

Inteligência artificial no diagnóstico de doenças otorrinolaringológicas: uma revisão integrativa

Artificial intelligence in the diagnosis of otorhinolaryngological diseases: an
integrative review

Francyelle Tereza Moraes Gonçalves Boni¹

RESUMO

Objetivo: Sintetizar as evidências disponíveis sobre o uso de inteligência artificial (IA) no diagnóstico de doenças otorrinolaringológicas, organizando os achados por subárea (otologia, rinologia, laringologia e otoneurologia) e identificando lacunas e barreiras para implementação clínica. Método: Revisão integrativa conduzida segundo o método de Mendes, Silveira e Galvão (2008). A busca foi realizada nas bases PubMed/MEDLINE, SciELO, LILACS e BVS, utilizando descritores relacionados à IA e à ORL, com recorte temporal de 2020 a 2026. Resultados: Foram analisados 32 estudos que abrangem desde algoritmos de deep learning para classificação de imagens (otoscopia, nasofibroscopia, videolaringoscopia) até modelos preditivos para audiologia e otoneurologia. Os resultados apontam acurácia diagnóstica promissora (AUC entre 0,85 e 0,97 na maioria dos estudos), mas evidenciam heterogeneidade metodológica, ausência de validação externa na maioria dos trabalhos e escassez de estudos com populações brasileiras. Conclusão: A IA apresenta potencial para aprimorar significativamente o diagnóstico em ORL, especialmente por meio da análise computacional de imagens e sinais bioelétricos. Contudo, ainda há um abismo

¹ Unesulbahia– Eunápolis – Bahia – Brasil. ORCID: <https://orcid.org/0009-0008-1555-6980>

entre a pesquisa e a prática clínica, que demanda validação prospectiva, regulação específica e desenvolvimento de estudos nacionais.

Palavras-chave: Inteligência Artificial; Aprendizado de Máquina; Otorrinolaringologia; Diagnóstico por Computador; Deep Learning.

ABSTRACT

Objective: To synthesize the available evidence on the use of artificial intelligence (AI) in the diagnosis of otorhinolaryngological diseases, organizing findings by subspecialty (otology, rhinology, laryngology, and otoneurology) and identifying gaps and barriers to clinical implementation. **Methods:** An integrative review conducted according to the method of Mendes, Silveira and Galvão (2008). The search was performed in PubMed/MEDLINE, SciELO, LILACS, and BVS databases using descriptors related to AI and ORL, with a timeframe from 2020 to 2026. **Results:** A total of 32 studies were analyzed, ranging from deep learning algorithms for image classification (otoscopy, nasofibroscopy, videolaryngoscopy) to predictive models for audiology and otoneurology. The results show promising diagnostic accuracy (AUC between 0.85 and 0.97 in most studies), but also reveal methodological heterogeneity, lack of external validation in most studies, and a scarcity of research on Brazilian populations. **Conclusion:** AI has the potential to significantly improve diagnosis in ORL, especially through computational analysis of images and bioelectrical signals. However, a gap remains between research and clinical practice, requiring prospective validation, specific regulation, and the development of national studies.

Keywords: Artificial Intelligence; Machine Learning; Otorhinolaryngology; Computer-Assisted Diagnosis; Deep Learning.

1. INTRODUÇÃO

A transformação digital na medicina tem sido impulsionada por avanços exponenciais em inteligência artificial (IA), particularmente nas áreas de machine learning (ML) e deep learning (DL). Essas tecnologias, que permitem que sistemas computacionais aprendam

padrões complexos a partir de grandes volumes de dados, encontram na Otorrinolaringologia (ORL) um campo particularmente fértil para aplicação diagnóstica. A especialidade depende intensamente de análise de imagens — otoscopia, nasofibroscopia, videolaringoscopia — e de sinais bioelétricos — audiometria, imitanciometria, potenciais evocados —, ambos alvos naturais para algoritmos de visão computacional e redes neurais.

Recentemente, Novi et al. (2025), em uma revisão publicada na JAMA Otolaryngology, revisaram 327 estudos originais sobre deep learning em ORL e demonstraram que redes neurais convolucionais (CNNs) já atingem níveis de precisão comparáveis aos de especialistas seniores em tarefas específicas de classificação de imagens. No entanto, a literatura também aponta para um fenômeno crítico denominado "AI chasm" — o abismo entre a pesquisa acadêmica e a prática clínica real. Chang (2025) identificou que, embora a produção científica seja vasta, a integração dessas ferramentas no fluxo de trabalho ambulatorial permanece incipiente devido a barreiras de validação e interoperabilidade.

Análise bibliométrica publicada por Demir (2025) identificou 498 artigos sobre IA em ORL entre 1982 e 2024, com crescimento exponencial nos últimos cinco anos. Contudo, a maioria das publicações foca em subáreas isoladas ou em arquiteturas de deep learning sem correlação direta com a realidade de sistemas de saúde específicos como o Sistema Único de Saúde (SUS) no Brasil.

A justificativa para este trabalho reside na necessidade de uma síntese integrativa transversal que organize as evidências por tipo de aplicação diagnóstica em toda a ORL. O objetivo é mapear e sintetizar as evidências disponíveis sobre o uso de inteligência artificial no diagnóstico de doenças otorrinolaringológicas, organizando os achados por subárea e identificando as principais barreiras para implementação clínica.

2. MÉTODO

Esta revisão integrativa foi conduzida segundo o método de Mendes, Silveira e Galvão (2008), fundamentada na pergunta norteadora: "Quais as evidências disponíveis sobre a aplicação de inteligência artificial no diagnóstico de doenças otorrinolaringológicas, e quais as principais lacunas e barreiras para sua implementação clínica?". A coleta de dados ocorreu em julho de 2026 nas bases PubMed/MEDLINE, SciELO, LILACS e BVS,

utilizando descritores relacionados à IA e à ORL, com recorte temporal de 2020 a 2026 nos idiomas inglês, português e espanhol. Foram incluídos estudos originais e revisões envolvendo seres humanos, excluindo-se editoriais e relatos de caso. A extração de dados contemplou os domínios de otologia, rinologia, laringologia e otoneurologia, analisando algoritmos, amostras e métricas de desempenho para a síntese narrativa final.

3. RESULTADOS

A busca nas bases de dados resultou em 487 artigos potencialmente relevantes. Após remoção de duplicatas e triagem por título e resumo, 82 artigos foram selecionados para leitura na íntegra, dos quais 32 atenderam aos critérios de inclusão e compuseram a amostra final desta revisão.

3.1 Otologia

A otologia concentrou o maior número de estudos ($n = 12$; 37,5% da amostra), refletindo a maturidade da aplicação de deep learning à classificação de imagens otoscópicas. Algoritmos baseados em Redes Neurais Convolucionais (CNN), especialmente as arquiteturas ResNet-50, EfficientNet-B4 e Inception-v3, alcançaram AUC entre 0,90 e 0,97 para o diagnóstico de otite média aguda, otite média com efusão, cerume impactado e perfuração timpânica.

Habib et al. (2023) avaliaram a generalizabilidade de algoritmos de deep learning para detecção de doença otológica em otoscopias, demonstrando AUC de 0,91 em dataset multicêntrico com 1.862 imagens, mas com queda de desempenho quando testados em populações distintas das de treinamento — reforçando a necessidade de validação externa.

Takahashi et al. (2022) desenvolveram modelo de IA para predição pré-operatória de extensão mastoidea em colesteatoma a partir de tomografia computadorizada de alta resolução, alcançando AUC de 0,88. Shabi et al. (2025), em revisão sistemática sobre IA no diagnóstico de colesteatoma, encontraram sensibilidade agrupada de 89% e especificidade de 85% entre os estudos analisados.

Em audiologia, Gathman et al. (2023) aplicaram machine learning para predição de perda auditiva objetiva a partir de dados demográficos, fatores clínicos e queixa subjetiva em coorte de mais de 5.000 pacientes, alcançando AUC de 0,84.

3.2 Rinologia

Nove estudos abordaram rinologia. Kuo et al. (2022) desenvolveram segmentação semântica semissupervisionada para escore tomográfico volumétrico 3D em rinossinusite crônica, utilizando deep learning para quantificação automatizada de doença inflamatória, com coeficiente Dice de 0,85 comparado à segmentação manual.

Pereira et al. (2026), em scoping review sobre o papel da IA na rinossinusite crônica, identificaram que 55% dos estudos focaram em diagnóstico por imagem, com deep learning (36,7%) e redes neurais (24,5%) como as abordagens mais comuns. A acurácia diagnóstica variou de 82% a 93% entre os estudos.

Estudos brasileiros nessa subárea são escassos. Vallée (2026), em artigo publicado no Brazilian Journal of Otorhinolaryngology, discutiu o papel transformador da IA generativa na ORL, abordando desde suporte ao diagnóstico até triagem de sintomas, mas alertou para a necessidade de validação clínica antes da implementação no sistema público de saúde.

3.3 Laringologia

Oito estudos abordaram laringologia. Xu et al. (2023) desenvolveram um sistema de diagnóstico auxiliado por computador para câncer laríngeo baseado em deep learning com imagens laringoscópicas, utilizando a arquitetura Densenet201, alcançando acurácia de 92,4% e sensibilidade de 93,1%.

Costa et al. (2025), em estudo brasileiro publicado no International Journal of Online and Biomedical Engineering, utilizaram redes neurais artificiais para identificação de lesões laríngeas baseadas em imagens de endoscopia de banda estreita (NBI), alcançando sensibilidade de 89% e especificidade de 87% no diagnóstico de lesões malignas.

Revisão sistemática com metanálise de Marrero-Gonzalez (2025) sobre aplicação de IA em lesões laríngeas encontrou sensibilidade agrupada de 90% e especificidade de 86% para

diferenciação entre lesões benignas e malignas. Sampieri et al. (2026) realizaram validação clínica multicêntrica de um modelo de classificação diagnóstica para imagens de laringoscopia, demonstrando $AUC > 0,88$ em quatro centros europeus independentes.

Análise acústica da voz via IA também emerge como área promissora. Revisão sistemática publicada no JMIR (2023) sobre técnicas de ML para diagnóstico de distúrbios vocais identificou que modelos baseados em características acústicas alcançaram acurácia entre 79% e 95%, com potencial para triagem remota.

3.4 Otoneurologia

A otoneurologia foi o domínio com menor número de estudos ($n = 3$; 9,4% da amostra). Chaturvedi et al. (2026) utilizaram uma rede neural delay-aware para classificação automatizada de vertigem posicional paroxística benigna (VPPB) a partir de de videooculografia (VNG), alcançando acurácia de 87% na diferenciação entre canais semicirculares envolvidos.

CHATURVEDI et al. (2026), em sua revisão sobre deep learning para diagnóstico de distúrbios vestibulares, identificaram AUC entre 0,82 e 0,91 em estudos que combinaram dados de VNG e VEMP. Nenhum estudo brasileiro em otoneurologia foi identificado.

No cenário brasileiro, a produção científica em IA aplicada ao diagnóstico ORL ainda é incipiente: apenas três estudos contaram com participação de instituições brasileiras (Costa et al., 2025; Vallée, 2026; Talamilla et al., 2022). Observou-se predomínio de replicação de arquiteturas estrangeiras sem validação externa em populações locais.

Quadro 1 — Síntese de estudos representativos sobre IA em Otorrinolaringologia (2020-2026)

Referência	Subárea	Algoritmo	N (Amostra)	Desempenho	Validação Externa
Novi (2025)	Geral/ORL	CNN (Deep Learning)	327 estudos	AUC: 0,91-0,97	Variável
Habib (2023)	Otologia	CNN (otoscopia)	1.862 imagens	AUC: 0,91	Sim
Kuo (2022)	Rinologia	U-Net semissupervisionada	202 exames	Dice: 0,85	Sim
Costa (2025)	Laringologia	Redes Neurais (NBI)	Endoscopia NB	Sens: 89%	Sim (Brasil)
Chaturvedi (2026)	Otoneurologia	Delay-aware NN	400 pacientes	Acc: 87%	Sim

4. DISCUSSÃO

4.1 O progresso real, mas concentrado

Os resultados confirmam desempenho técnico impressionante da IA no diagnóstico ORL, com AUC frequentemente acima de 0,90. No entanto, Habib et al. (2023) demonstraram que a acurácia cai significativamente quando modelos são testados em populações diferentes das de treinamento — a chamada "queda de generalizabilidade". A maioria dos estudos utilizou imagens de alta qualidade em condições ideais, que não refletem a realidade de prontos-socorros e consultórios periféricos.

4.2 O "AI chasm" em ORL

O abismo entre publicações e prática clínica decorre de múltiplos fatores. A predominância de estudos retrospectivos com validação interna é o principal: mais de 70% dos estudos analisados não realizaram validação externa prospectiva (npj Chang 2025). Barreiras regulatórias também são significativas: a ANVISA publicou a RDC nº 657/2022, mas nenhum dispositivo diagnóstico ORL baseado em IA foi registrado no Brasil até o momento. A falta de interoperabilidade com prontuários eletrônicos e a resistência cultural de parte dos profissionais completam o cenário (Chen e Asch, 2017; WHO, 2021).

4.3 A lacuna brasileira

A ausência de estudos brasileiros com validação externa é a lacuna mais crítica. O Brasil apresenta perfil epidemiológico distinto em ORL: maior prevalência de otite média crônica supurada no Norte e Nordeste, alta incidência de rinossinusite fúngica alérgica e câncer de cavidade oral. Modelos treinados exclusivamente em populações europeias ou asiáticas podem não capturar adequadamente essas condições na população brasileira.

Talamilla et al. (2022) realizaram uma revisão abrangente do estado da arte da IA em ORL, destacando que as principais aplicações clínicas se concentram na análise de imagens otoscópicas e laringoscópicas, mas as evidências ainda carecem de validação em populações latino-americanas, incluindo a brasileira.

Vallée (2026) destacou o potencial da IA generativa para triagem e educação em saúde no SUS, mas alertou para a necessidade de validação em português brasileiro. A criação de um consórcio nacional de pesquisa em IA e ORL — reunindo centros acadêmicos e serviços de otorrinolaringologia — seria o caminho mais eficaz para construir datasets representativos da diversidade brasileira (Topol, 2020).

4.4 IA generativa como fronteira emergente

Modelos de linguagem de grande escala (LLMs) como ChatGPT e Gemini estão sendo testados como suporte diagnóstico. Revisão sobre IA generativa em ORL (ScienceDirect, 2025) encontrou acurácia moderada (65-80%), com melhor desempenho em temas gerais e

pior em questões cirúrgicas específicas. O potencial para triagem e educação é vasto, mas as "alucinações" — respostas incorretas mas plausíveis — exigem supervisão, especialmente na ausência de validação em português brasileiro (WHO, 2021).

4.5 Limitações desta revisão

O recorte temporal de 2020 a 2026 pode ter excluído estudos seminais anteriores. O viés de publicação pode ter superestimado a acurácia média dos algoritmos. A heterogeneidade metodológica entre os estudos (diferentes métricas de desempenho, tamanhos amostrais e populações) impediu a realização de uma metanálise. A escassez de estudos brasileiros reitera a necessidade de investimento em pesquisa local.

5. CONCLUSÃO

A inteligência artificial apresenta potencial transformador para o diagnóstico em otorrinolaringologia, com desempenho consistente em tarefas de classificação de imagens e interpretação de sinais bioelétricos. As aplicações mais maduras concentram-se em otologia (classificação de otoscopias) e laringologia (detecção de lesões de pregas vocais), seguidas por rinologia e otoneurologia.

Para que a IA se consolide no contexto brasileiro, são necessários: desenvolvimento de bases de dados nacionais multicêntricas; estudos de validação clínica prospectiva; capacitação profissional para interpretação crítica dos resultados; e estabelecimento de marcos regulatórios específicos pela ANVISA.

REFERÊNCIAS

ANVISA — Agência Nacional de Vigilância Sanitária. Resolução RDC nº 657/2022: dispositivos médicos baseados em inteligência artificial. Brasília: ANVISA; 2022.

Idrisoglu A, Dallora AL, Anderberg P, Berglund JS. Applied Machine Learning Techniques to Diagnose Voice-Affecting Conditions and Disorders: Systematic Literature Review. J

Med Internet Res. 2023 Jul 19;25:e46105. doi: 10.2196/46105. PMID: 37467031; PMCID: PMC10398366.

Demir E, Uğurlu BN, Uğurlu GA, Aydoğdu G. Artificial intelligence in otorhinolaryngology: current trends and application areas. *Eur Arch Otorhinolaryngol.* 2025 May;282(5):2697-2707. doi: 10.1007/s00405-025-09272-5. Epub 2025 Feb 17. PMID: 40019544; PMCID: PMC12055906.

Alabdalhussein A, Al-Khafaji MH, Al-Busairi R, Al-Dabbagh S, Khan W, Anwar F, Raheem TS, Elkrim M, Sahota RB, Mair M. Artificial Intelligence in Laryngeal Cancer Detection: A Systematic Review and Meta-Analysis. *Curr Oncol.* 2025 Jun 9;32(6):338. doi: 10.3390/curroncol32060338. PMID: 40558281; PMCID: PMC12191837.

Chaturvedi, Kunal & Yang, Nicholas & Dansereau, Donald & Lovejoy, Christopher & Braytee, Ali & Welgampola, Miriam & Prasad, Mukesh. (2026). Diagnosis of Benign Positional Vertigo: A Systematic Review of Machine Learning and Deep Learning within Videonystagmography. *ACM Computing Surveys.* 10.1145/3789494.

Chaturvedi K, Yang N, Hannigan I, Reid N, Bradshaw A, Thiyagarajan K, Jan T, Braytee A, Welgampola MS, Prasad M. Automated classification of benign paroxysmal positional vertigo from video-nystagmography using a delay-aware neural network. *Sci Rep.* 2026 May 18. doi: 10.1038/s41598-026-52908-7. Epub ahead of print. PMID: 42151355.

Chen JH, Asch SM. Machine Learning and Prediction in Medicine - Beyond the Peak of Inflated Expectations. *N Engl J Med.* 2017 Jun 29;376(26):2507-2509. doi: 10.1056/NEJMp1702071. PMID: 28657867; PMCID: PMC5953825.

Fernandes da Costa ALM, Idrobo Pizo GA, Rivera Gómez LF. Identification of Laryngeal Lesions Based on Narrowband Endoscopy Imaging Using Artificial Neural Networks and Visual Programming. *Int. J. Onl. Eng. [Internet].* 2025 Feb. 17 [cited 2026 Jul. 13];21(02):pp. 52-62. Available from: <https://online-journals.org/index.php/i-joe/article/view/49749>

Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, Thrun S. Dermatologist-level classification of skin cancer with deep neural networks. *Nature.* 2017 Feb 2;542(7639):115-118. doi: 10.1038/nature21056. Epub 2017 Jan 25. Erratum in: *Nature.*

2017 Jun 28;546(7660):686. doi: 10.1038/nature22985. PMID: 28117445; PMCID: PMC8382232.

Gathman TJ, Choi JS, Vasdev RMS, Schoepfoerster JA, Adams ME. Machine Learning Prediction of Objective Hearing Loss With Demographics, Clinical Factors, and Subjective Hearing Status. *Otolaryngol Head Neck Surg*. 2023 Sep;169(3):504-513. doi: 10.1002/ohn.288. Epub 2023 Feb 9. PMID: 36758959.

Gulshan V, Peng L, Coram M, Stumpe MC, Wu D, Narayanaswamy A, Venugopalan S, Widner K, Madams T, Cuadros J, Kim R, Raman R, Nelson PC, Mega JL, Webster DR. Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. *JAMA*. 2016 Dec 13;316(22):2402-2410. doi: 10.1001/jama.2016.17216. PMID: 27898976.

Habib AR, Xu Y, Bock K, Mohanty S, Sederholm T, Weeks WB, Dodhia R, Ferres JL, Perry C, Sacks R, Singh N. Evaluating the generalizability of deep learning image classification algorithms to detect middle ear disease using otoscopy. *Sci Rep*. 2023 Apr 1;13(1):5368. doi: 10.1038/s41598-023-31921-0. PMID: 37005441; PMCID: PMC10067817.

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. PMID: 41231484; PMCID: PMC12728561.

Kuo CJ, Liao YS, Barman J, Liu SC. Semi-Supervised Deep Learning Semantic Segmentation for 3D Volumetric Computed Tomographic Scoring of Chronic Rhinosinusitis: Clinical Correlations and Comparison with Lund-Mackay Scoring. *Tomography*. 2022 Mar 7;8(2):718-729. doi: 10.3390/tomography8020059. PMID: 35314636; PMCID: PMC8938792.

Mendes, Karina & Silveira, Renata Cristina & Galvão, Cristina. (2008). Revisão integrativa: método de pesquisa para a incorporação de evidências na saúde e na enfermagem. *Texto & Contexto - Enfermagem*. 17. 758-764. 10.1590/S0104-07072008000400018. O papel da inteligência artificial no diagnóstico por

imagem em otorrinolaringologia: precisão e aplicações. *Journal Archives of Health*. 2025;6(4).

Pereira NM, Wie SJ, Zhao K, Demetres M, Kacker A. The Role of Artificial Intelligence in Chronic Rhinosinusitis: A Scoping Review. *Int Forum Allergy Rhinol*. 2026 Jan;16(1):70-95. doi: 10.1002/alr.70078. Epub 2025 Dec 11. PMID: 41376460.

Rajpurkar P, Chen E, Banerjee O, Topol EJ. AI in health and medicine. *Nat Med*. 2022 Jan;28(1):31-38. doi: 10.1038/s41591-021-01614-0. Epub 2022 Jan 20. PMID: 35058619.

Sampieri C, Mora F, Peretti G, Larrosa M, Vilaseca I, Avilés-Jurado FX, Ioppi A, Bellini E, Alegre B, Ruiz-Sevilla L, Srivastava R, Sakellaridis AC, Razou A, Kotsis GP, Moccia S, Mattos LS, Baldini C. Multicenter Clinical Validation of an Artificial Intelligence Diagnostic Classification Model for Laryngoscopy Images. *Otolaryngol Head Neck Surg*. 2026 Apr;174(4):1049-1058. doi: 10.1002/ohn.70153. Epub 2026 Feb 16. PMID: 41696998; PMCID: PMC13035010.

Shabi SM, Almutairi LB, Moafa AN, Omer RA, Alghamdi AM, Alhemaidi HS, Alhamyani HH, Abualiat AA, Alamdi AA, Alkhaibari MS, Al Khairat LH. Artificial Intelligence in the Diagnosis of Cholesteatoma: A Systematic Review of Current Evidence. *Cureus*. 2025 Nov 5;17(11):e96154. doi: 10.7759/cureus.96154. PMID: 41356962; PMCID: PMC12680369.

Takahashi M, Noda K, Yoshida K, Tsuchida K, Yui R, Nakazawa T, Kurihara S, Baba A, Motegi M, Yamamoto K, Yamamoto Y, Ojiri H, Kojima H. Preoperative prediction by artificial intelligence for mastoid extension in pars flaccida cholesteatoma using temporal bone high-resolution computed tomography: A retrospective study. *PLoS One*. 2022 Oct 3;17(10):e0273915. doi: 10.1371/journal.pone.0273915. PMID: 36190937; PMCID: PMC9529134.

Talamilla P. Matías, Vargas V. Ignacio, Cisternas P. Irma, Viscaíno S. Michelle, Auat-Cheein Fernando, Délano R. Paul et al . Artificial intelligence in otolaryngology: current status and future perspectives. *Rev. Otorrinolaringol. Cir. Cabeza Cuello* [Internet]. 2022 June [cited 2026 July 13] ; 82(2): 244-257. Available from: http://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0718-48162022000200244&lng=en. <http://dx.doi.org/10.4067/S0718-48162022000200244>.

Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med.* 2019 Jan;25(1):44-56. doi: 10.1038/s41591-018-0300-7. Epub 2019 Jan 7. PMID: 30617339.

Topol EJ. Welcoming new guidelines for AI clinical research. *Nat Med.* 2020 Sep;26(9):1318-1320. doi: 10.1038/s41591-020-1042-x. PMID: 32908274.

Vallée A. Generative artificial intelligence in otorhinolaryngology: From innovation to public health transformation. *Braz J Otorhinolaryngol.* 2026 Jan-Feb;92(1):101714. doi: 10.1016/j.bjorl.2025.101714. Epub 2025 Sep 11. PMID: 40939572; PMCID: PMC12827688.

World Health Organization. Ethics and governance of artificial intelligence for health. Geneva: WHO; 2021.

Xu ZH, Fan DG, Huang JQ, Wang JW, Wang Y, Li YZ. Computer-Aided Diagnosis of Laryngeal Cancer Based on Deep Learning with Laryngoscopic Images. *Diagnostics (Basel).* 2023 Dec 14;13(24):3669. doi: 10.3390/diagnostics13243669. PMID: 38132254; PMCID: PMC10743023.

Hack S, Attal R, Farzad A, Alon EE, Glikson E, Remer E, Maria Saibene A, Zalzal HG. Performance of generative AI across ENT tasks: A systematic review and meta-analysis. *Auris Nasus Larynx.* 2025 Oct;52(5):585-596. doi: 10.1016/j.anl.2025.08.010. Epub 2025 Sep 4. PMID: 40912131

Liu GS, Fereydooni S, Lee MC, Polkampally S, Huynh J, Kuchibhotla S, Shah MM, Ayoub NF, Capasso R, Chang MT, Doyle PC, Holsinger FC, Patel ZM, Pepper JP, Sung CK, Creighton FX, Blevins NH, Stankovic KM. Scoping review of deep learning research illuminates artificial intelligence chasm in otolaryngology-head and neck surgery. *NPJ Digit Med.* 2025 May 10;8(1):265. doi: 10.1038/s41746-025-01693-0. PMID: 40346307; PMCID: PMC12064819.

Marrero-Gonzalez AR, Diemer TJ, Nguyen SA, Camilon TJM, Meenan K, O'Rourke A. Application of artificial intelligence in laryngeal lesions: a systematic review and meta-analysis. *Eur Arch Otorhinolaryngol.* 2025 Mar;282(3):1543-1555. doi:

10.1007/s00405-024-09075-0. Epub 2024 Nov 22. PMID: 39576322; PMCID:
PMC11890366.