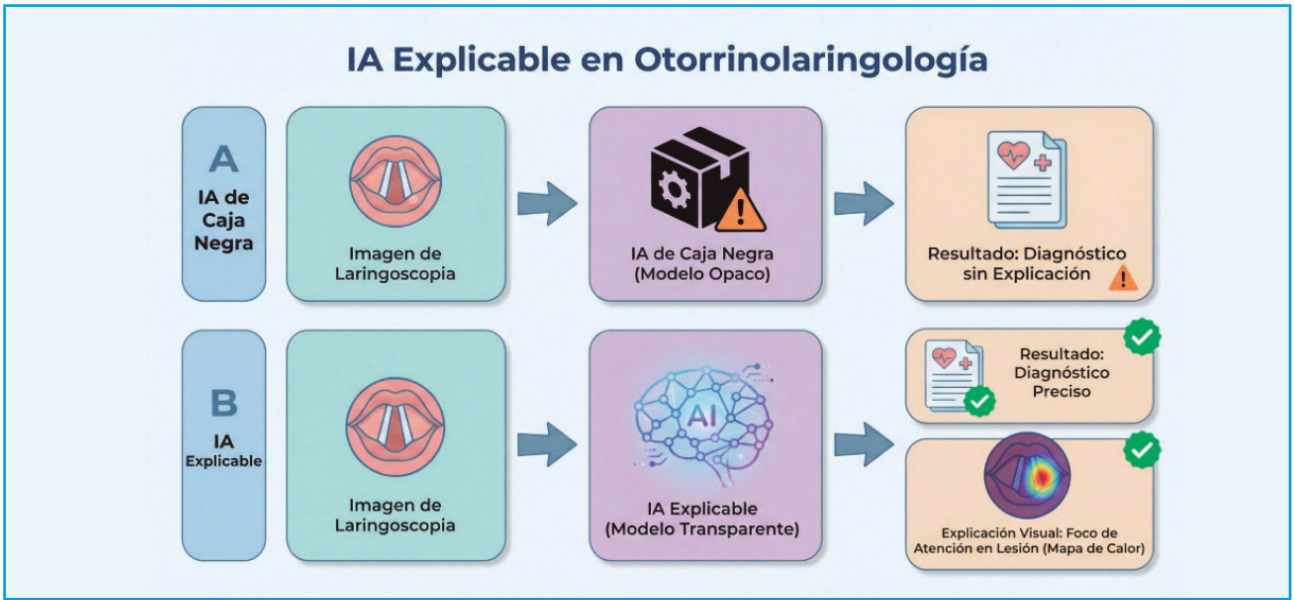


Figura 3. El problema de la "caja negra" y la Inteligencia Artificial Explicable (XAI) en la práctica clínica. (A) Los algoritmos de *deep learning* a menudo operan como una "caja negra", donde el proceso entre los datos de entrada (por ejemplo, una laringoscopia) y el diagnóstico final es opaco y difícil de interpretar para el clínico. (B) Para auditar su desempeño y fomentar la confianza, debemos exigir herramientas de IA Explicable (XAI) que utilicen mapas de calor (como *Grad-CAM*) para iluminar exactamente qué características anatómicas o lesiones motivaron sus decisiones, permitiéndonos validar su lógica[10,11].

ocultos por sí sola. Esto es invaluable para el clustering (agrupación), permitiéndonos, por ejemplo, descubrir nuevos fenotipos o subtipos de pacientes con rinosinusitis crónica basándose en múltiples variables que a simple vista no parecen correlacionadas[3].

Aprendizaje por refuerzo y enfoques híbridos

El aprendizaje por refuerzo funciona mediante prueba y error, donde el algoritmo recibe "recompensas" o "castigos" según si su acción mejora o empeora un escenario clínico. Por otro lado, dado que el etiquetado manual de datos por especialistas consume muchísimo tiempo, han surgido modelos de aprendizaje semi-supervisado. Estos combinan una pequeña cantidad de datos etiquetados por nosotros con una vasta cantidad de datos sin etiquetar, acelerando la creación de herramientas clínicas[1,3].

MODALIDADES DE DATOS Y ALGORITMOS CLAVE EN ORL

Nuestra especialidad integra información visual, acústica y tabular. La IA utiliza algoritmos específicos para interpretar cada uno de estos "sentidos".

Datos Estructurados (ML Clásico)

Cuando manejamos historias clínicas con variables demográficas y resultados numéricos (como en las audiometrías), los algoritmos de ML clásico, como *Random Forest* (Bosques Aleatorios) o las Máquinas de Vectores de Soporte (SVM), son altamente efectivos[5]. Se utilizan asiduamente para la predicción de resultados quirúrgicos, como pronosticar la recuperación auditiva tras una timpanoplastia o estimar el éxito.

Visión por Computadora (Imágenes y Video)

Dado que la ORL es altamente visual, las Redes Neuronales Convolucionales (CNN) son nuestras mayores aliadas[6]. Estos algoritmos escanean una imagen buscando bordes, texturas y formas de manera muy similar a la corteza visual humana.

- Clasificación: las CNN han logrado precisiones superiores al 90 % en la detección endoscópica de pólipos nasales o en la clasificación de otitis media mediante otoscopia, igualando e incluso superando la precisión de médicos no especialistas[5,6].
- Segmentación: más allá de diagnosticar, la IA puede delinear con precisión submilimétrica los contornos anatómicos en una TC o RM. Esto es crucial en cirugía de base de cráneo, donde la segmentación automática del nervio facial, el laberinto o los huesecillos reduce los tiempos de planificación preoperatoria[4].

Audiómica y Procesamiento de Señales

La voz y la respiración son ricas en información fisiológica. La audiómica utiliza el DL para procesar enormes conjuntos de datos acústicos y extraer "biomarcadores" imperceptibles al oído humano. Estos algoritmos pueden analizar grabaciones de voz

para detectar parálisis de cuerdas vocales, discriminar lesiones laríngeas benignas o sospechar carcinomas glóticos con alta sensibilidad. Además, los sonidos respiratorios, como la tos, se investigan activamente como métodos de cribado de bajo costo para patologías de la vía aérea[7].

El salto al lenguaje: Del Procesamiento del Lenguaje Natural (NLP) a los LLMs

En ORL, dedicamos un porcentaje inmenso de nuestro tiempo a documentar notas clínicas. Aquí es donde el procesamiento del lenguaje entra en juego.

Procesamiento del Lenguaje Natural (NLP)

El NLP permite a las computadoras procesar, interpretar y generar texto humano. Tradicionalmente, lo hemos usado para la "minería de datos": extraer variables valiosas (diagnósticos, tratamientos previos, complicaciones) ocultas dentro del texto desordenado de nuestras notas de evolución o informes patológicos, procesando miles de historias en minutos con precisiones superiores al 90 %[8].

Arquitectura Transformer

El verdadero cambio de paradigma ocurrió en 2017 con la invención de la arquitectura Transformer. Anteriormente, los modelos leían las palabras en orden secuencial, olvidando el contexto de las oraciones largas. Los Transformers procesan las oraciones en su totalidad simultáneamente y utilizan un mecanismo de "atención" para evaluar la importancia de cada palabra en relación con las demás, lo que dota a la máquina de una comprensión del contexto médico casi humana[1,8].

Grandes Modelos de Lenguaje (LLMs)

Basados en esta arquitectura Transformer, surgieron los Grandes Modelos de Lenguaje, como GPT (Generative Pre-trained Transformer). Estos sistemas son la antesala a la IA Generativa, capaces no solo de leer, sino de conversar y redactar. En nuestra especialidad, han demostrado capacidad para responder a preguntas de pacientes, resumir historiales e incluso aprobar exámenes de certificación de la junta de ORL[3,8,9].

Sin embargo, debemos ser extremadamente cautelosos: estos modelos no razonan de forma real, sino que predicen estadísticamente la siguiente palabra lógica. Esto los lleva en ocasiones a generar "alucinaciones" (inventar referencias científicas o tratamientos erróneos con absoluta confianza). Es vital entender su funcionamiento subyacente para dar paso a las aplicaciones de IA Generativa en la creación de planes quirúrgicos y material educativo, temas que se explorarán a fondo en el siguiente capítulo de este libro.

CONCLUSIONES

La integración de la Inteligencia Artificial en Otorrinolaringología marca el comienzo de una era centrada en la medicina de precisión y la eficiencia.

La IA como extensión de nuestras capacidades

Es crucial entender que la IA no viene a reemplazar nuestra práctica médica ni nuestra destreza quirúrgica. Su rol es el de un potenciador: asume el análisis de tareas repetitivas, extrae biomarcadores sutiles de la voz o imágenes que nuestro ojo humano podría pasar por alto, y actúa como una segunda opinión en escenarios clínicos complejos. Esto nos permitirá focalizarnos en lo que ninguna máquina puede hacer: la empatía, el cuidado compasivo y el juicio clínico matizado[2].

La importancia de la evaluación ética y la explicabilidad

A medida que delegamos tareas en estas herramientas, nuestra responsabilidad es auditar su desempeño. Los algoritmos de *deep learning* a menudo operan como una "caja negra" donde el proceso entre la entrada y el diagnóstico es opaco[10]. Necesitamos exigir sistemas de IA Explicable (XAI), que iluminen mediante mapas de calor u otras métricas el porqué de sus decisiones, permitiéndonos validar su lógica. Además, somos responsables de vigilar el sesgo algorítmico (bias). Si un algoritmo de análisis de voz se entrena sin diversidad poblacional, fracasará y perpetuará inequidades en la atención médica de nuestros pacientes[10,11].

Comprender los fundamentos presentados en este capítulo es el primer paso indispensable para liderar la adopción de la IA en la ORL, asegurándonos de que la tecnología avance siempre de forma segura, equitativa y en estricto beneficio de nuestros pacientes.

CONFLICTO DE INTERESES

Los autores declaran no tener conflictos de interés.

FINANCIACIÓN

No se recibió financiación para la elaboración de este capítulo.

BIBLIOGRAFÍA

1. Koyama H, Kashio A, Yamasoba T. Application of Artificial Intelligence in Otology: Past, Present, and Future. JCM. 2024 Dec 13;13(24):7577. doi:10.3390/jcm13247577.

2. Ayoub NF, Rameau A, Brenner MJ, Bur AM, Ator GA, Briggs SE, et al. American Academy of Otolaryngology-Head and Neck Surgery (AAO-HNS) Report on Artificial Intelligence. Otolaryngol Head Neck Surg. 2025 Feb;172(2):734–43. doi:10.1002/ohn.1080 PubMed PMID: 39666770; PubMed Central PMCID: PMC12369755.

3. Navarathna N, Kanhere A, Gomez C, Isaiah A. Artificial intelligence in pediatric otolaryngology: A state-of-the-art review of opportunities and pitfalls. Int J Pediatr Otorhinolaryngol. 2025 Jul;194:112369. doi:10.1016/j.ijporl.2025.112369 PubMed PMID: 40334638; PubMed Central PMCID: PMC12332797.

4. Novi SL, Navarathna N, D'Cruz M, Brooks JR, Maron BA, Isaiah A. Deep Learning in Otolaryngology: A Narrative Review. JAMA Otolaryngol Head Neck Surg. 2026 Jan 1;152(1):71–80. doi:10.1001/jamaoto.2025.3911 PubMed PMID: 41231484; PubMed Central PMCID: PMC12728561.

5. Koyama H. Machine learning application in otology. Auris Nasus Larynx. 2024 Aug;51(4):666–73. doi:10.1016/j.anl.2024.04.003 PubMed PMID: 38704894.

6. B H S, G D. The Application and Diagnostic Accuracy of Artificial Intelligence in Rhinology: A Review. Cureus. 2025 Jul;17(7):e87966. doi:10.7759/cureus.87966 PubMed PMID: 40821134; PubMed Central PMCID: PMC12351417.

7. Torborg SR, Kim AYE, Rameau A. New developments in the application of artificial intelligence to laryngology. Curr Opin Otolaryngol Head Neck Surg. 2024 Dec 1;32(6):391–7. doi:10.1097/MOO.0000000000000999 PubMed PMID: 39146248; PubMed Central PMCID: PMC11613154.

8. Banyi N, Ma B, Amanian A, Bur A, Abdalkhani A. Applications of Natural Language Processing in Otolaryngology: A Scoping Review. The Laryngoscope. 2025 Sep;135(9):3049–63. doi:10.1002/lary.32198.

9. Lechien JR, Rameau A. Applications of ChatGPT in Otolaryngology-Head Neck Surgery: A State of the Art Review. Otolaryngol Head Neck Surg. 2024 Sep;171(3):667–77. doi:10.1002/ohn.807 PubMed PMID: 38716790.

10. Tai K, Zhao R, Rameau A. Artificial Intelligence in Otolaryngology: Topics in Epistemology & Ethics. Otolaryngol Clin North Am. 2024 Oct;57(5):863–70. doi:10.1016/j.otc.2024.04.008 PubMed PMID: 38839555; PubMed Central PMCID: PMC11374503.

11. Tai K, Zhao R, Rameau A. Patient-Centered Equitable and Safe Artificial Intelligence in Otolaryngology-Head and Neck Surgery. Otolaryngol Head Neck Surg. 2024 Oct;171(4):1232–5. doi:10.1002/ohn.881 PubMed PMID: 38943446; PubMed Central PMCID: PMC11461108.

3

IA Generativa en la práctica otorrinolaringológica

Ignacio Alcalá Rueda[1,2], José Antonio Davín Escobar[2]
1. Servicio de Otorrinolaringología, Hospital Universitario Fundación Jiménez Díaz
2. Red SanitarIA.

INTRODUCCIÓN: ¿QUÉ ES LA IA GENERATIVA Y EN QUÉ SE DIFERENCIA DE LA IA PREDICTIVA?

Durante la última década, los otorrinolaringólogos hemos escuchado hablar de inteligencia artificial (IA) principalmente en el contexto de la investigación: algoritmos que analizan audiometrías o clasifican imágenes de tomografía. Sin embargo, es fundamental aclarar una confusión habitual en nuestros congresos y hospitales: la diferencia abismal entre la IA que hemos conocido hasta ahora y la que está transformando nuestra práctica hoy.

Tal y como repasábamos en el capítulo anterior, históricamente hemos utilizado la **IA Predictiva (o discriminativa)**. Esta tecnología funciona muy bien para clasificar en función de un entrenamiento previo: se le muestran miles de imágenes de tímpanos y, ante una nueva otoscopia, predice una etiqueta ("Otitis media: Sí/No") basándose en patrones cerrados preaprendidos. Este tipo de metodología a menudo ha permanecido inaccesible para el médico asistencial, funcionando como "cajas negras" (que no sabemos muy bien cómo funcionan) que clasifican datos existentes sin crear nada nuevo[1]. Hay que tener en cuenta que este tipo de IA "tradicional" no "escribe" ni "crea"; simplemente etiqueta lo que ve.

La Inteligencia Artificial Generativa (IAG), por el contrario, representa un cambio de paradigma. No se limita a clasificar, sino que "crea contenido nuevo". Esta IAG, basada en modelos de lenguaje extenso (LLMs) - sistemas entrenados con vastas cantidades de texto para predecir la siguiente palabra en una frase-, puede generar texto, imágenes, resúmenes y razonamientos complejos que no existían previamente, a partir de una petición que nosotros le hagamos en lenguaje natural. Tiene la capacidad de dialogar, resumir y "razonar" sobre casos complejos[2].

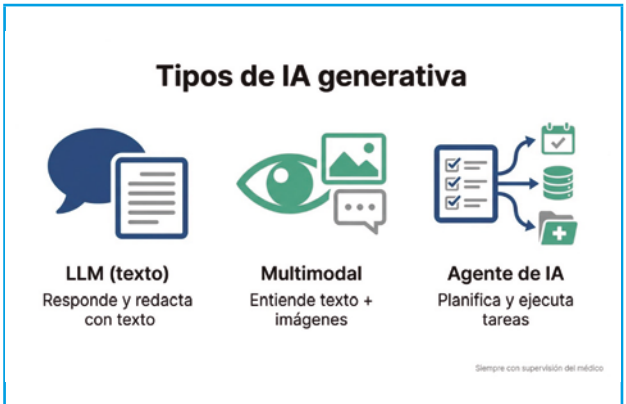


Figura 1. Tipos de IA generativa en clínica: un LLM trabaja con texto, un modelo multimodal combina texto e imágenes, y un agente añade planificación y uso de herramientas para ejecutar tareas, siempre con supervisión médica.

Esta capacidad de generar y adaptar el lenguaje es lo que permite que la IAG se integre en la Otorrinolaringología no solo como una herramienta diagnóstica, sino como un motor de transformación para la práctica clínica diaria, facilitando desde la derivación desde atención primaria hasta la educación del paciente[3].

Este capítulo pretende explicar cómo la IAG trasciende la curiosidad tecnológica para convertirse en una herramienta en el día a día del otorrinolaringólogo.

POTENCIANDO LAS HABILIDADES DEL ORL: TIPOS DE IAG

La IAG no viene a sustituir nuestro criterio clínico, sino a potenciar nuestras capacidades cognitivas y sensoriales, actuando como una extensión de nuestras habilidades (un "copiloto").

Modelos de Lenguaje (LLM)

Los LLM han demostrado una capacidad sorprendente para manejar el vasto conocimiento médico. En nuestra especialidad, estos modelos pueden actuar como tutores avanzados para la actualización continua. Algunos estudios, incluso, han evaluado el rendimiento de ChatGPT en exámenes de certificación de Otorrinolaringología y Cirugía de Cabeza y Cuello (tipo "*Board Exams*" en Canadá), demostrando que la IA puede llegar a lograr una puntuación de aprobado (75 %) en preguntas abiertas complejas, superando incluso su rendimiento cuando no se le daban instrucciones específicas[4]. Este tipo de estudios son relevantes porque confirman que la IA posee un núcleo de conocimiento teórico validado suficiente para apoyar al especialista en la revisión de literatura o el estudio de guías clínicas, lo que cambia la forma en la que nos relacionamos con el conocimiento y la evidencia.

Modelos Multimodales

La Otorrinolaringología es una especialidad eminentemente visual. Los nuevos modelos "multimodales" son capaces no solo de procesar texto, sino que "ven" y razonan sobre imágenes. Ya no hablamos de una IA que simplemente detecta un píxel anormal, sino de una que integra la imagen con todo el resto del conjunto de la historia clínica.

Algunos estudios han demostrado la viabilidad de utilizar estos modelos multimodales para diagnosticar enfermedades del oído medio integrando imágenes otoscópicas con datos específicos del paciente. Al combinar la imagen visual con el texto de la anamnesis, la IA alcanzó una precisión del 82,1 %, superando a los pediatras generalistas (70,6 %) y acercándose al rendimiento de los otorrinolaringólogos expertos[5]. Este hallazgo sugiere su inmenso potencial como herramienta de segunda opinión en atención primaria o urgencias, donde el especialista ORL no siempre está presente.

Agentes de IA

El futuro inmediato no son solo los chatbots o los LLMs que responden preguntas, sino los "agentes". Un "agente" es una IA que no solo conversa, sino que puede ejecutar tareas, usar herramientas (como buscar en una base de datos o acceder a la historia clínica) y planificar pasos para resolver un problema que requiera varias acciones, herramientas o programas.

En el contexto de la ORL, los agentes pueden ayudar a descomponer problemas complejos en pasos más sencillos. Por ejemplo, en lugar de solo responder "el paciente necesita cirugía", un agente podría planificar la programación quirúrgica, verificar si faltan pruebas preoperatorias y analizar resultados de laboratorio basándose en guías de práctica clínica. Los agentes autónomos representan el siguiente paso evolutivo, moviéndose de la asistencia pasiva a la ejecución activa de flujos de trabajo clínicos, sin necesidad de que un facultativo tome la decisión de "ejecutar" una orden, pero siempre supervisando, sin olvidar el concepto "*Human in the Loop*" (el humano siempre supervisando).

LA REVOLUCIÓN EN LA CONSULTA: ESCRIBAS Y SOPORTE A LA DECISIÓN CLÍNICA

La carga burocrática es una de las principales causas de *burnout* en nuestra especialidad. La IAG ofrece una salida real a este problema, permitiéndonos volver a una medicina en la que, paradójicamente, el ordenador juega un papel menos central en la consulta.

Escribas Médicos (Ambient AI)

La tecnología de "*Ambient AI*" o inteligencia ambiental permite que el sistema escuche la conversación natural entre el médico y el paciente (con el debido consentimiento) y redacte automáticamente la anamnesis estructurada. Esto libera al otorrino de teclear durante la consulta.

Este tipo de tecnología permite que el médico vuelva a mirar al paciente a los ojos en lugar de esconderse tras la pantalla del ordenador, recuperando la empatía y la conexión humana perdida por la exigencia del registro electrónico[6]. Además, estas herramientas pueden generar informes de alta o peticiones de pruebas en segundos a partir de la conversación, reduciendo drásticamente el tiempo administrativo que se suele emplear en estas tareas[7].

Sistemas de Soporte a la Decisión Clínica (CDSS) con RAG

Los sistemas de soporte a la decisión tradicionales se basaban en reglas fijas ("si tiene fiebre >38, dar antibiótico"). Los nuevos CDSS basados en IAG son dinámicos y utilizan una técnica crucial llamada *Retrieval-Augmented Generation* o Generación Aumentada por Recuperación (RAG).

¿Qué es un RAG? Imaginemos que la IA es un estudiante en un examen. Un LLM normal responde de memoria (y puede inventar si no sabe la respuesta correcta). Un sistema con RAG es un estudiante que



Figura 2. El escriba médico convierte la conversación en una nota estructurada y reduce la carga administrativa. El CDSS con RAG primero recupera información de fuentes fiables (guías/protocolos) y después genera la respuesta, reduciendo alucinaciones frente a la IAG "normal".

tiene el "libro abierto": ante una pregunta, busca en una base de datos fiable (guías clínicas actualizadas, protocolos del hospital), recupera la información correcta y luego redacta la respuesta.

Una revisión reciente sobre el uso de RAG en entornos asistenciales destaca que esta técnica es fundamental para reducir las alucinaciones (cuando la IA inventa datos con total seguridad) y mejorar la consistencia factual, anclando las respuestas en literatura verificada[8].

¿Y por qué esto es IAG? Porque el sistema genera una justificación clínica detallada y un plan personalizado, no solo una alerta binaria como si estuviera siguiendo un protocolo.

EJEMPLOS PRÁCTICOS EN ORL DE USOS DE IAG

Aterricemos estos conceptos en tareas diarias de nuestro día a día.

Generación de informes quirúrgicos

La redacción de informes quirúrgicos es tediosa y propensa a omisiones. La IAG puede transformar notas breves dictadas o incluso analizar clips de vídeo de la cirugía para generar informes detallados. De hecho, ya existe la tecnología capaz de generar resúmenes completos de vídeos quirúrgicos, detectando instrumentos y acciones y convirtiéndolos en narrativas textuales coherentes útiles para un informe. Este tipo de tecnologías pueden automatizar la generación de documentación postoperatoria con alta precisión[9].

Mapas conceptuales para guías clínicas

Ante la complejidad de ciertas guías de práctica clínica (ej. manejo de masas cervicales o rinoplastia), la IAG puede ayudar a sintetizar la información visualmente. Un estudio comparativo entre ChatGPT y herramientas específicas demostró su utilidad para generar mapas conceptuales a partir de guías de la Academia Americana (AAO-HNSF)[10].

Los autores encontraron que ChatGPT es una herramienta excelente para establecer interconexiones complejas (útil en cirugías como la rinoplastia), mientras que las herramientas específicas destacan en identificar los temas principales (útil en cirugía cervical), facilitando el estudio y la comprensión rápida de protocolos complejos.

Diagnóstico multimodal

En el caso concreto de la otología, ya existen modelos multimodales (que combinan modelo de lenguaje y de visualización de imágenes) que permiten diferenciar entre otitis media serosa y colesteatoma, combinando la imagen de la otoscopia con el texto de la historia clínica. Este tipo de técnicas diagnósticas



Figura 3. Ejemplos prácticos de IA generativa en Otorrinolaringología: automatizar informes, apoyar diagnóstico (incluyendo enfoque visual), resumir guías en mapas, mejorar comunicación con consentimientos e instrucciones postoperatorias, y triaje conversacional con supervisión.

han demostrado una alta precisión diagnóstica (93,7 % para otitis media serosa) al integrar estos datos, superando las limitaciones de los modelos que solo analizan imágenes sin contexto clínico[5].

De cara al paciente: comunicación y educación

Simplificación de documentos y consentimientos

Los consentimientos informados en cirugía de cabeza y cuello suelen ser ininteligibles para el paciente medio, escritos con cierta complejidad. La IAG puede reescribir estos documentos para bajarlos a un nivel de lectura comprensible sin perder precisión.

Herramientas como ChatGPT se llevan utilizando años para simplificar consentimientos quirúrgicos complejos, logrando reducir el nivel de lectura necesario de nivel "universitario" a nivel "escolar", mejorando significativamente la accesibilidad por parte de los pacientes[11]. Este enfoque asegura que el paciente realmente comprende los riesgos, haciendo el consentimiento verdaderamente "informado".

Instrucciones postoperatorias empáticas y claras

Los pacientes a menudo olvidan las instrucciones verbales tras la cirugía. La IAG permite generar guías personalizadas para cada caso concreto. Se ha comparado la eficacia de ChatGPT y Google Gemini para redactar instrucciones postoperatorias en cirugías de nariz (septoplastia, cirugía endoscópica nasosinusal). Aunque ambos generaron textos comprensibles, los modelos pueden tener algunas particularidades. En algunos estudios ChatGPT ofrecía una mayor "comprensibilidad", mientras que Gemini destacaba en "accionabilidad" (facilidad para llevar a cabo las tareas)[12].

Triaje y chatbots

El uso de asistentes conversacionales para el triaje inicial de síntomas (ej. "¿Debo ir a urgencias por este dolor de garganta?") es una realidad emergente. Estos sistemas pueden reducir la ansiedad del paciente y la saturación de los servicios. No obstante, algunas revisiones sistemáticas advierten que los LLM actuales todavía pueden presentar inconsistencias y falta de seguridad en el triaje, por lo que deben ser utilizados con precaución y siempre bajo supervisión[13].

CONCLUSIONES

La Inteligencia Artificial Generativa ha llegado a la Otorrinolaringología no para reemplazarnos, sino para liberarnos.

1. Reducción de carga administrativa: su mayor valor actual reside en eliminar la carga administrativa (escribas, informes automatizados), permitiéndonos dedicar más tiempo a la atención directa del paciente.

2. Copiloto de seguridad: actúa como un segundo par de ojos (oído y cerebro) para el diagnóstico complejo y la revisión de literatura, ofreciendo una "segunda opinión" instantánea basada en la evidencia.

3. *Human in the loop* (El humano en el bucle): la advertencia final es clara. La IAG puede sufrir "alucinaciones" (inventar datos de forma convincente) y presentar sesgos. Por ello, la supervisión humana es innegociable. El médico debe validar siempre lo que la IA genera. Además, debemos ser celosos con la privacidad de los datos. Normativas como el reciente Reglamento de IA de la Unión Europea (EU AI Act)[14] clasifican a la IA médica como de "alto riesgo", exigiendo transparencia, supervisión humana y robustez técnica. Asimismo, es imperativo utilizar técnicas de anonimización robustas antes de alimentar estos sistemas para no comprometer la confidencialidad del paciente[15].

Como especialistas, nuestra responsabilidad es liderar esta adopción tecnológica, asegurando que estas herramientas se utilicen con rigor científico, ética y, sobre todo, en beneficio de nuestros pacientes. La falta de un uso metodológico claro en los estudios actuales

de IA en ORL es un reto que debemos superar para garantizar la reproducibilidad y seguridad de estas herramientas.

CONFLICTO DE INTERESES

Los autores declaran no tener conflictos de interés.

FINANCIACIÓN

No se recibió financiación para la elaboración de este capítulo.

BIBLIOGRAFÍA

1. Alter IL, Chan K, Lechien J, Rameau A. An introduction to machine learning and generative artificial intelligence for otolaryngologists-head and neck surgeons: a narrative review. Eur Arch Otorhinolaryngol. 2024;281(5):2723-31.

2. De Varda AG, D'Elia FP, Kean H, Lampinen A, Fedorenko E. The cost of thinking is similar between large reasoning models and humans. Proc Natl Acad Sci U S A. 2025;122(47):e2520077122.

3. Vallée A. Generative artificial intelligence in otorhinolaryngology: From innovation to public health transformation. Braz J Otorhinolaryngol. 2025;92(1):101714.

4. Long C, Lowe K, Zhang J, Santos A dos, Alanazi A, O'Brien D, et al. A Novel Evaluation Model for Assessing ChatGPT on Otolaryngology-Head and Neck Surgery Certification Examinations: Performance Study. JMIR Med Educ. 2024;10:e49970.

5. Noda M, Yoshimura H, Okubo T, Koshu R, Uchiyama Y, Nomura A, et al. Feasibility of Multimodal Artificial Intelligence Using GPT-4 Vision for the Classification of Middle Ear Disease: Qualitative Study and Validation. JMIR AI. 2024;3:e58342.

6. SEORL-CCC: Inteligencia Artificial y Otorrinolaringología [Internet]. YouTube. Disponible en: https://www.youtube.com/watch?v=4_bNf-GFmrs.

7. SEORL-CCC: IA generativa en la atención al paciente laringectomizado [Internet]. YouTube. Disponible en: https://www.youtube.com/watch?v=mN3jxjp_DVA.

8. Neha F, Bhati D, Shukla DK. Retrieval-Augmented Generation (RAG) in Healthcare: A Comprehensive Review. AI. 2025;6(9):226.

9. Georgenthum H, Cosentino C, Marozzo F, Liò P. Enhancing surgical documentation through multimodal visual-temporal transformers and generative AI [Internet]. arXiv; 2025. Disponible en: https://arxiv.org/abs/2504.19918.

10. Maniaci A, Gagliano C, Salerno V, Cilia N, Lavalle S, Saibene AM, et al. ChatGPT 4.0 and Algor in generating concept maps: an observational study. Eur Arch Otorhinolaryngol. 2025;282(5):2669-77.

11. Ramanathan R, Kelly RJ, Shaw JD, Gopakumar A, Shannon MF, Gonzalez C, et al. Reducing Complexity in Surgical Consents: The Role of AI in Patient Communication. Med Res Arch. 2026;13(12). Disponible en: https://doi.org/10.18103/mra.v13i12.7178.

12. Shaari AL, Bhalla S, Xu A, Patel A, Filimonov A, Hsueh W, et al. Comparative Analysis of Artificial Intelligence Platforms in Generating Post-Operative Instructions for Rhinologic Surgery. Indian J Otolaryngol Head Neck Surg. 2024;77(1):601-3.

13. Busch F, Hoffmann L, Rueger C, van Dijk EH, Kader R, Ortiz-Prado E, et al. Current applications and challenges in large language models for patient care: a systematic review. Commun Med (Lond). 2025;5(1):26.

14. EU Artificial Intelligence Act [Internet]. [citado 19 de enero de 2026]. Disponible en: https://artificialintelligenceact.eu/

15. López SL, Alonso Alemany L, Dias JM, Acción L, Xhardez V. Guía práctica para la protección de datos personales en salud [Internet]. Fundar; CIECTI; 2023. Disponible en: https://fund.ar/wp-content/uploads/2023/03/Fundar_Ciecti_Guia_Proteccion_Datos_Salud_WEB.pdf.

4

Inteligencia artificial y robótica quirúrgica en ORL

José Granell[1,2,3], Hernán López-Tello[1], Isabel Fernández Rastrilla[1], Raimundo Gutiérrez Fonseca[1,4,5]

1. Servicio de Otorrinolaringología, Hospital Universitario Rey Juan Carlos
2. Servicio de Otorrinolaringología, Cirugía de Cabeza y Cuello, y Audiología. Hospital HLA Universitario Moncloa
3. Universidad Europea
4. Otorrinolaringología, Hospital Ruber Internacional
5. Universidad Rey Juan Carlos, Móstoles

INTRODUCCIÓN

En las últimas décadas, la cirugía robótica se ha consolidado como una herramienta fundamental para procedimientos complejos por abordajes de mínima invasión, a la vez que se va transformando la cirugía endoscópica en cirugía robótica de manera progresiva. También en Otorrinolaringología y Cirugía de Cabeza y Cuello. Aunque inicialmente fue concebida como una tecnología de telemanipulación, que amplifica la destreza humana, la cirugía robótica de tejido blando está evolucionando hacia sistemas apoyados en inteligencia artificial (IA) capaces no solo de asistir al cirujano, sino de analizar, aprender y optimizar su desempeño[1].

Elon Musk ha afirmado recientemente que en tres años los robots (el suyo en particular, el *Optimus* de Tesla) podrían superar al mejor cirujano humano[2]. Aunque este tipo de declaraciones generan interés mediático, la realidad clínica es considerablemente más compleja. La práctica quirúrgica implica la integración simultánea de información anatómica, fisiológica, contextual y ética, así como la toma de decisiones dinámicas ante eventos imprevisibles. La enorme cantidad de microdecisiones que un cirujano experto toma en cada intervención, muchas de ellas basadas en juicio clínico contextualizado, hace altamente improbable, en el horizonte inmediato, una sustitución completa del operador humano. La evolución realista no apunta a la reemplazabilidad, sino a la colaboración inteligente entre cirujano y sistema robótico.

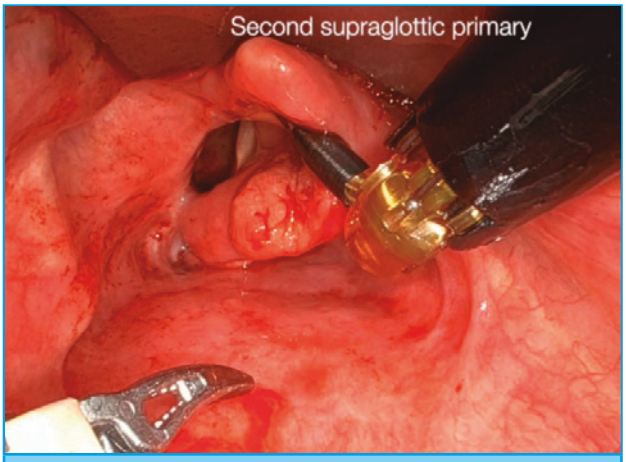


Imagen 1. Exposición para cirugía robótica transoral. Segundo tumor primario en un paciente ya sometido a una cirugía parcial supraglótica. El caso está instrumentado con el faringolaringoscopio FKWO (con la pala larga de TORS), y con el sistema de cirugía robótica da Vinci Xi (con dos instrumentos endowrist, disector de Maryland a la izquierda y espátula monopolar a la derecha).

Este capítulo explora dos líneas centrales de este desarrollo, aparentemente contradictorias: la progresión hacia la cirugía robótica autónoma, y las aplicaciones actuales de IA que optimizan el desempeño humano. Incluimos además un apartado específico sobre robótica e IA en cirugía otológica.

EVOLUCIÓN HACIA LA CIRUGÍA ROBÓTICA AUTÓNOMA

La instrumentación robotizada en cirugía de tejido blando ha aportado visión tridimensional ampliada,



Figura 1. Niveles de autonomía en cirugía robótica (adaptado de Yang et al. https://doi.org/10.1126/scirobotics.aam8638). Considera 6 niveles, desde el nivel 0 (sin autonomía) hasta el nivel 5 (autonomía total).

integración progresiva de la realidad aumentada, filtrado del temblor fisiológico, escalado de movimientos y mejoras ergonómicas significativas. Estas características han tenido un particular impacto clínico en espacios anatómicos de difícil acceso[3]. (**Imagen 1**)

Tradicionalmente, estos sistemas han permanecido bajo control íntegro del cirujano. La integración de la IA busca ahora permitir que los sistemas interpreten datos visuales, cinemáticos y contextuales para anticipar estados quirúrgicos, sugerir decisiones y ejecutar subtareas con grados crecientes de autonomía. Existe abundante literatura teórica sobre los grados de autonomía robótica; tomaremos la clasificación de Yang et al.[4] (**Figura 1**)

Uno de los desarrollos más relevantes en este sentido es el *Surgical Robot Transformer* (SRT), una arquitectura basada en modelos tipo transformer, capaces de aprender habilidades quirúrgicas a partir de datos multimodales[5]. Estos modelos procesan grandes volúmenes de vídeo quirúrgico sincronizado con datos cinemáticos para identificar patrones técnicos complejos. En entornos experimentales han demostrado capacidad para reproducir tareas como manipulación instrumental o sutura, con niveles de precisión y reproductibilidad cercanos al desempeño humano, sentando las bases de una futura robótica autónoma o semiautónoma. Puede consultarse el proyecto en la web del repositorio GitHub conjunto de la Universidad de Stanford y la Johns Hopkins[6].

Un aspecto de la cirugía robótica de tejido blando en el que potencialmente podría progresarse hacia la automatización de tareas es la microsutura vascular. Esta podría ser una evolución natural de los robots de supermicrocirugía como el *Symani*.

Este enfoque se inspira en la capacidad de los modelos para generalizar más allá de datos de entrenamiento concretos, lo que abre potencialmente la puerta a sistemas que no solo ejecuten movimientos predefinidos, sino que interpreten el contexto anatómico y técnico, ajusten su comportamiento en tiempo real y colaboren con el cirujano de forma proactiva. Aunque estos desarrollos aún se encuentran en fases experimentales, constituyen un cambio de paradigma que transforma la manera en que concebimos las relaciones entre el cirujano y la plataforma robótica.

APLICACIONES ACTUALES DE IA EN CIRUGÍA ROBÓTICA

Mientras la autonomía robótica permanece en fase experimental, la IA ya está transformando la práctica quirúrgica mediante herramientas de análisis y mejora del desempeño.

La quinta generación del sistema de cirugía robótica da Vinci (*Intuitive Surgical*) (**Imagen 2**) incorpora una arquitectura de computación significativamente ampliada, capaz de capturar vídeo en alta resolución, datos cinemáticos de los manipuladores maestros, y métricas de fuerza en tiempo real. La función *In-Console Video Replay* permite, por ejemplo, revisar momentos críticos durante la propia intervención, optimizando la toma de decisiones intraoperatorias. El sistema integra métricas como el *Force Gauge*, que registra en tiempo real la fuerza aplicada en la punta de los instrumentos. Esta información cuantitativa mejora la percepción tisular y puede reducir fuerzas excesivas sobre estructuras delicadas.

Una innovación clave es la infraestructura de almacenamiento seguro en la nube. Los datos quirúrgicos (anonimizados) pueden ser procesados por algoritmos de IA que generan análisis personalizados de desempeño (*surgical coaching*). Este modelo permite evaluar la economía de movimientos, los tiempos de instrumentación, las trayectorias subóptimas o la eficiencia técnica, proporcionando retroalimentación objetiva basada en métricas cuantificables.

Este paradigma transforma la formación quirúrgica hacia un modelo escalable, reproducible y basado en datos globales agregados, donde la experiencia colectiva de los cirujanos a nivel global puede alimentar algoritmos que devuelven recomendaciones individualizadas. La limitación actual de esto no es técnica, sino legal (o ética, según se interprete).

Además del *coaching*, la IA puede mejorar otros aspectos de la cirugía robótica. La realidad aumentada implica diversas formas de asistencia por IA, por ejemplo, técnicas de segmentación automática de estructuras críticas (nervios, vasos, márgenes tumorales) integradas al flujo visual del robot para asistir en la toma de decisiones. El proyecto PTAIR 2.0 (*Parathyroid Gland Artificial Intelligence Recognition*) utiliza un modelo de aprendizaje profundo que mejora la identificación de las glándulas paratiroides durante la tiroidectomía endoscópica o robótica. Este sistema supera incluso a cirujanos experimentados en el reconocimiento en tiempo real y en la evaluación de la isquemia[7].

Existe además un inmenso potencial en la simulación y el entrenamiento virtual, que usan aprendizaje adaptativo para la adquisición de habilidades específicas o la recreación de situaciones clínicas realistas que mejoren la curva de aprendizaje del cirujano, y que están cambiando la propia forma de enseñar y aprender cirugía.

ROBÓTICA E IA EN OTOLOGÍA: ENFOQUE EN IMPLANTACIÓN COCLEAR

La progresión hacia mayores niveles de autonomía robótica ha sido históricamente más rápida en procedimientos quirúrgicos sobre tejido duro (hueso), donde la referenciación espacial es más estable y reproducible. En este contexto, existen desde hace años sistemas de asistencia robotizada en cirugía ortopédica, como Mako (*Stryker*) o Rosa (*Zimmer Biomet*), para la planificación y colocación de prótesis articulares. La cirugía otológica representa un caso particular de cirugía sobre tejido duro, ya que combina el trabajo sobre hueso con la necesidad de una precisión exquisita por la proximidad de estructuras críticas (el nervio facial, el oído interno).

Desde finales de la década de 2010, la robótica ha comenzado a integrarse clínicamente en la implantación coclear. Los primeros ensayos clínicos en humanos se publicaron en 2017[8], demostrando la viabilidad del acceso robótico guiado por imagen.

Actualmente, la robotización en implantación coclear se centra en dos etapas clave.

La primera es el acceso a la cóclea. El sistema realiza el labrado de un túnel desde la cortical mastoidea hasta la cóclea siguiendo una trayectoria planificada preoperatoriamente mediante TC de alta resolución. Los algoritmos de planificación segmentan automáticamente estructuras críticas (nervio facial, cuerda del tímpano, oído interno) y calculan trayectorias seguras optimizadas. Durante el fresado, la navegación y los sistemas de verificación intraoperatoria (por ejemplo, la neuromonitorización) garantizan que la desviación se mantenga dentro de márgenes de seguridad submilimétricos. Este proceso reduce la variabilidad técnica y aumenta la reproductibilidad, pero manteniendo siempre supervisión humana.

La segunda fase robotizada es la inserción lenta del electrodo. La inserción manual puede generar microtraumatismos asociados a fuerzas irregulares; además, el ritmo de inserción robotizado no es reproducible por un operador humano. Los sistemas robotizados permiten velocidades constantes y controladas, extremadamente lentas, con fuerzas monitorizadas en tiempo real, optimizando el carácter atraumático del procedimiento. Esta inserción controlada puede potencialmente mejorar la preservación de estructuras intracocleares y favorecer resultados auditivos más predecibles.

La IA interviene tanto en la planificación preoperatoria como en la adaptación intraoperatoria a variaciones anatómicas. Sin embargo, incluso en este entorno altamente estructurado, el sistema actúa bajo supervisión directa del cirujano. La implantación coclear robotizada representa así uno de los ejemplos clínicos más avanzados de autonomía robótica parcial en ORL, situándose en el nivel 2 de la clasificación de Yang (el sistema de cirugía robótica da Vinci sigue siendo nivel 0).

CONCLUSIONES

La integración de inteligencia artificial en la cirugía robótica está redefiniendo la práctica de la cirugía en general, y de la Otorrinolaringología en particular. La IA ya está presente en herramientas de coaching, análisis de desempeño, visión asistida y simulación, que mejoran la seguridad, la formación y la eficacia del cirujano. Mientras tanto, proyectos de vanguardia como los basados en modelos tipo transformer avanzan hacia la posibilidad de sistemas robóticos semiautónomos, capaces de analizar contextos quirúrgicos y colaborar dinámicamente con el operador.

Esta hibridación de capacidades representa un paso fundamental hacia un futuro en el que la robótica no solo instrumenta al cirujano, sino que lo acompaña activamente en su aprendizaje y práctica, elevando los estándares de calidad y seguridad en el cuidado de nuestros pacientes.



Imagen 2. El da Vinci 5 (año 2025) es la quinta generación del sistema de cirugía robótica da Vinci. Su mayor capacidad de computación y su arquitectura con soporte seguro en la nube permiten el análisis anonimizado de vídeo y datos quirúrgicos a escala global, impulsando aplicaciones de inteligencia artificial y *surgical coaching*.

CONFLICTO DE INTERESES

José Granell actúa desde el año 2017 como tutor (proctor) de cirugía robótica transoral para Intuitive Surgical, fabricante del sistema de cirugía robótica da Vinci.

FINANCIACIÓN

No se recibió financiación para la elaboración de este capítulo.

BIBLIOGRAFÍA

1. Liu Y, Wijewickrema S, Copson B, Gerard JM, Antani S. Artificial intelligence assurance in head and neck surgery: now and next. Proc IEEE Int Symp Comput Based Med Syst. 2025;2025:977-82. https://doi.org/10.1109/cbms65348.2025.00195.

2. Elon Musk: AI-powered robots could surpass best human surgeons within three years [Internet]. The Independent; 2026 [citado 18 feb 2026]. Disponible en: https://www.independent.co.uk/tech/elon-musk-ai-optimus-surgeons-b2897000.html.

3. Weinstein GS, O'Malley BW Jr, Desai SC, Quon H. Transoral robotic surgery: does the ends justify the means? Curr Opin Otolaryngol Head Neck Surg. 2009;17(2):126-31. https://doi.org/10.1097/MOO.0b013e32832924f5.

4. Yang GZ, Cambias J, Cleary K, Daimler E, Drake J, Dupont PE, et al. Medical robotics: regulatory, ethical, and legal considerations for increasing levels of autonomy. Sci Robot. 2017;2(4):eaam8638. https://doi.org/10.1126/scirobotics.aam8638.

5. Shi C, Zheng Y, Fey AM. Recognition and prediction of surgical gestures and trajectories using transformer models in robot-assisted surgery. IEEE/RSJ Int Conf Intell Robots Syst (IROS). 2022:8017-24. https://doi.org/10.1109/IROS47612.2022.9981611.

6. Surgical Robot Transformer [Internet]. Stanford University, Johns Hopkins University; [citado 18 feb 2026]. Disponible en: https://surgical-robot-transformer.github.io/.

7. Wang B, Yu JF, Lin SY, Li YJ, Huang WY, Yan SY, et al. Intraoperative AI-assisted early prediction of parathyroid and ischemia alert in endoscopic thyroid surgery. Head Neck. 2024;46(8):1975-87. https://doi.org/10.1002/hed.27629.

8. Caversaccio M, Gavaghan K, Wimmer W, Williamson T, Ansó J, Mantokoudis G, et al. Robotic cochlear implantation: surgical procedure and first clinical experience. Acta Otolaryngol. 2017;137(4):447-54. https://doi.org/10.1080/00016489.2017.1278573.

5

Aplicaciones actuales de la inteligencia artificial en otología

Andrea López Salcedo, Isidora Rettig Infante, Alejandro Pozuelo Moreno, Carlos Franco Fente
Servicio de Otorrinolaringología, Hospital Infanta Sofía, San Sebastián de los Reyes

INTRODUCCIÓN

En Otología convivimos con tecnologías que ya han transformado la práctica clínica diaria: otoscopia digital, otoendoscopia en consulta, TC de alta resolución del temporal, audiometrías almacenadas de forma sistemática y telemetría de dispositivos. En ese contexto, la inteligencia artificial (IA) puede entenderse de manera práctica como un conjunto de herramientas capaces de aprender patrones a partir de muchos ejemplos y, después, ofrecer una ayuda concreta: clasificar una imagen, señalar una región de interés o estimar un resultado probable.

Para tener valor real, estas soluciones se pueden evaluar frente a tres objetivos: ¿reduce la variabilidad entre observadores?, ¿ahorra tiempo sin comprometer seguridad?, ¿ayuda a detectar antes lo relevante? Una revisión reciente centrada en Otología describe precisamente este cambio: pasar del entusiasmo general por la IA a identificar casos de uso plausibles, evaluarlos con criterios asistenciales y auditar su rendimiento en condiciones cercanas a la práctica real[1].

La Otología reúne condiciones favorables para estos desarrollos por dos motivos principales. Primero, muchas decisiones dependen de información visual (otoscopia, otoendoscopia, imagen del temporal) donde la variabilidad interobservador es un problema conocido. Segundo, la audiología genera datos comparables a lo largo del tiempo, lo que facilita el seguimiento longitudinal y abre la puerta a predicciones sobre evolución o respuesta terapéutica. Hoy, las aplicaciones con mayor madurez se concentran en tres áreas: (1) interpretación asistida de otoscopia/otoendoscopia, (2) apoyo al análisis de imagen del temporal y (3) audiología e implante coclear, sobre todo para ajustar expectativas y personalizar el seguimiento[1].

OTOSCOPIA Y OTOENDOSCOPIA ASISTIDAS: DEL CRIBADO A LA TELEOTOLOGÍA

La otoscopia es una exploración básica, pero también una de las más exigentes de interpretar. En la práctica, la calidad de la imagen se ve condicionada por factores cotidianos: cerumen, estrechez del conducto auditivo externo, movimientos del paciente (especialmente en pediatría), iluminación, enfoque, reflejos, secreciones. Incluso con una imagen "correcta", la interpretación puede variar según la experiencia del explorador. Por eso, si un sistema aprende a reconocer patrones timpánicos frecuentes, su aportación más realista no sería "diagnosticar por sí solo", sino estandarizar parte del cribado y hacer más segura la toma de decisiones en entornos donde no hay un otorrinolaringólogo disponible.

La evidencia agregada sugiere que los modelos pueden alcanzar rendimientos altos en clasificación de patología ótica, pero también señala limitaciones importantes. Un metaanálisis en Clinical Otolaryngology concluyó que, aunque la IA es prometedora, son recurrentes la heterogeneidad de etiquetas diagnósticas, los sesgos en la selección de imágenes y, sobre todo, la falta de validación externa. En otras palabras: muchos sistemas funcionan mejor en el hospital donde se entrenaron y empeoran cuando se aplican a otros centros, dispositivos o poblaciones[2]. **(Figuras 1 y 2)**

En otoendoscopia se han publicado modelos para distinguir un tímpano normal de alteraciones frecuentes como otitis seromucosa o perforación timpánica. Khan y colaboradores describieron un enfoque basado en redes neuronales entrenadas con imágenes otoendoscópicas y resultados muy altos dentro de su propio conjunto de datos[3]. Aquí aparece un punto clave para el uso clínico: qué ocurre cuando

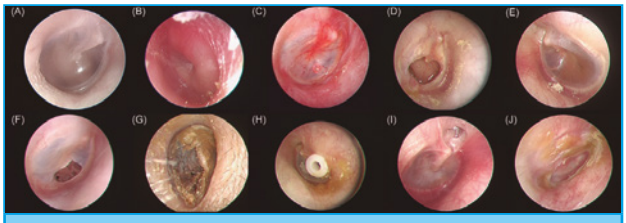


Figura 1. Imágenes representativas de 10 situaciones comunes en la otoscopia: (A) membrana timpánica normal, (B) otitis media aguda, (C) membrana timpánica congestiva, (D) otitis media crónica supurativa, (E) otitis media serosa, (F) perforación de membrana timpánica, (G) impactación de tapón de cerumen, (H) tubo de ventilación transtimpánico, (I) retracción de membrana timpánica, (J) otomicosis[4].

la imagen es subóptima, algo habitual en consulta. Si el sistema se atreve a dar una impresión diagnóstica aun con imágenes artefactadas, el riesgo aumenta. En cambio, si es capaz de reconocer que la imagen no es interpretable y recomienda repetir la captura o derivar, su valor asistencial puede ser mayor, porque introduce una conducta más segura.

En una línea similar, Chen y colaboradores publicaron un sistema basado en imágenes obtenidas con *smartphone* y técnicas de transferencia de aprendizaje para detectar y clasificar patología del oído medio, con el objetivo de facilitar cribado y telemedicina[4]. El mensaje clínicamente útil no debería ser "la IA diagnostica otitis", sino algo más operativo: puede ayudar a ordenar el circuito asistencial, priorizar derivaciones y reducir decisiones precipitadas, siempre que estén controladas la calidad de imagen y la validez fuera del entorno donde se desarrolló[2,4]. (**Figura 3**)

Por tanto, la entrada más lógica de estas herramientas es como apoyo en tres contextos: (1) teleotología y cribado desde atención primaria, (2) segunda opinión rápida en consulta ante dudas frecuentes y (3) docencia, porque obliga a definir con rigor qué constituye una imagen útil y cómo se etiqueta.

IA EN RADIOLOGÍA DEL TEMPORAL: APOYO A LA LECTURA Y PLANIFICACIÓN ANATÓMICA

La imagen del hueso temporal es otro territorio natural para la IA. Conviene diferenciar dos líneas de trabajo que, aunque se solapan, persiguen objetivos distintos: (1) detección o clasificación de entidades (p. ej., otosclerosis, colesteatoma) a partir de TC o RM, y (2) segmentación automática de estructuras anatómicas para facilitar la planificación y reducir tiempos.

En otosclerosis, la utilidad potencial es clara: hallazgos fenestrales sutiles, variabilidad en la lectura y necesidad de integrar clínica y audiometría con

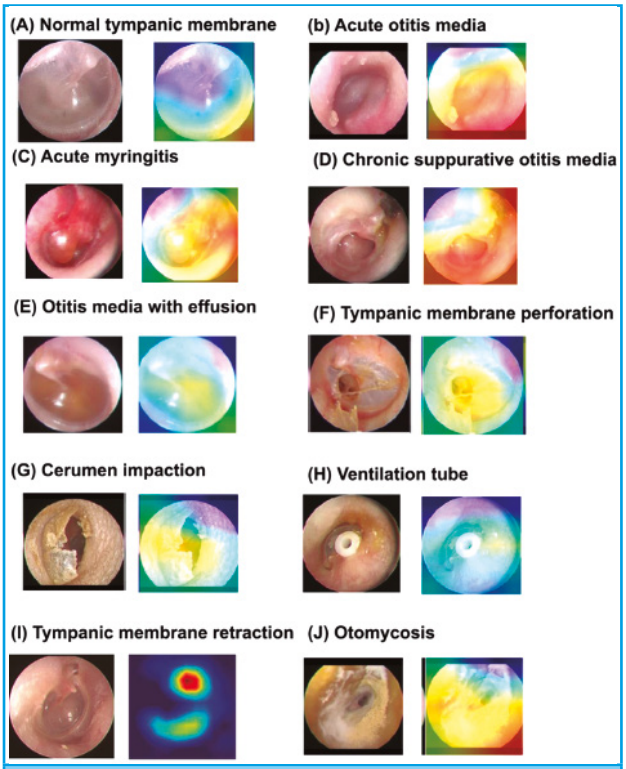


Figura 2. Mapas de activación de clase (CAM) representativos de 10 enfermedades comunes del tímpano y del oído medio. Un CAM es una representación similar a un mapa de calor de los datos generados mediante la agrupación de promedios globales. Los puntos calientes (rojos) representan las partes más relevantes del objeto[4].

la imagen. Se han publicado modelos que detectan otosclerosis en TC del temporal y, además, señalan regiones que contribuyen a la predicción, lo que ayuda a que el clínico entienda qué analiza el sistema[5]. En la práctica, esto podría aportar valor como criterio adicional cuando la sospecha clínica es fuerte y el informe es equívoco, o para homogeneizar criterios en entornos con distinta experiencia radiológica.

El colesteatoma es un problema más complejo. Una revisión sistemática reciente resume que muchos estudios reportan precisiones altas en validación interna, pero el rendimiento suele caer en validación externa, lo que refleja la heterogeneidad de la enfermedad y las diferencias entre protocolos de imagen[6]. Por eso, la IA no debería presentarse como sustituto del juicio clínico, sino como apoyo para estructurar informes y priorizar estudios. En escenarios donde la TC es poco concluyente y la clínica sugiere enfermedad, una herramienta que señale regiones sospechosas podría apoyar la decisión de completar el estudio con RM de difusión. El valor, de nuevo, está en mejorar la seguridad del circuito, no en automatizar una decisión compleja.

La segmentación anatómica es especialmente relevante para la Otología quirúrgica porque convierte la imagen

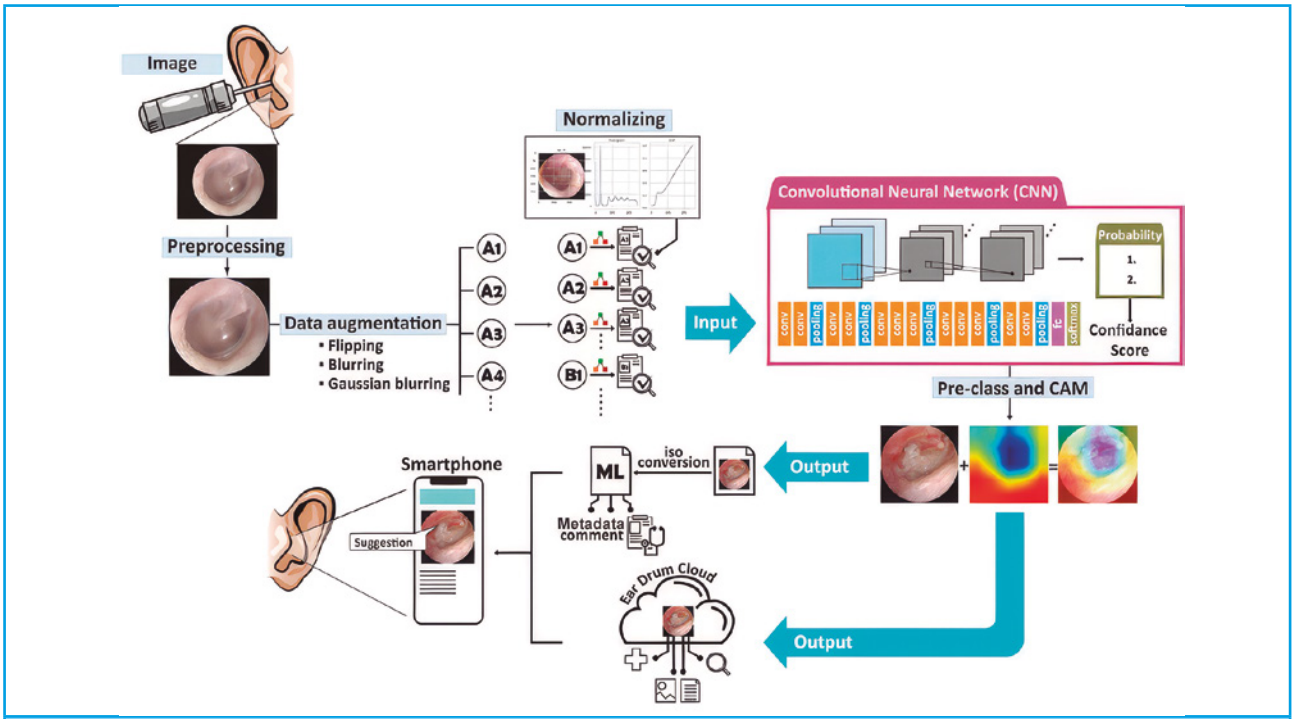


Figura 3. Desarrollo de un programa informático para *smartphone*s para diagnosticar enfermedades del oído medio y ofrecer sugerencias médicas. Cada capa extrae diferentes características de la membrana timpánica y todas las características extraídas se integran para determinar el tipo de enfermedad del oído y el tratamiento correspondiente[4].

en un modelo preoperatorio más accionable. Aquí el beneficio no depende de acertar un diagnóstico, sino de identificar estructuras y relaciones espaciales entre ellas. Ding y colaboradores evaluaron un modelo de segmentación 3D en CBCT del temporal con buen rendimiento en múltiples estructuras[7]. Estas herramientas podrían reducir el tiempo de preparación y facilitar la comprensión tridimensional, sobre todo en reintervenciones o anatomías complejas, además de reforzar la seguridad si se integran en sistemas de navegación. (**Figura 4**)

AUDIOLOGÍA E IMPLANTE COCLEAR

Si en radiología el reto principal es la calidad y la generalización, en audiología el reto es otro: evitar que la tecnología se evalúe solo con métricas técnicas y no con resultados clínicamente relevantes. Las revisiones recientes describen un abanico de aplicaciones: cribado, audiometría asistida, clasificación de patrones audiométricos, predicción de evolución y apoyo a la rehabilitación[8,9]. Sin embargo, el impacto real debería medirse con variables que importan al paciente y al sistema: comprensión del habla en ruido, adherencia al uso, reducción del abandono del dispositivo y optimización de recursos.

La audiometría asistida puede ser útil en entornos de alta demanda o con acceso limitado, pero solo si incorpora control de calidad y criterios claros de derivación. En rehabilitación con audífonos, muchas mejoras atribuidas a IA se concretan en ajustes dinámicos y mejora del habla en ruido; para el otorrinolaringólogo, la pregunta clave es si eso se traduce en mayor satisfacción, uso real y funcionalidad cotidiana[9].

El implante coclear es probablemente el escenario donde más se desea una herramienta predictiva robusta. Existe variabilidad sustancial de resultados, y la conversación preoperatoria exige equilibrar expectativas, indicación y planificación rehabilitadora. La literatura ha crecido, pero repite problemas de estandarización y validación externa[10]. Por ello, la promesa no debería formularse como predicción exacta del resultado, sino como estratificación de incertidumbre: identificar perfiles con alta probabilidad de buen beneficio y perfiles donde la variabilidad es mayor, de modo que sea razonable reforzar seguimiento, ajustar expectativas o considerar alternativas.

También se exploran aplicaciones para el ajuste y el seguimiento longitudinal. Aquí el marco de seguridad es especialmente importante: la IA debería funcionar como copiloto, con capacidad de auditoría, registro de incertidumbre y decisión final del equipo clínico. El principal riesgo no es técnico, sino humano: el sesgo de automatización, es decir, delegar decisiones complejas en un sistema sin comprender bien sus límites.

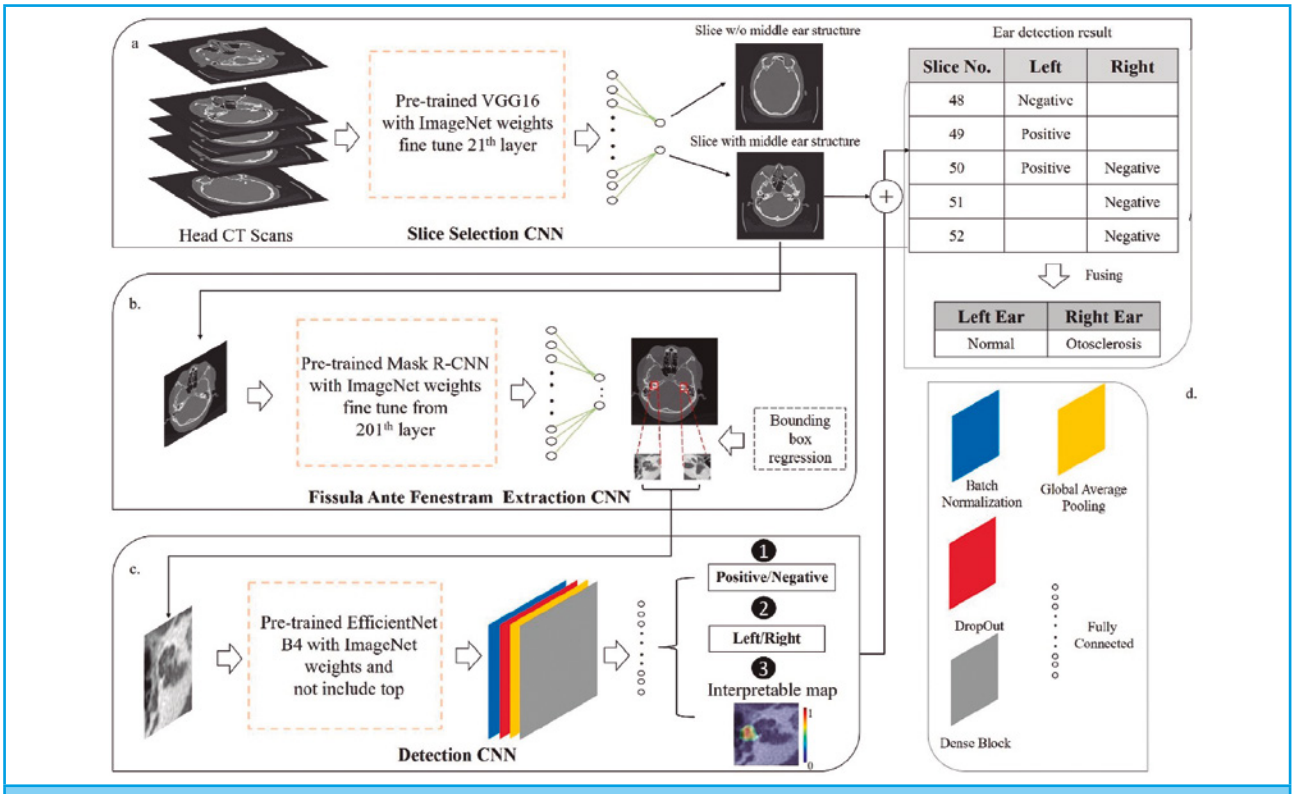


Figura 4. Descripción general del sistema OtoModel. El sistema consta de tres etapas: (a) identificar los cortes con la estructura del oído medio y generar el resultado de detección, (b) extraer características de imagen de los cortes seleccionados y predecir las coordenadas de un cuadro delimitador que define la región de la fisula ante fenestram, (c) calcular la probabilidad de clasificación de otosclerosis en los cortes seleccionados, (d) diagrama simplificado de la arquitectura de la red neuronal[5].

ADOPCIÓN DE LA TECNOLOGÍA

El punto clave no es solo describir qué puede hacer la IA, sino definir qué requisitos mínimos deberían cumplirse antes de considerarla una herramienta clínicamente recomendable. En medicina, un sistema puede funcionar en un artículo y, aun así, no ser fiable en la práctica real. Por eso, el primer filtro debería ser la validación externa: comprobar que el rendimiento se mantiene cuando se usa con datos de otros centros, con otros equipos de imagen o con poblaciones distintas a las del hospital donde se entrenó[2,6,10]. Sin esa comprobación, es fácil confundir un buen resultado experimental con un desempeño verdaderamente generalizable.

Además, en consulta y en urgencias hay una realidad que los estudios a veces simplifican: no todas las imágenes ni todos los registros son interpretables. Una herramienta útil no es la que siempre responde, sino la que sabe identificar cuándo no tiene base suficiente para ayudar. Esto implica que el sistema debería ser capaz de señalar incertidumbre o baja calidad de entrada y activar una conducta segura: repetir la prueba, pedir una segunda lectura o recomendar derivación, en lugar de ofrecer una clasificación aparentemente concluyente.

El tercer requisito es que la IA no se evalúe solo por su precisión técnica, sino por su impacto asistencial real. En Otología, lo relevante es si reduce variabilidad entre profesionales, si evita derivaciones innecesarias sin aumentar errores, si acelera el diagnóstico de lo relevante o si mejora la planificación en escenarios complejos como reintervenciones. Es decir: menos métricas abstractas y más resultados clínicos que se traduzcan en seguridad, eficiencia y mejor experiencia del paciente.

También importa mucho cómo se integra en el trabajo diario. Si la herramienta obliga a salir del flujo habitual, cargar archivos manualmente o duplicar documentación, lo más probable es que se use poco o solo de forma experimental. La adopción sostenida suele depender de que la tecnología se acople a lo que ya hacemos (PACS, historia clínica, circuitos de derivación, plantillas de informe) y de que aporte valor sin añadir fricción.

Por último, cualquier recomendación debería abordar explícitamente responsabilidad profesional y formación. La evidencia muestra interés entre profesionales de salud auditiva por la IA como apoyo, pero también preocupaciones razonables: quién asume la responsabilidad si falla, si el uso prolongado puede

erosionar habilidades, y qué tipo de capacitación se necesita para interpretar resultados sin caer en una confianza excesiva[11]. En la práctica, el mayor riesgo no suele ser "que la IA se equivoque", sino que el humano deje de cuestionarla.

CONCLUSIONES

La IA en Otología ya no es un horizonte abstracto. Existen aplicaciones con plausibilidad clínica para apoyar la interpretación de otoscopia/otoendoscopia, mejorar la consistencia en la lectura de imágenes del temporal y avanzar hacia una planificación anatómica más eficiente[2-7]. En audiología e implante coclear, el potencial más relevante es la personalización del seguimiento y la gestión de la incertidumbre[8-10]. El paso decisivo para una adopción segura será disponer de herramientas validadas externamente, integradas en flujos clínicos, capaces de reconocer sus límites y evaluadas por impacto asistencial. En ese escenario, la IA no compite con el otorrinolaringólogo: lo refuerza, siempre que la gobernanza clínica permanezca en manos de la especialidad.

CONFLICTO DE INTERESES

Los autores declaran no tener conflictos de interés.

FINANCIACIÓN

No se recibió financiación para la elaboración de este capítulo.

BIBLIOGRAFÍA

1. Koyama H, Kashio A, Yamasoba T. Application of artificial intelligence in otology: past, present, and future. J Clin Med. 2024;13(24):7577. https://doi.org/10.3390/jcm13247577.

2. Habib AR, Kajbafzadeh M, Hasan Z, Wong E, Gunasekera H, Perry C, et al. Artificial intelligence to classify ear disease from otoscopy: a systematic review and meta-analysis. Clin Otolaryngol. 2022;47(3):401-13. https://doi.org/10.1111/coa.13925.

3. Khan MA, Kwon S, Choo J, Hong SM, Kang SH, Park IH, et al. Automatic detection of tympanic membrane and middle ear infection from oto-endoscopic images via convolutional neural networks. Neural Netw. 2020;126:384-94. https://doi.org/10.1016/j.neunet.2020.03.023.

4. Chen YC, Chu YC, Huang CY, Lee YT, Lee WY, Hsu CY, et al. Smartphone-based artificial intelligence using a transfer learning algorithm for the detection and diagnosis of middle ear diseases: a retrospective deep learning study. EClinicalMedicine. 2022;51:101543. https://doi.org/10.1016/j.eclinm.2022.101543.

5. Wang Z, Song J, Lin K, Hong W, Mao S, Wu X, et al. Automated detection of otosclerosis with interpretable deep learning using temporal bone computed tomography images. Heliyon. 2024;10(8):e29670. https://doi.org/10.1016/j.heliyon.2024.e29670.

6. Shabi SM, Almutairi LB, Moafa AN, Omer RA, Alghamdi AM, Alhemaidi HS, et al. Artificial intelligence in the diagnosis of cholesteatoma: a systematic review of current evidence. Cureus. 2025;17(11):e96154. https://doi.org/10.7759/cureus.96154.

7. Ding AS, Lu A, Li Z, Sahu M, Galaiya DJ, Siewerdsen J, et al. A self-configuring deep learning network for segmentation of temporal bone anatomy in cone-beam CT imaging. Otolaryngol Head Neck Surg. 2023;169(1):80-90. https://doi.org/10.1002/ohn.261.

8. Frosolini A, Di Stadio A, Ciabatta A, Iannone L, Scaldaferri A, Lucidi D, et al. Artificial intelligence and machine learning in audiology: a scoping review. Sensors (Basel). 2024;24(18):6135. https://doi.org/10.3390/s24186135.

9. AlSamhori JF, AlSamhori ARF, Amourah RM, AlQadi Y, Koro ZW, Haddad TRA, et al. Artificial intelligence for hearing loss prevention, diagnosis, and management. J Med Surg Public Health. 2024;3:100133. https://doi.org/10.1016/j.glmedi.2024.100133.

10. Nair APS, Mishra SK, Alba Diaz PA. A systematic review of machine learning approaches in cochlear implant outcomes. npj Digit Med. 2025;8:411.

11. Oremule B, Saunders GH, Kluk K, d'Elia A, Bruce IA. Understanding, experience and attitudes towards artificial intelligence technologies for clinical decision support in hearing health: a mixed-methods survey of healthcare professionals in the UK. J Laryngol Otol. 2024;138(9):928-35. https://doi.org/10.1017/S0022215124000550.

6

Aplicaciones en otoneurología

Iván Muerte Moreno[1], Tomás Delgado Sánchez[1], Inés Eugenia Purroy Ortega[1], Ignacio Alcalá Rueda[2]

1. Servicio de Otorrinolaringología, Hospital Universitario Clínico San Carlos
2. Servicio de Otorrinolaringología, Hospital Universitario General de Villalba

INTRODUCCIÓN

El paciente con vértigo constituye uno de los motivos de consulta más frecuentes en Otorrinolaringología. Su evaluación requiere una historia clínica exhaustiva orientada a numerosos criterios diagnósticos, definidos por sociedades internacionales como la Sociedad Bárány, junto con la interpretación de la exploración oculomotora y de los patrones de control postural, con el objetivo de realizar un correcto diagnóstico diferencial y orientar el manejo terapéutico. Sin embargo, el proceso de anamnesis consume tiempo y muchos de los signos exploratorios son sutiles, transitorios o pueden pasar desapercibidos, además de presentar cierta variabilidad interobservador.

Las aplicaciones más recientes de la inteligencia artificial se centran en el apoyo al diagnóstico diferencial, la interpretación de las pruebas vestibulares y el análisis objetivo de los movimientos oculares, así como en la integración conjunta de la información clínica, exploratoria y de las pruebas vestibulares, con el fin de mejorar la precisión clínica y reducir el riesgo de error diagnóstico asociado a la complejidad del manejo del paciente con vértigo.

HISTORIA CLÍNICA ASISTIDA: ORDENAR, ESTRUCTURAR Y APOYAR EL RAZONAMIENTO CLÍNICO

En la práctica clínica diaria puede resultar un reto aplicar de forma sistemática los criterios diagnósticos propuestos por sociedades internacionales, lo que con frecuencia se traduce en historias clínicas extensas y heterogéneas, dependientes del tiempo disponible y del enfoque del otorrinolaringólogo. Además, la existencia de síntomas solapados entre entidades frecuentes como la migraña vestibular, la enfermedad de Ménière o el mareo perceptual persistente puede dificultar aún más la anamnesis y el diagnóstico diferencial.

En este contexto, los grandes modelos de lenguaje pueden integrarse como asistentes clínicos destinados a apoyar la recogida y organización de la información, sin intervenir directamente en el proceso diagnóstico. En la práctica, su aplicación se basa en la transcripción y estructuración de la entrevista clínica, permitiendo convertir el relato del paciente en una historia ordenada y legible[1], generar resúmenes clínicos y señalar información relevante que pueda haber pasado desapercibida. Esta integración no requiere cambios en la exploración ni en la toma de decisiones, y actúa como una herramienta de apoyo para ahorrar tiempo, mejorar la calidad de la documentación clínica y facilitar la comunicación con el paciente.

Una vez estructurada esta información clínica, pueden emplearse modelos específicos basados en variables tabuladas para orientar el diagnóstico diferencial. En este sentido, se han desarrollado sistemas de apoyo a la anamnesis como CatBoost, un método que integra de forma sistemática las respuestas de la historia clínica estructurada, obtenidas mediante cuestionarios clínicos estandarizados cumplimentados previamente o durante la consulta. En su validación, este enfoque alcanzó una precisión global del 88,4 %[2] y mostró un perfil especialmente útil para la consulta, con alta especificidad para la enfermedad de Ménière (≈96 %), evitando sobrediagnósticos, y buena sensibilidad para entidades prevalentes como el VPPB. En la práctica, se traduce en una herramienta que ordena la información del paciente y sugiere hipótesis probables, facilitando una anamnesis dirigida hacia el diagnóstico clínico final, sin sustituir el juicio del especialista.

De forma complementaria, la inteligencia artificial ha demostrado utilidad en la valoración objetiva del hidrops endolinfático mediante resonancia magnética. Sistemas como INHEARIT[3] permiten analizar de manera automatizada secuencias específicas de RM, segmentando el oído interno y cuantificando de forma reproducible el grado de hidrops coclear y vestibular. Esto reduce la subjetividad y el tiempo de evaluación respecto a la medición manual, y facilita la comparación entre estudios y el seguimiento evolutivo de pacientes con enfermedad de Ménière[4].

En conjunto, estas aplicaciones permiten integrar la inteligencia artificial como un apoyo realista y aplicable en la consulta del otoneurólogo, favoreciendo una anamnesis más estructurada, una interpretación más objetiva de la información clínica y radiológica y una reducción de la variabilidad entre exploradores. Lejos de sustituir el juicio clínico, estas herramientas actúan como un complemento que ayuda a ordenar la información, apoyar el razonamiento diagnóstico y optimizar el tiempo disponible en la práctica diaria.

HINTS ASISTIDO POR INTELIGENCIA ARTIFICIAL

En el síndrome vestibular agudo (SVA), un diagnóstico temprano y fiable es crucial para distinguir un ictus de una causa vestibular periférica. Aunque el protocolo HINTS ha demostrado ser más sensible que la resonancia magnética en las primeras 24-48 horas, su aplicación depende en gran medida de la experiencia del examinador y, por tanto, es susceptible de variabilidad interobservador.

Modelos basados en inteligencia artificial han demostrado resultados cuantitativos prometedores al analizar directamente registros instrumentales obtenidos en la práctica clínica. En un estudio prospectivo con 57 pacientes con SVA, un modelo que procesó las series temporales crudas del vHIT logró una sensibilidad del 87,7 %, una especificidad del 88,4 % y una exactitud global del 87,9 % para diferenciar ictus de vestibulopatía periférica, con un rendimiento comparable al de la interpretación experta basada en la ganancia del reflejo vestíbulo-ocular5.

Del mismo modo, cuando se integran múltiples fuentes de datos instrumentales, como parámetros de videonistagmografía, vHIT y posturografía, los modelos de aprendizaje automático superan a escalas clínicas tradicionales en la diferenciación de causas centrales y periféricas de SVA. En este contexto, se ha descrito un modelo multimodal con un área bajo la curva (AUC) de 0,96, claramente superior al HINTS realizado por expertos (AUC ~0,71) y a escalas de riesgo vascular como el ABCD² (AUC ~0,58)[6].

Estas cifras sugieren que la inteligencia artificial puede apoyar de forma objetiva la interpretación de pruebas vestibulares en situaciones complejas, actuando como una herramienta complementaria al juicio clínico.

VIDEONISTAGMOGRAFÍA DE BOLSILLO

La videonistagmografía es el método de referencia para la evaluación objetiva del nistagmo; sin embargo, su uso está limitado por el elevado coste, la necesidad de equipamiento específico y su disponibilidad restringida a unidades especializadas. Estas limitaciones dificultan su aplicación en entornos no especializados y en patologías vestibulares de carácter episódico, en las que el nistagmo puede no estar presente en el momento de la consulta. En este contexto, el análisis digital de imagen mediante dispositivos de uso cotidiano, como el *smartphone*, surge como una alternativa accesible para la captura y cuantificación del nistagmo.

Esta aproximación ha comenzado a materializarse en aplicaciones clínicas concretas, como el sistema *EyePhone*, descrito por Bastani et al. en 2024, basado en el análisis automatizado de los movimientos oculares.

EyePhone[7] es una aplicación que permite la detección y cuantificación objetiva del nistagmo mediante la cámara frontal del *smartphone*, incluyendo la identificación de su presencia, la medición de la velocidad de fase lenta y la determinación de su dirección. Además, posibilita el registro y almacenamiento de los movimientos oculares, facilitando su revisión posterior y el seguimiento evolutivo del paciente, incluso en contextos en los que el nistagmo es sutil o transitorio. De este modo, *EyePhone* aporta ventajas relevantes en el manejo de la patología vestibular, al ofrecer una herramienta accesible y portátil que permite una evaluación objetiva del nistagmo fuera de unidades especializadas. Al reducir la dependencia de la experiencia del explorador, disminuye la variabilidad interobservador y mejora la precisión diagnóstica, incluso en entornos clave como los servicios de urgencias. Además, su rendimiento comparable a la videonistagmografía convencional para la detección de nistagmo clínicamente relevante amplía las posibilidades de diagnóstico precoz y seguimiento evolutivo, particularmente en patologías de carácter episódico.

Además de aplicaciones como *EyePhone*[7], orientadas a la cuantificación básica del nistagmo mediante *smartphone*, existen otros desarrollos basados en inteligencia artificial que permiten un análisis más avanzado de los movimientos oculares. Entre ellos, ConVNG[8] actúa como un método de análisis independiente del dispositivo de grabación, capaz de procesar tanto vídeos obtenidos con *smartphone* como registros de videonistagmografía convencional. A partir del análisis automatizado del movimiento pupilar, permite reconstruir el nistagmo y cuantificar la velocidad de fase lenta con una precisión comparable a la videonistagmografía estándar, lo que facilita su integración en la práctica clínica diaria como herramienta de apoyo diagnóstico y de análisis objetivo del nistagmo.

Las herramientas basadas en el análisis automatizado de los movimientos oculares, como *EyePhone* y ConVNG, permiten extender la cuantificación objetiva del nistagmo a escenarios habituales de la práctica clínica. Entre sus principales aplicaciones destacan el registro del nistagmo durante crisis episódicas en el domicilio del paciente, el apoyo al triaje en urgencias, por ejemplo, ayudando a confirmar la presencia de nistagmo y a estimar su intensidad cuando la exploración clínica genera dudas, y la documentación y seguimiento, facilitando dejar constancia objetiva del nistagmo y valorar su evolución a lo largo del tiempo.

CONCLUSIONES

La integración de la inteligencia artificial en la otoneurología no implica sustituir al clínico, sino estandarizar y ordenar el proceso diagnóstico. Su utilidad práctica reside en transformar datos tradicionalmente subjetivos en información objetiva y reproducible, ya sea mediante la cuantificación automatizada de los movimientos oculares, el apoyo a la interpretación de pruebas vestibulares o la estructuración de la historia clínica. De este modo, la IA actúa como un soporte técnico que reduce la variabilidad interobservador y ayuda a manejar la complejidad del paciente con vértigo.

Desde un punto de vista práctico, estas herramientas pueden incorporarse desde hoy en la consulta del otoneurólogo como sistemas de apoyo que funcionan en segundo plano: ayudando a estructurar la anamnesis, señalando hallazgos relevantes en pruebas vestibulares o cuantificando de forma objetiva la imagen radiológica. Al liberar tiempo y facilitar decisiones basadas en datos, la inteligencia artificial permite al especialista centrarse en el razonamiento clínico, la toma de decisiones terapéuticas y la relación con el paciente.

A pesar de sus ventajas, la aplicación de la inteligencia artificial en otoneurología presenta limitaciones relevantes. Los modelos de apoyo diagnóstico muestran un rendimiento claramente inferior en patologías raras o con presentaciones atípicas[2], al estar entrenados principalmente en entidades frecuentes. Además, su fiabilidad depende de forma crítica de la calidad de los datos de entrada y carecen de la capacidad para integrar el contexto clínico global del paciente. Por ello, estas herramientas deben entenderse como sistemas de apoyo que refuerzan la práctica clínica, pero no sustituyen el juicio experto, especialmente ante cuadros complejos o discordantes.

CONFLICTO DE INTERESES

Los autores declaran no tener conflictos de interés.

FINANCIACIÓN

No se recibió financiación para la elaboración de este capítulo.

BIBLIOGRAFÍA

1. Lu B, Misariu AM, Ham JI, Archibald J, van der Woerd B. Evaluating the Efficacy of Large Language Models for Dizzy History Taking and Peripheral Vestibular Disorder Diagnosis. J Otolaryngol Head Neck Surg. 2025;54. https://doi.org/10.1177/19160216251377349.

2. Callejas Pastor CA, Ryu HT, Joo JS, Ku Y, Suh MW. Clinical decision support for vestibular diagnosis: large-scale machine learning with lived experience coaching. NPJ Digit Med. 2025;8(1):487.

3. Cho YS, Ahn JM, Choi JE, Kim Y, Ryu G, Seo YJ, et al. Automated measurement of hydrops ratio from MRI in patients with Ménière's disease using CNN-based segmentation. Sci Rep. 2020;10(1):7003.

4. Park CJ, Cho YS, Chung MJ, Kim Y, Ahn JM, Seo YJ, et al. A Fully Automated Analytic System for Measuring Endolymphatic Hydrops Ratios in Patients With Ménière Disease via Magnetic Resonance Imaging: Deep Learning Model Development Study. J Med Internet Res. 2021;23(9):e29678.

5. Korda A, Sauter TC, Caversaccio M, Mantokoudis G, et al. Artificial intelligence for early stroke diagnosis in acute vestibular syndrome. Front Neurol. 2022;13:919777.

6. Ahmadi SA, Vivar G, Navab N, Maier A, Magdowski K, Ahmadi M, et al. Modern machine-learning can support diagnostic differentiation of central and peripheral acute vestibular disorders. J Neurol. 2020;267:143-52.

7. Bastani PB, Newman-Toker DE, Kerber KA, Ahn J, Braga M, Johns P, et al. Quantifying Induced Nystagmus Using a Smartphone Eye Tracking Application (EyePhone). J Am Heart Assoc. 2024;13(2):e030927.

8. Friedrich MU, Schneider E, Büttner U, Ertl M, Henn M, Dieterich M, et al. Smartphone video nystagmography using convolutional neural networks: ConVNG. J Neurol. 2023;270(5):2518-30.

7

Aplicaciones en cirugía de cabeza y cuello

Gustavo Eisenberg Plaza, Mar Domínguez Fernández, Carlos Carazo Casas
Servicio de Otorrinolaringología y Cirugía de Cabeza y Cuello,
Hospital Universitario Ramón y Cajal

INTRODUCCIÓN

La consulta de Otorrinolaringología y Cirugía de Cabeza y Cuello es un entorno de decisiones complejas, en no pocas ocasiones bajo cierto grado de incertidumbre. En una misma mañana podemos evaluar una disfonía persistente en un fumador, una leucoplasia estable, un nódulo tiroideo incidental o un paciente con carcinoma orofaríngeo candidato a cirugía. Decidir qué biopsiar, qué vigilar o cómo preservar función sin comprometer control oncológico implica integrar experiencia, evidencia y juicio clínico.

La inteligencia artificial (IA) no viene a sustituir esa responsabilidad, pero puede reducir variabilidad, mejorar consistencia y hacer visibles patrones que escapan al análisis humano aislado. Aunque muchos modelos presentan resultados prometedores, la mayoría siguen siendo retrospectivos y con validación interna. La evidencia prospectiva multicéntrica con impacto demostrado en resultados clínicos es aún limitada.

Este capítulo revisa las aplicaciones más relevantes de la IA en cirugía de cabeza y cuello, centrándose en escenarios con potencial de implementación realista y valor clínico tangible.

VÍA AERODIGESTIVA SUPERIOR

Endoscopia laríngea asistida

La endoscopia es un entorno idóneo para la IA: datos visuales abundantes, decisiones repetitivas y variabilidad interobservador. Uno de los avances más relevantes ha sido el paso de clasificar imágenes estáticas a detectar lesiones en vídeo en tiempo real.

Azam et al. aplicaron un modelo de detección tipo YOLO (*You Only Look Once*) a videolaringoscopia con luz blanca y NBI, obteniendo resultados prometedores para identificar lesiones malignas laríngeas[1]. El sistema no emite un "diagnóstico", sino que resalta áreas sospechosas mediante recuadros o mapas visuales, compatibles con el flujo asistencial, a menudo comprometido.

Más allá de la precisión técnica, la utilidad clínica depende de la posibilidad de aplicar los nuevos procedimientos en entornos reales, distintos de lo que pueda ser un entorno controlado bajo un ensayo clínico o trabajo de investigación. Shuai et al. desarrollaron una red multimodal en la que se combinaban imágenes larigoscópicas con datos clínicos estructurados. Validada externamente en dos centros, se compararon los resultados con los obtenidos de la evaluación de otorrinolaringólogos expertos[2]. Este enfoque (multimodalidad + validación externa + comparación humano-máquina) representa el estándar deseable como paso previo a la generalización de su aplicación en otros entornos.

Hoy, su aplicación más realista es el triaje, la estandarización y la auditoría docente. El principal riesgo es el *automation bias*: aceptar la sugerencia algorítmica sin completar la evaluación clínica. La IA debe considerarse siempre una segunda lectura complementaria.

Cavidad oral: estratificación de riesgo más allá de la displasia

En cavidad oral, el reto no es detectar cáncer avanzado, sino estratificar riesgo en lesiones potencialmente malignas.

Adeoye et al. desarrollaron un modelo de *deep learning* tipo "*time-to-event*" para estimar el riesgo y el momento probable de transformación maligna en trastornos potencialmente malignos orales, con validación externa[3]. Este enfoque permite priorizar seguimientos y optimizar recursos, sin sustituir la histología.

Otra vía es el análisis de láminas histopatológicas mediante algoritmos de visión artificial, mediante la digitalización de la histología. El *whole slide imaging* (WSI) permite digitalizar láminas completas, facilitando análisis automatizados. Un modelo multirresolución publicado en *npj Digital Medicine* predijo la progresión de lesiones a carcinoma escamoso oral, mejorando la subjetividad del estadiaje convencional[4].

La traslación clínica no implica "automatizar al patólogo", sino enriquecer el circuito asistencial: mapas de áreas de alto riesgo que orienten muestreo, discusión en comité y consistencia interobservador.

IMAGEN ONCOLÓGICA Y PLANIFICACIÓN

En imagen, la mayor aportación actual de la IA es operativa: segmentación automática de tumor y órganos de riesgo.

Uno de los campos más desarrollados se centra en la radiómica en CT/MRI/PET. La IA convierte una imagen (TAC, RM, PET, etc.) en muchos números ("*features*") que describen forma, intensidad y texturas del tumor o la lesión (p.ej., heterogeneidad, bordes...). Analiza patrones sutiles en las imágenes que el ojo humano no detecta. Según revisiones de 2024, estos modelos predicen la respuesta a la quimio-radioterapia y el riesgo de metástasis ocultas en carcinomas escamosos de cabeza y cuello.

El reto HECKTOR evaluó la segmentación automática del volumen tumoral previo a tratamiento radioterápico en PET/CT multicéntrico[5]. La iniciativa HaN-Seg estableció un marco estandarizado para segmentación de órganos de riesgo en TC y RM[6]. Ambos muestran que la IA puede acelerar y homogeneizar tareas repetitivas.

En la práctica clínica, el modelo realista es "borrador automático + revisión humana". El beneficio es liberar tiempo experto para decisiones críticas (márgenes quirúrgicos, invasión de base de cráneo, correlación imagen-RM), no sustituir la valoración clínica.

Los modelos pronósticos que extraen variables cuantitativas de la imagen (radiomics) o que aprenden patrones directamente de los píxeles mediante redes neuronales (*deep learning*) pueden perder rendimiento al cambiar el escáner, el protocolo o la población. Por eso, antes de adoptarlos, deben demostrar robustez con validación externa, buena calibración de riesgo y utilidad clínica real en la toma de decisiones.

Existen modelos ya exportables a la práctica real médica en el campo de la imagen como Aidoc (*Head and Neck Package*), presentado como software de "triaje" que analiza automáticamente los TAC de cuello en busca de hallazgos críticos (como masas sospechosas o adenopatías cervicales de gran tamaño) y los prioriza en la lista de trabajo del radiólogo.

TIROIDES Y PARATIROIDES

Ecografía tiroidea

La decisión de realizar PAAF en un nódulo tiroideo es un escenario ideal para IA: alto volumen, variabilidad interobservador y consecuencias clínicas claras.

Peng et al. publicaron en *The Lancet Digital Health* un estudio multicéntrico donde un modelo de *deep learning* asistía al diagnóstico ecográfico, reduciendo potencialmente PAAF innecesarias y homogeneizando criterios[7]. Un estudio publicado en el *Multidisciplinary Head and Neck Cancers Symposium* demostró que modelos de *deep learning* pueden predecir la malignidad de un nódulo por imagen con una precisión superior al 93-98 %, superando en ocasiones la interpretación humana del sistema TI-RADS, así como a reclasificar muestras histológicas de nódulos establecidos en categorías Bethesda III y IV (indeterminados), reduciendo la necesidad de biopsias repetitivas o cirugías diagnósticas innecesarias. De hecho, existen soluciones que ya han superado el examen regulatorio de la Unión Europea y están disponibles comercialmente para su integración en la actividad asistencial. Conocidos como CAD (*Computer-Aided Diagnosis*), destacan Koios DS™ *Thyroid (Koios Medical*), IA basada en *deep learning* para clasificar nódulos tiroideos según el sistema TI-RADS. Estudios publicados muestran que reduce las biopsias innecesarias en un 30 % manteniendo una sensibilidad del 99 %. Otra IA disponible AmCAD-UT (AmCAD BioMed), automatiza la detección de características ecográficas (microcalcificaciones, ecogenicidad, bordes) para estandarizar el informe radiológico.

Su implementación exige integración en el flujo asistencial (ecógrafo o PACS), umbrales conservadores para evitar falsos negativos, y reglas claras ante discrepancias entre la IA y la evaluación humana con

el TI-RADS. Inicialmente, su papel más seguro es como segunda lectura y herramienta educativa.

Identificación intraoperatoria de paratiroides

La preservación paratiroidea es un objetivo quirúrgico clave con gran impacto funcional.

Con este objetivo se ha desarrollado el algoritmo Faster R-CNN (denominado PTAIR en estudios de 2022-2025) que identifica las paratiroides en cirugía endoscópica. En ensayos clínicos, la IA logró identificar las glándulas 3,8 segundos antes que cirujanos expertos y con una tasa de precisión del 96,9 %, superando a cirujanos noveles.

La autofluorescencia en infrarrojo cercano (NIRAF) ya se utiliza como ayuda visual. Avci et al. describieron un modelo de *deep learning* para localizar glándulas paratiroides en imágenes intraoperatorias de autofluorescencia, consiguiendo un alto rendimiento en su cohorte[8]. Su valor radica en la superposición visual en tiempo real, especialmente útil en anatomías complejas o en la curva de aprendizaje. Sistemas como el FLUOSOFT, trabajando con esa asociación IA y autofluorescencia en tiempo real, ayudan a localizar adenomas de milímetros (ej. 3 mm) que serían invisibles al ojo humano, reduciendo así el riesgo de hipocalcemia postoperatoria.

No obstante, está por demostrar que la localización precisa equivalga a reducción de hipocalcemia postquirúrgica. Se necesitan estudios prospectivos, idealmente multicéntricos, con endpoints clínicos (hipocalcemia transitoria y permanente, suplementación, reingresos).

LA VOZ COMO BIOMARCADOR DIGITAL

Para el otorrinolaringólogo general, la voz resulta atractiva como posible biomarcador porque es "barata", fácil de repetir y compatible con la telemedicina. Basta una grabación para obtener información, sin exploraciones invasivas ni equipamiento complejo.

Algunos trabajos recientes, como el análisis del *dataset Bridge2AI* Voice, han explorado si determinados rasgos acústicos se asocian a lesiones benignas o malignas de las cuerdas vocales[9]. Hoy en día, estos sistemas no sustituyen la endoscopia, ni están pensados para diagnosticar cáncer laríngeo.

Su utilidad plausible es doble:

- Triaje: priorizar exploraciones en pacientes de mayor riesgo.
- Seguimiento: comparar la voz del mismo paciente a lo largo del tiempo tras cirugía, radioterapia o rehabilitación vocal.

El riesgo principal es la exposición a múltiples sesgos, ya que la voz cambia según determinadas características (sexo, edad, idioma, tabaquismo, calidad de grabación). La voz puede ayudar a priorizar exploraciones, pero no a descartar enfermedad.

INTEGRACIÓN CLÍNICA DE LA INTELIGENCIA ARTIFICIAL POR PERFILES

La pregunta clave no es la precisión algorítmica, sino su impacto real.

ORL general: endoscopia asistida; herramientas de triaje.

ORL oncológico / comité: mapas patológicos; apoyo a estratificación de riesgo.

Cirugía tiroidea/paratiroidea: ayudas visuales intraoperatorias con resultados funcionales medibles.

Imagen oncológica: segmentación automática del tumor y órganos de riesgo como infraestructura asistencial.

IMPLEMENTACIÓN RESPONSABLE

Un modelo realista de adopción incluye:

1. Uso en paralelo (*shadow mode*): la IA funciona, pero no cambia decisiones. Se debe comparar con la práctica habitual y registrar los errores.
2. Definición de umbrales y responsabilidades: establecer cuándo se puede seguir la IA y quién decide si hay discrepancias.
3. Formación del equipo: educación en fortalezas y límites de la herramienta clínica a utilizar.
4. Monitorización y vigilancia continua: cambios en equipos, profesionales o población pueden hacer que la IA rinda peor con el tiempo. Vigilarlo es parte de la seguridad clínica.

Las guías CONSORT-AI, SPIRIT-AI, TRIPOD+AI y PROBAST+AI establecen estándares de calidad y reporte[13-16]. El marco regulatorio europeo (MDR y AI Act) exige trazabilidad y evaluación de riesgo[10-11].

SESGOS Y LIMITACIONES

Los errores frecuentes incluyen:

- Entrenamiento en casos “claros” y fallo en intermedios.
- Falta de validación externa.
- Dependencia de un estilo experto concreto.
- Atajos espurios (logos, textos o marcas del centro).
- Automation bias: confiar demasiado en la IA cuando “suena convincente”.

La prevención es técnica y organizativa: validación local, auditorías periódicas y cultura de discrepancia permitida.

CONCLUSIONES

La IA en cirugía de cabeza y cuello no reemplaza al especialista, pero puede reducir variabilidad, estandarizar procesos y liberar tiempo experto.

Su mayor impacto actual se encuentra en:

- Endoscopia asistida y triaje.
- Estratificación del riesgo en lesiones.
- Segmentación automática en imagen oncológica.
- Apoyo ecográfico en tiroides.
- Identificación intraoperatoria de paratiroides.

El futuro plausible (2026-2030) apunta hacia:

1. Modelos multimodales (imagen + clínica + patología).
2. Colaboración multicéntrica y aprendizaje federado.
3. IA centrada en resultados funcionales (voz, deglución, calidad de vida).

Adoptar IA en ORL exige prudencia, exigencia metodológica y vigilancia continua. La pregunta no es si la IA sustituirá al cirujano, sino cómo puede ayudarle a tomar decisiones más consistentes, seguras y centradas en el paciente.

CONFLICTO DE INTERESES

Los autores declaran no tener conflictos de interés.

FINANCIACIÓN

No se recibió financiación para la elaboración de este capítulo.

BIBLIOGRAFÍA

1. Azam MA, Sampieri C, Ioppi A, et al. Deep Learning Applied to White Light and Narrow Band Imaging Videolaryngoscopy: Toward Real-Time Laryngeal Cancer Detection. Laryngoscope. 2022;132:1798-806.
2. Shuai Y, Li Y, Jin Z, et al. A deep learning fusion network trained with medical records and laryngoscopic images in the early diagnosis of glottic carcinoma. iScience. 2025;28(12):114231.
3. Adeoye J, Jensen DH, Grønhoj C, et al. Time-to-event deep learning for malignant transformation of oral potentially malignant disorders. Cancers (Basel). 2021;13(23):6054.
4. Liu-Swetz Y, Niksic S, et al. AI-driven prediction of progression to oral squamous cell carcinoma using a multiresolution pathology model. npj Digit Med. 2025;8.
5. Oreiller V, Andrearczyk V, Jreige M, et al. Head and neck tumor segmentation in PET/CT: The HECKTOR challenge. Med Image Anal. 2022;77:102336.
6. Podobnik G, et al. HaN-Seg: The head and neck organ-at-risk CT and MR segmentation challenge. Radiother Oncol. 2024.
7. Peng S, Liu Y, Lv W, et al. Deep learning can assist ultrasound-based diagnosis of thyroid nodules: a multicentre diagnostic study. Lancet Digit Health. 2021;3(4):e250-9.
8. Avci A, Wang C, Larian B. A Visual Deep Learning Model to Accurately Localize Parathyroid Glands Using Autofluorescence Images During Surgery. Ann Surg Oncol. 2022;29:4248-52.
9. Jenkins P, Harrison R, Bedrick S, et al. Voice as a biomarker: exploratory analysis for benign and malignant vocal fold lesions. Front Digit Health. 2025;7:1609811.
10. Regulation (EU) 2017/745 of the European Parliament and of the Council of 5 April 2017 on medical devices (MDR). Official Journal of the European Union. OJ L 117, 5.5.2017.
11. Regulation (EU) 2024/1689 of the European Parliament and of the Council of 13 June 2024 laying down harmonised rules on artificial intelligence (AI Act). Official Journal of the European Union. OJ L, 12.7.2024.
12. European Commission. AI Act enters into force (news release). 1 Aug 2024.
13. Liu X, Rivera SC, Moher D, et al. Reporting guidelines for clinical trial reports for interventions involving artificial intelligence: the CONSORT-AI extension. BMJ. 2020;370:m3164.
14. Rivera SC, Liu X, Chan A-W, et al. Guidelines for clinical trial protocols for interventions involving artificial intelligence: the SPIRIT-AI extension. BMJ. 2020;370:m3210.
15. Collins GS, Moons KGM, Dhiman P, et al. TRIPOD+AI statement: updated guidance for reporting clinical prediction models that use regression or machine learning methods. BMJ. 2024;385:e078378.
16. Moons KGM, Damen JAA, Kaul T, et al. PROBAST+AI: an updated quality, risk of bias, and applicability assessment tool for prediction models using regression or artificial intelligence methods. BMJ. 2025;388:e082505.
17. Lekadir K, Frangi AF, et al. FUTURE-AI: international consensus guideline for trustworthy and deployable artificial intelligence in healthcare. BMJ. 2025;388:e081554.

8

Aplicaciones de la IA en el análisis acústico de la voz

Blanca Martínez Cabrera, Teresa Rivera Schmitz, Coloma Grau-van Laak, Isabel García López

Servicio de Otorrinolaringología, Hospital Universitario La Paz

INTRODUCCIÓN

Determinar el impacto de la disfonía es de utilidad en la práctica clínica diaria. Para ello contamos con herramientas ampliamente utilizadas, como escalas subjetivas que recogen la opinión del paciente (VHI) o del examinador (GRABS, CAPE-V). En la búsqueda de parámetros de evaluación objetiva que completan a los anteriores, el análisis acústico de la voz se ha desarrollado como una herramienta imprescindible en las consultas de laringología. Dicho análisis consiste en la cuantificación de distintos parámetros extraídos de la señal acústica vocal registrada a través de un micrófono y analizada por medio de un software.

El análisis acústico constituye, por lo tanto, una herramienta fundamental para la evaluación objetiva de la voz mediante la cuantificación de parámetros acústicos, que permiten evaluar, de forma indirecta, la vibración de las cuerdas vocales, la estabilidad del sistema fonatorio y la calidad vocal percibida.

La Inteligencia Artificial (IA) ha irrumpido en multitud de aspectos de la práctica médica. En el campo del análisis acústico de la voz existe ya un amplio desarrollo que busca, fundamentalmente, encontrar patrones para clasificar una voz como normal o patológica e identificar biomarcadores digitales.

UTILIDAD DEL ANÁLISIS ACÚSTICO EN LA PRÁCTICA CLÍNICA

El análisis acústico de la voz estudia indirectamente el comportamiento vibratorio laríngeo y la configuración del tracto vocal, complementando así la evaluación clínica de la voz. Su integración con el análisis perceptual y aerodinámico además de la videoestroboscopia laríngea permite una aproximación multimodal a la fisiopatología vocal tanto para el diagnóstico como para monitorizar la calidad vocal en el tiempo.

Según la teoría fuente-filtro, la voz es una onda sonora compleja formada por ondas simples: una generada en la fuente, mediante la vibración en las cuerdas vocales, y varias más que se van modificando en el filtro, el tracto vocal. Por tanto, el análisis de dicha señal permite inferir parámetros biomecánicos de la vibración cordal como la periodicidad, la simetría vibratoria y el grado de cierre glótico entre otros.

La ventaja de utilizar el análisis acústico radica en su capacidad para identificar de manera cuantitativa los componentes vocales responsables de la disfonía y objetivar así el impacto funcional de la misma. De esta manera nos aporta datos en el diagnóstico inicial, así como en la monitorización de la respuesta al tratamiento logopédico o quirúrgico. Además, es un recurso al alcance de todos ya que hay numerosos software gratuitos y fáciles de instalar y emplear.

Sin embargo, el análisis acústico pierde significado si se utilizara de manera aislada ya que no es capaz de interpretar los hallazgos por sí mismo. No se dispone tampoco de parámetros de normalidad consensuados o estos cambian para cada parámetro según el sistema utilizado. Si a esto se le añade que la señal vocal tiene cierta variabilidad y subjetividad por la que el paciente puede alterarla de manera voluntaria se entiende que los resultados podrían perder credibilidad.

Se puede decir, por tanto, que el análisis acústico de la voz representa una herramienta de alto valor diagnóstico y evolutivo, pero siempre complementaria a un abordaje multidimensional que combine evaluación perceptual y aerodinámica y exploración laríngea mediante laringoestroboscopia.

La incorporación de la IA al análisis acústico de la voz podría suponer un cambio de paradigma: de una herramienta complementaria para completar la exploración clásica ORL a un sistema capaz de interpretar los resultados con fines diagnósticos, de monitorización e incluso pronósticos. Pero por ahora su interpretación exige el conocimiento de sus limitaciones metodológicas y de la naturaleza compleja de la señal acústica de la voz.

PARÁMETROS FUNDAMENTALES DEL ANÁLISIS ACÚSTICO

Los parámetros que pueden ser extraídos de la señal acústica de la voz son numerosísimos. Cada software o cada programa de análisis acústico proporciona determinadas mediciones que, en general pueden ser divididas en aquellas que hablan de la estabilidad de la señal (en términos de frecuencia o amplitud de la onda sonora) y las que miden la presencia de ruido en dicha señal.

La Sociedad Europea de Laringología publicó en 2023 un nuevo consenso acerca de los parámetros que deben registrarse para la evaluación de la voz en la práctica clínica[1].

Según este consenso, dichos parámetros son la frecuencia fundamental (F0), el Jitter, el Shimmer, y la relación armónico-ruido (HNR). Además, el análisis espectrográfico y el análisis cepstral de la voz están avalados ampliamente en la literatura científica como parámetros de utilidad en análisis acústico.

La F0 corresponde al número de ciclos de vibración de las cuerdas vocales por segundo y constituye el principal correlato acústico de la altura tonal percibida (pitch).

El Jitter mide la variabilidad ciclo a ciclo de la frecuencia fundamental, es decir, las pequeñas irregularidades en la duración de los periodos vibratorios consecutivos. Se expresa generalmente como un porcentaje o valor relativo, calculado a partir de la diferencia entre periodos consecutivos de la señal vocal.

El Shimmer, por su parte, evalúa la variabilidad ciclo a ciclo de la amplitud de la señal acústica. Este parámetro refleja fluctuaciones en la intensidad de cada ciclo vibratorio.

El HNR cuantifica la proporción entre los componentes periódicos de la señal vocal (armónicos) y los componentes aperiódicos o ruidosos.

El espectrograma constituye una representación visual de la señal acústica que permite analizar cómo se distribuye la energía de la voz en el tiempo y en la frecuencia. Esta herramienta facilita la identificación de armónicos, formantes y componentes de ruido, y permite evaluar de manera cualitativa diferentes características de la producción vocal.

Por último, el análisis cepstral, especialmente mediante el parámetro Cepstral Peak Prominence (CPP), evalúa la periodicidad global de la señal vocal a partir del análisis del espectro de frecuencias. El CPP se considera actualmente una de las medidas acústicas más robustas para la evaluación de la calidad vocal, particularmente en voces altamente aperiódicas donde otros parámetros tradicionales pueden resultar menos fiables.

En los últimos años, estos parámetros acústicos han adquirido además un papel relevante como variables de entrada en modelos de IA y aprendizaje automático, utilizados para la detección y clasificación automatizada de alteraciones vocales.

QUÉ HACE LA IA EN EL ANÁLISIS ACÚSTICO

Los sistemas de IA potencian la objetividad clínica al automatizar e integrar patrones acústicos complejos que no pueden evaluarse con parámetros acústicos aislados, permitiendo clasificar la voz en normal o patológica y permitiendo la identificación de biomarcadores digitales[2].

Para que un algoritmo de IA pueda "entender" la voz, debe transformarla en datos numéricos o representaciones visuales complejas que posteriormente pueden ser utilizadas por modelos de aprendizaje automático o aprendizaje profundo.

Los modelos de IA permiten detectar alteraciones mínimas y correlaciones en variables acústicas que pueden pasar desapercibidas incluso por laringólogos expertos.

Las Redes Neuronales Convolucionales (CNN) procesan los espectrogramas, principalmente los Mel-Espectrogramas que se diferencian de los anteriores en que el primero utiliza una escala de frecuencias lineal (Hertz), mientras que el segundo utiliza la escala Mel, que se ajusta a cómo perciben las personas los sonidos[3].

Otro grupo de variables ampliamente utilizado son los parámetros cepstrales, que cuantifican el grado de organización armónica de la señal vocal, siendo especialmente relevantes la prominencia del pico cepstral (CPP) y la prominencia del pico cepstral suavizado (CPPS), indicadores robustos de calidad vocal y disfonía[4].

Asimismo, los coeficientes cepstrales en la escala Mel (MFCC) condensan la información espectral de la señal, facilitando el procesamiento eficiente de grandes volúmenes de datos acústicos[5,6]

Estos parámetros son analizados como imágenes complejas permitiendo identificar patrones espaciales como transiciones de formantes y picos espectrales[7].

Los modelos como los Perceptrones Multicapa (MLP) y las CNN entrenados con vectores MFCC han logrado una alta precisión diagnóstica en patología laríngea, superiores al 94-99 % en la detección de patologías como nódulos, parálisis y cáncer de laringe[6].

En resumen, la IA aporta una capacidad de análisis multidimensional que permite capturar y analizar la complejidad de la voz humana.

APLICACIONES CLÍNICAS DE IA EN ANÁLISIS ACÚSTICO

El análisis automatizado de la voz mediante inteligencia artificial se está investigando como biomarcador digital no invasivo con potencial para el diagnóstico precoz y la monitorización de múltiples enfermedades.

Cribado y detección temprana de patología laríngea mediante análisis acústico

El análisis de la voz mediante IA se está estudiando como herramienta de cribado en atención primaria permitiendo identificar disfonías con alta probabilidad de malignidad antes de la confirmación endoscópica. No hay un parámetro único que nos diga si una voz es normal o patológica, la IA permite usar modelos multivariantes combinando parámetros acústicos con variables demográficas.

Se han logrado precisiones de hasta el 99 % en el reconocimiento de voces patológicas y una sensibilidad del 97 % para detectar lesiones benignas en las cuerdas vocales[8].

Aunque los sistemas de detección de patología laríngea desarrollados por la IA son cada vez más precisos, aún no está claro si son adecuados y fáciles de usar en la clínica. A día de hoy, no hay evidencia científica de que estos sistemas de detección sean útiles en el cribado de lesiones laríngeas.

Un punto crucial para aplicar la IA en el diagnóstico diferencial de patología laríngea es la necesidad de utilizar la "IA explicable" (XAI). A diferencia de los sistemas de IA donde el usuario solo conoce la entrada y la salida de los datos, los sistemas XAI permiten comprender y rastrear la ruta informática y el algoritmo por el cual la XAI ha llegado a la respuesta emitida (decisión diagnóstica), lo cual es fundamental para su validación.

Aplicaciones en enfermedades neurológicas

El análisis potenciado por la inteligencia artificial (IA) permite identificar alteraciones subclínicas en la calidad vocal y la articulación de las palabras que resultan a menudo imperceptibles para el oído humano. Se ha demostrado que los modelos de aprendizaje profundo pueden detectar biomarcadores vocales en etapas tempranas de trastornos del movimiento, como la enfermedad de Parkinson. En algunos casos, estas alteraciones vocales pueden preceder a la aparición del temblor motor característico de esta enfermedad, con una sensibilidad diagnóstica notable[9].

Rehabilitación vocal y seguimiento del paciente

El análisis acústico empleando la inteligencia artificial está transformando el seguimiento postoperatorio y la logopedia. Además, el uso de modelos de IA en aplicaciones móviles permite al paciente realizar tele-rehabilitación, recibiendo retroalimentación en tiempo real sobre su rendimiento vocal en casa[10].

Herramientas de IA en análisis acústico de la voz

Para implementar estas tecnologías en la práctica clínica o investigación, existen recursos accesibles:

- Bases de Datos de Referencia: para validar modelos o comparar casos, se utilizan múltiples bases de datos entre las que encontramos: Saarbruecken Voice Database (SVD)[11] y las bases de datos MEEI y VOICED Database[12].
- Aplicaciones de análisis acústico: OpenSmile y Praat son los estándares para obtener datos acústicos estructurados que luego pueden procesarse con modelos de *machine learning*.
- Modelos y plataformas de Inteligencia Artificial:
  - TensorFlow y PyTorch: bibliotecas de aprendizaje profundo ampliamente utilizadas para desarrollar modelos de clasificación vocal.

- OpenL3: modelo de aprendizaje profundo autosupervisado diseñado para extraer representaciones acústicas útiles para clasificación de las voces.
- Bridge2AI-Voice: proyecto financiado por el National Institute of Health (NIH) cuyo objetivo es desarrollar una base de datos multimodal que integre grabaciones vocales con datos clínicos, genómicos y radiológicos para facilitar la investigación en biomarcadores vocales[13].

CONCLUSIONES

La voz es una característica biométrica única; es, en esencia, una "huella dactilar" sonora. La capacidad de la IA para identificar no solo enfermedades, sino también la identidad, el origen étnico, el estado emocional o rasgos de personalidad, exige una protección estricta de los datos.

La mayoría de las herramientas aún no están integradas en la práctica clínica diaria. Se necesitan estudios que proporcionen validación externa.

La mayoría de las herramientas descargables requieren conocimientos técnicos para su implementación y no están aprobadas por agencias regulatorias para uso clínico, lo que puede resultar una limitación para su utilización en la consulta.

BIBLIOGRAFÍA

1. Lechien JR, Geneid A, Bohlender JE, Cantarella G, Avellaneda JC, Desuter G, Sjogren EV, Finck C, Hans S, Hess M, Oguz H, Remacle MJ, Schneider-Stickler B, Tedla M, Schindler A, Vilaseca I, Zabrodsky M, Dikkers FG, Crevier-Buchman L. Consensus for voice quality assessment in clinical practice: guidelines of the European Laryngological Society and Union of the European Phoniatricians. Eur Arch Otorhinolaryngol. 2023 Dec;280(12):5459-5473. doi: 10.1007/s00405-023-08211-6. Epub 2023 Sep 14. PMID: 37707614.

2. Ma, K., Wang, Y., Zhou, Y., Chen, L., Zhang, T., Xu, F., & Peng, X. (2025). Acoustic signatures of organic lesions and the role of artificial intelligence in voice disorder diagnostics. Digital Health, 11, 20552076251376264. https://doi.org/10.1177/20552076251376264.

3. Ma, S., Liao, W., Zhang, Y., Zhang, F., Wang, Y., Lu, Z., Zhao, C., Yu, J., & He, P. (2025). Research on automatic assessment of the severity of unilateral vocal cord paralysis based on Mel-spectrogram and convolutional neural networks. BioMedical Engineering OnLine, 24, 76.

4. Brockmann Bauser, M. (2025). How Well Will AI Help Recognize Voice Disorders? A State of the art Review of Current Acoustic Assessment Strategies and Future Applications. World Journal Of Otorhinolaryngology - Head And Neck Surgery, 11(4), 518-523. https://doi.org/10.1002/wjo2.70015.

5. Shaikh, A. A. S., Bhargavi, & Naik, G. R. (2023). Unraveling the complexities of pathological voice through saliency analysis. Computers In Biology And Medicine, 166, 107566. https://doi.org/10.1016/j.compbiomed.2023.107566.

6. Fang, S.-H., Tsao, Y., Hsiao, M.-J., et al. (2019). Detection of Pathological Voice Using Cepstrum Vectors: A Deep Learning Approach. Journal of Voice, Vol. 33, No. 5: 634–641.

7. Yao, D., Koivu, A., & Simonyan, K. (2025). Applications of Artificial Intelligence in Neurological Voice Disorders. World Journal of Otorhinolaryngology - Head and Neck Surgery,

8. Nudelman, C. J., Tardini, V., & Bottalico, P. (2025b). Artificial Intelligence to Detect Voice Disorders: An AI-Supported Systematic Review of Accuracy Outcomes. Journal Of Voice. https://doi.org/10.1016/j.jvoice.2025.09.021.

9. Ham, H., Jin, B., Cha, K. S., Woo, K. A., Shin, J. H., & Kim, H. (2025). Syllable-based speech characteristics as potential biomarker for differential diagnosis of Parkinson's disease, multiple system atrophy, and cerebellar ataxia. Journal Of Neurology, 272(9), 613. https://doi.org/10.1007/s00415-025-13352-1

10. Mulfari, D., La Placa, D., Rovito, C., Celesti, A., & Villari, M. (2022). Deep learning applications in telerehabilitation speech therapy scenarios. Computers In Biology And Medicine, 148, 105864. https://doi.org/10.1016/j.compbiomed.2022.105864

11. Barry W, Pützer, M. Saarbrucken voice database. Institute of Phonetics; 2007. [Online]. Available: http://stimmdatenbank.coli. unisaarland.de.

12. U. Cesari, G. De Pietro, E. Marciano, C. Niri, G. Sannino, and L. Verde. A new database of healthy and pathological voices. Computers & Electrical Engineering, vol. 68, pp. 310-321, 5 2018.

13. Bridge2AI-Voice Consortium (2024). Developing Multi-Disorder Voice Protocols: A team science approach involving clinical expertise, bioethics, standards, and DEI. Proceedings of the Annual Conference of the International Speech Communication Association, INTERSPEECH, 1445-1449. https://doi.org/10.21437/Interspeech.2024-1926.

9

Aplicaciones en Patología Glandular Salivar

Pilar Benavent Marín, Álvaro Sánchez Barrueco, Virginia Ruiz San José, José Miguel Villacampa Aubá
Unidad de Glándulas Salivales y Sialoendoscopia, Servicio de Otorrinolaringología, Hospital Universitario Fundación Jiménez Díaz y Hospital Universitario General de Villalba

INTRODUCCIÓN

La inteligencia artificial (IA) engloba técnicas capaces de extraer patrones a partir de datos clínicos, de imagen o anatomopatológicos para apoyar procesos diagnósticos, de estratificación de riesgo o de selección terapéutica. En patología salivar, su interés es especialmente alto por tres motivos: (1) la dependencia de la caracterización por imágenes en el preoperatorio; (2) la heterogeneidad histológica de los tumores salivares y el impacto del tipo histológico en la conducta quirúrgica; y (3) el objetivo de preservación glandular y reducción de morbilidad en patología obstructiva. La interpretación y entrenamiento de modelos debe basarse en definiciones diagnósticas vigentes, idealmente alineadas con la clasificación actual de la Organización Mundial de la Salud en patología de glándulas salivales[1].

Este capítulo recoge las aplicaciones con potencial traslacional en Otorrinolaringología (ORL), priorizando escenarios frecuentes: tumores parotídeos o submandibulares (diferenciación de entidades comunes y predicción de malignidad), anatomía patológica digital (segunda lectura y reducción de variabilidad en entidades complejas), fenotipado ductal/parenquimatoso en enfermedad crónica y planificación terapéutica en patología obstructiva. Por último, se incluyen las precauciones metodológicas para realizar una lectura crítica e implantación responsable[2].

AVANCES EN IA EN PATOLOGÍA DE GLÁNDULAS SALIVALES

Apoyo diagnóstico en tumores de parótida y submandibular

En consulta ORL, el valor real de los modelos de IA en tumores salivares no es "diagnosticar por sí solos", sino reducir incertidumbre preoperatoria cuando la clínica, la ecografía o la resonancia magnética (RM) y la punción aspiración con aguja fina (PAAF) o biopsia con aguja gruesa (BAG) no convergen; y cuando el resultado impacta en la indicación y/o extensión quirúrgica. En la literatura, predominan modelos de aprendizaje profundo (*deep learning*, DL) entrenados con ecografía o RM para tareas concretas (p. ej., adenoma pleomorfo vs. Warthin, benigno vs. maligno), con métricas prometedoras en series retrospectivas y unicéntricas, pero con riesgo de sobreajuste y de caída de rendimiento al cambiar de centro o protocolo[2].

En RM, la integración de información funcional (difusión/perfusión) puede aportar discriminación adicional cuando la morfología es equívoca. Un ejemplo reciente es el uso de DL incorporando parámetros de RM dinámica con contraste (DCE-MRI) para clasificación de tumores parotídeos, lo que refuerza la idea de que el rendimiento mejora cuando el modelo incorpora la biología tumoral indirecta (vascularización, permeabilidad) y no solo textura/morfología[3].

En ecografía de glándulas salivales (EcoGS), redes convolucionales (CNN) y enfoques híbridos han logrado diferenciar subtipos frecuentes y malignidad, con el atractivo añadido de ser una técnica accesible, repetible y con posibilidad de correlación clínica

en tiempo real. La utilidad real depende de la estandarización de adquisición, de la variabilidad interobservador y del equilibrio de clases (pocos malignos)[4,5].

También en EcoGS existe la posibilidad de segmentación automática de imágenes basada en regiones de interés (ROI) que permiten al clínico entender los criterios de la IA utilizados para la toma de decisiones. Aunque los estudios actuales se centran en la ecografía convencional (*B-mode*) y la segmentación automática, el desarrollo de modelos de aprendizaje automático (*machine learning*) que incorporen parámetros cuantitativos derivados de elastografía, Doppler y ecografía con contraste puede contribuir a enfoques cuantitativos más robustos[6,7].

También se están explorando enfoques cuantitativos en tomografía computarizada (TC), aunque no se trate de una técnica de primera línea para el estudio inicial de glándulas salivales: un trabajo reciente propone radiomics "hábitat" en TC sin contraste para diferenciar adenoma pleomorfo y adenolinfoma, con AUC (*area under the curve*) altas en entrenamiento y validación, e integra factores clínicos (edad, tabaquismo) con mejor rendimiento y beneficio clínico en análisis de decisión[8].

Apoyo a anatomía patológica digital

La patología digital (*whole slide imaging, WSI*) permite aplicar DL para reconocer patrones y apoyar la clasificación de neoplasias salivares. Se han descrito sistemas capaces de clasificar neoplasias a partir de WSI, con potencial para reducir variabilidad diagnóstica en contextos de bajo volumen o sin subespecialización[9]. Además, se están explorando formas de cuantificar variabilidad histopatológica entre centros y laboratorios; un paso relevante para la reproducibilidad y para el entrenamiento de modelos robustos[8]. El mayor valor a corto plazo es la segunda opinión: señalar casos potencialmente discordantes o raros, para priorizar revisión por patólogo experto y mantener la trazabilidad de errores[10].

Hay escenarios de alto interés clínico por su impacto pronóstico/terapéutico donde la anatomía patológica digital puede aportar: por ejemplo, la diferenciación histológica entre carcinoma de células acinares y carcinoma secretor, entidades con solapamientos morfológicos. Un estudio comparativo reciente evalúa distintos modelos CNN para esta tarea y muestra rendimientos variables según arquitectura y tamaño del conjunto de datos, subrayando que el cuello de botella no es solo el "modelo", sino la calidad de anotación y la necesidad de validación multicéntrica antes de cualquier uso clínico[11].

Fenotipado de enfermedad inflamatoria o disfunción ductal

Más allá de la oncología, empiezan a emerger aplicaciones orientadas a cuantificar cambios glandulares crónicos que permitan distinguir el mecanismo fisiopatogénico predominante (parenquimatoso o ductal).

Cuando el predominio es parenquimatoso (p. ej., Sjögren, sialoadenitis IgG4 u otras sialoadenitis), el reto práctico es objetivar severidad y evolución. Especialmente desde la validación de los criterios ecográficos OMERACT, se han desarrollado modelos predictivos para diagnóstico de Sjögren con resultados prometedores[12]. Si el fenotipo es ductal (litiasis, estenosis, ectasias, tapones mucosos, falta de distensibilidad de la papila), el objetivo práctico es mapear la arquitectura ductal, localizar el nivel de la obstrucción (papila, conducto principal, hilio, ramas ductales), estimar severidad/extensión y reconocer cambios crónicos asociados. En esta línea, se ha descrito la segmentación automática y clasificación mediante DL de parótidas con ductopenia (disminución o ausencia de visualización radiológica del conducto) en sialografía con CBCT, orientado a objetivar severidad y facilitar correlación estructura-función en investigación clínica[13].

Planificación terapéutica en patología obstructiva

En sialolitiasis, la decisión terapéutica busca preservar la glándula mediante estrategias mínimamente invasivas, minimizando conversiones a cirugía extirpativa y evitando abordajes innecesarios. Se han propuesto modelos de ML para apoyar la selección de tratamiento en litiasis submandibular incorporando variables radiológicas (tamaño/volumen, localización, distancia a papila, relación con hilio). Su utilidad potencial es homogeneizar criterios y documentar la decisión, pero su adopción exige interpretabilidad y validación externa en cohortes con algoritmos terapéuticos comparables[14]. Complementariamente, la navegación basada en TC aplicada a cirugía asistida por sialoendoscopia puede mejorar la localización de litiasis difíciles y apoyar la preservación glandular en casos seleccionados[15].

Sistemas conversacionales y soporte a la toma de decisiones

Los modelos de lenguaje (*large language models, LLM*) pueden asistir en tareas de baja complejidad clínica: (1) redacción/optimización de material informativo para pacientes, (2) estructuración de consentimientos y (3) apoyo documental (resumen de informes,

preparación de sesiones). En el ámbito salivar, se ha evaluado ChatGPT como herramienta de apoyo en escenarios de sialoendoscopia comparándolo con un grupo de expertos. Los resultados son prometedores pero inferiores al consenso experto, lo que apoya restringir su uso a soporte y nunca a sustitución del juicio clínico[16]. Además, un estudio específico sobre patología salivar evaluó la exactitud y reproducibilidad de respuestas de ChatGPT-4 a preguntas sobre enfermedades salivares (con revisión por ORL), mostrando alta proporción de respuestas correctas pero con descenso de rendimiento en preguntas clínicas complejas frente a conocimiento básico. Este patrón refuerza que la supervisión humana y la verificación con fuentes primarias son obligatorias[17].

En oncología de cabeza y cuello (incluyendo escenarios con afectación parotídea), comparativas entre LLMs y guías clínicas muestran que pueden generar recomendaciones globalmente razonables, pero con discrepancias en decisiones críticas (p. ej., indicación de cirugía o de tratamientos secuenciales), por lo que su papel debe entenderse como apoyo al razonamiento y nunca como sustitución del juicio clínico[18].

En pacientes con cáncer de cabeza y cuello candidatos a radioterapia, la predicción de xerostomía tardía es un objetivo clínico relevante por su impacto en calidad de vida y por su influencia en la optimización de la planificación. Se ha propuesto un modelo que añade biomarcadores de PET-FDG de parótidas y submandibulares a modelos dosimétricos, mostrando mejora significativa de rendimiento en cohortes de entrenamiento y validación, por su contribución a objetivar la saliva no estimulada y, por tanto, la percepción subjetiva de xerostomía[22].

Además, la saliva como fuente de marcadores es un campo activo en medicina oral y oncología. Revisiones recientes describen el uso de ML para selección y validación de biomarcadores (genómicos, proteómicos, metabolómicos), insistiendo en la necesidad de validación independiente, calibración y evaluación de utilidad clínica antes de cualquier traslación asistencial[23].

PRECAUCIONES EN EL USO DE IA

Para valorar si un estudio de IA es trasladable a la práctica ORL, la lectura crítica debe cubrir tres ejes: validez, reproducibilidad y seguridad clínica. Es imprescindible confirmar validación externa, ya que el rendimiento suele caer al cambiar de centro/equipo/protocolo. Además, debe descartarse la fuga de información (*data leakage*), especialmente frecuente en pruebas de imagen, dado que puede separarse la información por cortes o lesiones y no por paciente. Finalmente, debe revisarse la gestión de la incertidumbre mediante calibración, establecimiento de umbrales claros para "no decisión" y un circuito explícito de revisión humana en casos indeterminados, con la posibilidad de apoyo basado en las ROI que ha utilizado la IA para tomar decisiones. En este sentido, para estudios diagnósticos basados en IA, STARD-AI aporta un marco de reporte especialmente útil[19].

La evaluación debe alinearse con la pregunta clínica: en cribado se prioriza sensibilidad y valor predictivo negativo; en decisiones quirúrgicas interesa minimizar falsos negativos de malignidad sin inducir sobretratamiento por falsos positivos. Para plantear la implantación del sistema de IA, además de la discriminación, es imprescindible evaluar la calibración y, cuando sea posible, el análisis de utilidad (decision-curve analysis). En modelos predictivos o de selección terapéutica, la transparencia del reporte y el riesgo de sesgo se valoran con TRIPOD+AI y PROBAST+AI [20,21].

CONCLUSIONES

La IA aplicada a patología glandular salivar avanza desde pruebas de concepto hacia herramientas potencialmente útiles en escenarios delimitados: apoyo diagnóstico por imagen en tumores frecuentes, soporte a patología digital como segunda lectura y cuantificación de fenotipos ductales/parenquimatosos en enfermedad crónica.

La principal barrera sigue siendo la generalización por tamaños muestrales reducidos y heterogeneidad de adquisición. Por ello, la adopción responsable debe basarse en validación externa, reporte transparente, manejo explícito de incertidumbre y gobernanza clínica. En cuanto a LLM, su aportación razonable se limita a educación/documentación y soporte de baja complejidad, sin sustituir decisiones clínicas en sialoendoscopia o cirugía salivar[2,16,19].

CONFLICTO DE INTERESES

Los autores declaran no tener conflictos de interés.

FINANCIACIÓN

No se recibió financiación para la elaboración de este capítulo.

BIBLIOGRAFÍA

1. Skálová A, Hyrcza M, Leivo I, et al. Update from the 5th Edition of the World Health Organization Classification of Head and Neck Tumors: Salivary Glands. Head Neck Pathol. 2022;16(1):40-53.
2. Gündüz K, Alçın B, Kızıl Y, Piazza C. Artificial intelligence in the diagnosis of salivary gland diseases. Curr Opin Otolaryngol Head Neck Surg. 2022;30(6):396-403.
3. Sinci KA, Koska IO, Cetinoglu YK, et al. Deep learning–based classification of parotid gland tumors: integrating dynamic contrast-enhanced MRI for enhanced diagnostic accuracy. BMC Med Imaging. 2025;25:264.
4. Liu XH, Jiang JX, Wu Y, et al. Deep learning based ultrasound analysis facilitates precise distinction between parotid pleomorphic adenoma and Warthin tumor. Front Oncol. 2024;14:1337631.
5. He J, Zhou X, Liu X, et al. Ultrasound-based deep learning differentiates salivary gland tumors and assesses malignancy. Oral Surg Oral Med Oral Pathol Oral Radiol. 2025;140(2):227-236.
6. Wei W, Xu J, Xia F, et al. Deep learning-assisted diagnosis of benign and malignant parotid gland tumors based on automatic segmentation of ultrasound images: a multicenter retrospective study. Front Oncol. 2024;14:1417330.
7. Chau IJ, Kim CH, Nguyen SA, et al. Classification of salivary gland tumors on ultrasound using artificial intelligence: a systematic review and meta-analysis. Otolaryngol Head Neck Surg. 2026 Jan 4. [Epub ahead of print].
8. Liu Q, Wang Y, Yao Q, et al. Habitat Radiomics Analysis Based on Non-Contrast CT in Differentiation of Parotid Pleomorphic Adenoma and Adenolymphoma. Curr Med Imaging. 2025;21:e15734056409272.
9. Li S, Wang L, Zhong H, et al. A Recognition System for Diagnosing Salivary Gland Neoplasms Based on Vision Transformer. Am J Pathol. 2025;195(2):221-231.
10. Alsanie W, Chong H, Offiah AC, et al. Exploring the feasibility of AI-based analysis of histopathological variability in salivary gland tumours. Sci Rep. 2025;15:29171.
11. Sousa-Neto et al. Comparative analysis of convolutional neural network models for the histopathological differentiation of acinic cell carcinoma and secretory carcinoma. Oral Surg Oral Med Oral Pathol Oral Radiol. 2026;141(3):387-399.
12. Olivas O, García-Sevilla M, Cubero L, Pascau J, Naredo E. Performance of Artificial Intelligence-Based Salivary Gland Ultrasound in Sjögren Syndrome [abstract]. Arthritis Rheumatol. 2025;77(suppl 9).
13. Halle E, Amiel T, Aframian DJ, et al. Automated segmentation and deep learning classification of ductopenic parotid salivary glands in sialo cone-beam CT images. Int J Comput Assist Radiol Surg. 2025;20(1):21-30.
14. Campagner A, Lazzeroni M, Pizzi C, Cabitza F. Weakly supervised treatment selection: machine learning models for appropriate surgical planning of submandibular stones. Comput Biol Med. 2026;202:111416.
15. Aničin A, Urbančič J. Sialendoscopy and CT navigation assistance in the surgery of sialolithiasis. Radiol Oncol. 2021;55(3):284-291.
16. Chiesa-Estomba CM, Lechien JR, Vaira LA, et al. Exploring the potential of Chat-GPT as a supportive tool for sialendoscopy clinical decision making and patient information support. Eur Arch Otorhinolaryngol. 2024;281(4):2081-6.
17. Küçüktağ Z, Altan E, Saygı Uysal G, Özdoğan A. Are ChatGPT's Answers to Questions About Salivary Gland Diseases Accurate and Reliable? Turk Arch Otorhinolaryngol. 2025;63(3):143-50.

18. Lorenzi A, Pugliese G, Maniaci A, et al. Reliability of large language models for advanced head and neck malignancies management: a comparison between ChatGPT 4 and Gemini Advanced. Eur Arch Otorhinolaryngol. 2024;281:5001-6.

19. Sounderajah V, Guni A, Liu X, et al. STARD-AI: an extension of the STARD statement for reporting diagnostic accuracy studies of artificial intelligence. Nat Med. 2025;31(10):3283-9.

20. Collins GS, Moons KGM, Dhiman P, et al. TRIPOD+AI statement: updated guidance for reporting clinical prediction models that use regression or machine learning methods. BMJ. 2024;385:e078378.

21. Moons KGM, Damen JA, Kaul T, et al. PROBAST+AI: a tool to assess risk of bias and applicability of clinical prediction model studies that use machine learning. BMJ. 2025;388:e082505.

22. Li Y, van Rijn-Dekker MI, de Vette SPM, et al. Late-xerostomia prediction model based on 18F-FDG PET image biomarkers of the main salivary glands. Radiother Oncol. 2024;196:110319.

23. Adeoye J, Su YX. Artificial intelligence in salivary biomarker discovery and validation for oral diseases. Oral Dis. 2024;30:23-37.

10

Aplicaciones de la IA en el Síndrome de Apnea del Sueño

Marta Morato Galán[1], Ignacio Alcalá Rueda[2], Cristóbal Fernández Manzano[1,3]
1. Servicio de Otorrinolaringología, Hospital Universitario Quirónsalud Madrid
2. Servicio de Otorrinolaringología, Hospital Fundación Jiménez Díaz, Madrid
3. Servicio de Otorrinolaringología, Hospital del Escorial, San Lorenzo de El Escorial

INTRODUCCIÓN

La apnea del sueño representa una patología altamente prevalente, infradiagnosticada y con un impacto clínico y socioeconómico considerable. El diagnóstico clásico basado en polisomnografía presenta limitaciones evidentes de accesibilidad, coste y escalabilidad. En este contexto, la inteligencia artificial (IA) emerge como una herramienta capaz de analizar grandes volúmenes de datos fisiológicos, identificar patrones complejos y ofrecer soluciones de cribado, diagnóstico y seguimiento más accesibles y personalizados[1].

Esta situación se circunscribe a una realidad poblacional que es la preocupación creciente por el descanso nocturno. Existen de forma cada vez más frecuente dispositivos wearables que permiten registrar ciertos parámetros biológicos relacionados con el sueño. Las señales fisiológicas utilizadas por la inteligencia artificial en apnea del sueño han evolucionado desde parámetros simples hacia modelos complejos y multimodales. La oximetría y la fotopletismografía constituyen actualmente el núcleo de la mayoría de aplicaciones clínicas, mientras que ECG, movimiento y sonido aportan información complementaria[2,3].

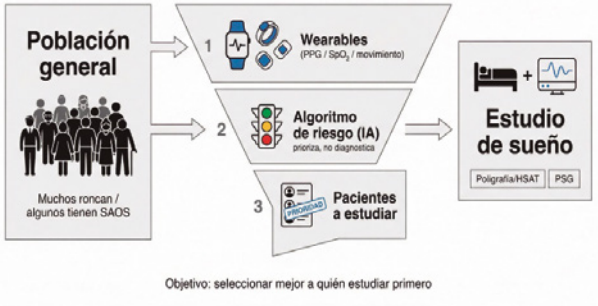


Figura 1. Cribado poblacional con wearables.

La combinación inteligente de estas señales, junto con modelos de IA bien validados, está redefiniendo el abordaje del SAOS, especialmente en cribado y seguimiento, y sienta las bases para una medicina del sueño más accesible, personalizada y continua. (**Figura 1**)

SEÑALES FISIOLÓGICAS UTILIZADAS POR LA INTELIGENCIA ARTIFICIAL EN LA APNEA DEL SUEÑO

La eficacia de la inteligencia artificial aplicada a la apnea del sueño depende de la calidad, tipo y combinación de las señales fisiológicas analizadas. A diferencia de la polisomnografía convencional, que integra múltiples canales de forma simultánea, los sistemas basados en IA, especialmente aquellos apoyados en dispositivos wearables, suelen trabajar con un número limitado de señales. Sin embargo, mediante técnicas avanzadas de procesamiento y aprendizaje automático, estas señales pueden contener información suficiente para detectar eventos respiratorios, estimar la severidad del trastorno y caracterizar perfiles fisiopatológicos relevantes, como por ejemplo, pacientes con apnea obstructiva del sueño de características posicionales (POSA).

A continuación se describen las más relevantes.

OXIMETRÍA DE PULSO (SPO_2)

La oximetría de pulso es, con diferencia, la señal más ampliamente utilizada en modelos de inteligencia artificial aplicados a la apnea del sueño. Mide de forma continua la saturación periférica de oxígeno y refleja

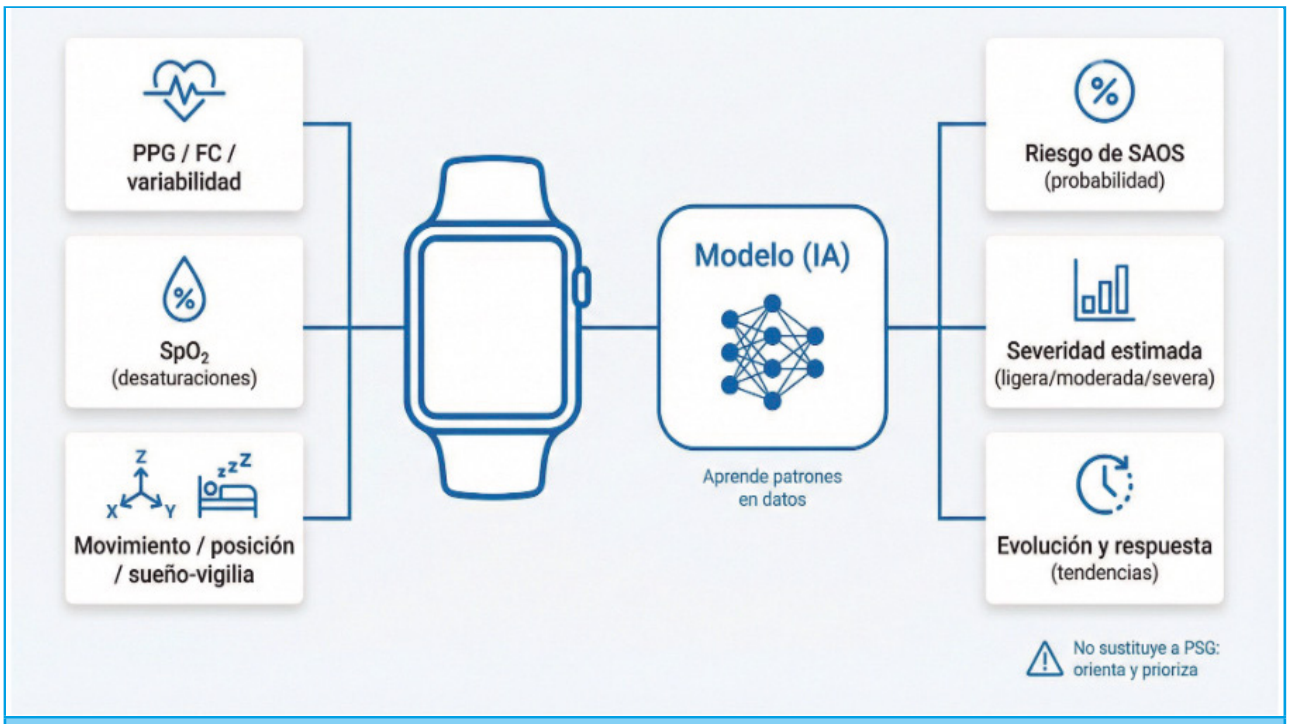


Figura 2. De las señales del wearable a una salida clínicamente interpretable.

de manera indirecta las consecuencias fisiológicas de los eventos respiratorios obstructivos y centrales[3].

Desde un punto de vista fisiopatológico, las apneas e hipopneas producen desaturaciones intermitentes, cuya frecuencia, profundidad y duración se asocian no solo con la severidad del SAOS, sino también con el riesgo cardiovascular. Tradicionalmente, estos cambios se han resumido mediante índices como el ODI (*oxygen desaturation index*). Sin embargo, la IA permite ir más allá del simple conteo de desaturaciones.

Diversos estudios han demostrado que, incluso utilizando únicamente SpO_2, los modelos de *deep learning* pueden estimar el AHI con una precisión aceptable, especialmente para identificar SAOS moderado-grave. Esta simplicidad convierte a la oximetría en una herramienta ideal para cribado domiciliario, aunque con limitaciones para distinguir tipos de apnea o detectar eventos sin desaturación significativa[5,6].

FOTOPLETISMOGRAFÍA (PPG)

La fotopletismografía se ha convertido en una señal clave en el desarrollo de wearables modernos. Se basa en la detección óptica de cambios en el volumen sanguíneo periférico y está integrada en la mayoría de relojes y anillos inteligentes actuales[1].

Desde la perspectiva de la inteligencia artificial, la PPG es especialmente valiosa porque combina información cardiovascular y respiratoria indirecta. A partir de esta señal, los algoritmos pueden extraer: frecuencia cardiaca y su variabilidad (HRV), respuestas autonómicas asociadas a microdespertares y patrones de pulso relacionados con desaturaciones.

En apnea del sueño, los eventos obstructivos generan una activación simpática transitoria que se traduce en cambios característicos en la señal PPG. Los modelos de *deep learning* son capaces de identificar estas alteraciones incluso cuando la desaturación es mínima, lo que confiere a la PPG un papel complementario a la SpO_2[6].

Además, la PPG presenta ventajas prácticas importantes: es cómoda, continua, bien aceptada por el paciente y fácilmente integrable en dispositivos de uso cotidiano. Su principal limitación radica en la variabilidad de calidad de señal, influida por el movimiento, la perfusión periférica y las características del sensor.

Electrocardiograma (ECG) y variabilidad de la frecuencia cardiaca (HRV)

El electrocardiograma ha sido utilizado históricamente en estudios de sueño, pero su aplicación en IA ha renovado su interés. A partir del ECG, los algoritmos pueden analizar la variabilidad de la frecuencia cardiaca, que refleja el equilibrio entre los sistemas simpático y parasimpático. Su uso es especialmente interesante en contextos donde la señal respiratoria directa no está disponible, pero tiene limitaciones técnicas importantes[4].

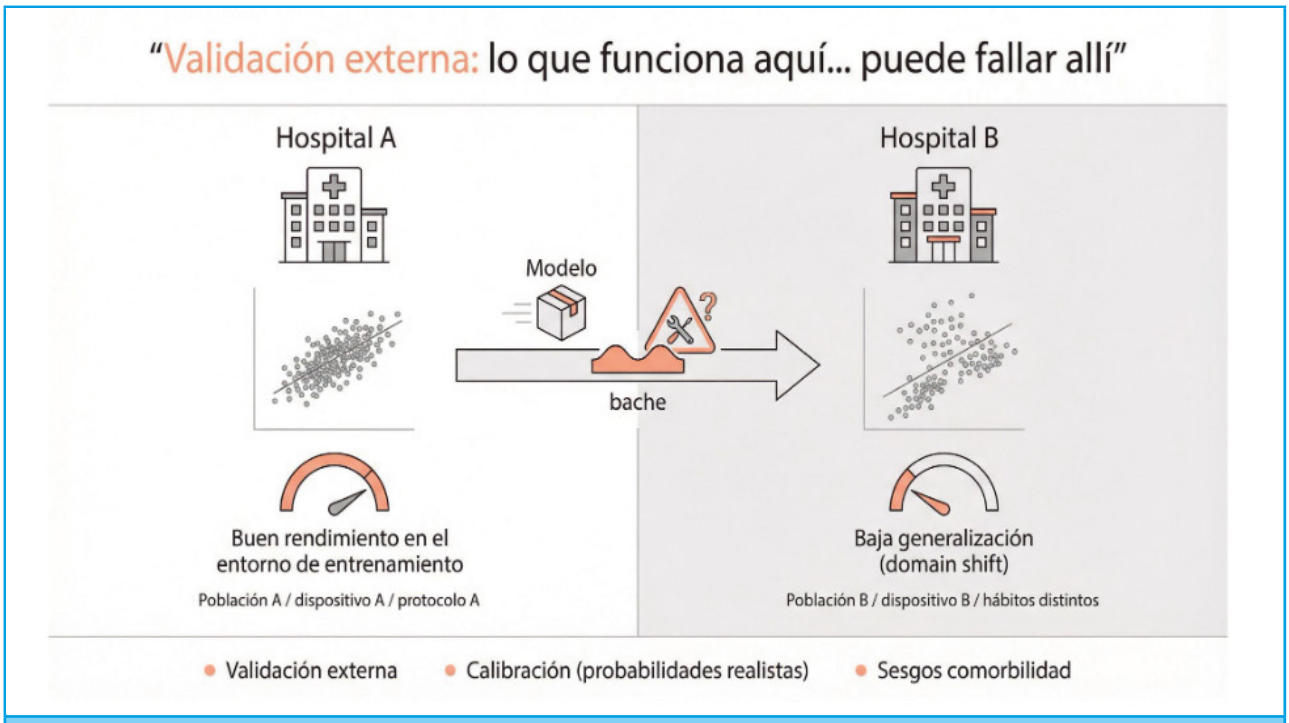


Figura 3. Importancia de la validación externa y el "*domain shift*".

COMBINACIÓN DE SEÑALES: EL ENFOQUE MULTIMODAL

La tendencia más sólida en la literatura reciente es la integración multimodal de señales fisiológicas. En lugar de depender de una única fuente de información, los modelos combinan SpO_2, PPG, movimiento y sonido, captando distintas dimensiones del fenómeno respiratorio y autonómico.

Este enfoque refleja mejor la complejidad fisiopatológica del SAOS y mejora de forma consistente la precisión diagnóstica. Además, reduce la dependencia de una señal concreta, aumentando la robustez frente a pérdidas de calidad o artefactos[6,7].

Desde el punto de vista clínico, los modelos multimodales son los que muestran mayor potencial para: cribado fiable, estimación de severidad, fenotipado y seguimiento longitudinal. (**Figura 2**)

FUNDAMENTOS DE INTELIGENCIA ARTIFICIAL APLICADOS A LA APNEA DEL SUEÑO

La inteligencia artificial (IA) engloba un conjunto de métodos computacionales capaces de identificar patrones en datos complejos y generar predicciones o clasificaciones. En apnea del sueño, estos modelos se entrenan principalmente para: (1) detectar eventos respiratorios, (2) estimar severidad (p. ej., AHI/IAH o carga hipóxica), (3) clasificar fenotipos y (4) apoyar decisiones clínicas (cribado, priorización, adherencia a CPAP y seguimiento)[4,5].

En comparación con los enfoques tradicionales basados en reglas (por ejemplo, umbrales de desaturación), la IA permite integrar señales múltiples y relaciones no lineales, que son especialmente relevantes en SAOS, donde la fisiopatología se expresa con gran variabilidad interindividual.

QUÉ "APRENDE" UN MODELO EN APNEA: TAREAS TÍPICAS

En la literatura, la IA se aplica con frecuencia a cuatro tareas principales, fundamentalmente enfocadas a la lectura de pruebas y una de ellas a la toma de decisiones: (1) detección de eventos (evento a evento): clasifica ventanas temporales como apnea/hipopnea vs. normalidad, (2) estimación de severidad (IAH/AHI o categorías): más habitual en wearables, el objetivo no es detectar cada evento, sino aproximar la severidad global o identificar SAOS moderado-grave, (3) clasificación de tipo de apnea (obstructiva vs. central): más compleja con wearables, porque requiere inferir esfuerzo respiratorio o correlatos indirectos, (4) predicción y estratificación de riesgo: modelos que estiman carga hipóxica, riesgo cardiometabólico o probabilidad de mala adherencia a CPAP. Esta línea es clínicamente muy atractiva porque se acerca más a decisiones que a números.



Figura 4. Integración práctica de wearables e IA en el flujo ORL.

VALIDACIÓN Y RENDIMIENTO DE LOS MODELOS EN APNEA DEL SUEÑO

En medicina del sueño, un modelo puede parecer bueno hasta que se valida en población real. Por eso, hay que distinguir[3,8]:

Validación interna: entrenamiento y test en el mismo dataset (riesgo de sesgo). Validación externa: prueba en otra cohorte/hospital/dispositivo (lo que realmente importa). Estudios prospectivos: el estándar deseable para afirmar utilidad clínica.

Clínicamente, en cribado interesa mucho minimizar falsos negativos en grupos de riesgo; y en priorización de unidades de sueño, maximizar la detección de moderado-grave.

Los modelos sufren cuando cambian: el tipo de sensor (PPG de reloj vs. anillo), el algoritmo de filtrado del fabricante, el lugar de uso (laboratorio vs. domicilio) o la población (edad, comorbilidad, IMC, pigmentación cutánea en PPG). A esto se le llama *domain shift* y es una de las razones principales por las que un modelo excelente en un estudio puede fallar en práctica real. La PSG sigue siendo el estándar diagnóstico, pero la IA + wearables está reconfigurando el circuito asistencial: más pacientes detectados, mejor priorización, y seguimiento más eficiente. (**Figura 3**)

DISPOSITIVOS WEARABLES EN APNEA DEL SUEÑO

Tipología de dispositivos y rendimiento

Los principales tipos de dispositivos incluyen: relojes inteligentes, anillos inteligentes, parches torácicos y dispositivos multimodales domiciliarios.

Las revisiones sistemáticas recientes coinciden en que los dispositivos wearables con IA muestran un rendimiento aceptable para cribado, pero con limitaciones para diagnóstico definitivo. De forma resumida[1,2]:

La sensibilidad para detectar SAOS moderado-grave suele situarse entre el 80 y el 95 % en los modelos mejor validados. La especificidad es más variable, especialmente en SAOS leve. La correlación con el AHI de PSG es moderada-alta, pero con dispersión relevante. El error en la estimación individual del AHI puede ser clínicamente significativo en casos límite.

Estos hallazgos refuerzan la idea de que la IA es más fiable como herramienta de cribado que como sustituto directo de la PSG.

Asimismo, el tipo de dispositivo influye en la calidad de la señal: relojes, anillos y parches no son equivalentes, y los algoritmos suelen estar optimizados para sensores concretos, lo que limita la generalización.

VALIDACIÓN POR SEVERIDAD: EL PROBLEMA DEL SAOS LEVE

Un hallazgo consistente es que la validación frente a PSG es menos robusta en SAOS leve. Esto se debe a varios factores: menor carga hipóxica y eventos respiratorios sin desaturación.

Desde el punto de vista clínico, este hecho es relevante: los dispositivos basados en IA no deben emplearse para excluir SAOS leve cuando existe alta sospecha clínica, sino para identificar pacientes con mayor probabilidad de enfermedad clínicamente relevante.

Sesgos y limitaciones en la validación clínica

Los estudios de validación presentan limitaciones recurrentes: sesgo de selección (poblaciones con alta prevalencia de SAOS), entrenamiento y validación en el mismo entorno, dependencia del fabricante (algoritmos propietarios no transparentes) y variabilidad en la anotación PSG, que introduce ruido en el gold standard. Además, muchos dispositivos se validan en condiciones ideales (laboratorio), lo que no siempre refleja el rendimiento en domicilio.

A la luz de la evidencia disponible, el uso clínico más razonable de los wearables con IA frente a la PSG es: (1) cribado y priorización en pacientes con sospecha de SAOS; (2) identificación de SAOS moderado-grave con alta probabilidad; (3) seguimiento longitudinal tras intervención (CPAP, cirugía, pérdida de peso); (4) complemento a la evaluación clínica, no sustituto del juicio médico.

La PSG continúa siendo necesaria para realizar el diagnóstico definitivo y la caracterización completa del sueño. El reto futuro reside en estudios prospectivos, multicéntricos y con validación externa robusta, así como en la integración de métricas más allá del AHI que reflejen mejor el impacto clínico del trastorno. (**Figura 4**)

CONCLUSIONES

La inteligencia artificial aplicada a dispositivos wearables emerge como una herramienta especialmente atractiva desde el punto de vista de la salud pública. Los wearables permiten la recogida continua y no invasiva de señales fisiológicas relevantes, como la oximetría, la fotopletismografía y el movimiento corporal, mientras que los algoritmos de IA son capaces de analizar estos datos a gran escala, identificando patrones compatibles con apnea del sueño. Este enfoque resulta potencialmente coste-efectivo, escalable y bien aceptado por la población general, lo que lo convierte en una opción idónea para programas de cribado[2,8].

La evidencia actual sugiere que estas herramientas muestran un rendimiento adecuado para el cribado de SAOS moderado-grave, que es precisamente el subgrupo con mayor impacto clínico y mayor beneficio potencial del tratamiento. Desde una perspectiva poblacional, el objetivo del cribado es estratificar el riesgo y priorizar el acceso a estudios de sueño convencionales en aquellos sujetos con mayor probabilidad de enfermedad clínicamente relevante [3,8].

CONFLICTO DE INTERESES

Los autores declaran no tener conflictos de interés.

FINANCIACIÓN

No se recibió financiación para la elaboración de este capítulo.

BIBLIOGRAFÍA

1. Abd-alrazaq A, Aslam H, AlSaad R, Alsahli M, Ahmed A, Damseh R, et al. Detection of sleep apnea using wearable artificial intelligence technology: a systematic review and meta-analysis. J Med Internet Res. 2024;26:e58187. https://doi.org/10.2196/58187.

2. Osa-Sanchez A, Ramos-Martinez-de-Soria J, Mendez-Zorrilla A, Ruiz IO, Garcia-Zapirain B. Wearable sensors and artificial intelligence for sleep apnea detection: a systematic review. J Med Syst. 2025;49(1):66. https://doi.org/10.1007/s10916-025-02199-8.

3. Haghighat S, Joghatayi M, Issa J, Azimian S, Brinz J, Ashkan A, et al. Diagnostic accuracy of artificial intelligence for obstructive sleep apnea detection: a systematic review. BMC Med Inform Decis Mak. 2025;25(1):278. https://doi.org/10.1186/s12911-025-03129-x.

4. 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(7):1337-63. https://doi.org/10.5664/jcsm.10532.

5. Tyagi PK, Agarwal D. Systematic review of automated sleep apnea detection based on physiological signal data using deep learning algorithm: a meta-analysis approach. Biomed Eng Lett. 2023;13(3):293-312. https://doi.org/10.1007/s13534-023-00297-5.

6. Levy J, Álvarez D, Del Campo F, Behar JA. Deep learning for obstructive sleep apnea diagnosis based on single channel oximetry. Nat Commun. 2023;14(1):4881. https://doi.org/10.1038/s41467-023-40604-3.

7. Wang S, Xuan W, Chen D, Gu Y, Liu F, Chen J, et al. Machine learning assisted wearable wireless device for sleep apnea syndrome diagnosis. Biosensors. 2023;13(4):483. https://doi.org/10.3390/bios13040483.

8. Tisyakorn J, Saiphoklang N, Sapankaew T, Thapa K, Anutariya C, Sujarae A, et al. Screening moderate to severe obstructive sleep apnea with wearable device. Sleep Breath. 2024;29(1):61. https://doi.org/10.1007/s11325-024-03232-9.

9. Zovko K, Sadowski Y, Perković T, Šolić P, Pavlinac Dodig I, Pecotić R, et al. Advanced data framework for sleep medicine applications: machine learning-based detection of sleep apnea events. Appl Sci. 2025;15(1):376. https://doi.org/10.3390/app15010376.

11

Aplicaciones en Rinología

Pablo Sarrió Solera[1], Jesús Gimeno Hernández[1], M.ª del Mar Martínez Ruiz-Coello[1], Juan José Ocaña Domínguez[2]

1. Servicio de Otorrinolaringología, Unidad de Rinología, Olfato y Base de Cráneo Anterior, Hospital Clínico San Carlos
2. Servicio de Otorrinolaringología, Hospital Blua Sanitas Valdebebas

INTRODUCCIÓN

La inteligencia artificial (IA) ha experimentado un crecimiento exponencial en el campo de la Otorrinolaringología, y la rinología se ha posicionado como una de las subespecialidades pioneras en la adopción de estas tecnologías[1]. Aunque la implementación de la IA en la práctica clínica diaria de la rinología aún enfrenta desafíos, la literatura científica refleja un crecimiento exponencial en la investigación en este campo (**Figura 1**)[1,2]. A continuación se enumerarán las principales aplicaciones actuales de la inteligencia artificial en la rinología, basadas en aprendizaje automático (*machine learning*, ML), aprendizaje profundo (*deep learning*, DL) y procesamiento de lenguaje natural (NLP)[1,3,4].

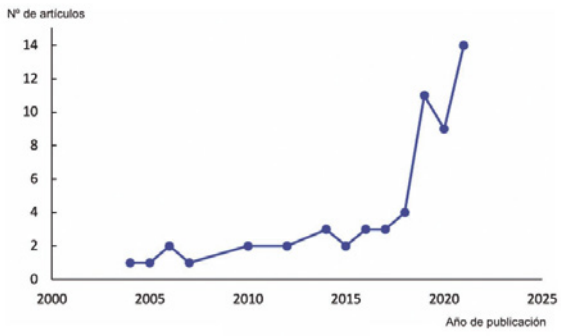


Figura 1. Evolución de las publicaciones científicas sobre IA en rinología. Tomado de Amanian et al.[1]

DIAGNÓSTICO RADIOLÓGICO

El análisis de imágenes radiológicas, específicamente la tomografía computarizada (TC) y la resonancia magnética (RM), constituye el área con mayor volumen de publicaciones sobre IA en rinología. Las redes neuronales convolucionales (CNN) han demostrado una eficacia sobresaliente en la automatización del diagnóstico y la clasificación de patologías.

La TC de senos paranasales es fundamental para diagnosticar y cuantificar la gravedad de la rinosinusitis crónica (RSC) mediante escalas validadas como el score de Lund-Mackay (LMS)[5]. Sin embargo, el cálculo manual del LMS consume mucho tiempo en la práctica clínica. Recientemente, se ha desarrollado un modelo basado en una arquitectura 2D U-Net capaz de segmentar automáticamente los senos paranasales y calcular el LMS basándose en el conteo de píxeles y umbrales de opacificación. Este modelo alcanzó una precisión global superior al 90 % para los senos maxilares, etmoidales anteriores y posteriores, esfenoidales y frontales, logrando estandarizar los informes radiológicos de manera objetiva (**Figura 2**)[6].

La IA también se aplica para distinguir características sutiles entre neoplasias. Mediante análisis de textura por resonancia magnética o TC, los modelos de ML pueden diferenciar con alta precisión entre papilomas invertidos, carcinomas de células escamosas y neuroblastomas olfatorios. Estos sistemas apoyan tanto la planificación quirúrgica preoperatoria como la monitorización de recurrencias postoperatorias[1,4].

ENDOSCOPIA NASAL INTELIGENTE

La endoscopia nasal es la prueba diagnóstica central en la rinología, pero su precisión depende

enormemente de la experiencia del explorador. El análisis de imágenes y vídeos endoscópicos mediante DL está revolucionando este campo, abarcando desde la detección de pólipos hasta la clasificación de tumores (**Figura 3**)[7,8]. En un avance significativo, se desarrolló un sistema que combina el modelo EfficientNet-B2 para clasificación y nnUNet para segmentación de masas nasosinusales a partir de imágenes endoscópicas. Evaluado en un conjunto de más de 1200 imágenes de múltiples calidades para imitar el entorno clínico real, el algoritmo logró una precisión general del 90,5 % en la detección de masas. Aún más destacable, el modelo alcanzó una especificidad del 94,7 % y una sensibilidad del 86,4 % en la identificación de tumores malignos[8].

En la endoscopia nasal tiene gran utilidad la llamada *edge computing*. Estudios recientes han integrado algoritmos de la familia YOLO (*you only look once*) operando localmente mediante *edge computing* conectado directamente a la torre de endoscopia. Estos sistemas pueden procesar el vídeo a velocidades superiores a los 20-22 fotogramas por segundo (FPS), permitiendo la segmentación en tiempo real sin interrupciones perceptibles (latencias inferiores a 40 ms)[9]. Esta misma tecnología se ha utilizado para brindar apoyo a la decisión clínica en tiempo real para el diagnóstico de rinosinusitis, alcanzando una sensibilidad del 75 % y especificidad del 76 %, emulando el proceso de toma de decisiones de un otorrinolaringólogo capacitado[10].

Existen además aplicaciones móviles como Nose-Keeper que integran modelos de DL para la detección temprana del carcinoma nasofaríngeo, logrando una precisión diagnóstica que frecuentemente supera la de especialistas humanos, al proporcionar mapas de atención que destacan visualmente las zonas sospechosas[11].

FENOENDOTIPADO EN RSC (MEDICINA PERSONALIZADA)

El manejo de la rinosinusitis crónica (RSC) ha transitado desde una división dicotómica clásica (con o sin pólipos) hacia una clasificación más compleja basada en fenotipos y endotipos inflamatorios. En este contexto, el aprendizaje automático no supervisado (*clustering*) ha demostrado una enorme utilidad clínica al analizar decenas de variables simultáneas[9]. Diferentes estudios han empleado algoritmos para agrupar pacientes utilizando variables que incluyen factores demográficos, puntajes del cuestionario SNOT-22, índices de comorbilidad y citocinas séricas o mucosas. Estas agrupaciones descubiertas por la

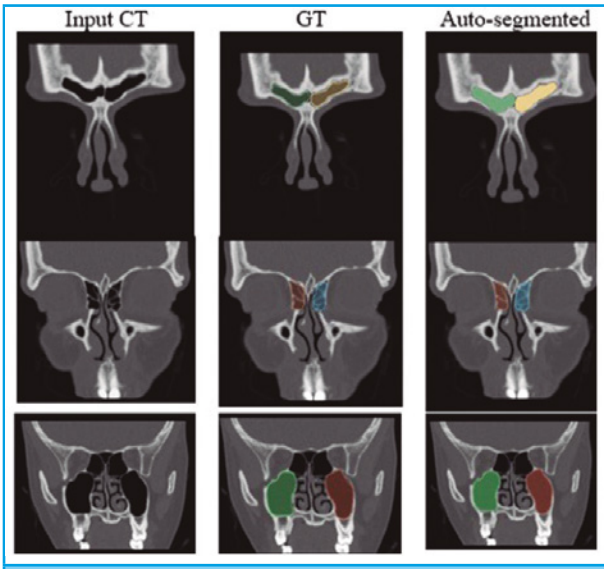


Figura 2. Uso de una red neuronal convolucional para automatizar la puntuación radiológica de la tomografía computarizada de los senos paranasales. Ejemplos de los resultados de segmentación. De arriba hacia abajo: senos frontales, etmoidales y maxilares. GT: estándar de referencia (*ground truth*). Tomado de Lee et al.[6]

IA han logrado correlacionar perfiles específicos de pacientes con respuestas divergentes a tratamientos, sensibilidad a la aspirina o tasas variables de mejora sintomática tras la cirugía endoscópica[1].

Existen herramientas emergentes como *Sinus Track*, una plataforma desarrollada en Argentina con el propósito de centralizar datos fragmentados de pacientes con sinusitis crónica, estandarizar la recolección de datos y emplear el aprendizaje automático para descubrir patrones y promover la medicina de precisión[12].

SOPORTE EN LA DECISIÓN CLÍNICA

Algunas patologías nasales, como la rinitis alérgica, también se han beneficiado de estas innovaciones. Se han diseñado sistemas de soporte de decisión clínica que, basados en los resultados de las pruebas cutáneas y datos clínicos, diagnostican la rinitis alérgica con una precisión del 88 %, superando ampliamente a los médicos en formación. Además, los algoritmos han demostrado la capacidad de identificar factores de riesgo ambiental (como la exposición prenatal a contaminantes) para el desarrollo de rinitis en la infancia[1,2].

NAVEGACIÓN Y PLANIFICACIÓN QUIRÚRGICA

Tras la revolución que supuso la cirugía endoscópica nasal, el campo de la visión artificial está intentando perfeccionarla buscando una precisión submilimétrica

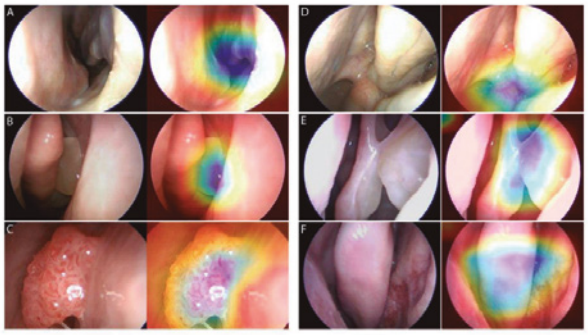


Figura 3. Mapas de atención para el modelo de clasificación generados mediante la técnica Grad-CAM. Se proporcionan ejemplos de imágenes del conjunto de prueba junto con sus correspondientes mapas de calor. El color azul indica una mayor influencia en la decisión de clasificación. Ejemplos de predicción correcta para la clasificación de: (A) Normal. (B) Pólipo. (C) Tumor. Ejemplos de predicciones erróneas: (D) Imagen normal clasificada erróneamente como pólipo. (E) Imagen de pólipo clasificada erróneamente como normal. (F) Tumor en la pared nasal lateral clasificado erróneamente como normal. Tomado de Levi et al.[8]

en la que el vídeo intraoperatorio se fusione de forma automática y dinámica con las TC preoperatorias sin intervención manual[13]. Utilizando métodos de CNN autosupervisados, el sistema puede estimar la profundidad de los tejidos a través del endoscopio monocular y registrar la anatomía tridimensional en tiempo real[1]. Estos sistemas evalúan el vídeo endoscópico, predicen cuál será el siguiente paso del procedimiento, identifican las estructuras críticas subyacentes y ofrecen retroalimentación al cirujano, actuando como un copiloto digital que alerta sobre potenciales complicaciones inminentes[1,4].

En el campo de la cirugía robótica aplicada a la rinología, existen prototipos de brazos robóticos portadores del endoscopio con algoritmos de seguimiento automatizado que permiten al cirujano operar cómodamente con ambas manos, así como sistemas capaces de fresar automáticamente la pared anterior del seno esfenoidal siguiendo una ruta predefinida[1].

RINOPLASTIA

El aprendizaje automático y las redes neuronales se emplean para predecir la morfología ósea y simular resultados. Aplicaciones como ProNose AI utilizan simulaciones avanzadas para planificar las intervenciones estéticas y predecir los resultados visuales, sirviendo como una valiosa herramienta de comunicación entre las expectativas del paciente y las posibilidades quirúrgicas. De igual forma, algoritmos entrenados en bases de datos faciales pueden deducir automáticamente si un paciente se ha sometido a una rinoplastia previa analizando una fotografía[4].

OLFATO

El aprendizaje automático ha tenido un papel destacado en la caracterización de los trastornos del olfato asociados a la RSC y a los síndromes virales. Los modelos han demostrado que patrones específicos de infiltración inflamatoria celular (como niveles elevados de IL-5 e IL-13) predicen la gravedad de la pérdida del olfato preoperatoria y la probabilidad de recuperación postquirúrgica. Estas predicciones generadas por la IA permitirán a los otorrinolaringólogos identificar pacientes en riesgo de anosmia persistente, ajustar las expectativas del paciente e indicar tratamientos antiinflamatorios adyuvantes tempranos[1].

DERMATOLOGÍA NASAL

El auge de los teléfonos inteligentes ha permitido llevar la IA directamente a las manos de los profesionales de atención primaria e incluso de los pacientes. Un área relevante para la rinología anatómica externa es la evaluación de lesiones cutáneas sospechosas en la pirámide nasal. Aplicaciones certificadas como *SkinVision* utilizan redes neuronales para orientar el diagnóstico de cánceres de piel como el melanoma, carcinomas basocelulares o espinocelulares, logrando un impacto en el cribado inicial, aunque estos estudios han resaltado la importancia de validar dichas aplicaciones en entornos clínicos del mundo real[14].

CONCLUSIONES

Existen herramientas basadas en IA (en continua evolución) para contribuir al diagnóstico y tratamiento en rinología, con múltiples aplicaciones: radiodiagnóstico nasal, patología inflamatoria y tumoral nasosinusal, cirugía endoscópica, dermatología nasal y olfato. La IA aplicada a la rinología debe entenderse como una herramienta de apoyo a la decisión clínica, cuyo objetivo no es reemplazar el juicio del médico, sino aumentar su capacidad diagnóstica, reducir la variabilidad interobservador y optimizar la medicina personalizada[1].

CONFLICTO DE INTERESES

Los autores declaran no tener conflictos de interés.

FINANCIACIÓN

No se recibió financiación para la elaboración de este capítulo.

BIBLIOGRAFÍA

1. Amanian A, Heffernan A, Ishii M, Creighton FX, Thamboo A. The Evolution and Application of Artificial Intelligence in Rhinology: A State of the Art Review. Otolaryngol Head Neck Surg. julio de 2023;169(1):21-30. doi:10.1177/01945998221110076 PubMed PMID: 35787221; PubMed Central PMCID: PMC11110957.

2. Bidwell J, Gyawali D, Morse J, Ganeshan V, Nguyen T, McCoul ED. Real-time augmentation of diagnostic nasal endoscopy video using AI-enabled edge computing. Int Forum Allergy Rhinol. febrero de 2025;15(2):191-4. doi:10.1002/alr.23458 PubMed PMID: 39316067; PubMed Central PMCID: PMC11785153.

3. Bulfamante AM, Ferella F, Miller AM, Rosso C, Pipolo C, Fuccillo E, et al. Artificial intelligence, machine learning, and deep learning in rhinology: a systematic review. Eur Arch Otorhinolaryngol. febrero de 2023;280(2):529-42. doi:10.1007/s00405-022-07701-3 PubMed PMID: 36260141; PubMed Central PMCID: PMC9849161.

4. Gyawali D, Mundy T, Hosseini M, Bodaghi M, Fujiwara A, Bhatia SS, et al. Machine Learning-Enhanced Clinical Decision Support for Diagnosing Sinusitis With Nasal Endoscopy. Int Forum Allergy Rhinol. febrero de 2026;16(2):152-61. doi:10.1002/alr.70045 PubMed PMID: 41091528; PubMed Central PMCID: PMC12863022.

5. Hashimoto DA, Rosman G, Rus D, Meireles OR. Artificial Intelligence in Surgery: Promises and Perils. Ann Surg. julio de 2018;268(1):70-6. doi:10.1097/SLA.0000000000002693 PubMed PMID: 29389679; PubMed Central PMCID: PMC5995666.

6. Huang S, Yang J, Fong S, Zhao Q. Artificial intelligence in cancer diagnosis and prognosis: Opportunities and challenges. Cancer Lett. 28 de febrero de 2020;471:61-71. doi:10.1016/j.canlet.2019.12.007 PubMed PMID: 31830558.

7. Kips J, Papeleu J, Shen A, Mylle S, Genouw E, Hoorens I, et al. Artificial intelligence-based smartphone application for skin cancer detection: A prospective diagnostic accuracy study. Br J Dermatol. 17 de febrero de 2026;ljag057. doi:10.1093/bjd/ljag057 PubMed PMID: 41701029.

8. Lee DJ, Hamghalam M, Wang L, Lin HM, Colak E, Mamdani M, et al. The use of a convolutional neural network to automate radiologic scoring of computed tomography of paranasal sinuses. Biomed Eng Online. 27 de abril de 2025;24(1):49. doi:10.1186/s12938-025-01376-7 PubMed PMID: 40289097; PubMed Central PMCID: PMC12036281.

9. Levi L, Ye K, Fieux M, Renteria A, Lin S, Xing L, et al. Machine Learning of Endoscopy Images to Identify, Classify, and Segment Sinonasal Masses. Int Forum Allergy Rhinol. mayo de 2025;15(5):524-35. doi:10.1002/alr.23525 PubMed PMID: 39776302; PubMed Central PMCID: PMC12048764.

10. Liu GS, Yang A, Kim D, Hojel A, Voevodsky D, Wang J, et al. Deep learning classification of inverted papilloma malignant transformation using 3D convolutional neural networks and magnetic resonance imaging. Int Forum Allergy Rhinol. agosto de 2022;12(8):1025-33. doi:10.1002/alr.22958 PubMed PMID: 34989484.

11. Lund VJ, Mackay IS. Staging in rhinosinusitus. Rhinology. diciembre de 1993;31(4):183-4. PubMed PMID: 8140385.

12. Sinus Track [Internet]. Argentina: Sinus Track; [citado 24 feb 2026]. Disponible en: https://sinustrack.org/.

13. Osie G, Darbari Kaul R, Alvarado R, Katsoulotos G, Rimmer J, Kalish L, et al. A Scoping Review of Artificial Intelligence Research in Rhinology. Am J Rhinol Allergy. julio de 2023;37(4):438-48. doi:10.1177/19458924231162437 PubMed PMID: 36895144; PubMed Central PMCID: PMC10273866.

14. Yue Y, Zeng X, Lin H, Xu J, Zhang F, Zhou K, et al. A deep learning based smartphone application for early detection of nasopharyngeal carcinoma using endoscopic images. NPJ Digit Med. 31 de diciembre de 2024;7(1):384. doi:10.1038/s41746-024-01403-2 PubMed PMID: 39738998; PubMed Central PMCID: PMC11685909.

12

Aplicaciones en cirugía plástica facial y reconstructiva

Alfonso Campos González, Asier Blanco Goñi, Javier Morales Domínguez
Servicio de Otorrinolaringología, Hospital Fundación Jiménez Díaz

INTRODUCCIÓN

La inteligencia artificial (IA) se está integrando de forma progresiva en la cirugía plástica facial y reconstructiva dentro de la Otorrinolaringología, aportando herramientas para cuantificar la anatomía, estandarizar decisiones, anticipar riesgos y medir resultados de manera objetiva. A diferencia de los enfoques basados exclusivamente en la experiencia visual del cirujano, la IA permite analizar grandes volúmenes de imágenes y datos clínicos, convirtiendo patrones complejos (asimetrías, proporciones, dinámicas faciales o evolución del edema) en métricas comparables[1,2,3]. Este capítulo organiza sus aplicaciones en tres momentos clínicos: consulta preoperatoria, utilidades en quirófano y evaluación postoperatoria con comparativas y gestión de expectativas[1,4,5].

CONSULTA PREVIA Y PLANIFICACIÓN PREOPERATORIA

La consulta preoperatoria es el punto de máximo impacto potencial de la IA en términos de eficiencia, seguridad y satisfacción. Aquí se concentran la adquisición de datos, la definición del problema (funcional y/o estético), la alineación de expectativas y la selección de estrategia quirúrgica. Las revisiones recientes coinciden en que el grueso de aplicaciones actuales se basa en el análisis y comparación de imágenes, aprendizaje automático y modelos generativos aplicados a fotografía 2D, 3D y datos clínicos estructurados.

Estandarización de la evaluación facial: landmarks, proporciones y asimetrías

Los algoritmos de detección automática de puntos anatómicos (*landmarks*) permiten obtener mediciones reproducibles: longitudes, ángulos, proyecciones y relaciones entre subunidades faciales. En rinoplastia, esto incluye análisis de dorso, punta, rotación/proyección, ángulos nasolabial/nasofrontal, simetría de narinas y relación nariz-mentón. En parálisis facial y reconstrucción, añade métricas dinámicas (sonrisa, cierre ocular, comisuras) y gradación objetiva de asimetrías.

La utilidad práctica no es "sustituir" la valoración clínica, sino: (1) reducir variabilidad interobservador, (2) facilitar comparativas pre/post, (3) mejorar la comunicación con el paciente y (4) crear bases de datos auditables para investigación y mejora de resultados. Las revisiones sistemáticas en la especialidad recogen que la mayoría de estudios de validación comparan la precisión del algoritmo frente a expertos, y tienden a mostrar errores bajos cuando se emplean protocolos fotográficos estandarizados y bases de datos representativas. Con una herramienta de análisis con IA podemos estandarizar las proporciones[6]. (**Figura 1**)

Apoyo en el diagnóstico

En cirugía reconstructiva, la IA puede apoyar el reconocimiento de patrones faciales relacionados con síndromes craneofaciales, malformaciones congénitas o secuelas postraumáticas. Esto se traduce en una planificación más temprana y estructurada de casos complejos (cicatrices, colapsos valvulares, deformidades del tercio medio o secuelas oncológicas[3]), integrando fotografía clínica, TAC y exploración

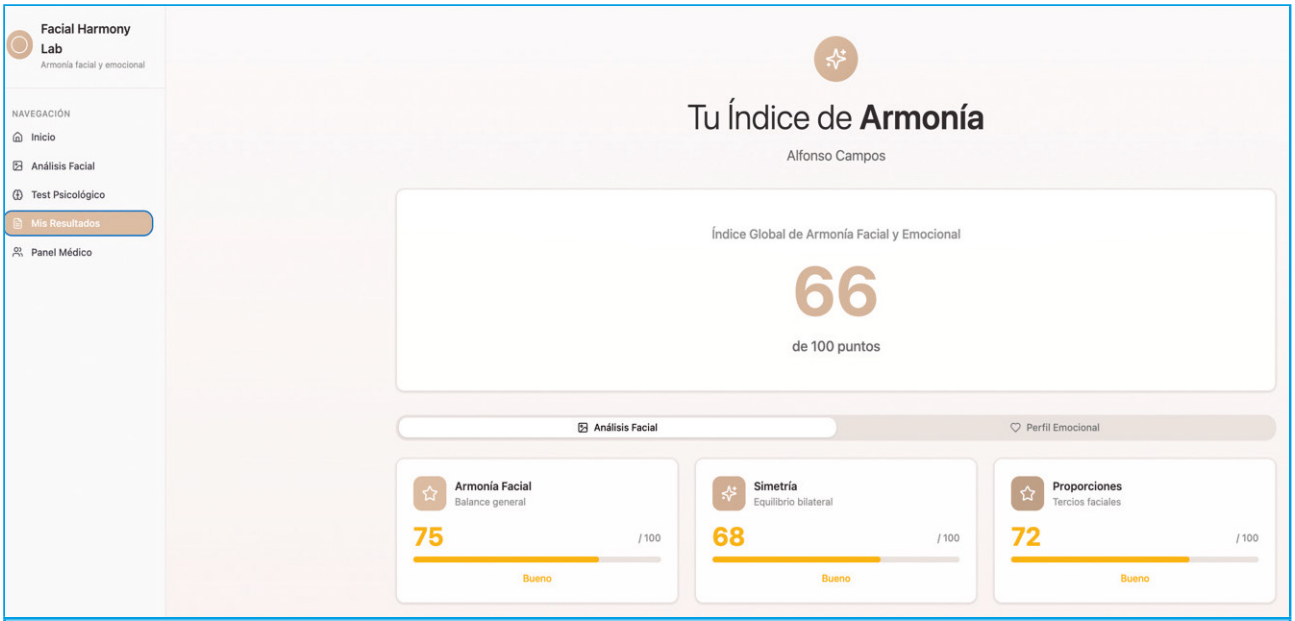


Figura 1. Interfaz del sistema Facial Harmony Lab mostrando el Índice Global de Armonía Facial y Emocional. (El panel integra métricas de análisis facial basadas en simetría, proporciones faciales y balance global, generando un índice cuantitativo sobre 100 puntos que permite evaluar de forma objetiva el grado de armonía facial del paciente).

funcional. Aunque muchas herramientas nacen fuera del entorno quirúrgico, las revisiones recientes subrayan su potencial para acelerar derivaciones y priorizar estudios complementarios, siempre con validación local y supervisión clínica[1,7].

Predicción de riesgo y personalización de la estrategia quirúrgica

Los modelos predictivos permiten estimar probabilidades de complicaciones o resultados subóptimos a partir de variables clínicas (tabaquismo, comorbilidades, antecedentes, tipo de piel/tejidos, cirugías previas) y variables de imagen. En rinoplastia, el interés práctico se centra en: riesgo de edema prolongado, irregularidades en dorso/punta, necesidad de injertos, inestabilidad estructural, retracciones y potencial de revisión[5,7]. Los trabajos recalcan que el mayor reto no es entrenar modelos, sino garantizar generalización, transparencia y ausencia de sesgos por edad, sexo, fototipo y características étnicas[8].

Simulación, comunicación y decisión compartida: el núcleo de la expectativa

La simulación preoperatoria (2D y, cada vez más, 3D) es probablemente la aplicación más visible para el paciente y, a la vez, una de las más delicadas desde el punto de vista ético y legal. Los modelos generativos pueden producir una proyección "realista" del resultado esperado, facilitando un lenguaje común: qué es posible, qué no lo es y qué compromisos técnicos se asumen (función vs. estética, estabilidad vs. refinamiento, etc.[9,10]).

Para que la simulación aumente la satisfacción y no genere frustración, conviene enmarcarla como herramienta de comunicación y no como promesa. La IA puede ayudar a: (1) cuantificar el punto de partida, (2) definir objetivos anatómicos medibles, (3) mostrar rangos probables (no un único resultado) y (4) documentar el acuerdo. En las revisiones de la literatura se insiste en que los mejores resultados en expectativas aparecen cuando la simulación se acompaña de educación estructurada: explicación de límites por tejidos, inflamación, cicatriz interna, tiempo de maduración y variabilidad individual[4]. En la **Figura 2** podemos observar cómo la IA nos puede ayudar a valorar el estado previo a nivel emocional de nuestros pacientes.

Estudios de validación: qué debe demostrarse antes de usarlo en rutina

Desde el punto de vista de implementación, no basta con que una herramienta "funcione". Debe validarse en: (a) precisión (comparación con expertos o gold standard), (b) reproducibilidad (misma salida ante entradas equivalentes), (c) generalización (funciona en tu población y con tu protocolo fotográfico), (d) utilidad clínica (mejora decisiones, seguridad o tiempos) y (e) impacto en satisfacción (expectativas y resultados percibidos). Las revisiones recientes en cirugía plástica facial (incluyendo las específicamente centradas en procedimientos faciales) recogen que muchas herramientas aún se encuentran en fases tempranas: buenos resultados técnicos, pero necesidad



Figura 2. Uso de una red neuronal convolucional para automatizar la puntuación radiológica de la tomografía computarizada de los senos paranasales. Ejemplos de los resultados de segmentación. De arriba hacia abajo: senos frontales, etmoidales y maxilares. GT: estándar de referencia (*ground truth*). Tomado de Lee et al.[6]

de estudios prospectivos, multicéntricos y con medidas centradas en el paciente[1].

Un ejemplo reciente de "validación realista" de modelos multimodales generalistas es el estudio de Haider et al[11]. (J. Clin. Med. 2025) que comparó ChatGPT-4o, ChatGPT-4, Gemini 1.5 Pro y Claude 3.5 Sonnet para análisis facial preoperatorio. Los autores validaron las respuestas frente a un estándar de referencia: evaluación de cirujanos plásticos para variables cualitativas y medidas manuales con ImageJ para ratios faciales. Los modelos mostraron rendimiento moderado en rasgos cualitativos (exactitud media ~0,52-0,61), pero bajo en medidas cuantitativas de proporciones y cánones (exactitud media global ~0,35; con pobre fiabilidad interevaluador en ratios, kappa cercana o inferior a 0 en muchas preguntas). La conclusión práctica es clara: los modelos multimodales generalistas pueden ayudar como "asistentes" en descripción global de rasgos, pero no son adecuados para sustituir mediciones clínicas o antropometría precisa sin integrarse con visión por computador especializada.

UTILIDADES DE LA IA EN QUIRÓFANO

En quirófano, la IA tiende a integrarse como "capa" sobre tecnologías existentes (imagen, navegación, realidad aumentada, robótica) más que como solución aislada. Las utilidades más relevantes descritas en la literatura son:

- Realidad aumentada y navegación: superposición de planificación preoperatoria sobre el campo quirúrgico para mejorar orientación y precisión en osteotomías, resecciones o reconstrucciones.
- Segmentación y guía basada en imagen: asistencia en TAC/CBCT para definir límites anatómicos, zonas de riesgo y trayectorias en reconstrucción compleja.
- Análisis intraoperatorio de perfusión: apoyo en microcirugía/reconstrucción para detectar precozmente compromiso vascular mediante análisis de imagen (color, perfusión) y alertas tempranas.
- Seguimiento de instrumentos y seguridad: visión por computador para identificar fases de la cirugía, estandarizar checklists y reducir variabilidad en procesos repetitivos.

En cirugía plástica facial, la adopción real depende de infraestructura y coste. Por eso, muchas propuestas se enfocan en usos "ligeros" y escalables: asistencia por imagen, checklists inteligentes y herramientas de documentación intraoperatoria[2,3,9].

CONSULTA POSTOPERATORIA: COMPARACIÓN DE RESULTADOS, OBJETIVACIÓN Y GESTIÓN DE EXPECTATIVAS

La etapa postoperatoria es clave porque une dos mundos: el resultado anatómico/funcional real y la percepción del paciente (expectativa, identidad, emoción). La IA aporta valor cuando convierte el seguimiento en algo medible y comparable, y cuando ayuda a explicar la evolución normal (inflamación, asimetrías transitorias, maduración cicatricial) evitando interpretaciones prematuras[10].

Comparativas pre/post estandarizadas (fotografía, 3D y métricas)

Con protocolos de imagen estandarizados, los algoritmos pueden alinear automáticamente fotografías o modelos 3D, medir cambios y generar informes comparativos: simetría, contornos, proyección, rotación, relaciones faciales y, en reconstrucción, restauración de subunidades. Esto permite objetivar progresos en visitas seriadas (1 mes, 3 meses, 6 meses, 12 meses), y comparar técnicas o decisiones intraoperatorias a nivel de auditoría clínica[4].

En rinoplastia, un uso especialmente útil es el seguimiento del edema y la rotación de la punta: la IA puede cuantificar volumen relativo y asimetrías residuales, facilitando recomendaciones (masaje, cuidados, expectativas temporales) y evitando revisiones precipitadas[6].

Detección precoz de complicaciones y seguimiento remoto

La telemedicina apoyada por IA permite que el paciente envíe imágenes estructuradas desde su domicilio. Modelos de clasificación pueden ayudar a priorizar: hematoma, infección, alteraciones de cicatriz, signos de compromiso vascular en colgajos o problemas de cierre ocular en parálisis facial.

El uso de herramientas basadas en aprendizaje automático y procesamiento del lenguaje natural han demostrado utilidad en la resolución de preguntas postoperatorias frecuentes cuando se entrenan con información médica validada y bajo supervisión experta. Estos sistemas permiten estandarizar la recogida de información postoperatoria, identificar patrones evolutivos anómalos y priorizar la atención clínica en los casos que realmente lo requieren, contribuyendo a una optimización de recursos sin comprometer la seguridad del paciente[12].

El valor real está en el triaje: identificar a quién hay que ver hoy y quién puede seguir un plan conservador, con el cirujano siempre como decisor final.

Expectativas: de "foto ideal" a "rango probable" y control de la promesa

La gestión de expectativas es una de las principales causas de satisfacción o insatisfacción en cirugía estética facial. La IA puede contribuir de cuatro maneras:

- Trazabilidad del acuerdo: registrar objetivos anatómicos y prioridades (función, naturalidad, corrección de asimetrías) y vincularlos a métricas comparables en el postoperatorio.
- Comparación con simulación: usar la simulación como referencia orientativa, explicando desviaciones esperables por inflamación y biología tisular; idealmente mostrando escenarios/rangos en lugar de un único resultado.
- Educación personalizada: generar explicaciones adaptadas al caso (tipo de piel, estructura, necesidad de injertos, tiempo de maduración) para reducir ansiedad y expectativas rígidas.
- Elección de técnica quirúrgica: el uso de evaluaciones morfométricas automatizadas a partir de imágenes faciales estandarizadas facilita comparaciones longitudinales pre- y postoperatorias y analiza de forma sistemática el impacto de distintas técnicas quirúrgicas con una reproducibilidad superior a la evaluación subjetiva[4,6].

En la práctica, esto se traduce en una consulta postoperatoria más "objetiva": el paciente ve su evolución con datos y comparativas consistentes, y el cirujano dispone de un lenguaje común para justificar tiempos, límites y decisiones. La literatura reciente remarca que el mayor beneficio no es estético en sí, sino la reducción de discrepancias entre expectativa y realidad mediante comunicación estructurada[10].

Consideraciones éticas y limitaciones específicas en comparativas

Las comparativas automatizadas introducen riesgos: sesgos por iluminación o postura, sobreinterpretación de pequeñas diferencias, y dependencia excesiva de puntuaciones de "atractivo". Se recomienda priorizar métricas anatómicas y funcionales, proteger datos biométricos, asegurar consentimiento explícito para uso de imágenes y auditar la herramienta periódicamente. En términos de responsabilidad, la IA debe entenderse como apoyo: la decisión clínica y la comunicación final con el paciente siguen siendo del cirujano. Si se incorporan herramientas de IA para gestionar expectativas, conviene: apoyar lo cuantitativo en sistemas específicos, presentar la simulación como rango probable y no como promesa, y documentar claramente límites y variabilidad biológica[7,8].

CONCLUSIONES

La IA ya aporta valor tangible en Otorrinolaringología y cirugía plástica facial, especialmente en la consulta preoperatoria: estandariza mediciones, mejora la planificación, facilita la decisión compartida y ayuda a alinear expectativas. En quirófano, sus utilidades son más acotadas y dependen de tecnología complementaria, pero crecen en navegación y realidad aumentada. En el postoperatorio, la IA permite comparar resultados de forma objetiva y, sobre todo, convertir la expectativa en un proceso guiado con datos, reduciendo incertidumbre y potenciando satisfacción. El siguiente paso para una adopción responsable es reforzar la validación clínica (prospectiva, multicéntrica) y la auditoría de sesgos, manteniendo siempre el juicio profesional como eje de seguridad.

CONFLICTO DE INTERESES

Los autores declaran no tener conflictos de interés.

FINANCIACIÓN

No se recibió financiación para la elaboración de este capítulo.

BIBLIOGRAFÍA

1. Souza S, Bhethanabotla RM, Mohan S. Applications of artificial intelligence in facial plastic and reconstructive surgery: a systematic review. Curr Opin Otolaryngol Head Neck Surg. 1 de agosto de 2024;32(4):222-33. doi:10.1097/MOO.0000000000000975 PubMed PMID: 38695544.

2. Bayar Muluk N. Artificial Intelligence in Facial Plastic Procedures. Clin Otolaryngol. enero de 2026;51(1):1-6. doi:10.1111/coa.70052 PubMed PMID: 41110831.

3. Stephanian B, Karki S, Debnath K, Saltychev M, Rossi-Meyer M, Kandathil CK, et al. Role of Artificial Intelligence and Machine Learning in Facial Aesthetic Surgery: A Systematic Review. Facial Plast Surg Aesthet Med. 2024;26(6):679-705. doi:10.1089/fpsam.2024.0204 PubMed PMID: 39591584.

4. Garg SP, Collins AS, Rios-Diaz AJ. AI Tools in Plastic Surgery: A Scoping Review. J Craniofac Surg. 1 de abril de 2026;37(3-4):848-54. doi:10.1097/SCS.0000000000012414 PubMed PMID: 41614695.

5. Fung E, Patel D, Tatum S. Artificial intelligence in maxillofacial and facial plastic and reconstructive surgery. Curr Opin Otolaryngol Head Neck Surg. 1 de agosto de 2024;32(4):257-62. doi:10.1097/MOO.0000000000000983 PubMed PMID: 38837245.

6. Song JK, Rosellini I, Ka Fai W, Yi KH. Artificial Intelligence in Plastic Surgery and Anatomical Education: A New Era of Precision, Personalization, and Accessibility. J Craniofac Surg. 1 de abril de 2026;37(3-4):606-10. doi:10.1097/SCS.0000000000011945 PubMed PMID: 40951961.

7. Copeland-Halperin LR. Artificial Intelligence in Plastic Surgery: Current Status, Limitations, and Future Directions. Aesthet Surg J. 29 de enero de 2026;46(2):113-21. doi:10.1093/asj/sjaf239 PubMed PMID: 41609493.

8. Mansoor M, Ibrahim AF. The Transformative Role of Artificial Intelligence in Plastic and Reconstructive Surgery: Challenges and Opportunities. J Clin Med. 15 de abril de 2025;14(8):2698. doi:10.3390/jcm14082698 PubMed PMID: 40283528; PubMed Central PMCID: PMC12028257.

9. Shoham G, Naveh S, Confino I, Zoabi T, Govrin O, Fliss E, et al. A Systematic Review of Applications, Challenges, and Future Trajectories of Artificial Intelligence in Cosmetic Surgery. Aesthet Surg J. 29 de enero de 2026;46(2):150-9. doi:10.1093/asj/sjaf238 PubMed PMID: 41234118.

10. Haider SA, Prabha S, Gomez-Cabello CA, Borna S, Genovese A, Trabilsy M, et al. Facial Analysis for Plastic Surgery in the Era of Artificial Intelligence: A Comparative Evaluation of Multimodal Large Language Models. J Clin Med. 16 de mayo de 2025;14(10):3484. doi:10.3390/jcm14103484 PubMed PMID: 40429479; PubMed Central PMCID: PMC12112453.

11. Genovese A, Prabha S, Borna S, Gomez-Cabello CA, Haider SA, Trabilsy M, et al. Artificial Intelligence for Patient Support: Assessing Retrieval-Augmented Generation for Answering Postoperative Rhinoplasty Questions. Aesthet Surg J. 16 de junio de 2025;45(7):735-44. doi:10.1093/asj/sjaf038 PubMed PMID: 40088460.

12. Saravi B, Schorn L, Lommen J, Wilkat M, Vollmer A, Güzel HE, et al. Automatic Apparent Nasal Index from Single Facial Photographs Using a Lightweight Deep Learning Pipeline: A Pilot Study. Medicina (Kaunas). 27 de octubre de 2025;61(11):1922. doi:10.3390/medicina61111922 PubMed PMID: 41303759; PubMed Central PMCID: PMC12654233.

13

Aplicación de la IA en ORL infantil

Francisco Javier Hernández Calvín, Carlos Ruiz Escudero
Servicio de Otorrinolaringología, Hospital Universitario Quirónsalud

INTRODUCCIÓN

La inteligencia artificial (IA), en sus vertientes de aprendizaje automático (*machine learning*, ML) y aprendizaje profundo (*deep learning*, DL), está transformando la adquisición, interpretación y operacionalización de la información clínica. En ORL pediátrica, el interés es particularmente alto por tres razones: (1) la práctica se apoya en señales (imágenes otoscópicas, registros audiológicos y de sueño) idóneas para DL; (2) existe variabilidad interobservador en diagnósticos críticos (p. ej., otitis media aguda y serosa) y cuellos de botella en pruebas tiempo-intensivas como los potenciales evocados auditivos de tronco cerebral (PEATC) o la polisomnografía nocturna (PSG); y (3) la ORL pediátrica requiere estrategias de cribado, priorización y seguimiento escalables, compatibles con telemedicina y entornos de recursos limitados[1].

FUNDAMENTOS CONCEPTUALES DE LA IA EN ORL PEDIÁTRICA

Las aplicaciones de la IA pueden agruparse en cinco categorías: percepción asistida, estratificación de riesgo, soporte a la decisión clínica, automatización de flujos de trabajo y planificación quirúrgica/entrenamiento.

PROBLEMÁTICA EN EL DESARROLLO DE MODELOS DE IA EN ORL PEDIÁTRICA

El principal reto para la traslación clínica de modelos en ORL pediátrica es el "cambio de dominio" (*domain shift*), entendido como la discrepancia entre los datos de entrenamiento y los encontrados en la práctica clínica real. Este problema es especialmente relevante en pediatría por la asimetría de los errores diagnósticos, el entrenamiento con cohortes seleccionadas, la mayor variabilidad anatómica ligada a la edad, la escasez de datos y la mayor sensibilidad ética.

APLICACIONES DE LA IA EN LA PREVENCIÓN

Prevención secundaria en patología del oído medio

El objetivo es detectar enfermedad tratable antes de que evolucione a hipoacusia y retraso del desarrollo, especialmente en contextos con recursos limitados.

- Timpanograma operado por personal no experto: En un estudio realizado en la Alaska rural un modelo de timpanometría automática de banda estrecha mostró una sensibilidad del 95,2 %, una especificidad del 92,3 % y un área bajo la curva ROC (AUC) de 0,968[2].
- Inmitancia acústica de banda ancha (WAI): Muestra mayor sensibilidad para detectar derrames serosos, especialmente en lactantes (<6 meses). Peng y cols. en bebés de 2-6 meses, alcanzaron una exactitud >90 % y métricas de desempeño >0,8[3].

Prevención secundaria en la hipoacusia infantil

La determinación del umbral de los PEATC presenta variabilidad inter e intraevaluador significativa. Entre nueve modelos de DL evaluados, ResPatchTST alcanzó el mejor desempeño en validación independiente (exactitud 91,90 %, AUC 0,976)[4]. La automatización de los PEATC puede potenciar los programas de

cribado, pero exige calibración clínica, trazabilidad y validación por subgrupos.

Prevención en patología respiratoria obstructiva del sueño

La PSG constituye el método de referencia para el SAOS, pero el desarrollo de herramientas alternativas accesibles podría mejorar su identificación en contextos con acceso limitado a laboratorios del sueño.

- Modelos basados en variables clínicas: Qin y cols.[5] incluyeron 2.464 niños (3-18 años) con sospecha de SAOS, recogiendo datos clínicos, cuestionarios validados y PSG. Tras selección de variables mediante Elastic Net, el modelo alcanzó un AUC promedio de 0,73 para AHI ≥ 5 y 0,78 para AHI ≥ 10 en la validación externa.

- Dispositivos portátiles de monitoreo del sueño: Wang y cols.[6] evaluaron la concordancia entre el QSA600 (radar de ondas milimétricas y oximetría) y la PSG en población infantil, obteniendo un coeficiente de correlación intraclase (ICC) de 0,945 (IC 95 %: 0,93-0,96) para el índice de apnea-hipopnea obstructiva (IAHO).

APLICACIONES DE LA IA EN EL DIAGNÓSTICO

Constituye un cambio de paradigma que facilite la transición del "ojo entrenado" a la cuantificación reproducible.

Diagnóstico de la patología del oído medio

La otoscopia es indispensable, pero incluso con material estandarizado, hay diferencias entre clínicos al clasificar oídos como OMA/OME/normal (concordancia ORL-pediatra del 77 %)[7].

- Modelos de IA y video-otoscopia: en un estudio con *smartphone* adaptado a otoendoscopio, una red neuronal residual-recurrente alcanzó una especificidad del 93,5 % para OMA8. Respecto a la OME, Shim y cols.[9] mostraron que incluso el modelo con peor rendimiento (ResNet50, precisión 92,9 %) superó al mejor desempeño humano (84,0 %). No obstante, factores como calidad de imagen, cerumen o dispositivos heterogéneos pueden degradar el rendimiento, lo que hace imprescindible la validación externa.

- Modelos de diagnóstico multimodal: integran imágenes, registros de impedancia acústica y hallazgos clínicos en un solo modelo, reduciendo la ambigüedad diagnóstica.

Diagnóstico en la hipoacusia infantil

Además de la automatización de los PEATC, la IA se ha aplicado a la integración multimodal de variables clínicas, audiológicas y las obtenidas por imagen.

- Automatización de las pruebas objetivas: los modelos de DL aún no se han incorporado a la práctica clínica por la escasez de datos y la falta de validación externa, aunque modelos basados en transformadores (PatchTST, ResPatchTST) han mostrado un desempeño prometedor[4].

- Predicción de resultados en niños con implante coclear (IC): Nair y cols.[10] revisaron la aplicación de ML para predecir resultados tras IC. Los modelos basados en RNM funcional mostraron alta precisión predictiva. Lu y cols.[11] mediante SVM y medidas de función neural, obtuvieron una precisión del 71 % para resultados auditivos y del 93 % para rehabilitación del habla.

SAOS pediátrico: IA para detectar, estadificar y seleccionar tratamiento

- Triage/diagnóstico basado en variables clínicas (véase sección 4.3).

- Detección de señales de audio (ronquido) y ML: Ding y cols.[12] revisaron 14 estudios sobre detección de SAOS basada en DL a partir de sonidos de ronquido, analizando las representaciones de señal y arquitecturas empleadas.

- Monitorización y automatización de estadificación del sueño: El uso de radar de onda milimétrica y oximetría (véase sección 4.3) se muestra prometedor.

- Selección del tratamiento: ¿Quién se beneficia de la adenoamigdalectomía?: la IA puede reducir el infra y sobretratamiento, especialmente donde la PSG es poco accesible. Liu y cols.[13], con 323 niños del Childhood Adenotonsillectomy Trial (CHAT), aplicaron DL sobre variables de PSG (IAH, dinámica cardíaca, asincronía toracoabdominal) para predecir qué niños mejorarían con la cirugía. Gutiérrez-Tobal y cols.[14], con 464 niños del CHAT y un enfoque de inteligencia artificial explicable (XAI), identificaron 3 fenotipos; el de mayor edad, sobrepeso y circunferencia de cintura aumentada mostró menor probabilidad de resolución espontánea.

TRATAMIENTO MÉDICO Y QUIRÚRGICO: DE LA DECISIÓN A LA EJECUCIÓN

Otología/IC: segmentación automática y planificación quirúrgica

La segmentación manual del peñasco consume tiempo y depende del operador. Ke y cols.[15] estudiaron imágenes tomográficas del hueso temporal en 40 niños mediante DL con CNN. Los coeficientes de Dice oscilaron entre 0,658 y 0,915, con una distancia media de superficie inferior a 0,18 mm en 11 estructuras.

Endoscopia en ORL y lesiones laríngeas

La evidencia más robusta procede de patología tumoral laríngea en adultos; la generalización pediátrica requiere bases de datos propias y validación específica.

IA para entrenamiento, simulación y evaluación de habilidades

La realidad virtual (RV) se ha consolidado como herramienta formativa en cirugía del hueso temporal. Linke y cols.[16] evaluaron la validez de constructo del simulador VOXEL-MAN TempoSurg®. La revisión de Askoura y cols.[17] (14 estudios sobre RV en formación quirúrgica ORL) demostró mejoras significativas en habilidades y reducción de errores, aunque faltan estudios específicos en ORL infantil.

CONCLUSIONES

La implementación clínica de la IA en ORL pediátrica requiere abordar desafíos de validación externa, mitigación de sesgos y protección de datos pediátricos. No obstante, la IA representa una herramienta de gran potencial en la ORL infantil, con aplicaciones desde la prevención hasta la planificación quirúrgica y la predicción de resultados.

CONFLICTO DE INTERESES

Los autores declaran no tener conflictos de interés.

FINANCIACIÓN

No se recibió financiación para la elaboración de este capítulo.

BIBLIOGRAFÍA

1. Navarathna N, Kanhere A, Gomez C, Isaiah A. Artificial intelligence in pediatric otolaryngology: A state-of-the-art review of opportunities and pitfalls. Int J Pediatr Otorhinolaryngol. 2025;194:112369.
2. Jin FQ, Huang O, Kleindienst Robler S, Morton S, Platt A, Egger JR, et al. A Hybrid Deep Learning Approach to Identify Preventable Childhood Hearing Loss. Ear Hear. 2023;44(5):1262-70.
3. Peng S, Zhao Y, Yao X, Yin H, Ma B, Liu K, et al. Using Machine Learning for Analysis of Wideband Acoustic Immittance and Assessment of Middle Ear Function in Infants. Audiol Res. 2025;15(2):35.
4. Liu Y, Xiang L, Li Q, Li K, Yang Y, Wang T, et al. Comparison of Deep Learning Models for Objective Auditory Brainstem Response Detection: A Multicenter Validation Study. Trends Hear. 2025;29:23312165251347773.
5. Qin H, Zhang L, Li X, Xu Z, Zhang J, Wang S, et al. Pediatric obstructive sleep apnea diagnosis: leveraging machine learning with linear discriminant analysis. Front Pediatr. 2024;12:1328209.
6. Wang W, Song R, Wu Y, Zheng L, Zhang W, Chen Z, et al. Deep learning-based automated diagnosis of obstructive sleep apnea and sleep stage classification in children using millimeter-wave radar and pulse oximeter. Sleep Health. 2025;11(6):859-67.
7. Sundgaard JV, Värendh M, Nordström F, Kamide Y, Tanaka C, Harte J, et al. Inter-rater reliability of the diagnosis of otitis media based on otoscopic images and wideband tympanometry measurements. Int J Pediatr Otorhinolaryngol. 2022;153:111034.
8. Shaikh N, Conway SJ, Kovacevic J, Condessa F, Shope TR, Haralam MA, et al. Development and Validation of an Automated Classifier to Diagnose Acute Otitis Media in Children. JAMA Pediatr. 2024;178(4):401-7.
9. Shim JH, Sunwoo W, Choi BY, Kim KG, Kim YJ. Improving the Accuracy of Otitis Media with Effusion Diagnosis in Pediatric Patients Using Deep Learning. Bioengineering (Basel). 2023;10(11):1337.
10. Nair APS, Mishra SK, Alba Diaz PA. A systematic review of machine learning approaches in cochlear implant outcomes. NPJ Digit Med. 2025;8(1):411.
11. Lu S, Xie J, Wei X, Kong Y, Chen B, Chen J, et al. Machine Learning-Based Prediction of the Outcomes of Cochlear Implantation in Patients With Cochlear Nerve Deficiency and Normal Cochlea: A 2-Year Follow-Up of 70 Children. Front Neurosci. 2022;16:895560.
12. Ding L, Peng JX, Song YJ. Deep learning approaches for image-based snoring sound analysis in the diagnosis of obstructive sleep apnea-hypopnea syndrome: A systematic review. World J Radiol. 2025;17(9):109116.
13. Liu X, Pamula Y, Immanuel S, Kennedy D, Martin J, Baumert M. Utilisation of machine learning to predict surgical candidates for the treatment of childhood upper airway obstruction. Sleep Breath. 2022;26(2):649-61.
14. Gutiérrez-Tobal GC, Gomez-Pilar J, Ferreira-Santos D, Pereira-Rodrigues P, Álvarez D, Campo FD, et al. A subject-based association network defines new pediatric sleep apnea phenotypes with different odds of recovery after treatment. Comput Methods Programs Biomed. 2026;275:109209.
15. Ke J, Lv Y, Ma F, Du Y, Xiong S, Wang J, et al. Deep learning-based approach for the automatic segmentation of adult and pediatric temporal bone computed tomography images. Quant Imaging Med Surg. 2023;13(3):1577-91.
16. Linke R, Leichtle A, Sheikh F, Schmidt C, Frenzel H, Graefe H, et al. Assessment of skills using a virtual reality temporal bone surgery simulator. Acta Otorhinolaryngol Ital. 2013;33(4):273-81.
17. Askoura A, Mahmoud M. Beyond the cadaver: evaluating virtual reality simulation for modern otolaryngology surgical training. Egypt J Otolaryngol. 2025;41:182.

14

Aplicaciones de la inteligencia artificial en investigación sanitaria

Carlos Carazo Casas, Álvaro Borque Sanz, Rubén Polo López, Alfonso Santamaría Gadea
Servicio de Otorrinolaringología, Hospital Universitario Ramón y Cajal

INTRODUCCIÓN

La investigación clínica en Otorrinolaringología genera cada día un volumen creciente de información: notas de consulta, informes radiológicos, descripciones quirúrgicas, registros audiométricos, imágenes endoscópicas y datos de seguimiento. Sin embargo, la mayor parte de esta información permanece atrapada en texto libre, formatos heterogéneos y sistemas que no se comunican entre sí, lo que dificulta su aprovechamiento para la investigación. El resultado es una paradoja conocida por todo clínico investigador: generamos abundantes datos, pero investigamos con dificultad.

La inteligencia artificial (IA) ofrece herramientas para superar este cuello de botella. A diferencia de los capítulos anteriores de esta monografía, donde la IA se presenta como una herramienta diagnóstica o asistencial, aquí nos centramos en su papel como instrumento metodológico: un medio para diseñar, ejecutar y analizar mejor nuestros estudios. Los fundamentos técnicos (capítulo 1), la IA generativa (capítulo 2) y el marco ético-regulatorio (capítulo 14) se abordan en sus respectivos capítulos; el presente se centra en cinco aplicaciones concretas: la extracción automática de variables a partir de historias clínicas, el descubrimiento de subgrupos de pacientes, la aceleración de las revisiones sistemáticas, la identificación de candidatos para ensayos clínicos y las soluciones al problema de la escasez de datos y la privacidad. (**Figura 1**)

EXTRACCIÓN AUTOMÁTICA DE VARIABLES A PARTIR DE TEXTO CLÍNICO

El procesamiento del lenguaje natural (NLP, por sus siglas en inglés), introducido en el capítulo 1, permite que un ordenador "lea" texto libre y extraiga información estructurada: diagnósticos, síntomas, lateralidad, estadificación o tratamientos previos. Aplicado a la investigación, esto significa convertir cientos o miles de historias clínicas en una base de datos con variables definidas, sin necesidad de que un investigador las revise una a una.

Una revisión reciente centrada en ORL[1] mostró que el NLP se ha aplicado a informes de anatomía patológica, notas de consulta y registros audiológicos, y que los modelos más recientes (basados en la arquitectura *transformer*) superan consistentemente a los enfoques basados en diccionarios o reglas manuales. En anatomía patológica de cabeza y cuello, los modelos de lenguaje extenso (LLMs) ajustados para esta tarea lograron una concordancia del 90 % con la revisión manual de un patólogo experto[2]. En la práctica, esto permitiría construir registros oncológicos a gran escala sin etiquetado manual.

¿Por qué es relevante automatizar este proceso? Porque la alternativa, la recogida manual de datos, introduce errores significativos. Un metaanálisis que comparó distintos métodos de procesamiento de datos en investigación clínica situó la tasa de error de la entrada manual entre el 6 % y el 11 %[3], y cifras similares se han reportado específicamente en la revisión retrospectiva de historias clínicas[4]. En este contexto, plataformas emergentes basadas en NLP, como *Latrikos HealthTech* 18, están diseñadas para

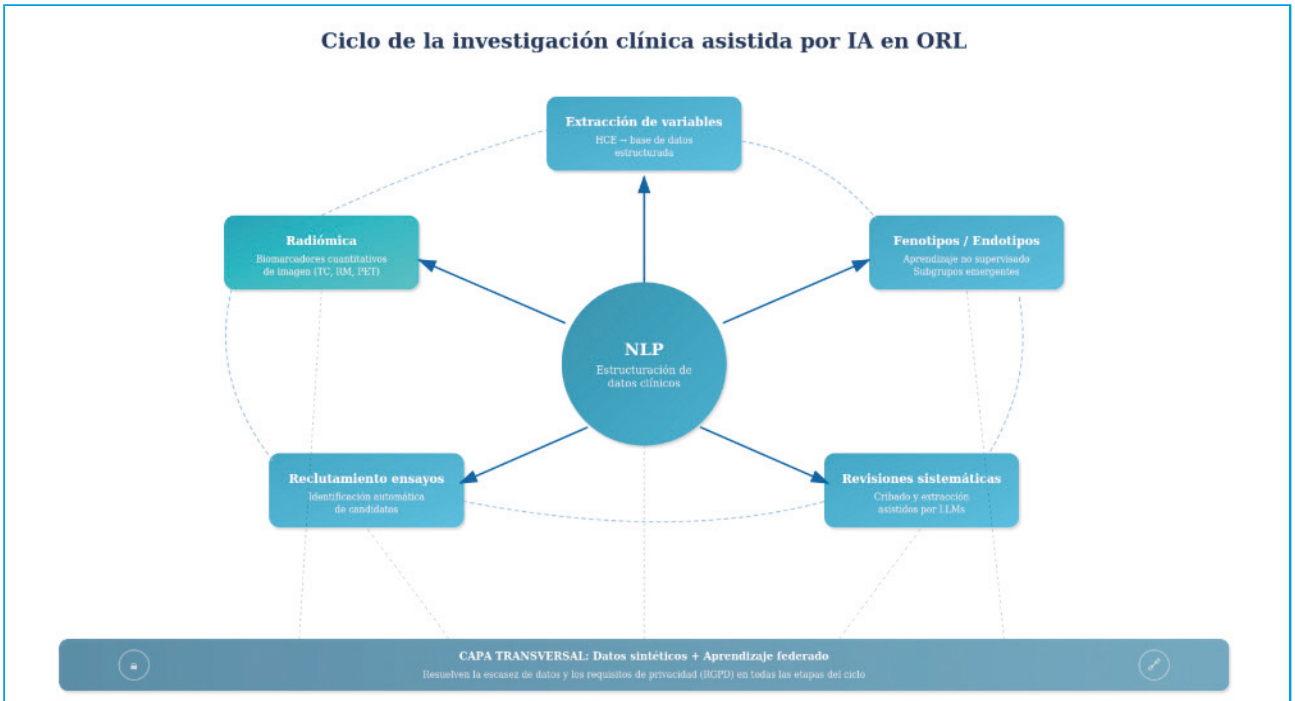


Figura 1. Ciclo de la investigación clínica asistida por inteligencia artificial en Otorrinolaringología. El procesamiento del lenguaje natural (NLP) estructura datos clínicos no estructurados, habilitando tanto el descubrimiento de fenotipos/endotipos mediante aprendizaje no supervisado como la identificación automatizada de cohortes. Las revisiones sistemáticas asistidas por IA aceleran la síntesis de evidencia. Los datos sintéticos y el aprendizaje federado actúan como capas transversales que resuelven los problemas de escasez de datos y privacidad. La radiómica aporta biomarcadores cuantitativos de imagen integrables en cualquier etapa del ciclo.

convertir notas clínicas en variables reutilizables, con el objetivo de reducir los errores propios de la recogida humana.

Con todo, esta tecnología no está exenta de riesgos. El principal es que el sistema confunda un hallazgo negativo ("no se observa adenopatía") con uno indeterminado ("adenopatía no valorable"), un error sutil que puede distorsionar cohortes retrospectivas si no se revisa el resultado del modelo.

DESCUBRIMIENTO DE SUBGRUPOS DE PACIENTES: FENOTIPOS Y ENDOTIPOS COMPUTACIONALES

En la investigación clásica de nuestra especialidad, clasificamos las enfermedades con criterios definidos por consenso de expertos: rinosinusitis crónica con o sin pólipos, apnea del sueño leve, moderada o grave según el índice de apnea-hipopnea (IAH). Estas categorías son útiles para la comunicación clínica, pero simplifican una realidad biológica heterogénea.

El aprendizaje no supervisado, explicado en el capítulo 1, permite abordar estas preguntas de un modo diferente. En lugar de que el investigador defina a priori los grupos, los algoritmos de agrupamiento (*clustering*) analizan simultáneamente decenas o cientos de variables y detectan subgrupos naturales dentro de los datos. Lo que emergen son los llamados fenotipos (subgrupos definidos por características observables) o endotipos (subgrupos definidos por mecanismos biológicos subyacentes).

En rinosinusitis crónica (RSC), Wang y cols.[5] aplicaron este enfoque sobre factores inflamatorios y de remodelado tisular, identificando cinco endotipos moleculares con perfiles de gravedad y respuesta terapéutica diferenciados, una clasificación mucho más informativa que la dicotomía clásica "con/sin pólipos". En el síndrome de apnea obstructiva del sueño (SAOS), el agrupamiento sobre datos polisomnográficos ha identificado subgrupos con perfiles de riesgo cardiovascular y metabólico distintos, ofreciendo una estratificación más útil que el IAH aislado[6].

Un aspecto metodológicamente relevante es que la elección del algoritmo influye en los subgrupos obtenidos: un estudio comparativo sobre 865 pacientes mostró que solo dos de los cinco subgrupos eran estables independientemente del método utilizado[7]. Los subgrupos computacionales son hipótesis, no verdades definitivas: deben validarse con múltiples métodos y con resultados clínicos reales. (**Figura 2**)

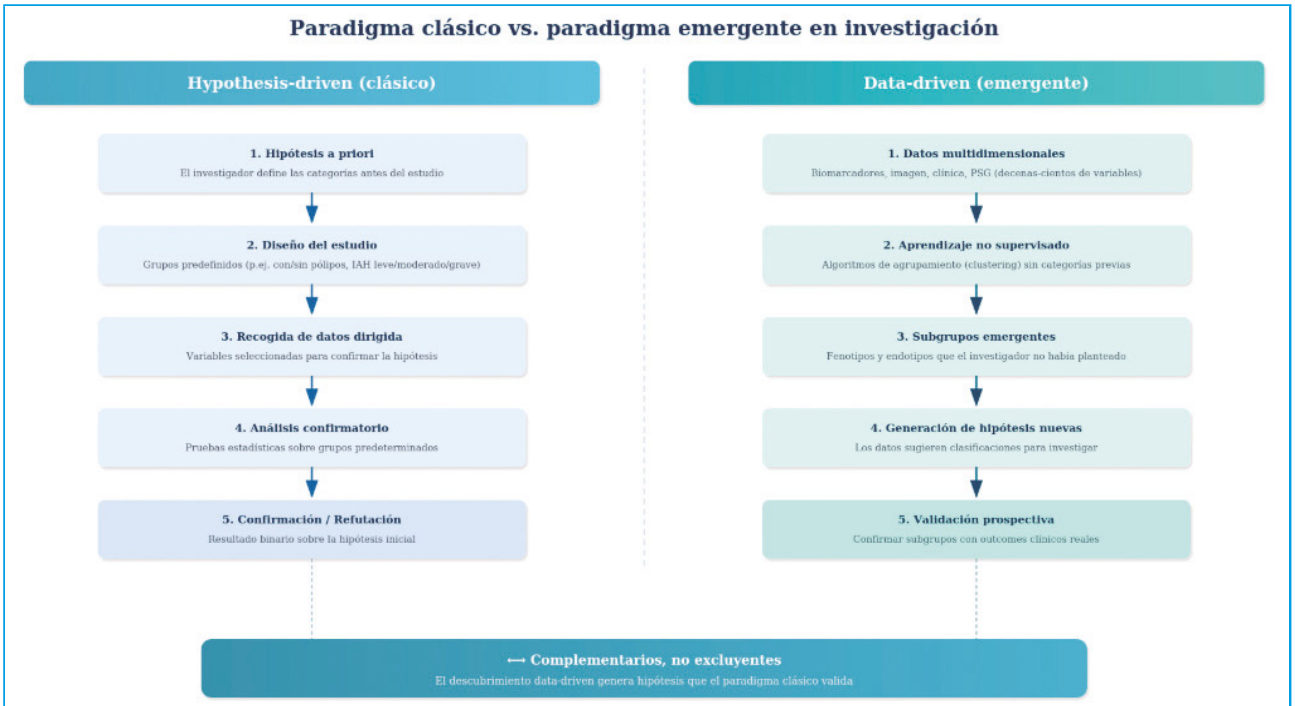


Figura 2. Comparación entre el paradigma de investigación clásico basado en hipótesis (*hypothesis-driven*) y el paradigma emergente basado en descubrimiento (*data-driven*). En el enfoque clásico, el investigador define a priori las categorías y diseña el estudio para confirmarlas. En el enfoque *data-driven*, los algoritmos de aprendizaje no supervisado identifican subgrupos emergentes a partir de variables multidimensionales, generando hipótesis nuevas que requieren validación prospectiva posterior. Ambos paradigmas son complementarios, no excluyentes.

REVISIONES SISTEMÁTICAS ASISTIDAS POR IA

Las revisiones sistemáticas son el pilar de la medicina basada en la evidencia, pero su elaboración manual consume cientos de horas. La IA está acelerando cada una de sus etapas.

En la fase de cribado, los sistemas basados en LLMs han alcanzado sensibilidades del 87-98 % y especificidades del 96-98 %[8]. GPT-4, por ejemplo, cribó más de 24.000 resúmenes con una concordancia del 91 % respecto al revisor humano[9]. En la extracción de datos, sistemas diseñados para que el investigador supervise y corrija al modelo han logrado concordancias del 93 %[10].

La evaluación del riesgo de sesgo sigue siendo el eslabón más débil: la IA sola acierta entre el 63 % y el 74 %, pero la combinación humano-IA mejora hasta el 91-96 %, igualando o superando al revisor individual[11]. El consenso actual es que la IA reduce la carga del cribado inicial (ahorro estimado del 60-77 % del tiempo), pero las decisiones finales de inclusión y la valoración crítica deben permanecer bajo supervisión del investigador. Estos resultados dependen del diseño del prompt, del dominio clínico y de la calibración local del modelo, por lo que no son directamente extrapolables sin validación previa.

IDENTIFICACIÓN AUTOMÁTICA DE CANDIDATOS PARA ENSAYOS CLÍNICOS

El reclutamiento es uno de los cuellos de botella que más retrasan la investigación clínica: más de la mitad de los ensayos no alcanzan el tamaño muestral previsto en plazo. Los criterios de elegibilidad, escritos en lenguaje natural, deben cruzarse manualmente con historias clínicas individuales.

Los sistemas basados en NLP pueden automatizar este cruce: leer los criterios del ensayo, traducirlos a consultas sobre la base de datos del hospital e identificar candidatos que cumplen los requisitos. Un marco reciente basado en LLMs logró una concordancia del 88 % con la selección manual y una ejecución correcta de las consultas en el 91 % de los casos[12]. En ORL, el NLP se ha validado para extraer variables relevantes para la identificación de cohortes, aunque su adopción rutinaria requiere protocolos estandarizados y validación local[1].

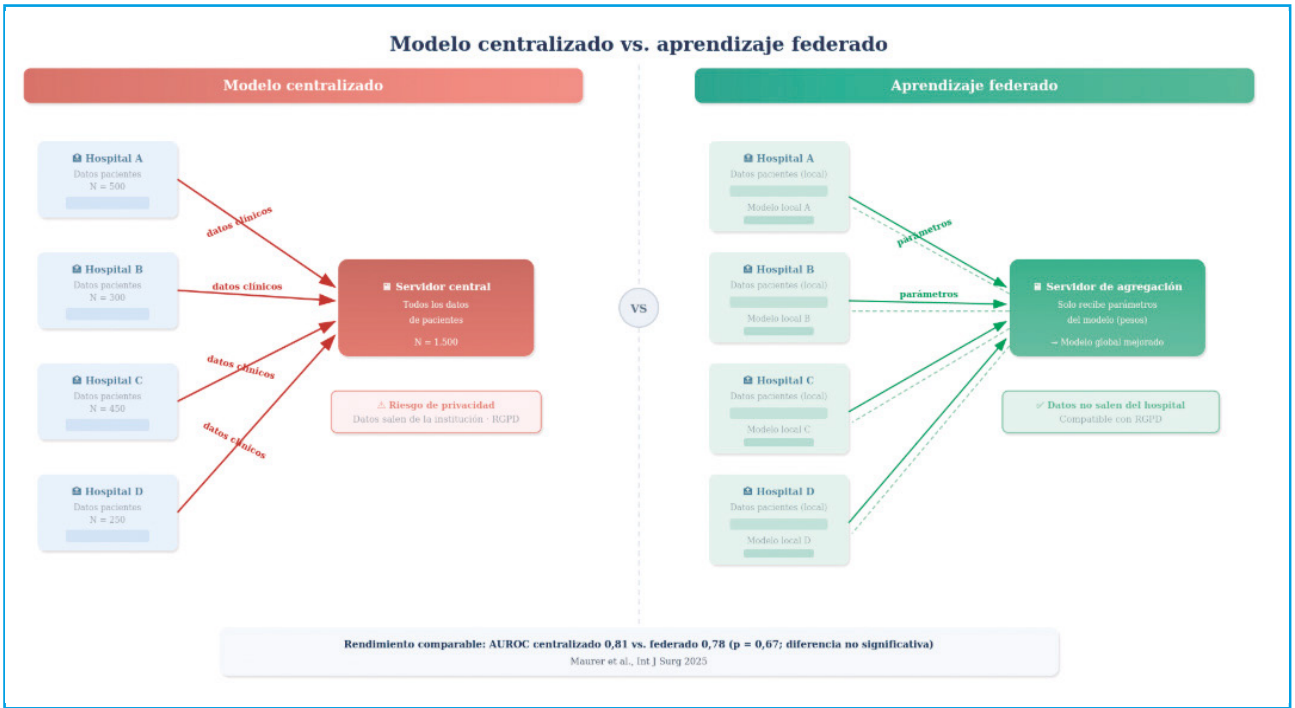


Figura 3. Esquema del aprendizaje federado frente al modelo centralizado. En el modelo centralizado (izquierda), los datos de múltiples centros se transfieren a un servidor único para entrenar el modelo, con los consiguientes riesgos de privacidad. En el aprendizaje federado (derecha), cada centro entrena un modelo local con sus propios datos y comparte únicamente los parámetros del modelo con un servidor de agregación, que devuelve un modelo mejorado sin que los datos clínicos abandonen su institución de origen.

DATOS SINTÉTICOS Y APRENDIZAJE FEDERADO: SOLUCIONES A LA ESCASEZ Y LA PRIVACIDAD

La ORL, como especialidad de tamaño poblacional intermedio, se enfrenta a un problema recurrente en investigación: no tenemos suficientes pacientes en un solo centro para entrenar modelos robustos, y las restricciones legales (Reglamento General de Protección de Datos, RGPD) dificultan compartir datos entre hospitales. Dos estrategias complementarias abordan este doble reto.

La primera es la generación de datos sintéticos: crear pacientes "artificiales" cuyos datos reproducen las propiedades estadísticas de una cohorte real sin corresponder a ningún individuo concreto, aunque el riesgo de reidentificación no se elimina por completo y debe evaluarse formalmente. Estudios recientes en cirugía han demostrado que modelos entrenados con cohortes sintéticas alcanzan rendimientos comparables a los entrenados con datos reales[13], lo que abre la puerta a simular ensayos y estimar riesgos quirúrgicos sin comprometer la confidencialidad.

La segunda estrategia es el aprendizaje federado (**Figura 3**). En lugar de enviar los datos de cada hospital a un servidor central, cada centro entrena un modelo con sus propios datos y comparte únicamente los parámetros matemáticos, no los datos de los pacientes. Un servidor central combina los aprendizajes y devuelve un modelo mejorado. En un estudio multicéntrico de cirugía colorrectal, este enfoque logró un rendimiento prácticamente equivalente al del modelo centralizado (área bajo la curva ROC [AUROC] 0,78 frente a 0,81; p = 0,67)[14]. La Academia Americana de Otorrinolaringología (AAO-HNS) ha destacado el aprendizaje federado como vía prioritaria para el desarrollo responsable de la IA en nuestra especialidad[15].

Ambas estrategias pueden combinarse: compartir datos sintéticos generados localmente en lugar de parámetros del modelo, añadiendo una capa adicional de protección frente a posibles vulnerabilidades de privacidad.

RADIÓMICA COMO HERRAMIENTA DE INVESTIGACIÓN

La radiómica convierte imágenes médicas convencionales (TC, RM, PET) en cientos de variables numéricas que describen propiedades del tejido no perceptibles al ojo humano: homogeneidad, textura, distribución de intensidades. Su valor en ORL, además del clínico (abordado en otros capítulos),

Aplicación	Datos típicos en ORL	Output	Riesgo principal	Mitigación
Extracción NLP	Notas clínicas, informes AP	Variables estructuradas	Confusión negación/ausencia	Revisión humana de muestra
Fenotipos/endotipos	Biomarcadores, PSG, imagen	Subgrupos emergentes	Inestabilidad según algoritmo	Validación con múltiples métodos y outcomes clínicos
Revisiones sistemáticas	Abstracts, artículos completos	Cribado, extracción, riesgo de sesgo	Dependencia del prompt y dominio	Calibración local, decisión final humana
Reclutamiento ensayos	Criterios elegibilidad + HCE	Lista de candidatos	Falsos positivos/negativos	Confirmación clínica individual
Datos sintéticos	Cohortes reales	Cohortes artificiales	Riesgo residual de reidentificación	Evaluación formal de privacidad
Aprendizaje federado	Datos multicéntricos distribuidos	Modelo global sin centralizar datos	Inferencia por gradientes	Agregación segura, encriptación
Radiómica	TC, RM, PET	Biomarcadores cuantitativos	Variabilidad por escáner/protocolo	Estandarización, TRIPOD+AI

Tabla 1. Resumen de aplicaciones de IA en investigación en ORL.

es metodológico: permite generar biomarcadores de imagen integrables con datos clínicos y moleculares.

Una revisión en *JAMA Otolaryngology*[16] mostró que los modelos que combinan radiómica con datos clínicos superan consistentemente a los basados solo en datos clínicos para predecir recurrencia y supervivencia en carcinoma escamoso de cabeza y cuello (AUROC 0,69-0,97). En tumores nasosinusales, un metaanálisis reportó AUROC de 0,92 en validación para predecir recurrencia postoperatoria[17].

No obstante, las variables extraídas dependen del escáner y el protocolo de adquisición, lo que dificulta la reproducibilidad entre centros. La adopción de marcos como TRIPOD+AI es imprescindible para que la radiómica madure como herramienta de investigación.

CONCLUSIONES

La IA está transformando el modo en que investigamos en ORL. El procesamiento del lenguaje natural convierte años de datos clínicos acumulados en bases de datos explotables; los algoritmos de agrupamiento descubren subtipos de enfermedades que los criterios convencionales no capturan; las herramientas de cribado automático aceleran las revisiones sistemáticas; los sistemas de identificación de cohortes facilitan el reclutamiento para ensayos; y los datos sintéticos junto con el aprendizaje federado resuelven el doble problema de la escasez de datos y la protección de la privacidad. La radiómica añade una dimensión cuantitativa a las imágenes que enriquece los modelos pronósticos.

Sin embargo, la mayoría de estas herramientas se encuentran aún en fases de validación y no deben adoptarse sin verificación local, auditoría de sesgos y supervisión por parte del investigador. El mayor riesgo no es técnico, sino cultural: confundir automatización con garantía de calidad. La IA acelera la investigación, pero la responsabilidad metodológica sigue siendo nuestra.

CONFLICTO DE INTERESES

Carlos Carazo Casas es advisor médico de *Latrikos HealthTech*, plataforma mencionada en este capítulo. El resto de autores declaran no tener conflictos de interés.

FINANCIACIÓN

No se recibió financiación para la elaboración de este capítulo.

BIBLIOGRAFÍA

1. Banyi N, Ma B, Amanian A, Bur A, Abdalkhani A. Applications of Natural Language Processing in Otolaryngology: A Scoping Review. Laryngoscope. 2025. https://doi.org/10.1002/lary.32198.
2. Foy BH, Smith KD, Vargas OL, et al. Evaluation of Large-Language Models for Structured Feature Extraction of Anatomic and Clinical Pathology Reports. Clin Chem. 2026. https://doi.org/10.1093/clinchem/hvag006.
3. Garza MY, Williams T, Ounpraseuth S, et al. Error Rates of Data Processing Methods in Clinical Research: A Systematic Review and Meta-Analysis. Int J Med Inform. 2024;105749.
4. Feng JE, Anoushiravani A, Tesoriero PJ, et al. Transcription Error Rates in Retrospective Chart Reviews. Orthopedics. 2020;43(5):e404-8.
5. Wang X, Sima Y, Zhao Y, et al. Endotypes of Chronic Rhinosinusitis Based on Inflammatory and Remodeling Factors. J Allergy Clin Immunol. 2023;151(2):458-68.
6. Ma EY, Kim JW, Lee Y, et al. Combined Unsupervised-Supervised Machine Learning for Phenotyping Complex Diseases With Its Application to Obstructive Sleep Apnea. Sci Rep. 2021;11(1):4457.
7. Ghorvei M, Karhu T, Hietakoste S, et al. A Comparative Analysis of Unsupervised Machine-Learning Methods in PSG-Related Phenotyping. J Sleep Res. 2024;34(3). https://doi.org/10.1111/jsr.14349.
8. Dai ZY, Wang FQ, Shen C, et al. Accuracy of Large Language Models for Literature Screening in Thoracic Surgery: Diagnostic Study. J Med Internet Res. 2025;27:e67488.
9. Guo E, Gupta M, Deng J, et al. Automated Paper Screening for Clinical Reviews Using Large Language Models: Data Analysis Study. J Med Internet Res. 2023;26. https://doi.org/10.2196/58091.
10. Li Y, Datta S, Rastegar-Mojarad M, et al. Enhancing Systematic Literature Reviews With Generative Artificial Intelligence. J Am Med Inform Assoc. 2025;32:616-25.
11. Woelfle T, Hirt J, Janiaud P, et al. Benchmarking Human-AI Collaboration for Common Evidence Appraisal Tools. J Clin Epidemiol. 2024;175:111533.
12. Yang L, Han Y, Liu L, et al. EC2Seq2Sql: Patient-Trial Matching With LLM Agents. PLoS One. 2026;21(2):e0341827.
13. Foppa C, D'Amico S, Delleani M, et al. Synthetic Data Generated by Artificial Intelligence to Optimize Surgical Trial Design. Ann Surg. 2025. https://doi.org/10.1097/SLA.0000000000006871.
14. Maurer MM, Pfitzner B, van De Water R, et al. Privacy Preserving Federated Learning for 90-Day Mortality Prediction in Colorectal Surgery: A Multicenter Retrospective Study. Int J Surg. 2025. https://doi.org/10.1097/JS9.0000000000002663.
15. Ayoub NF, Rameau A, Brenner MJ, et al. American Academy of Otolaryngology-Head and Neck Surgery (AAO-HNS) Report on Artificial Intelligence. Otolaryngol Head Neck Surg. 2025;172(2):734-43.
16. Bourdillon AT, Yao A, Bur AM. Radiomics in Otolaryngology-Head and Neck Surgery: A Review. JAMA Otolaryngol Head Neck Surg. 2026. https://doi.org/10.1001/jamaoto.2025.5462.
17. Waters C, Hall T, Temperley HC, et al. Role of Radiomics to Predict Disease Recurrence in Sinonasal Squamous Cell Carcinoma: A Systematic Review and Meta-Analysis. Clin Otolaryngol. 2025. https://doi.org/10.1111/coa.70031.
18. Latrikos HealthTech [Internet]. Disponible en: https://latrikos.com.

15

Ética y gobernanza de la ia en ORL

Andrea López Salcedo, Carmen Vallés Rodríguez, Nazaret Benítez Lobón, Irene Oliver Laguna
Servicio de Otorrinolaringología, Hospital Infanta Sofía, San Sebastián de los Reyes

INTRODUCCIÓN

En la actualidad, la práctica de la Otorrinolaringología y Cirugía de Cabeza y Cuello se encuentra en un proceso de transformación impulsado por la integración de la inteligencia artificial (IA).

Este avance no representa únicamente la incorporación de nuevas herramientas tecnológicas, sino una redefinición de los procesos de toma de decisiones, la relación médico-paciente y las estructuras de responsabilidad legal y ética en el entorno sanitario.

Para el especialista que se aproxima por primera vez a este campo, es imperativo comprender que la IA en medicina no es un fin en sí mismo, sino un medio para potenciar el juicio clínico, optimizar la eficiencia y mejorar los resultados en salud. No obstante, la adopción de estas tecnologías exige que se garantice la seguridad, la equidad y la transparencia durante la práctica clínica[1].

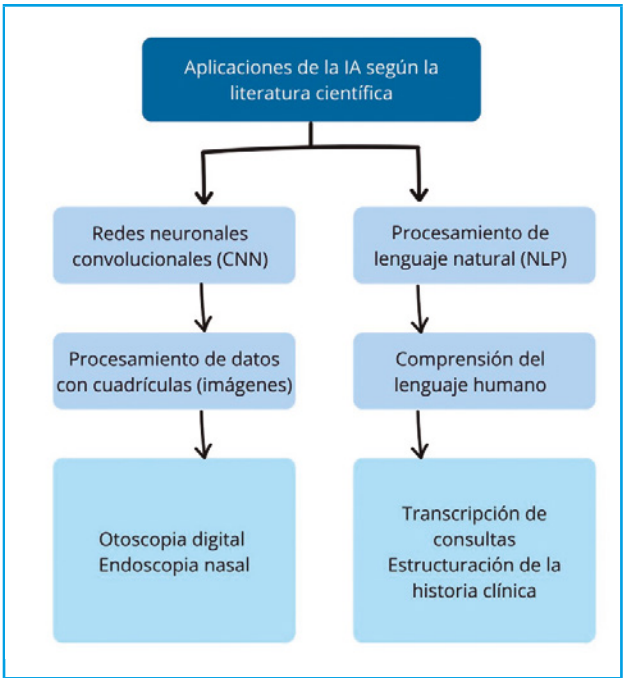


Figura 1. Clasificación de las aplicaciones de la IA según su función y el tipo de procesamiento de datos.

FUNDAMENTOS TÉCNICOS DE LA IA EN OTORRINOLARINGOLOGÍA

La IA se define de manera general como la capacidad de algoritmos integrados en sistemas para aprender de los datos, permitiéndoles realizar tareas automatizadas sin necesidad de una programación explícita para cada paso intermedio que podría ser realizado por un ser humano[2].

En el contexto clínico, esta definición se podría traducir, por ejemplo, en sistemas capaces de identificar patrones en miles de estudios previos para asistir en el proceso diagnóstico. Sin embargo, para una comprensión profunda, es necesario desglosar la arquitectura que sustenta esta tecnología.

El aprendizaje automático o *machine learning* (ML) es la rama de la IA que permite a los sistemas mejorar su rendimiento a través de la exposición a grandes volúmenes de datos[3].

Dentro del ML, el aprendizaje profundo o *deep learning* (DL) utiliza redes neuronales artificiales con múltiples capas que imitan el procesamiento de información del cerebro humano. Esta arquitectura es particularmente eficaz en Otorrinolaringología para el análisis de imágenes radiológicas y endoscópicas.

Un nivel más reciente de evolución son los modelos masivos multimodales o Large Multi-modal Models (LMMs), que tienen la capacidad de aceptar diversas entradas de datos (texto, imágenes, audio) y generar

salidas complejas, como informes clínicos o resúmenes de historias clínicas[2].

La literatura científica clasifica las aplicaciones de la IA según su función y el tipo de procesamiento de datos. Las redes neuronales convolucionales (CNN) se especializan en el procesamiento de datos complejos como imágenes, facilitando diagnósticos en otoscopia digital o endoscopia nasal[3]. Por otro lado, el procesamiento de lenguaje natural (NLP) se centra en la comprensión del lenguaje humano, permitiendo, entre otras aplicaciones, la transcripción automática de consultas y la estructuración de la historia clínica, lo que se ha denominado "liberación del teclado"[2].

La comprensión de estos términos permite al usuario evaluar la explicabilidad del sistema. Los sistemas de IA suelen describirse como "cajas negras" debido a la opacidad de sus procesos internos de toma de decisiones[5]. La gobernanza moderna exige que estos modelos evolucionen hacia una IA explicable (XAI), donde el facultativo pueda entender los factores que llevaron a un algoritmo a sugerir un diagnóstico o tratamiento específico[3]. (**Figura 1**)

EL MARCO GLOBAL DE GOBERNANZA: LAS DIRECTRICES DE LA OMS

La Organización Mundial de la Salud (OMS) ha publicado guías exhaustivas sobre ética y gobernanza de la IA para la salud, reconociendo que, si bien estas herramientas pueden revolucionar la medicina, su implementación descontrolada podría comprometer la seguridad del paciente y agravar las desigualdades existentes.

El marco de la OMS se fundamenta en principios éticos transversales: preservar la autonomía humana, promover el bienestar y la seguridad, garantizar la transparencia y la explicabilidad, y asegurar la equidad.

Con la rápida adopción de los LMMs (como GPT-4 o Gemini) en la redacción de informes y el triaje, la OMS actualizó sus orientaciones en 2024 para abordar los riesgos específicos de estas tecnologías generativas. Estos modelos presentan riesgos significativos de generar información falsa o "alucinaciones", lo que exige una supervisión humana estricta y auditorías post-comercialización obligatorias. La gobernanza de estos modelos requiere un enfoque de ciclo de vida completo: desde el diseño ético y el entrenamiento con datos de alta calidad, hasta la monitorización continua para detectar sesgos en el entorno clínico real[2]. (**Figura 2**)

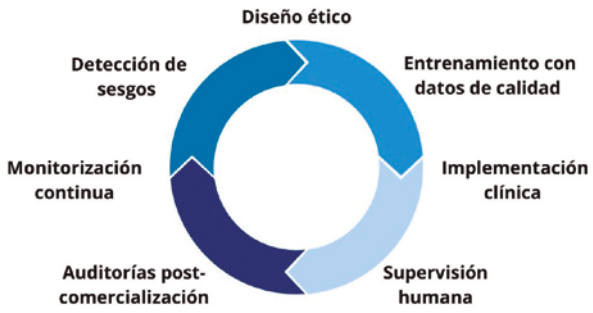


Figura 2. Enfoque de gobernanza dinámica.

EL ENTORNO REGULATORIO: EL REGLAMENTO DE IA (AI ACT)

El marco legal definitivo para la práctica clínica está marcado por normativas como el Reglamento de Inteligencia Artificial de la Unión Europea (AI Act), que establece un sistema de regulación basado en el riesgo[6].

Esta normativa clasifica los sistemas en categorías, siendo la de Alto Riesgo la que engloba a la mayoría de las herramientas de IA aplicadas al diagnóstico y el tratamiento[7].

Los sistemas de alto riesgo deben cumplir con estándares estrictos de gobernanza de datos, documentación técnica y supervisión humana antes de su comercialización[6].

Es fundamental destacar que el Reglamento de IA no sustituye a las normativas de productos sanitarios (como el MDR), sino que las complementa, exigiendo que cualquier software de IA cuente con certificaciones de seguridad[7].

APLICACIONES CLÍNICAS SEGÚN SUBESPECIALIDADES

La Otorrinolaringología es una de las especialidades con mayor diversidad de áreas. La adopción de la IA variará significativamente entre subespecialidades, suponiendo cuestiones que requieren validaciones específicas[1].

RINOLOGÍA

En rinología, la IA se ha centrado en la interpretación de tomografías computarizadas (TC) y la clasificación de patologías de la mucosa.

Revisiones sistemáticas recientes indican que modelos basados en CNN pueden identificar rinosinusitis

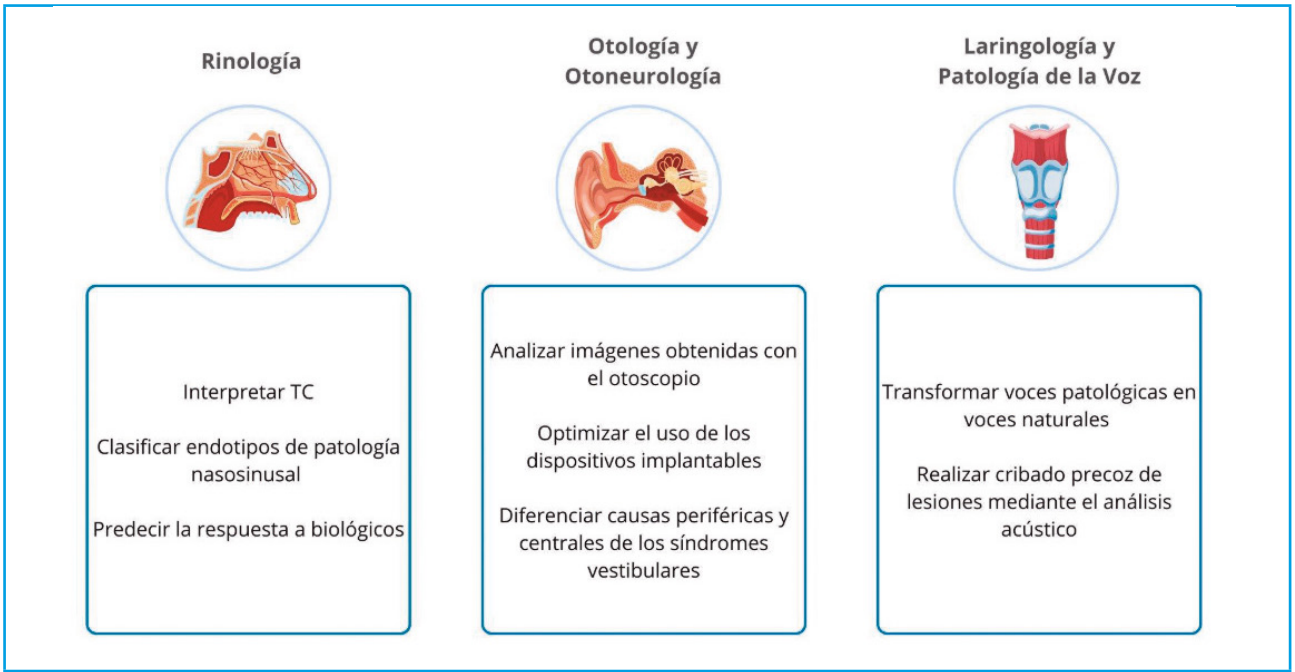


Figura 3. Posibles aplicaciones de la IA según la subespecialidad.

crónica con pólipos con una precisión de entre el 81 % y el 99 %. La radiómica, ciencia que estudia las imágenes médicas imperceptibles al ojo humano mediante la aplicación de algoritmos automatizados con el objetivo de asociarlas a estados fisiológicos o patológicos concretos, aplicada a los senos paranasales permite la identificación de endotipos y puede predecir la respuesta a tratamientos biológicos[4].

El desafío actual reside en la falta de estandarización de los datos y en la necesidad de estudios multicéntricos para validar estos modelos[8].

OTOLOGÍA Y OTONEUROLOGÍA

Más allá del análisis de imágenes otoscópicas, la optimización de dispositivos implantables representa un avance crítico. En implantes cocleares, el aprendizaje automático personaliza el mapeo del procesador analizando respuestas auditivas de miles de usuarios. No obstante, esta dependencia de grandes volúmenes de datos conlleva el riesgo ético de perpetuar sesgos demográficos, ofreciendo rendimientos subóptimos en poblaciones infrarrepresentadas en el entrenamiento de los algoritmos.

LARINGOLOGÍA Y PATOLOGÍA DE LA VOZ

El enfoque en esta área se desplaza hacia la transformación de voces patológicas en naturales y el cribado precoz de lesiones mediante análisis acústico. Paralelamente, los sistemas de escucha activa liberan al clínico de la carga administrativa, permitiendo que se centre en el paciente mientras la IA redacta el informe. Dada la naturaleza de estos datos biométricos, la gobernanza es vital para mitigar riesgos de suplantación de identidad y garantizar la privacidad[1,2].(**Figura 3**)

ÉTICA CLÍNICA Y DESAFÍOS BIOÉTICOS EN LA ERA ALGORÍTMICA

La integración de la IA plantea dilemas bioéticos que afectan los principios de beneficencia, no maleficencia, autonomía y justicia[9].

EL DILEMA DE LA AUTONOMÍA Y LA INJUSTICIA EPISTÉMICA

El consentimiento informado debe evolucionar hacia un modelo de transparencia algorítmica; el paciente tiene derecho a conocer si su diagnóstico o plan quirúrgico ha sido mediado por un sistema inteligente[10].

Surge además el riesgo de la injusticia epistémica, que ocurre cuando la "verdad" del algoritmo desvaloriza la experiencia subjetiva del paciente o la intuición clínica del médico, creando un vacío de credibilidad que deshumaniza el acto médico[11].

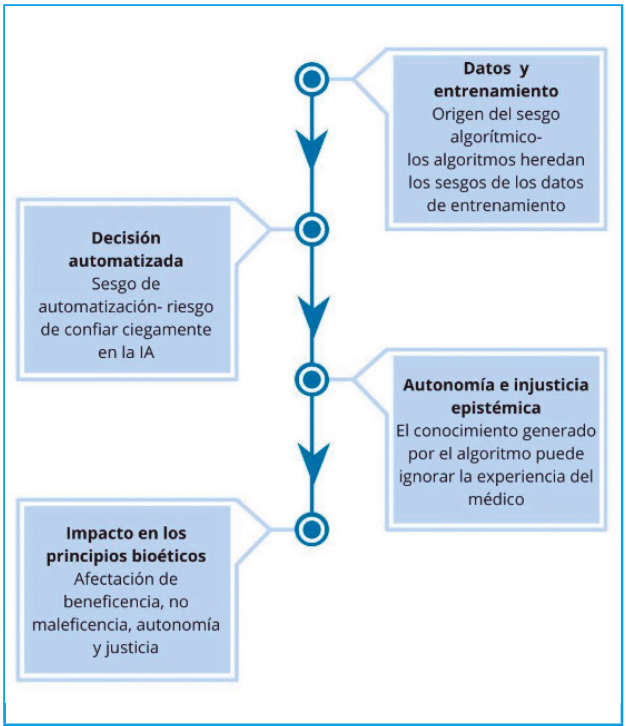


Figura 4. Escalada ética desde el sesgo técnico hasta la justicia sanitaria en la integración de IA.

SESGO ALGORÍTMICO Y SESGO DE AUTOMATIZACIÓN

Los sistemas pueden heredar y amplificar sesgos presentes en los datos de entrenamiento. Si un modelo de detección de cáncer de laringe se entrena con una cohorte específica, su precisión decae en otros grupos, lo que constituye un sesgo "algorítmico" que compromete la equidad diagnóstica[3].

A esto se suma el sesgo de automatización, donde el facultativo, fatigado por la carga asistencial, confía ciegamente en la IA e ignora signos clínicos discordantes[1]. Por ello, el consenso internacional subraya que la IA debe ser un sistema de aumento, no de reemplazo, del juicio humano[5]. (**Figura 4**)

RESPONSABILIDAD LEGAL Y SEGURIDAD DE LOS DATOS

La cuestión de la responsabilidad ante errores diagnósticos asistidos por IA es compleja. En la mayoría de los marcos legales, el médico sigue siendo el responsable final del acto clínico[10]. Sin embargo, si el daño se debe a un defecto intrínseco del software, la responsabilidad puede recaer sobre el fabricante bajo las directivas de productos defectuosos[6].

En cuanto a la privacidad, la IA se alimenta de datos médicos altamente protegidos. La gobernanza de datos debe asegurar la confidencialidad, integridad y minimización de la información[2].

El Espacio Europeo de Datos Sanitarios (EEDS), vigente desde 2025, facilita el uso secundario de datos para investigación siempre que se cumplan requisitos estrictos de anonimización y seguridad[6].

Es obligatorio realizar una Evaluación de Impacto en la Protección de Datos (EIPD) antes de implementar sistemas de IA que traten datos de salud a gran escala[2].

CONCLUSIONES

La IA no debe ser vista como una amenaza al humanismo médico, sino como un aliado que, bien gobernado, puede devolver al médico el tiempo necesario para la empatía y la escucha activa[1].

Para integrar la IA con éxito, la American Academy of Otolaryngology ha sugerido principios fundamentales: mantener la responsabilidad del clínico, asegurar la transparencia, auditar los algoritmos continuamente para evitar sesgos y garantizar que el profesional domine las habilidades clínicas tradicionales antes de delegar tareas a la máquina[12].

La Otorrinolaringología del futuro será digital, pero su núcleo seguirá siendo el compromiso ético y el juicio experto del especialista[1].

CONFLICTO DE INTERESES

Los autores declaran no tener conflictos de interés.

FINANCIACIÓN

No se recibió financiación para la elaboración de este capítulo.

BIBLIOGRAFÍA

1. Burmeister JR, et al. Bridging the AI implementation gap in otolaryngology: A clinical commentary. Digit Health. 2025;11:20552076251396981.
2. World Health Organization. Ethics and governance of artificial intelligence for health: large multi-modal models. WHO guidance. Genève: WHO; 2024.
3. Tai K, et al. Artificial Intelligence in Otolaryngology: Topics in Epistemology & Ethics. Otolaryngol Clin North Am. 2024;57(5):863-70.
4. Petsiou DP, et al. Effectiveness of artificial intelligence in detecting sinonasal pathology using clinical imaging modalities: a systematic review. Rhinology. 2025;10.
5. Nwosu OI, et al. Artificial Intelligence Governance and Otolaryngology-Head and Neck Surgery. Laryngoscope. 2023;133(11):2868-70.
6. European Commission. AI in healthcare: legislation, safety and the European Health Data Space. 2026.
7. Tucuvi. How the AI Act will affect hospitals and patients: five key points. 2025.
8. Liu YY, Jiang SP, Wang YB. Artificial intelligence optimizes the standardized diagnosis and treatment of chronic sinusitis. Front Physiol. 2025;16:1522090.
9. Melo Z. Inteligencia artificial en salud: desafíos éticos para lograr la aplicación de las tecnologías a la salud del paciente. Trayectorias Humanas Trascontinentales. 2024;18.
10. Vences Garrido A. Uso responsable, ético y legal de Inteligencia Artificial en Salud. Guía para profesionales. 2025.
11. Perdomo Reyes MI. Injusticia epistémica y reproducción de sesgos de género en la inteligencia artificial. CTS Rev Iberoam Cienc Tecnol Soc. 2024;19(56):89-100.
12. Ayoub NF, et al. American Academy of Otolaryngology-Head and Neck Surgery (AAO-HNS) Report on Artificial Intelligence. Otolaryngol Head Neck Surg. 2025;172(2):734-43.

16

Inteligencia artificial en la gestión y optimización de los flujos clínicos en hospitales terciarios (consulta, hospital y quirófano)

Manuel Gómez Serrano, Marta Maroto de Pablo, Elena Andrino, Alex Ramírez Rosa
Servicio de Otorrinolaringología y Cirugía de Cabeza y Cuello, Hospital Universitario Puerta de Hierro Majadahonda

INTRODUCCIÓN

Un flujo clínico (*clinical workflow*) es la organización coordinada del recorrido que realiza un paciente dentro del sistema sanitario, desde el primer contacto hasta la resolución del proceso, el seguimiento prolongado o el fallecimiento. Integra todos los niveles asistenciales y sus transiciones, ofreciendo una visión global donde confluyen aspectos clínicos, administrativos y de gestión. Su finalidad no es definir el mejor tratamiento, propio de las guías clínicas, ni detallar técnicas específicas, propio de los protocolos, sino garantizar una atención coordinada, eficiente y centrada en el paciente.

En la actualidad, los sistemas sanitarios afrontan una creciente presión derivada del envejecimiento poblacional, el aumento de enfermedades crónicas, la limitación de recursos y la necesidad de mejorar calidad reduciendo costes. Esta complejidad genera ineficiencias que impactan en retrasos diagnósticos y terapéuticos, sobrecarga profesional y uso subóptimo de recursos[1].

En este contexto, la inteligencia artificial surge como una herramienta transformadora capaz de analizar grandes volúmenes de datos, identificar oportunidades de mejora y optimizar procesos de forma dinámica. A diferencia de los modelos tradicionales basados en reglas rígidas y experiencia previa, los sistemas de IA pueden aprender de datos históricos, realizar predicciones precisas y adaptar la asignación de recursos en tiempo real, contribuyendo a mejorar los pilares fundamentales de la atención sanitaria[2]. Este capítulo examina cómo la IA optimiza los pilares fundamentales de la prestación de servicios clínicos.

MEJORA DE FLUJOS EN CONSULTA CLÍNICA

La consulta constituye el punto de entrada habitual al sistema de salud, funcionando como puerta de entrada crítica pero frecuentemente saturada. Su optimización requiere abordar simultáneamente la predicción de la duración de las consultas, la toma de decisiones clínicas informada y validada y la reducción de tiempos de espera.

PROGRAMACIÓN INTELIGENTE DE CITAS Y PREDICCIÓN DE DURACIÓN DE CONSULTA

La programación tradicional de citas se basa erróneamente en tiempos promedio predefinidos, una aproximación simplista que ignora la heterogeneidad que existe en la duración real de las consultas individuales. Esta variabilidad refleja factores complejos del paciente, del procedimiento y del médico.

Los sistemas sofisticados de apoyo de decisiones basados en *machine learning* reducen esta variabilidad. El sistema denominado *Cluster-Predict-Schedule* integra aprendizaje supervisado y no supervisado para

agrupar pacientes según factores multidimensionales que predicen duración de consulta, permitiendo optimizar el uso del tiempo del médico, reducir tiempos entre pacientes, mejorar la experiencia del paciente y reducir el coste operativo un 15 %[3].

Sistemas avanzados de programación de citas pueden minimizar inasistencias identificando pacientes de alto riesgo de inasistencia y aplicando intervenciones preventivas personalizadas (recordatorios SMS o cambios de horario), logrando reducciones documentadas de hasta el 15 % en tasas de no asistencia[7].

SISTEMAS DE SOPORTE A DECISIONES CLÍNICAS EN CONSULTA (CDSS) ASISTIDOS POR IA

Estos sistemas ofrecen recomendaciones basadas en evidencia actualizada que mejoran la precisión diagnóstica y la calidad asistencial, especialmente al anticipar riesgos clínicos y estratificar a los pacientes según su nivel de riesgo. Así, la IA puede identificar qué pacientes requieren seguimiento intensivo o atención especializada inmediata y cuáles pueden manejarse en atención estándar o primaria. Modelos de *machine learning* entrenados con datos históricos han alcanzado especificidades del 92 % al discriminar qué casos necesitan realmente derivación, optimizando el uso de recursos[4].

En la práctica, estos beneficios son medibles. Yaseen et al. demostraron que la aplicación de IA en gestión hospitalaria y toma de decisiones clínicas mejoró la atención en aproximadamente un 25 %, aumentó la adherencia terapéutica del 52 % al 68 % y redujo tiempos administrativos en un 44 %[5], evidenciando un impacto directo en la calidad y seguridad del cuidado.

ASISTENCIA EN LA REDACCIÓN DE LA HISTORIA CLÍNICA DURANTE LA ENTREVISTA MÉDICA

La inteligencia artificial aplicada a la consulta permite generar de forma automática y estructurada la historia clínica en tiempo real mediante sistemas de *ambient clinical intelligence*, que combinan reconocimiento de voz y procesamiento del lenguaje natural para transcribir, organizar y contextualizar la información clínica.

Su impacto en la gestión hospitalaria es notable: reduce el tiempo de documentación (20-30 %), disminuye la carga administrativa fuera del horario asistencial, mejora la calidad del registro, optimiza la codificación y genera datos estructurados útiles para analítica avanzada. Ya existen soluciones implantadas en hospitales terciarios e integradas en grandes plataformas de historia clínica electrónica[18,19].

Desde el punto de vista económico y organizativo, facilita aumentar la capacidad asistencial sin ampliar plantilla, mejora la satisfacción profesional y reduce el riesgo de *burnout*. No obstante, requiere validación médica final, auditorías de calidad y estricto cumplimiento de la normativa de protección de datos. En hospitales con alta presión asistencial, es una de las aplicaciones de IA con mayor impacto inmediato y menor necesidad de cambios estructurales[20].

OPTIMIZACIÓN DE FLUJOS HOSPITALARIOS

El recorrido de los pacientes dentro de un hospital implica procesos complejos como la clasificación inicial (triaje), la asignación de recursos según la demanda, el seguimiento continuo y la coordinación entre distintos servicios, que a menudo deben equilibrar prioridades diferentes. La IA tiene el potencial de mejorar de forma significativa cada una de estas etapas clave.

TRIAJE INTELIGENTE Y GESTIÓN DEL FLUJO DE PACIENTES

El triaje es el proceso de clasificación inicial de los pacientes según la gravedad y la urgencia de su situación clínica, con el objetivo de priorizar la atención. No constituye un diagnóstico, sino una herramienta organizativa para decidir el orden de asistencia. Habitualmente lo realiza personal no médico entrenado en urgencias y en sistemas estandarizados de clasificación. Constituye la primera línea crítica de optimización en el entorno hospitalario moderno. Sistemas autónomos basados en IA pueden analizar datos clínicos multidimensionales complejos para priorizar pacientes según su riesgo actual y necesidad urgente, permitiendo que los recursos más críticos (camas, especialistas, salas de procedimiento) se concentren estratégicamente donde tienen más impacto clínico. Podrían coordinar dinámicamente la asignación de camas, servicios y personal en tiempo real, mejorando significativamente los tiempos de respuesta y reduciendo transferencias innecesarias[1].

AUTOMATIZACIÓN DE PROCESOS ADMINISTRATIVOS MEDIANTE PROCESAMIENTO DE LENGUAJE NATURAL

La documentación clínica consume aproximada-

mente el 20-25 % del tiempo profesional total de los médicos en hospitales modernos, por lo que tecnologías avanzadas de procesamiento de lenguaje natural (NLP) integradas en sistemas de historiales electrónicos pueden automatizar significativamente esta carga, desde la transcripción automática de notas clínicas verbales hasta la extracción de datos relevantes para toma de decisiones en tiempo real, permitiendo al médico dedicar más tiempo al cuidado directo del paciente[6].

OPTIMIZACIÓN DE ALTA HOSPITALARIA Y CONTINUIDAD DE CUIDADOS

La transición desde hospital al hogar constituye un momento crítico de riesgo extremadamente alto donde una coordinación deficiente puede causar complicaciones que determinen la readmisión e incluso la muerte del paciente. Un sistema integral propuesto recientemente integra modelado predictivo avanzado, análisis probabilístico y técnicas de inferencia causal para identificar pacientes de alto riesgo de readmisión basados en características clínicas complejas, factores sociodemográficos e indicadores de adherencia, lo que permitió reducir significativamente la no asistencia a citas postalta en un 15 %, traduciéndose en ahorros anuales en capacidad clínica no utilizada de hasta $670.000 (€623.000)[7].

OPTIMIZACIÓN DE FLUJOS QUIRÚRGICOS

El quirófano representa el entorno más complejo y costoso de cualquier hospital, captando gran parte de la atención de los gestores médicos. La ayuda de la IA en los procesos quirúrgicos tendrá un impacto en valor en salud a través de la eficiencia operacional y seguridad del paciente.

PREDICCIÓN PRECISA DE DURACIÓN QUIRÚRGICA

La predicción de la duración quirúrgica es clave para optimizar los quirófanos. Los métodos tradicionales basados en promedios históricos presentan errores del 15-30 %, mientras que modelos de aprendizaje automático que incorporan variables del paciente, cirujano y procedimiento logran mayor precisión y mejoran la utilización y eficiencia, como demostró Lex et al. en un estudio con 300.000 cirugías traumatológicas. Sin embargo, en Otorrinolaringología aún se requieren estudios que confirmen estos resultados[8].

En hospitales universitarios, la actividad docente añade complejidad, ya que la participación de residentes incrementa los tiempos quirúrgicos, especialmente en procedimientos intermedios y avanzados. Este aumento no implica ineficiencia, sino inversión formativa. Por ello, los modelos de IA deben incluir variables relacionadas con el contexto docente para evitar sesgos y estimaciones irreales que puedan perjudicar a servicios con alta carga formativa. La optimización en estos centros debe equilibrar eficiencia, seguridad del paciente y misión educativa[18,20].

PROGRAMACIÓN QUIRÚRGICA AVANZADA MEDIANTE OPTIMIZACIÓN MULTIOBJETIVO Y OPTIMIZACIÓN DE RECURSOS

En la programación quirúrgica hospitalaria, los sistemas tradicionales utilizan reglas simples definidas manualmente, que resultan poco eficaces cuando existen múltiples variables complejas simultáneas (disponibilidad de personal, equipamiento, camas UCI, duración imprevisible, etc.). Como alternativa, se han desarrollado algoritmos de aprendizaje por refuerzo multiagente, donde cada quirófano actúa como un agente inteligente que aprende de experiencias previas y coordina decisiones con otros quirófanos, logrando una organización más eficiente. Liu et al. demostraron que este enfoque supera a los métodos tradicionales basados en reglas[9].

Además, la IA puede optimizar no solo la asignación de casos, sino también los tiempos intraoperatorios. Mediante análisis en tiempo real de vídeo quirúrgico con redes neuronales convolucionales, es posible identificar la fase de la cirugía y predecir su finalización, permitiendo preparar con antelación al siguiente paciente y reducir tiempos muertos. Ramadan et al. reportaron una disminución del tiempo de espera del 87,3 %[10].

OPTIMIZACIÓN DEL TRABAJO ENTRE ATENCIÓN PRIMARIA Y ESPECIALIZADA

La coordinación entre niveles asistenciales es un desafío clave del sistema sanitario donde la IA puede tener un impacto transformador, especialmente en telemedicina y en la optimización de derivaciones entre atención primaria y especializada.

Las eConsultas asincrónicas facilitan la comunicación entre médicos de primaria y especialistas sin necesidad de derivación inmediata. Aunque existen barreras como sobrecarga de trabajo, privacidad o cuestiones

organizativas, la IA puede ayudar a mitigarlas y mejorar el acceso a la atención especializada cuando se implementan con protocolos adecuados[13].

El programa brasileño RegulaSUS demostró que combinar protocolos clínicos, sistemas de IA y telemedicina permite filtrar derivaciones innecesarias, resolver muchos casos a distancia y priorizar solo los que requieren atención presencial. Este modelo mejoró la eficiencia, redujo costes en un 60 % y evitó miles de derivaciones innecesarias, generando un ahorro anual de más de $7,8 millones (€7,3 millones) en un único sistema de salud[14].

SEGUIMIENTO TELEMÁTICO. CONTINUIDAD ASISTENCIAL

El seguimiento telemático emerge como componente crítico para mantener continuidad asistencial robusta en enfermedades crónicas complejas. La monitorización remota demuestra mayor eficacia cuando integra evaluación diagnóstica inicial especializada con seguimiento coordinado entre niveles de atención[15,16].

La IA puede potenciar significativamente estos resultados mediante análisis automatizado de imágenes clínicas de alta calidad, transcripción inteligente de consultas y algoritmos que detectan automáticamente signos que requieren evaluación presencial[17]. Así, la IA transforma la telemedicina en un sistema inteligente de continuidad asistencial que mejora simultáneamente acceso, eficiencia y calidad del cuidado.

RETOS, OPORTUNIDADES Y CONSIDERACIONES ÉTICAS

Aunque la IA ha demostrado un gran potencial en la optimización de flujos clínicos, su adopción real enfrenta desafíos organizativos y éticos. Entre ellos destacan la desconexión entre las necesidades clínicas y las soluciones tecnológicas, la abundancia de desarrollo técnico sin aplicación práctica clara, la brecha digital, la falta de liderazgo institucional y marcos regulatorios restrictivos[11]. Además, los algoritmos pueden incorporar sesgos si se entrenan con datos no representativos[12], por lo que es esencial una colaboración multidisciplinar y una supervisión continua que garanticen un uso ético y adecuado de los datos. En este sentido, es fundamental que la sociedad comprenda que el uso de datos sanitarios correctamente anonimizados es clave para mejorar la calidad de la atención. Sin datos locales y representativos, las conclusiones generadas por la IA pueden no ser aplicables a la población real. Por ello, la participación responsable y consciente de la ciudadanía en el uso seguro de sus datos resulta esencial para desarrollar sistemas de IA verdaderamente útiles, equitativos y adaptados a su entorno.

CONCLUSIONES

La IA está mejorando la prestación de servicios sanitarios de forma medible. Una adopción estratégica y bien planificada de estas tecnologías no solo optimizará indicadores operativos y financieros, sino que permitirá liberar tiempo clínico, reducir ineficiencias estructurales y disminuir la frustración profesional, reforzando así el enfoque centrado en el paciente.

CONFLICTO DE INTERESES

Los autores declaran no tener conflictos de interés.

FINANCIACIÓN

Este trabajo no ha recibido financiación externa.

BIBLIOGRAFÍA

1. Warrier S, S AK. Autonomous agentic AI for clinical workflow orchestration: self-managing healthcare operations. En: 2025 6th International Conference on IoT Based Control Networks and Intelligent Systems (ICICNIS). IEEE; 2025.
2. Hammouri Q. The transformative integration of artificial intelligence in modern healthcare systems: a comprehensive review. Healthc Eng. 2025.
3. Feng H, Jia Y, Huang T, Zhou S, Chen H. An adaptive decision support system for outpatient appointment scheduling with heterogeneous service times. Sci Rep. 2024;14(1):27747. doi: https://doi.org/10.1038/s41598-024-77873-x

4. Babaoglu H, Sat H, Kavak Y, Tufan A. The utility of machine learning-based decision support system in referral of suspected rheumatic disease. Clin Exp Rheumatol. 2025.

5. Yaseen M, Ahmad R, Ali S, Shafiq M, Islam S. The role of artificial intelligence in improving hospital administration, enhancing clinical decision-making, optimizing patient outcomes in chronic and acute diseases, and advancing public health initiatives. Insights J Health Rehabil. 2025.

6. Cheruku VR. AI-orchestrated workflow automation in cloud-based hospital information systems: enhancing efficiency and patient outcomes. World J Adv Res Rev. 2025.

7. Toffaha KM, Simsekler MCE, Sleptchenko A, Kortt M, Omar MA. A knowledge-based probabilistic framework for enhancing reliability in healthcare appointment scheduling. IEEE Access. 2025.

8. Lex JR, Abbas A, Mosseri J, Toor JS, Simone M, Ravi B, et al. Using machine learning to predict-then-optimize elective orthopedic surgery scheduling to improve operating room utilization: retrospective study. JMIR Med Inform. 2025;13:e70857. doi: https://doi.org/10.2196/70857.

9. Liu K, Chen Y, Borndörfer R, Koch T. Multi-agent reinforcement learning for intraday operating rooms scheduling under uncertainty [preprint]. arXiv. 2025.

10. Ramadan S, Abu-Shams M, Al-Dahidi S, Odeh I, Almasarwah N. A data-driven approach for predicting remaining intra-surgical time and enhancing operating room efficiency. J Ind Eng Manag. 2025.

11. Leenen JPL, Bakers F, de Weger R, van Harten WH, Meijer K. Exploring the complex nature of implementation of artificial intelligence in clinical practice: an interview study with healthcare professionals, researchers and policy and governance experts. PLoS One. 2025.

12. Nagori N, Malhan K, Tokgoz E, Aboalayon K, Musafer H, Kiassat C. Identification of factors correlating to patient appointment no-shows using deep and machine learning. En: Proceedings of the 2025 International Conference on Auditory Display (ICAD). 2025.

13. Osman MA, Schick-Makaroff K, Thompson S, Bialy L, Featherstone R, Kurzawa J, et al. Barriers and facilitators for implementation of electronic consultations (eConsult) to enhance access to specialist care: a scoping review. BMJ Glob Health. 2019;4(5):e001629. doi: https://doi.org/10.1136/bmjgh-2019-001629.

14. Pfeil JN, Roman R, Rados DRV, Umpierre RN, Grassi de Oliveira M, Beck da Silva Etges AP, et al. Telemedicine gatekeeping over 15,000 patients from specialist consultation waiting lists: a cost-minimization study. Telemed Rep. 2025. doi: https://doi.org/10.1177/26924366251388854.

15. Arsenjeva J, Petersen J, Egeberg A, Thomsen SF, Kjær TW. Remote monitoring of psoriasis: comparing care models and evaluating quality of life outcomes: mixed methods study. J Med Internet Res. 2025.

16. Staszewski E, Ornetti P, Devilliers H, Maillefert JF, Molto A. Telerheumatology with primary care centers: feedback from an experimental telemedicine project in Burgundy (2019-2021). Ann Rheum Dis. 2022.

17. Thomassen EEK, Tveter A, Kristianslund E, Berg I, Ørstera N. Healthcare professionals' attitude towards remote monitoring. Ann Rheum Dis. 2022.

18. Sinsky C, Colligan L, Li L, Prgomet M, Reynolds S, Goeders L, et al. Allocation of physician time in ambulatory practice: a time and motion study in 4 specialties. Ann Intern Med. 2016;165(11):753-60. doi: https://doi.org/10.7326/M16-0961.

19. Van Buchem MM, Kant IMJ, King L, Kazmaier J, Steyerberg EW, Bauer MP. Impact of a digital scribe system on clinical documentation time and quality: usability study. JMIR AI. 2024;3:e60020. doi: https://doi.org/10.2196/60020.

20. Shanafelt TD, Noseworthy JH. Executive leadership and physician well-being: nine organizational strategies to promote engagement and reduce *burnout*. Mayo Clin Proc. 2017;92(1):129-46. doi: https://doi.org/10.1016/j.mayocp.2016.10.004.

17

Conclusiones

Carlos Carazo Casas
Servicio de Otorrinolaringología, Hospital Universitario Ramón y Cajal

INTRODUCCIÓN

Esta monografía ha recorrido el estado actual de la inteligencia artificial (IA) aplicada a la Otorrinolaringología, desde sus fundamentos técnicos hasta las aplicaciones específicas en cada subespecialidad, pasando por la investigación, la ética, la robótica y la gestión clínica. Más que un catálogo de posibilidades, los quince capítulos anteriores dibujan un mapa de madurez desigual pero claramente ascendente: algunas herramientas ya pueden integrarse en la práctica con cautela informada, mientras que otras aún necesitan validación robusta antes de salir del laboratorio.

LO QUE LA IA YA PUEDE APORTAR AL OTORRINOLARINGÓLOGO

El primer dato relevante es que la IA en nuestra especialidad no es una promesa de futuro, sino un presente parcial pero tangible[1]. En el ámbito diagnóstico, los algoritmos de aprendizaje profundo han demostrado capacidad para clasificar imágenes otoscópicas[2], endoscópicas y radiológicas[2] con rendimientos comparables o superiores a la valoración humana en condiciones controladas. La detección de lesiones laríngeas en vídeo en tiempo real, la cuantificación automática del score de Lund-Mackay[3], la segmentación del hueso temporal o la diferenciación de tumores parotídeos por resonancia magnética son ejemplos concretos que han superado la fase de prueba de concepto.

En otoneurología, los modelos de IA aplicados al síndrome vestibular agudo han mostrado rendimiento diagnóstico superior al protocolo HINTS incluso realizado por expertos, y herramientas como *EyePhone* o ConVNG permiten llevar la cuantificación objetiva del nistagmo a un *smartphone*. En audiología, la automatización de los potenciales evocados auditivos y la predicción de resultados en implante coclear avanzan hacia una personalización del seguimiento que puede mejorar la gestión de expectativas[4]. En cirugía del sueño, los wearables combinados con IA están redefiniendo el cribado de la apnea obstructiva, con modelos validados externamente que alcanzan correlaciones elevadas con la polisomnografía[5]. En ORL pediátrica, la IA muestra un potencial específico en el cribado auditivo automatizado, la interpretación de timpanometría por personal no especializado en entornos de recursos limitados y la evaluación objetiva de los trastornos respiratorios del sueño infantil, ámbitos donde la escalabilidad y la accesibilidad son especialmente relevantes[6]. En patología glandular salivar, los modelos de aprendizaje profundo aplicados a ecografía y resonancia magnética permiten reducir la incertidumbre preoperatoria en la diferenciación entre tumores benignos y malignos, apoyando la toma de decisiones sobre la indicación y extensión quirúrgica[7].

En laringología y análisis de voz, los modelos acústicos permiten cuantificar parámetros objetivos de calidad vocal y explorar la voz como biomarcador digital no invasivo, con aplicaciones en cribado de patología laríngea, detección precoz de trastornos neurológicos como el parkinsonismo y seguimiento de la rehabilitación logopédica[7].

Más allá del diagnóstico, la IA generativa ha abierto un segundo frente transformador. Los grandes modelos de lenguaje pueden actuar como escribas médicos, asistentes de documentación, generadores de informes estructurados y herramientas de apoyo a la comunicación con el paciente. Su utilidad no reside en sustituir el razonamiento clínico, sino en liberar tiempo administrativo y estandarizar procesos que hoy consumen una parte desproporcionada de la jornada del especialista. Además de su papel como asistente de documentación, la IA generativa puede facilitar la interacción entre niveles asistenciales, apoyando el triaje de derivaciones desde atención

primaria y mejorando la calidad de la información que llega al especialista.

En el plano quirúrgico, la robótica asistida por IA evoluciona desde la telemanipulación pura hacia sistemas capaces de ofrecer coaching basado en datos[8], segmentación intraoperatoria de estructuras críticas y, en el caso de la implantación coclear robotizada, niveles incipientes de autonomía supervisada. La cirugía plástica facial ha encontrado en la IA una vía para objetivar la evaluación estética y transformar la gestión de expectativas en un proceso basado en datos[8]. Y los flujos clínicos, desde la programación adaptativa de agendas basada en predicción de duración de consultas y la identificación proactiva de pacientes con riesgo de inasistencia hasta la optimización de la secuenciación quirúrgica, representan un terreno donde la IA puede generar eficiencias medibles a corto plazo.

RETOS TRANSVERSALES: VALIDACIÓN, INTEGRACIÓN Y EQUIDAD

Un análisis honesto de la evidencia acumulada en esta monografía obliga a señalar que la distancia entre el rendimiento experimental y la utilidad clínica real sigue siendo considerable en muchas aplicaciones. Tres obstáculos se repiten de forma transversal en prácticamente todos los capítulos.

El primero es la validación externa insuficiente. La mayoría de los modelos publicados en ORL han sido evaluados en el mismo centro donde se entrenaron, con poblaciones seleccionadas y protocolos de imagen homogéneos. Cuando se trasladan a otros entornos, el rendimiento suele caer, un fenómeno conocido como *domain shift*. Mientras no dispongamos de estudios prospectivos y multicéntricos con medidas de resultado centradas en el paciente, conviene interpretar las métricas de precisión con cautela y no confundir un buen resultado técnico con una herramienta clínicamente recomendable.

El segundo es la integración en el flujo de trabajo. Una herramienta de IA que obliga a salir de la historia clínica, cargar archivos manualmente o duplicar registros tiene pocas posibilidades de adopción sostenida[9]. La experiencia descrita en el capítulo de flujos clínicos demuestra que el valor de la IA se materializa cuando se acopla de forma invisible a lo que el profesional ya hace: sistemas de imagen, PACS, circuitos de derivación, programación de agenda.

El tercero es la equidad y la transparencia. Los sesgos algorítmicos por edad, sexo, etnia o fototipo pueden amplificar desigualdades existentes si no se auditan activamente. El Reglamento Europeo de IA[10] clasifica las aplicaciones sanitarias como de alto riesgo y exige transparencia, trazabilidad y supervisión humana[10,11]. Para el otorrinolaringólogo, esto se traduce en una obligación práctica: entender qué hace la herramienta, saber cuándo no es fiable y mantener la decisión clínica final como responsabilidad profesional inequívoca.

EL RETO DE ESCRIBIR SOBRE UN TERRENO QUE SE MUEVE BAJO LOS PIES

La elaboración de esta monografía ha puesto de manifiesto una dificultad que merece reflexión propia: la velocidad a la que evoluciona la IA hace que cualquier revisión del estado del arte comience a quedar desactualizada incluso antes de su publicación. En los meses que ha llevado coordinar, redactar y revisar estos capítulos, se han publicado nuevas arquitecturas de modelos, se han lanzado versiones actualizadas de herramientas que aquí se citan y han aparecido aplicaciones que no existían cuando los autores empezaron a escribir.

Este fenómeno no es nuevo en tecnología, pero en IA tiene una intensidad sin precedentes en el ámbito sanitario. Los ciclos de innovación en farmacología o en dispositivos médicos se miden en años; en IA, pueden medirse en semanas. Un modelo de lenguaje que hace seis meses representaba el estado del arte puede haber sido superado en rendimiento, coste y accesibilidad por varios competidores. Una herramienta de segmentación de imagen que se validó con una arquitectura concreta puede quedar eclipsada por un enfoque multimodal que ni siquiera existía cuando se diseñó el estudio.

Esto plantea un reto editorial y científico real. Para los autores, supone escribir con la consciencia de que parte de la información será superada por nuevos desarrollos antes de que el lector tenga el texto en sus manos. Para el lector, exige interpretar cada capítulo no como un inventario cerrado, sino como una fotografía del momento que captura principios, limitaciones y criterios de evaluación que sí son duraderos. Y para la comunidad de ORL en su conjunto, subraya la necesidad de establecer mecanismos de actualización continua (revisiones vivas, repositorios colaborativos, formación permanente) que complementen el formato monográfico tradicional.

La paradoja, sin embargo, tiene un lado positivo: precisamente porque el terreno cambia tan rápido, los fundamentos metodológicos y éticos adquieren

mayor valor. Las preguntas que debemos hacernos ante cualquier herramienta de IA (¿se ha validado externamente?, ¿funciona en mi población?, ¿se integra en mi flujo de trabajo?, ¿quién asume la responsabilidad si falla?) no caducan con la siguiente versión del modelo. Son las mismas hoy que lo serán dentro de cinco años, independientemente de la arquitectura que esté de moda.

HACIA UNA ADOPCIÓN RESPONSABLE

La investigación clínica asistida por IA ofrece una vía para acelerar el ciclo de generación de evidencia en nuestra especialidad. El procesamiento de lenguaje natural puede transformar miles de historias clínicas en bases de datos estructuradas, el aprendizaje no supervisado puede descubrir fenotipos que no habíamos definido a priori y los datos sintéticos y el aprendizaje federado pueden resolver parte del problema de la escasez de datos y la privacidad.

Precisamente aquí reside uno de los mensajes centrales de esta monografía: la IA no es solo una cuestión tecnológica, sino también formativa, organizativa y regulatoria. Su adopción responsable exige que los otorrinolaringólogos desarrollemos una alfabetización digital suficiente para evaluar críticamente las herramientas, participar en su diseño y validación, y exigir estándares de calidad antes de incorporarlas a la asistencia. Iniciativas como las guías TRIPOD+AI[12], CONSORT-AI[13] o FUTURE-AI[14] proporcionan marcos de referencia para una evaluación rigurosa que trasciende la caducidad de los modelos concretos.

PERSPECTIVA DE FUTURO

Es razonable anticipar que en los próximos años la convergencia de la IA multimodal, la robótica inteligente y los dispositivos conectados transformará aspectos significativos de nuestra práctica. Los modelos que hoy analizan imágenes o texto por separado tenderán a integrar múltiples fuentes de información en sistemas de apoyo a la decisión más completos. La cirugía robótica avanzará hacia niveles de asistencia más sofisticados, aunque la autonomía plena en tejido blando sigue siendo un horizonte lejano. Y la telemedicina apoyada por IA permitirá rediseñar circuitos asistenciales, acercando el cribado y el seguimiento al domicilio del paciente. Sin embargo, la velocidad del cambio tecnológico no debería dictar la velocidad de la adopción clínica. La medicina se rige por principios de seguridad, beneficencia y prudencia que exigen demostrar que una innovación mejora resultados antes de generalizarla.

MENSAJE FINAL

La inteligencia artificial no va a sustituir al otorrinolaringólogo. Pero el otorrinolaringólogo que sepa utilizar la IA de forma crítica, ética y eficiente estará mejor preparado para ofrecer una asistencia más precisa, más personalizada y más sostenible. Esta monografía ha querido aportar las bases para que ese camino se recorra con rigor, con realismo y con el paciente siempre en el centro de cada decisión.

CONFLICTO DE INTERESES

Carlos Carazo Casas es advisor médico de Latrikos HealthTech, plataforma mencionada en el capítulo 13 de esta monografía.

FINANCIACIÓN

No se recibió financiación para la elaboración de este capítulo.

BIBLIOGRAFÍA

1. Ayoub NF, Rameau A, Brenner MJ, et al. American Academy of Otolaryngology-Head and Neck Surgery (AAO-HNS) Report on Artificial Intelligence. Otolaryngol Head Neck Surg. 2025;172(2):734-743.
2. Amanian A, Heffernan A, Ishii M, Creighton FX, Thamboo A. The evolution and application of artificial intelligence in rhinology: a state of the art review. Otolaryngol Head Neck Surg. 2023;169(1):21-30.
3. Habib AR, Kajbafzadeh M, Hasan Z, et al. Artificial intelligence to classify ear disease from otoscopy: a systematic review and meta-analysis. Clin Otolaryngol. 2022;47(3):401-413.
4. Koyama H, Kashio A, Yamasoba T. Application of artificial intelligence in otology: past, present, and future. J Clin Med. 2024;13(24):7577.
5. Navarathna N, Kanhere A, Gomez C, Isaiah A. Artificial intelligence in pediatric otolaryngology: a state-of-the-art review. Int J Pediatr Otorhinolaryngol. 2025;194:112369.
6. Burmeister JR, et al. Bridging the AI implementation gap in otolaryngology: A clinical commentary. Digit Health. 2025;11:20552076251396981.
7. Collins GS, Moons KGM, Dhiman P, et al. TRIPOD+AI statement: updated guidance for reporting clinical prediction models that use regression or machine learning methods. BMJ. 2024;385:e078378.
8. Lekadir K, Frangi AF, et al. FUTURE-AI: international consensus guideline for trustworthy and deployable artificial intelligence in healthcare. BMJ. 2025;388:e081554.
9. Regulation (EU) 2024/1689 of the European Parliament and of the Council of 13 June 2024 laying down harmonised rules on artificial intelligence (AI Act). Official Journal of the European Union. OJ L, 12.7.2024.
10. World Health Organization. Ethics and governance of artificial intelligence for health: large multi-modal models. WHO guidance. Genève: WHO; 2024.
11. Abd-alrazaq A, Aslam H, AlSaad R, et al. Detection of sleep apnea using wearable artificial intelligence technology: a systematic review and meta-analysis. J Med Internet Res. 2024;26:e58187.
12. Souza S, Bhethanabotla RM, Mohan S. Applications of Artificial Intelligence in Facial Plastic and Reconstructive Surgery: A Systematic Review. Curr Opin Otolaryngol Head Neck Surg. 2024;32(4):222-233.

Impresión y distribución cortesía de:

Asociación Madrileña de Otorrinolaringología (AMORL)
Secretaría Técnica IFMEC
Paseo de la Castellana, 126
Madrid 28046
Teléfono: (+34) 672 49 29 72
www.amorl.es

© 2026 Asociación Madrileña de Otorrinolaringología
Edita: AMORL
ISBN: 978-84-09-87982-3
Primera edición impresa en junio de 2026
Tirada: 100 ejemplares
Impresión: Indica

Todos los derechos reservados.
Queda prohibida la reproducción parcial o total de la obra, por cualquier medio mecánico o electrónico, sin la debida autorización del editor.