

Modelos de inteligencia artificial para apoyo clínico en cirugía dental e implantología: una revisión sistemática

Artificial intelligence models for clinical support in dental surgery and implantology: a systematic review

Adrián Sebastián Realpe Flores*
Profesional Independiente
Quito - Ecuador
od.adrianrealpe@gmail.com
<https://orcid.org/0009-0009-3862-7427>

Solange Daniela Chávez Jaramillo
Profesional Independiente
Quito - Ecuador
dasolcj@outlook.com
<https://orcid.org/0009-0000-4477-9659>

Maritza Mishell Alarcón Mugmal
Profesional Independiente
Quito - Ecuador
mishel98@hotmail.es
<https://orcid.org/0009-0002-5010-8960>

Carlos Elián Coque Bastidas
Profesional Independiente
Quito - Ecuador
carloselian2110@outlook.com
<https://orcid.org/0009-0008-5110-7381>

*Correspondencia:
od.adrianrealpe@gmail.com

Cómo citar este artículo:
Realpe, A., Chávez, S., Alarcón, M., & Coque, C. (2026). Modelos de inteligencia artificial para apoyo clínico en cirugía dental e implantología: una revisión sistemática. *Esprint Investigación*, 5(1), 681-697. <https://doi.org/10.61347/ei.v5i1.278>

Recibido: 27 de febrero de 2026

Aceptado: 3 de abril de 2026

Publicado: 10 de abril de 2026

Copyright: Derechos de autor 2026 Adrián Sebastián Realpe Flores, Solange Daniela Chávez Jaramillo, Maritza Mishell Alarcón Mugmal, Carlos Elián Coque Bastidas.



Esta obra está bajo una licencia internacional Creative Commons Atribución-NonComercial 4.0.

Resumen: La inteligencia artificial (IA) se ha consolidado como una herramienta clave en la medicina contemporánea, destacándose por su capacidad para optimizar el diagnóstico, la planificación y la toma de decisiones clínicas mediante el análisis de grandes volúmenes de datos. En cirugía dental e implantología, su aplicación ha experimentado un crecimiento significativo, especialmente en el procesamiento de imágenes y la predicción de resultados terapéuticos. El objetivo de la presente revisión sistemática fue analizar de manera integral los modelos de IA utilizados como apoyo clínico en estas áreas, así como evaluar su desempeño diagnóstico e identificar sus principales limitaciones y desafíos de implementación. Se realizó una revisión sistemática siguiendo las directrices de la declaración PRISMA 2020, mediante una búsqueda estructurada en Scopus y PubMed, incluyendo estudios originales publicados entre 2020 y 2026. Tras el proceso de selección y evaluación del riesgo de sesgo, se incluyeron 19 estudios en la síntesis final. Los resultados evidencian un predominio de modelos de aprendizaje profundo (deep learning), particularmente redes neuronales convolucionales (CNN), así como modelos de detección de objetos (YOLO) y arquitecturas híbridas, aplicados principalmente al análisis de imágenes radiográficas en tareas como la segmentación anatómica, la clasificación de implantes, el diagnóstico radiográfico y la planificación implantológica. Estos modelos presentan un alto desempeño diagnóstico, con métricas superiores al 90% en múltiples tareas. No obstante, se identificaron limitaciones relacionadas con la calidad y disponibilidad de los datos, la generalización de los modelos y su validación en entornos clínicos reales. En conclusión, la IA representa una herramienta prometedora de apoyo clínico en implantología; sin embargo, su implementación efectiva requiere superar desafíos metodológicos, técnicos y regulatorios, así como fortalecer la evidencia mediante estudios clínicos robustos.

Palabras clave: Aprendizaje automático, cirugía dental, implantología oral, inteligencia artificial, modelos predictivos, redes neuronales convolucionales.

Abstract: Artificial intelligence (AI) has become a key tool in contemporary medicine, standing out for its ability to optimize diagnosis, planning, and clinical decision-making through the analysis of large volumes of data. In dental surgery and implantology, its application has experienced significant growth, particularly in image processing and the prediction of therapeutic outcomes. The aim of this systematic review was to comprehensively analyze AI models used as clinical support in these areas, as well as to evaluate their diagnostic performance and identify their main limitations and implementation challenges. A systematic review was conducted following the PRISMA 2020 guidelines, using a structured search strategy in Scopus and PubMed, including original studies published between 2020 and 2026. After the selection process and risk of bias assessment, 19 studies were included in the final synthesis. The results show a predominance of deep learning models, particularly convolutional neural networks (CNNs), as well as object detection models (YOLO) and hybrid architectures, mainly applied to the analysis of radiographic images in tasks such as anatomical segmentation, implant classification, radiographic diagnosis, and implant planning. These models demonstrate high diagnostic performance, with metrics exceeding 90% in multiple tasks. However, limitations related to data quality and availability, model generalization, and validation in real clinical settings were identified. In conclusion, AI represents a promising clinical support tool in implantology; however, its effective implementation requires overcoming methodological, technical, and regulatory challenges, as well as strengthening the evidence through robust clinical studies.

Keywords: Artificial intelligence, convolutional neural networks, dental surgery, machine learning, oral implantology, predictive models.

1. Introducción

Este desarrollo ha sido impulsado por el crecimiento acelerado del big data y la digitalización de los sistemas de salud, los cuales favorecen la generación, almacenamiento e integración de datos biomédicos complejos, especialmente imágenes médicas, potenciando así el desarrollo de modelos computacionales cada vez más precisos (Miragall et al., 2023). Además, la incorporación de técnicas avanzadas como el aprendizaje profundo permite replicar procesos cognitivos complejos y analizar grandes volúmenes de información con alta precisión, llegando incluso a superar, en determinados escenarios, las capacidades humanas (Krishnan, 2022).

De este modo, la IA ha evolucionado desde aplicaciones experimentales hacia sistemas clínicamente relevantes, capaces de identificar patrones complejos en datos heterogéneos, incluyendo imágenes radiográficas, registros clínicos electrónicos y variables biomédicas (Revilla-León et al., 2023). Como resultado, estas tecnologías generan un impacto significativo en la toma de decisiones clínicas, al proporcionar herramientas que asisten en el diagnóstico, la planificación preoperatoria, la simulación quirúrgica y el seguimiento postoperatorio, además de mejorar la seguridad del paciente y optimizar los resultados terapéuticos (Balch et al., 2024; Gracia et al., 2025; Morris et al., 2024).

En el campo de la implantología dental, la IA demuestra un potencial considerable al permitir el análisis integrado de antecedentes médicos, imágenes diagnósticas y resultados clínicos, lo que contribuye a una comprensión más completa del paciente (Saeed et al., 2023). Estas aplicaciones incluyen el reconocimiento automatizado del tipo de implante, la predicción de su éxito clínico y la optimización de su diseño, alcanzando altos niveles de precisión y favoreciendo una práctica clínica más eficiente y basada en evidencia (Gómez-Polo et al., 2024).

Asimismo, los modelos basados en aprendizaje automático han facilitado la identificación temprana de pacientes que requieren implantes dentales, así como la predicción de resultados terapéuticos y la planificación de tratamientos personalizados (Alharbi & Almutiq, 2022). De manera complementaria, los sistemas basados en aprendizaje profundo han ampliado estas capacidades, particularmente en el análisis de imágenes, permitiendo la clasificación automatizada de implantes dentales con alta precisión y niveles comparables a los de especialistas (Lubbad et al., 2024).

En el ámbito diagnóstico, estos avances también han posibilitado la detección automatizada de regiones de dientes ausentes en radiografías panorámicas, optimizando la precisión diagnóstica y reduciendo la carga de trabajo del clínico (Park et al., 2022). Por lo tanto, estas aplicaciones evidencian que la inteligencia artificial no solo optimiza el diagnóstico, sino que también fortalece la predicción de resultados y la planificación terapéutica, consolidándose como una herramienta de apoyo clave en la toma de decisiones clínicas (Morris et al., 2024; Sitaras et al., 2025).

A pesar del progreso, la implementación de la IA en la práctica clínica aún presenta limitaciones importantes. Existe una falta de estandarización en la recopilación y procesamiento de datos, así como una alta heterogeneidad metodológica, lo que dificulta la comparación entre estudios y limita la reproducibilidad (Revilla-León et al., 2023). Además, la variabilidad en los datos radiográficos afecta la consistencia y la capacidad de generalización de los modelos. A ello se suman limitaciones metodológicas comunes, como la omisión de variables clínicas relevantes, tamaños muestrales reducidos o el uso de datos de un solo centro, lo que restringe la generalización de los resultados.

En consecuencia, aunque algunos modelos logran alta precisión en tareas específicas, como el reconocimiento de implantes, su desempeño en la predicción del éxito clínico presenta una variabilidad considerable, lo que subraya la necesidad de mejorar la calidad, consistencia y validez de

la evidencia disponible. Esta brecha en el conocimiento, relacionada con la integración, estandarización y validación de modelos de inteligencia artificial en implantología dental, limita su adopción generalizada en la práctica clínica.

En este contexto, el objetivo de la presente revisión sistemática es analizar y sintetizar la evidencia científica sobre los modelos de inteligencia artificial como herramientas de apoyo clínico en cirugía dental e implantología. En particular, se busca responder a las siguientes preguntas de investigación: (1) ¿Qué tipos de modelos de inteligencia artificial se utilizan en cirugía dental e implantología y cuáles son sus principales aplicaciones clínicas? (2) ¿Cuál es el desempeño diagnóstico de estos modelos? y (3) ¿Cuáles son las principales limitaciones y desafíos para su implementación en la práctica clínica?

2. Metodología

La presente revisión sistemática se llevó a cabo siguiendo las directrices establecidas por la declaración PRISMA 2020, con el propósito de garantizar la transparencia, reproducibilidad y rigor metodológico del proceso de identificación, selección, evaluación y síntesis de la evidencia científica disponible (Page et al., 2021).

Criterios de elegibilidad

Se incluyeron estudios originales publicados entre los años 2020 y 2026, hasta la fecha de consulta (27 de marzo de 2026), que abordaron el desarrollo, implementación o evaluación de modelos de inteligencia artificial aplicados en contextos de cirugía dental o implantología oral. No se estableció restricción de idioma, siempre que reportaran resultados cuantitativos o cualitativos relacionados con el desempeño de los modelos.

Se excluyeron revisiones de la literatura, editoriales, cartas al editor, resúmenes de conferencias, opiniones, artículos retractados, libros, estudios duplicados, así como aquellos trabajos que no abordaron directamente aplicaciones clínicas en cirugía dental o implantología, o que no presentaron resultados evaluables del rendimiento de modelos de inteligencia artificial. Asimismo, se excluyeron estudios cuyo texto completo no estuvo disponible o que no cumplieron con criterios metodológicos mínimos de calidad.

Fuentes de información y estrategia de búsqueda

La búsqueda sistemática de la literatura se realizó en las bases de datos Scopus y PubMed, seleccionadas por su amplia cobertura de literatura biomédica y científica de alto impacto. Ambas bases de datos fueron consultadas de manera independiente, asegurando la recuperación exhaustiva de estudios relevantes en el área de interés.

La estrategia de búsqueda se estructuró a partir de dos categorías conceptuales principales: (1) inteligencia artificial y (2) cirugía dental o implantología. La búsqueda se restringió al campo de título (*title*), con el fin de aumentar la especificidad de los resultados, y se adaptó a las particularidades sintácticas de cada base de datos. La cadena de búsqueda empleada y el número de estudios recuperados se muestran en la tabla 1.

Tabla 1*Estrategia de búsqueda*

Base de datos	Cadena de búsqueda	Estudios
Scopus	(TITLE ("artificial intelligence" OR "machine learning" OR "deep learning") AND TITLE ("dental surgery" OR "oral implantology" OR "maxillofacial surgery" OR "oral surgery" OR "dental implant*" OR "implant dentistry")) AND PUBYEAR > 2019 AND PUBYEAR < 2027 AND (LIMIT-TO (DOCTYPE, "ar"))	90
PubMed	("artificial intelligence"[Title] OR "machine learning"[Title] OR "deep learning"[Title]) AND ("dental surgery"[Title] OR "oral implantology"[Title] OR "maxillofacial surgery"[Title] OR "oral surgery"[Title] OR "dental implant*"[Title] OR "implant dentistry"[Title])	140
Total		230


Proceso de selección de estudios

Dos revisores evaluaron de manera independiente los registros recuperados mediante la lectura de títulos y resúmenes, aplicando los criterios de inclusión y exclusión previamente definidos. Posteriormente, los revisores discutieron los estudios potencialmente elegibles para su inclusión definitiva. En caso de discrepancias, un tercer evaluador intervino para resolver los desacuerdos y garantizar la objetividad en el proceso de selección.

Evaluación de riesgo de sesgo

La evaluación del riesgo de sesgo se llevó a cabo en función del diseño metodológico de los estudios incluidos, utilizando herramientas validadas específicas para cada tipo de estudio. En los estudios de desarrollo y evaluación diagnóstica se aplicó QUADAS-2, identificándose 4 estudios con bajo riesgo, 9 con riesgo moderado y 21 con alto riesgo de sesgo.

Para los estudios de tipo transversal se utilizó la herramienta JBI, identificándose 5 estudios con bajo riesgo de sesgo. En los estudios de predicción o modelos predictivos se empleó PROBAST, identificándose 4 estudios con alto riesgo de sesgo. Los estudios experimentales *in vitro* fueron evaluados mediante la guía CRIS, evidenciándose 2 estudios con alto riesgo de sesgo. Finalmente, en los ensayos clínicos aleatorizados se utilizó la herramienta RoB 2, identificándose un estudio con bajo riesgo de sesgo y otro con alto riesgo. La figura 1 mostró los resultados del riesgo de sesgo por tipo de estudio.

Figura 1*Riesgo de sesgo identificado por tipo de estudio*

Extracción y síntesis de datos

La extracción de datos se realizó de manera sistemática mediante una matriz estructurada que permitió recopilar información relevante de cada estudio incluido. Las variables extraídas incluyeron: tipo de estudio, país de realización, modelo de inteligencia artificial utilizado, aplicaciones clínicas del modelo, métricas de evaluación y valores de desempeño reportados, así como las principales limitaciones y desafíos identificados.

Posteriormente, se llevó a cabo una síntesis narrativa de los hallazgos, en la cual los datos fueron analizados e interpretados de forma cualitativa, permitiendo identificar patrones, establecer relaciones entre los resultados y formular conclusiones fundamentadas en la evidencia disponible.

3. Resultados

Selección de estudios


El proceso de selección de estudios se llevó a cabo conforme a las directrices PRISMA 2020, siguiendo las fases de identificación, cribado e inclusión. En la fase de identificación, se recuperaron un total de 230 registros provenientes de dos bases de datos: 90 de Scopus y 140 de PubMed. Posteriormente, se eliminaron 77 registros duplicados, obteniéndose 153 estudios únicos para la fase de cribado.

Durante esta etapa, tras la revisión de títulos, resúmenes y palabras clave, se excluyeron 79 registros por no cumplir con los criterios de elegibilidad o por no responder a las preguntas de investigación. En consecuencia, se solicitaron 74 artículos para revisión a texto completo, de los cuales 27 no pudieron ser recuperados. Finalmente, 47 estudios fueron evaluados en su totalidad para determinar su elegibilidad.

Tras la evaluación metodológica, se excluyeron 28 estudios debido a un alto riesgo de sesgo, resultando en un total de 19 estudios incluidos en la síntesis final de la revisión sistemática. La Figura 2 presenta el proceso realizado.

Figura 2

Diagrama de flujo PRISMA 2020



Modelos de IA, aplicaciones clínicas y desempeño

La tabla 2 presenta una síntesis estructurada de los 19 estudios incluidos en esta revisión, integrando de manera comparativa los principales modelos de inteligencia artificial empleados en cirugía dental e implantología, sus aplicaciones clínicas y el desempeño reportado. En particular, se detallan las arquitecturas utilizadas, las áreas de aplicación, así como las métricas de evaluación empleadas junto con los valores de desempeño alcanzados.

Esta sistematización permite identificar patrones consistentes en el uso y rendimiento de los modelos de IA, facilitando una visión integral y comparativa de su aplicabilidad clínica y su potencial en la práctica odontológica contemporánea.

Tabla 2
Modelos de inteligencia artificial en cirugía dental e implantología

Autor	Tipo de estudio	Modelo de IA	Aplicaciones clínicas	Métricas y desempeño
Kurt Bayrakdar et al. (2021)	Desarrollo y evaluación diagnóstica	DCNN (3D U-Net modificado)	Segmentación anatómica en CBCT, planificación de implantes, detección de estructuras críticas	Detección: conducto mandibular 72.2%, senos 66.4%, dientes ausentes 95.3%; ICC: 0.995–0.996; diferencias no significativas en altura ósea (p>0.05), significativas en grosor (p<0.001)
Lee et al. (2020)	Desarrollo y evaluación diagnóstica	DCNN automatizada (Neuro-T)	Clasificación de sistemas de implantes dentales (DIS), apoyo diagnóstico	AUC: 0.954; Youden: 0.808; Sens: 0.955; Esp: 0.853; AUC por implante hasta 0.981
Eschert et al. (2022)	Observacional transversal	CNN	Diagnóstico asistido, planificación, predicción de supervivencia, CAD/CAM	Desempeño reportado cualitativamente, destacando valores altos
Benakatti et al.(2025)	Desarrollo y evaluación diagnóstica	DETR (CNN + Transformer)	Identificación de implantes, odontología forense, seguimiento clínico	Precision: 0.83; Recall: 0.89; F1: 0.82; AUC-PR: 0.96
Khairkar et al. (2025)	Desarrollo y evaluación diagnóstica	YOLOv8, YOLOv9, YOLOv10	Clasificación automática de implantes, planificación y seguimiento	YOLOv10: Accuracy 97.1%, Precision 96.5%, Recall 95.9%, F1 96.2%, AUC 0.98
Binaljadm et al. (2025)	Observacional transversal	LLMs (GPT-3.5, Gemini, Copilot)	Educación del paciente, soporte clínico, acceso a información	Validez: 80% (GPT/Copilot); α : 0.859–1.00; variabilidad en calidad y errores
Khan et al. (2025)	Desarrollo y evaluación diagnóstica	CNN	Clasificación de implantes, detección de periimplantitis	Accuracy: 97.2%; Sens: 96.3%; Esp: 98.0%; AUC: 0.94
Şişman & Acar (2025)	Observacional transversal	ChatGPT 3.5, Claude	Soporte clínico, triage, educación médica	Precisión: 92–95%; calidad de la respuesta: hasta 89%; completitud: 86–95%
Balel et al. (2025)	Desarrollo y evaluación diagnóstica	CNN + YOLOv8	Detección y numeración de implantes	Precision: 91.4%; Recall: 90.5%; F1: 93.1%; mAP50: 0.943
Park et al. (2023)	Desarrollo y evaluación diagnóstica	CNN	Clasificación de implantes, diagnóstico radiográfico	Accuracy: 88.53%; Precision: 85.7%; Recall: 82.3%; AUC: 0.885

Autor	Tipo de estudio	Modelo de IA	Aplicaciones clínicas	Métricas y desempeño
Hassan et al. (2023)	Desarrollo y evaluación diagnóstica	YOLOv8m-seg	Identificación de implantes en radiografías	Precision: 0.919; Recall: 0.98; F1: 0.95; mAP: 0.972
Alotaibi et al. (2025)	Desarrollo y evaluación diagnóstica	CNN + YOLOv11 (2 etapas)	Planificación automática de implantes en CBCT	F1: 0.59; mAP50: 0.56; MAE: 11.9–15.9 px; Accuracy hasta 76%
Akpınar (2025)	Observacional transversal	LLMs (ChatGPT, MediSearch, OpenEvidence)	Diagnóstico, educación, planificación	Precisión: >90% identificación; oseointegración: 62.4–80.5%
Neychev et al. (2024)	Ensayo clínico Aleatorizado	ANN	Predicción de dolor postoperatorio	Accuracy: 92.6%; Loss: 5.6e-03 (train), 0.23 (val)
Kibcak et al. (2025)	Desarrollo y evaluación diagnóstica	U-Net + AlexNet	Segmentación y detección de periimplantitis	U-Net: Accuracy 0.999, Dice 0.986; AlexNet: F1 0.835
Nambiar & Nanjundegowda (2025)	Desarrollo y evaluación diagnóstica	Mask R-CNN + ResNet-101	Segmentación y numeración dental	Precision: 0.9566; Recall: 0.9635; mAP: 0.9241; Dice: 0.92
Terzi et al. (2025)	Observacional transversal	ChatGPT	Educación al paciente, soporte informativo	DISCERN aprox. 43–47; GQS: 3.15–3.25 (calidad moderada)
Degidi et al. (2025)	Desarrollo y evaluación diagnóstica	CNN	Evaluación de carga inmediata, diagnóstico	Sens: 90.49%; Esp: 96.26%; AUC: 0.934
Ariji et al. (2025)	Desarrollo y evaluación diagnóstica	YOLOv7 + EfficientNet	Detección y clasificación de implantes	Recall: 1.000; Precision: 0.979; F1: 0.989; AUC hasta 1.000

Nota. DCNN: Deep Convolutional Neural Network; CNN: Convolutional Neural Network; ANN: Artificial Neural Network; YOLO: You Only Look Once; DETR: DEtection TRansformer; LLM: Large Language Model; CBCT: Cone Beam Computed Tomography; AUC: Area Under the Curve; ICC: Intraclass Correlation Coefficient; mAP: mean Average Precision; IoU: Intersection over Union; F1-score: Media armónica entre precisión y recall; MAE: Mean Absolute Error; PPV / NPV: Valor predictivo positivo / negativo; DISCERN / GQS: escalas de calidad de información en salud

Los hallazgos evidencian un predominio de los modelos de aprendizaje profundo basados en imágenes, particularmente redes neuronales convolucionales (CNN) y sus variantes, los cuales son ampliamente utilizados para tareas de segmentación, clasificación y diagnóstico en imágenes radiográficas como CBCT y panorámicas. Estas arquitecturas constituyen el núcleo de aplicaciones clínicas relacionadas con la planificación implantológica, la detección de patologías y la automatización del análisis radiográfico.

Asimismo, los modelos de detección de objetos (YOLO) y arquitecturas híbridas como DETR han sido aplicados para la identificación y clasificación automatizada de implantes dentales, destacándose por su capacidad para procesar múltiples objetos simultáneamente y mejorar la eficiencia clínica. Además, los modelos de lenguaje (LLMs) representan una línea emergente con aplicaciones principalmente orientadas a la interacción clínica, la educación del paciente y el soporte en la toma de decisiones. Aunque su uso en tareas diagnósticas directas es aún complementario, su integración en flujos clínicos sugiere un potencial creciente en la práctica odontológica.

Limitaciones de los modelos de IA

a) *Limitaciones relacionadas con los datos*

La insuficiencia y falta de diversidad de los conjuntos de datos comprometen la capacidad de generalización de los modelos. Tamaños muestrales reducidos, datos provenientes de un solo centro y una representación limitada de tipos de implantes o condiciones clínicas restringen la aplicabilidad real (Alotaibi et al., 2025; Balel et al., 2025; Hassan et al., 2023; Lee et al., 2020; Neychev et al., 2024; W. Park et al., 2023). Además, la distribución desigual de clases y la escasez de datos para implantes menos frecuentes influyen en el rendimiento de los modelos (Ariji et al., 2025; W. Park et al., 2023). La dependencia de conjuntos de datos (datasets) privados o de acceso restringido limita la reproducibilidad y validación externa, dificultando su adopción clínica (Khairkar et al., 2025).

b) *Limitaciones técnicas y de desempeño*

Los modelos exhiben errores en tareas críticas como segmentación, detección y clasificación, particularmente en condiciones complejas o con variabilidad anatómica, como discrepancias significativas en mediciones óseas (Kurt Bayrakdar et al., 2021). Asimismo, la presencia de artefactos, superposición anatómica y variabilidad en la calidad de las imágenes radiográficas aumenta la probabilidad de falsos positivos o negativos (Ariji et al., 2025; Khan et al., 2025; Kibcak et al., 2025). Persisten problemas de sobreajuste, baja generalización y disminución del rendimiento en escenarios con múltiples clases o diferencias morfológicas sutiles, incluso en modelos avanzados (Ariji et al., 2025; Benakatti et al., 2025; Khairkar et al., 2025).

c) *Limitaciones clínicas y de aplicabilidad*

Muchos modelos no han sido validados en entornos clínicos reales, lo que limita su implementación (Alotaibi et al., 2025; Nambiar & Nanjundegowda, 2025). Además, el enfoque exclusivamente en datos radiográficos de varios modelos ignora variables clínicas relevantes, lo que restringe la capacidad de realizar diagnósticos holísticos (Khan et al., 2025). La IA no sustituye el juicio clínico, sino que actúa como herramienta complementaria; sin embargo, la dependencia de evaluaciones subjetivas humanas para el entrenamiento también introduce sesgos potenciales en los modelos (Degidi et al., 2025; Khan et al., 2025).

d) Limitaciones específicas de modelos de lenguaje (LLMs)

Se reportó la generación de respuestas inexactas, incompletas o no verificables en consultas clínicas complejas (Binaljadm et al., 2025; Akpınar, 2025). La variabilidad en las respuestas y la falta de consistencia entre interacciones afectan la confiabilidad para uso clínico (Şişman & Acar, 2025; Terzi et al., 2025). Además, la ausencia de referencias verificables y la limitada capacidad para adaptarse a contextos clínicos individuales también restringen su utilidad en la toma de decisiones médicas (Binaljadm et al., 2025).

Desafíos en la implementación de modelos de IA**a) Disponibilidad, calidad y estandarización de datos**

Se reportó la generación de respuestas inexactas, incompletas o no verificables en consultas clínicas complejas (Binaljadm et al., 2025; Akpınar, 2025). La variabilidad en las respuestas y la falta de consistencia entre interacciones afectan la confiabilidad para uso clínico (Şişman & Acar, 2025; Terzi et al., 2025). Además, la ausencia de referencias verificables y la limitada capacidad para adaptarse a contextos clínicos individuales también restringen su utilidad en la toma de decisiones médicas (Binaljadm et al., 2025).

b) Generalización y robustez del modelo

La alta variabilidad anatómica, clínica y radiográfica dificulta la adaptación a diferentes poblaciones y escenarios clínicos (Alotaibi et al., 2025; Khan et al., 2025). La identificación precisa de múltiples implantes y estructuras con características similares, así como la validación multicéntrica en condiciones reales, constituyen retos significativos (Ariji et al., 2025; Hassan et al., 2023; Degidi et al., 2025; Nambiar & Nanjundegowda, 2025).

c) Integración en la práctica clínica

La incorporación de la IA en entornos clínicos requiere superar barreras relacionadas con la interoperabilidad con sistemas existentes, la adaptación de los flujos de trabajo y la usabilidad para los profesionales (Balel et al., 2025; Kurt Bayrakdar et al., 2021; Kibcak et al., 2025). Además, los modelos deben equilibrar precisión y eficiencia computacional para no afectar la carga de trabajo clínica ni los tiempos de atención (Hassan et al., 2023; Khairkar et al., 2025).

d) Interpretabilidad, confianza y adopción

La falta de transparencia de los modelos (*black box*) dificulta la interpretación de los resultados y limita la confianza de los profesionales en su uso clínico (Neychev et al., 2024). La resistencia al cambio, la falta de formación y las percepciones erróneas sobre la IA constituyen barreras importantes para su adopción (Eschert et al., 2022). Por tanto, es necesario capacitar y promover una integración colaborativa entre humanos y sistemas inteligentes (Degidi et al., 2025).

e) Aspectos éticos, legales y regulatorios

Los desafíos relacionados con la privacidad, la responsabilidad legal y la regulación (Akpınar, 2025; Eschert et al., 2022) evidencian la necesidad de establecer marcos éticos claros, que definan la responsabilidad ante errores y garanticen la protección del paciente (Binaljadm et al., 2025).

f) *Desafíos computacionales y técnicos*

Los modelos de IA requieren altos recursos computacionales, optimización de hiperparámetros y arquitecturas complejas, lo cual dificulta su adopción en entornos clínicos con recursos restringidos (Benakatti et al., 2025; Kibcak et al., 2025). El equilibrio entre precisión, velocidad y eficiencia continúa siendo un desafío clave para garantizar su aplicabilidad en la práctica diaria (Hassan et al., 2023).

4. Discusión

El presente estudio analizó de manera sistemática la evidencia disponible sobre los modelos de inteligencia artificial aplicados en cirugía dental e implantología, con el fin de identificar sus principales aplicaciones clínicas, evaluar su desempeño diagnóstico y examinar críticamente sus limitaciones y desafíos de implementación.

Los estudios incluidos coinciden en destacar el alto potencial de los modelos basados en aprendizaje profundo (*deep learning*) para mejorar la precisión diagnóstica y la eficiencia clínica. En particular, modelos como DCNN y CNN han demostrado ser herramientas efectivas para la segmentación anatómica y la planificación implantológica, facilitando la identificación de estructuras críticas y optimizando el proceso clínico (Kurt Bayrakdar et al., 2021; Khan et al., 2025). Asimismo, diversos autores concluyen que estos modelos pueden igualar o incluso superar el rendimiento de profesionales humanos en tareas específicas, como la clasificación de sistemas de implantes dentales, lo que refuerza su valor como herramientas de apoyo clínico (Lee et al., 2020; Park et al., 2023).

En relación con modelos más avanzados, como YOLO y arquitecturas híbridas, se observa un consenso en cuanto a su alta precisión y capacidad para automatizar tareas complejas en tiempo reducido. Estas arquitecturas permiten una identificación rápida y precisa de implantes, reduciendo la carga de trabajo clínico y mejorando la toma de decisiones (Balel et al., 2025; Hassan et al., 2023; Khairkar et al., 2025). No obstante, estos resultados deben interpretarse con cautela, ya que la mayoría de los estudios se desarrollaron en entornos controlados, lo que limita la extrapolación de sus resultados a la práctica clínica real. En este sentido, los autores coinciden en la necesidad de ampliar los conjuntos de datos y validar los modelos en escenarios clínicos reales para garantizar su robustez.

Por otro lado, los LLMs muestran un enfoque distinto, centrado en la interacción clínica y la educación del paciente. Si bien estos modelos presentan un desempeño adecuado en términos de generación de información, los autores destacan que su uso debe ser supervisado debido a limitaciones en precisión, consistencia y profundidad clínica (Akpınar, 2025; Binaljadm et al., 2025; Şişman & Acar, 2025; Terzi et al., 2025). En este contexto, su rol actual se orienta principalmente al apoyo informativo más que a la toma de decisiones clínicas directas, lo que delimita su aplicabilidad en entornos clínicos complejos. En general, existe acuerdo en que la IA debe ser considerada como una herramienta complementaria y no sustitutiva del juicio clínico, destacando la necesidad de regulación, validación y formación profesional para su adecuada integración (Degidi et al., 2025; Eschert et al., 2022).

Los hallazgos de este estudio son consistentes con revisiones sistemáticas recientes que reportan un uso predominante de algoritmos de aprendizaje profundo en implantología, especialmente en tareas de diagnóstico, planificación y predicción de resultados clínicos (Vázquez-Sebrango et al., 2025). Asimismo, se ha documentado que estos modelos pueden alcanzar altos niveles de precisión y mejorar la eficiencia clínica, lo cual coincide con la evidencia sintetizada en la presente revisión (Sowmiya et al., 2025).

En términos de desempeño diagnóstico, Zhu et al. (2023) reportaron que los modelos de IA alcanzan niveles comparables o incluso superiores a los de expertos humanos en la interpretación de imágenes

dentales, con valores de AUC superiores al 96% y mejoras significativas en sensibilidad diagnóstica. Estos hallazgos respaldan los resultados obtenidos en este estudio, donde múltiples modelos alcanzaron métricas elevadas en tareas específicas.

Sin embargo, la literatura también coincide en señalar importantes limitaciones relacionadas con la calidad de los datos, la falta de estandarización y la necesidad de validación clínica. A pesar de su alto desempeño, los modelos actuales no deben considerarse herramientas autónomas, debido a limitaciones en tareas como la medición de estructuras óseas y la predicción de resultados clínicos (Emami & Shirani, 2025). Esta observación es coherente con los resultados de la presente revisión, en los cuales se identificaron limitaciones similares en la precisión de ciertas mediciones y en la capacidad de generalización de los modelos.

Finalmente, se enfatiza la necesidad de avanzar hacia enfoques multimodales que integren datos clínicos e imágenes para mejorar la precisión diagnóstica y la toma de decisiones clínicas (Mohammadi et al., 2025). Asimismo, se ha evidenciado que la complejidad de las imágenes dentales y la variabilidad anatómica representan desafíos importantes para los modelos actuales, lo que refuerza la necesidad de desarrollar modelos más robustos, interpretables y clínicamente validados, en concordancia con las limitaciones identificadas en esta revisión (Panetta et al., 2022).

Limitaciones y trabajo a futuro

Este estudio presenta algunas limitaciones que deben ser consideradas. La heterogeneidad metodológica de los estudios incluidos, particularmente en términos de métricas de evaluación y diseños experimentales, dificultó la comparación directa entre modelos. Asimismo, la ausencia de estudios comparativos con métodos clínicos tradicionales limitó la posibilidad de establecer conclusiones definitivas sobre la superioridad de la IA. Finalmente, la dependencia de datos reportados en estudios individuales podría introducir sesgos asociados a la calidad y representatividad de los conjuntos de datos utilizados.

En cuanto a futuras investigaciones, se destaca la necesidad de desarrollar estudios multicéntricos con conjuntos de datos más amplios y diversos, así como avanzar hacia modelos multimodales que integren información clínica y radiográfica. Asimismo, resulta fundamental establecer estándares de validación, regulación y transparencia algorítmica, que permitan garantizar la seguridad, confiabilidad y aplicabilidad de estas tecnologías en la práctica clínica real.

5. Conclusiones

Los modelos de inteligencia artificial más utilizados en cirugía dental e implantología corresponden principalmente a arquitecturas de aprendizaje profundo (*deep learning*), destacando las redes neuronales convolucionales y sus variantes, así como modelos de detección de objetos como YOLO y enfoques híbridos como DETR. Estos modelos se aplican predominantemente en el análisis de imágenes radiográficas, con aplicaciones clínicas centradas en la segmentación anatómica, la clasificación de sistemas de implantes, la detección de patologías periimplantarias y la planificación implantológica. Adicionalmente, los modelos de lenguaje de gran escala (LLMs) emergen como herramientas complementarias, orientadas a la educación del paciente, el soporte en la toma de decisiones y la optimización del flujo de trabajo clínico.

En términos de desempeño, estos modelos muestran altos niveles de precisión diagnóstica, evidenciados mediante métricas como *accuracy*, *precision*, *recall*, *F1-score* y *AUC*, que en la mayoría de los estudios alcanzan o superan valores del 90%, especialmente en tareas de clasificación, detección y

segmentación de estructuras e implantes dentales. En este sentido, la inteligencia artificial puede igualar o incluso superar el rendimiento de los profesionales clínicos en tareas específicas, contribuyendo a mejorar la precisión diagnóstica y a reducir la variabilidad interobservador.

No obstante, la evidencia analizada pone de manifiesto limitaciones relevantes relacionadas con la disponibilidad, calidad y representatividad de los datos, así como con restricciones técnicas en el desempeño de los modelos, particularmente en condiciones clínicas complejas. Asimismo, persiste una limitada validación en entornos clínicos reales, junto con la falta de integración de variables clínicas y la necesidad de supervisión profesional, lo que restringe su adopción como herramientas autónomas.

En cuanto a los desafíos, se identifica la necesidad de avanzar hacia el desarrollo de conjuntos de datos multicéntricos, estandarizados y de alta calidad, mejorar la capacidad de generalización y robustez de los modelos, facilitar su integración en los flujos de trabajo clínicos y establecer marcos éticos, legales y regulatorios claros que garanticen un uso seguro y responsable de la inteligencia artificial en la práctica odontológica.

En conjunto, los hallazgos de esta revisión confirman que la inteligencia artificial representa una herramienta prometedora para la optimización del diagnóstico y la planificación en implantología dental; sin embargo, su implementación clínica efectiva dependerá del fortalecimiento de la evidencia, la validación en escenarios reales y la integración adecuada con el juicio clínico profesional.

Referencias

- Akpınar, H. (2025). Comparison of responses from different artificial intelligence-powered chatbots regarding the All-on-four dental implant concept. *BMC Oral Health*, 25, 922. <https://doi.org/10.1186/s12903-025-06294-7>
- Alharbi, M., & Almutiq, M. (2022). Prediction of dental implants using machine learning algorithms. *Journal of Healthcare Engineering*, 2022(1), 7307675. <https://doi.org/10.1155/2022/7307675>
- Alotaibi, S., Alsomali, M., Alghamdi, S., Alfadda, S., Alturaiki, I., Al-Ekrish, A., & Altwaijry, N. (2025). Automatic placement of simulated dental implants within CBCT images in optimum positions: A deep learning model. *Medical & Biological Engineering & Computing*, 63(8), 2325–2339. <https://doi.org/10.1007/s11517-025-03327-9>
- Ariji, Y., Kusano, K., Fukuda, M., Wakata, Y., Nozawa, M., Kotaki, S., Ariji, E., & Baba, S. (2025). Two-step deep learning models for detection and identification of the manufacturers and types of dental implants on panoramic radiographs. *Odontology*, 113(2), 788–798. <https://doi.org/10.1007/s10266-024-00989-z>
- Balch, J., Shickel, B., Bihorac, A., Upchurch, G., & Loftus, T. (2024). Integration of AI in surgical decision support: Improving clinical judgment. *Global Surgical Education - Journal of the Association for Surgical Education*, 3(1), 56. <https://doi.org/10.1007/s44186-024-00257-2>
- Balel, Y., Sağtaş, K., Teke, F., & Kurt, M. (2025). Artificial intelligence-based detection and numbering of dental implants on panoramic radiographs. *Clinical Implant Dentistry and Related Research*, 27(1), e70000. <https://doi.org/10.1111/cid.70000>
- Kurt Bayrakdar, S., Orhan, K., Bayrakdar, I., Bilgir, E., Ezhov, M., Gusarev, M., & Shumilov, E. (2021). A deep learning approach for dental implant planning in cone-beam computed tomography images. *BMC Medical Imaging*, 21, 86. <https://doi.org/10.1186/s12880-021-00618-z>

- Benakatti, V., Nayakar, R., Anandhalli, M., & Sukhasare, R. (2025). Advanced deep learning techniques for recognition of dental implants. *Journal of Oral Biology and Craniofacial Research*, 15(2), 215–220. <https://doi.org/10.1016/j.jobcr.2025.01.016>
- Binaljadm, T., Alqutaibi, A., Halboub, E., Zafar, M., & Saker, S. (2025). Artificial intelligence chatbots as sources of implant dentistry information for the public: Validity and reliability assessment. *European Journal of Dentistry*. <https://doi.org/10.1055/s-0045-1809155>
- Degidi, M., Daprile, G., Battelli, F., Caselli, E., Cisternino, L., Greco, A., Palumbo, D., Quasso, F., Rossi, F., Tavelli, C., & Zaccheroni, Z. (2025). The use of an artificial intelligence-driven novel tool for the evaluation of dental implants primary stability and immediate loading feasibility: A multicenter retrospective study. *Journal of Clinical Medicine*, 14(6), 2011. <https://doi.org/10.3390/jcm14062011>
- Emami, M., & Shirani, M. (2025). Application and performance of artificial intelligence in implant dentistry: An umbrella review. *Dentistry Review*, 5(3), 100159. <https://doi.org/10.1016/j.dentre.2025.100159>
- Eschert, T., Schwendicke, F., Krois, J., Bohner, L., Vinayahalingam, S., & Hanisch, M. (2022). A survey on the use of artificial intelligence by clinicians in dentistry and oral and maxillofacial surgery. *Medicina*, 58(8), 1059. <https://doi.org/10.3390/medicina58081059>
- Gómez-Polo, M., Sallorenzo, A., Ortega, R., Barmak, A., Att, W., & Revilla-León, M. (2024). Influence of implant angulation and clinical implant scan body height on the accuracy of complete arch intraoral digital scans. *The Journal of Prosthetic Dentistry*, 131(1), 119–127. <https://doi.org/10.1016/j.prosdent.2021.11.018>
- Gracia, J., Pfang, B., Morales, M., Caramés, C., del Olmo, M., Villegas, M., Short, J., Arcos, J., Álvaro, J., Manzano, F., & Muñoz, L. (2025). Implementing a closed loop clinical decision support system for sustainable preoperative care. *NPJ Digital Medicine*, 8(1), 6. <https://doi.org/10.1038/s41746-024-01371-7>
- Hassan, N., Kamel, A., Omran, A., Gad, M., Muhammad, N., Ahmed, O., & Abdel-Fattah, M. (2023). Automated identification of dental implants: A new, fast and accurate artificial intelligence system. *The European Journal of Prosthodontics and Restorative Dentistry*, 32. https://doi.org/10.1922/EJPRD_2620Hassan06
- Khairkar, A., Kadam, S., Kadam, P., & Deshpande, S. (2025). Advancing dental implant classification through YOLO-based deep learning models. *International Journal of Information Technology*. <https://doi.org/10.1007/s41870-025-02885-3>
- Khan, G., Aaliyah, S., Pal, S., Tiwari, R., Smitha M., Dixit, H., Prashant M., & Ali, T. (2025). Artificial intelligence for dental implant classification and peri-implant disease detection: A clinical study. *Bioinformation*, 21(8), 2361–2364. <https://doi.org/10.6026/973206300212361>
- Kibcak, E., Buhara, O., Temelci, A., Akkaya, N., Ünsal, G., & Minervini, G. (2025). Deep learning-driven segmentation of dental implants and peri-implantitis detection in orthopantomographs: A novel diagnostic tool. *Journal of Evidence-Based Dental Practice*, 25(1), 102058. <https://doi.org/10.1016/j.jebdp.2024.102058>
- Krishnan, D. (2022). Artificial intelligence in oral and maxillofacial surgery education. *Oral and Maxillofacial Surgery Clinics of North America*, 34(4), 585–591. <https://doi.org/10.1016/j.coms.2022.03.006>

- Lee, J., Kim, Y., Lee, J., & Jeong, S. (2020). A performance comparison between automated deep learning and dental professionals in classification of dental implant systems from dental imaging: A multi-center study. *Diagnostics*, 10(11), 910. <https://doi.org/10.3390/diagnostics10110910>
- Lubbad, M., Kurtulus, I., Karaboga, D., Kilic, K., Basturk, A., Akay, B., Nalbantoglu, O., Yilmaz, O., Ayata, M., Yilmaz, S., & Pacal, I. (2024). A comparative analysis of deep learning-based approaches for classifying dental implants decision support system. *Journal of Imaging Informatics in Medicine*, 37(5), 2559–2580. <https://doi.org/10.1007/s10278-024-01086-x>
- Miragall, M., Knoedler, S., Kauke-Navarro, M., Saadoun, R., Grabenhorst, A., Grill, F., Ritschl, L., Fichter, A., Safi, A., & Knoedler, L. (2023). Face the future—Artificial intelligence in oral and maxillofacial surgery. *Journal of Clinical Medicine*, 12(21). <https://doi.org/10.3390/jcm12216843>
- Mohammadi, H., Soleymanpourshamsi, T., & Amirfarhangi, S. (2025). Artificial intelligence in dental implant prognosis: A narrative review of predictive models, performance, and clinical potential. *Open Access Research Journal of Biology and Pharmacy*, 15(1), 48–54. <https://doi.org/10.53022/oarjbp.2025.15.1.0043>
- Morris, M., Fiocco, D., Caneva, T., Yiapanis, P., & Orgill, D. (2024). Current and future applications of artificial intelligence in surgery: Implications for clinical practice and research. *Frontiers in Surgery*, 11. <https://doi.org/10.3389/fsurg.2024.1393898>
- Nambiar, R., & Nanjundegowda, R. (2025). Detection of missing tooth regions using deep learning in panoramic radiographs for dental implant planning. *Engineering, Technology & Applied Science Research*, 15(5), 28071–28076. <https://doi.org/10.48084/etasr.13101>
- Neychev, D., Raycheva, R., & Kafadarova, N. (2024). Deep learning in oral surgery for third molar extraction: Empirical evidence and original model. *Biotechnology & Biotechnological Equipment*, 38(1), 2349564. <https://doi.org/10.1080/13102818.2024.2349564>
- Page, M., McKenzie, J., Bossuyt, P., Boutron, I., Hoffmann, T., Mulrow, C., Shamseer, L., Tetzlaff, J. M., Akl, E., Brennan, S., Chou, R., Glanville, J., Grimshaw, J., Hróbjartsson, A., Lalu, M., Li, T., Loder, E., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>
- Panetta, K., Rajendran, R., Ramesh, A., Rao, S., & Agaian, S. (2022). Tufts dental database: A multimodal panoramic X-ray dataset for benchmarking diagnostic systems. *IEEE Journal of Biomedical and Health Informatics*, 26(4), 1650–1659. <https://doi.org/10.1109/JBHI.2021.3117575>
- Park, J., Lee, J., Moon, S., & Lee, K. (2022). Deep learning-based detection of missing tooth regions for dental implant planning in panoramic radiographic images. *Applied Sciences*, 12(3). <https://doi.org/10.3390/app12031595>
- Park, W., Huh, J., & Lee, J. (2023). Automated deep learning for classification of dental implant radiographs using a large multi-center dataset. *Scientific Reports*, 13(1), 4862. <https://doi.org/10.1038/s41598-023-32118-1>
- Revilla-León, M., Gómez-Polo, M., Vyas, S., Barmak, B., Galluci, G., Att, W., & Krishnamurthy, V. (2023). Artificial intelligence applications in implant dentistry: A systematic review. *The Journal of Prosthetic Dentistry*, 129(2), 293–300. <https://doi.org/10.1016/j.prosdent.2021.05.008>

- Saeed, A., Alkhurays, M., AlMutlaqah, M., AlAzbah, M., & Alajlan, S. A. (2023). Future of using robotic and artificial intelligence in implant dentistry. *Cureus*, 15(8), e43209. <https://doi.org/10.7759/cureus.43209>
- Şişman, A., & Acar, A. (2025). Artificial intelligence-based chatbot assistance in clinical decision-making for medically complex patients in oral surgery: A comparative study. *BMC Oral Health*, 25(1), 351. <https://doi.org/10.1186/s12903-025-05732-w>
- Sitaras, S., Tsolakis, I., Gelsini, M., Tsolakis, A., Schwendicke, F., Wolf, T., & Perlea, P. (2025). Applications of artificial intelligence in dental medicine: A critical review. *International Dental Journal*, 75(2), 474–486. <https://doi.org/10.1016/j.identj.2024.11.009>
- Sowmiya, S., Sridharan, R., Indirajith, S. S., Jeyakumar, E., & Leoney, A. (2025). Artificial intelligence-driven advancements in dental implants: A narrative review. *International Journal of Dental Materials*, 7(4), 120–124. <https://doi.org/10.37983/IJDM.2025.7403>
- Terzi, M., Yavuz, M., Bicer, T., & Buyuk, S. K. (2025). Evaluation of artificial intelligence robot's knowledge and reliability on dental implants and peri-implant phenotype. *Scientific Reports*, 15(1), 9519. <https://doi.org/10.1038/s41598-025-94576-z>
- Vázquez-Sebrango, G., Anitua, E., Macía, I., & Arganda-Carreras, I. (2025). The role of artificial intelligence in implant dentistry: A systematic review. *International Journal of Oral and Maxillofacial Surgery*, 54(11), 1098–1122. <https://doi.org/10.1016/j.ijom.2025.04.005>
- Zhu, J., Chen, Z., Zhao, J., Yu, Y., Li, X., Shi, K., Zhang, F., Yu, F., Shi, K., Sun, Z., Lin, N., & Zheng, Y. (2023). Artificial intelligence in the diagnosis of dental diseases on panoramic radiographs: A preliminary study. *BMC Oral Health*, 23(1), 358. <https://doi.org/10.1186/s12903-023-03027-6>

Transparencia

Conflicto de interés

Los autores declaran que no existen conflictos de interés de naturaleza alguna como parte de la presente investigación.

Fuente de financiamiento

Los autores financiaron completamente la investigación.

Contribución de autoría

Adrián Sebastián Realpe Flores: Conceptualización, software, validación, análisis formal, investigación, gestión de datos, redacción - preparación del borrador original, redacción - revisión y edición, financiamiento, administración del proyecto, recursos, supervisión.

Solange Daniela Chávez Jaramillo: Conceptualización, metodología, validación, análisis formal, investigación, gestión de datos, redacción - preparación del borrador original, redacción - revisión y edición, financiamiento, recursos, supervisión.

Maritza Mishell Alarcón Mugmal: Conceptualización, metodología, software, análisis formal, investigación, gestión de datos, visualización, redacción - preparación del borrador original, redacción - revisión y edición, financiamiento, recursos.

Carlos Elián Coque Bastidas: Conceptualización, análisis formal, investigación, visualización, redacción - preparación del borrador original, redacción - revisión y edición, financiamiento, recursos.

Los autores contribuyeron activamente en el análisis de los resultados, revisión y aprobación del manuscrito final.