



PREDIÇÃO DE FALHAS EM IMPLANTES DENTÁRIOS USANDO MODELOS DE APRENDIZADO DE MÁQUINA: UMA REVISÃO INTEGRATIVA

DENTAL IMPLANT FAILURE PREDICTION USING MACHINE LEARNING
MODELS: AN INTEGRATIVE REVIEW

PREDICCIÓN DE FALLOS DE IMPLANTES DENTALES MEDIANTE MODELOS
DE APRENDIZAJE AUTOMÁTICO: UNA REVISIÓN INTEGRAL

Rafaela Santana Freitas Monteiro¹, Nathalia Seimi Deama², Maria Eduarda de Moura Silva Albuquerque³, Manoela Sobreira Pereira Clementino⁴, Eloiza Leonardo de Melo⁵, Maria Regina Almeida de Menezes⁶, Mateus Fernando Souza Leite⁷, Rômulo Henrique Moura do Monte dos Santos⁸, Marleny Elizabeth Márquez de Martínez Gerbi⁹

DOI: 10.54899/dcs.v22i81.3012

Recibido: 7/7/2025 | Aceptado: 8/7/2025 | Publicación en línea: 28/7/2025.

RESUMO

Apesar da elevada taxa de sucesso dos implantes dentários, suas falhas ainda representam um desafio clínico. Fatores como condições do paciente, do implante, técnica cirúrgica e componentes protéticos estão associados às falhas quando analisados por métodos estatísticos convencionais, que, no entanto, possuem limitações diante de interações complexas. A inteligência artificial (IA), por meio de modelos de aprendizado de máquina (AM), surge como alternativa promissora para prever falhas, complicações e prognósticos, favorecendo um planejamento mais individualizado e eficiente. Este estudo realizou uma revisão integrativa da literatura publicada entre 2018 e 2025, a busca nas bases de dados resultou em 2.459 registros, sendo 27 estudos incluídos após triagem e análise completa, conforme o diagrama PRISMA adaptado. Os modelos mais frequentes foram redes neurais profundas (48%), random forest (30%) e máquinas de vetores de suporte (22%). As principais variáveis de entrada incluíram características do implante (100%), dados demográficos dos pacientes (85%) e fatores clínicos

¹ Graduanda em Odontologia, Universidade de Pernambuco (UPE), Recife, Pernambuco, Brasil.

E-mail: rafaelasantanafm@gmail.com Orcid: <https://orcid.org/0000-0002-7525-0528>

² Especialista em Prótese Dentária e Implante Dentário, Universidade de Pernambuco (UPE), Recife, Pernambuco, Brasil. E-mail: nathalia.seimi@upe.br Orcid: <https://orcid.org/0000-0002-5327-7084>

³ Graduanda em Odontologia, Universidade de Pernambuco (UPE), Recife, Pernambuco, Brasil.

E-mail: mariaeduardamsa2@gmail.com Orcid: <https://orcid.org/0000-0001-6900-3232>

⁴ Graduanda em Odontologia, Universidade de Pernambuco (UPE), Recife, Pernambuco, Brasil.

E-mail: mano.ela06@hotmail.com Orcid: <https://orcid.org/0000-0003-4076-7954>

⁵ Doutora em Dentística, Universidade de Pernambuco (UPE), Recife, Pernambuco, Brasil.

E-mail: eloiza.melo@servidor.uepb.edu.br Orcid: <https://orcid.org/0000-0001-5845-1478>

⁶ Doutora em Odontologia, Universidade de Pernambuco (UPE), Recife, Pernambuco, Brasil.

E-mail: regina.menezes@upe.br Orcid: <https://orcid.org/0000-0003-3012-3979>

⁷ Graduando em Odontologia, Universidade de Pernambuco (UPE), Recife, Pernambuco, Brasil.

E-mail: mateus15.fsl@gmail.com Orcid: <https://orcid.org/0000-0003-3448-6646>

⁸ Graduando em Odontologia, Universidade de Pernambuco (UPE), Recife, Pernambuco, Brasil.

E-mail: romulo.henrique.moura@gmail.com Orcid: <https://orcid.org/0009-0005-7607-7631>

⁹ Doutora em Laser em Odontologia, Universidade Federal da Bahia (UFBA), Salvador, Bahia, Brasil.

E-mail: marleny.gerbi@upe.com Orcid: <https://orcid.org/0000-0001-9174-2541>

(78%). As métricas de desempenho variaram entre 70% e 96,13%, com destaque para modelos com AUROC acima de 0,90 na predição de falhas e superior a 0,97 na detecção de peri-implantite. No entanto, limitações relevantes foram observadas, como a baixa taxa de validação externa, heterogeneidade metodológica e ausência de padronização dos desfechos. Conclui-se que os modelos de ML demonstram desempenho promissor na predição de falhas em implantes dentários, embora haja necessidade de estudos multicêntricos com validação externa, maior padronização e foco na aplicação clínica, a fim de viabilizar sua incorporação prática na odontologia.

Palavras-chave: Implantes Dentários. Aprendizado de Máquina. Inteligência Artificial. Predição de Falha. Prognóstico.

ABSTRACT

Despite the high success rate of dental implants, their failures remain a clinical challenge. Factors such as patient conditions, implant characteristics, surgical techniques, and prosthetic components are commonly associated with implant failures when analyzed using conventional statistical methods, which have limitations in addressing complex interactions. Artificial intelligence (AI), through machine learning (ML) models, has emerged as a promising alternative for predicting failures, complications, and prognoses, enabling more individualized and efficient treatment planning. This study conducted an integrative review of the literature published between 2018 and 2025, identifying 2,459 records across selected databases. After screening and full-text analysis, 27 studies were included according to the PRISMA flowchart. The most frequent models were deep neural networks (48%), random forest (30%), and support vector machines (22%). The most common input variables included implant characteristics (100%), patient demographic data (85%), and clinical factors (78%). Model performance ranged from 70% to 96.13%, with notable AUROC values exceeding 0.90 for failure prediction and above 0.97 for peri-implantitis detection. However, significant limitations were observed, including low rates of external validation, methodological heterogeneity, and lack of outcome standardization. It is concluded that ML models show promising performance in predicting dental implant failures, although multicenter studies with external validation, improved methodological standardization, and greater clinical focus are necessary to enable their effective integration into dental practice.

Keywords: Dental Implants. Machine Learning. Artificial Intelligence. Failure Prediction. Prognosis.

RESUMEN

A pesar de la alta tasa de éxito de los implantes dentales, sus fallos continúan representando un desafío clínico. Factores como las condiciones del paciente, las características del implante, la técnica quirúrgica y los componentes protésicos están comúnmente asociados a estas fallas cuando se analizan mediante métodos estadísticos convencionales, los cuales presentan limitaciones frente a interacciones complejas. La inteligencia artificial (IA), a través de modelos de aprendizaje automático (AA), se presenta como una alternativa prometedora para predecir fallos, complicaciones y pronósticos, permitiendo una planificación terapéutica más individualizada y eficiente. Este estudio realizó una revisión integrativa de la literatura publicada entre 2018 y 2025, identificando 2.459 registros en bases de datos seleccionadas. Tras la criba y el análisis completo de los textos, se incluyeron 27 estudios según el diagrama PRISMA. Los

modelos más frecuentes fueron redes neuronales profundas (48%), random forest (30%) y máquinas de vectores de soporte (22%). Las variables de entrada más comunes incluyeron características del implante (100%), datos demográficos del paciente (85%) y factores clínicos (78%). El rendimiento de los modelos varió entre el 70% y el 96,13%, destacando valores de AUROC superiores a 0,90 para la predicción de fallos y mayores a 0,97 para la detección de periimplantitis. No obstante, se observaron limitaciones importantes, como baja validación externa, heterogeneidad metodológica y falta de estandarización de resultados. Se concluye que los modelos de AA muestran un rendimiento prometedor en la predicción de fallos en implantes dentales, aunque se requieren estudios multicéntricos con validación externa, mayor estandarización metodológica y enfoque clínico para su integración efectiva en la práctica odontológica.

Palabras clave: Implantes Dentales. Aprendizaje Automático. Inteligencia Artificial. Predicción de Falló. Prognóstico.



Esta obra está bajo una [Licencia Creative Commons Atribución- NoComercial 4.0 Internacional](https://creativecommons.org/licenses/by-nc/4.0/)

INTRODUÇÃO

No que tange o contexto da reabilitação protética de pacientes edêntulos, os implantes dentários representam um marco revolucionário por oferecerem tratamentos previsíveis e com elevadas taxas de sucesso, que variam entre 90% e 98% [Buser et al., 2017; Nazari et al., 2025]. Contudo, apesar da previsibilidade clínica, ainda há incidência de falhas, tornando necessário intervenções adicionais, que além de aumentar os custos do tratamento e reduz a satisfação do paciente com o tratamento reabilitador [Chrcanovic et al., 2016]. Tais falhas são classicamente categorizadas em precoces — que ocorrem antes da osseointegração — ou tardias — após o implante ser posto em função — e possuem etiologias multifatoriais, incluindo fatores relacionados ao paciente, ao tipo e dimensões do implante, ao procedimento cirúrgico e ao planejamento protético [Jemt et al., 2017].

A partir de análises estatísticas convencionais presentes na literatura é possível identificar os diversos fatores de risco associados à falha de implantes, como tabagismo, diabetes, histórico de doença periodontal, qualidade óssea local e escolha inadequada do tipo ou dimensão do implante [Moy et al., 2005; Chrcanovic et al., 2015]. Entretanto, tais abordagens apresentam limitações para capturar relações complexas e não lineares entre variáveis clínicas, comprometendo sua capacidade de gerar avaliações de risco personalizadas [Papaspnyridakos et al., 2012].

Nesse cenário, o avanço de técnicas computacionais mais robustas, como o aprendizado de máquina (Machine Learning - ML), tem despertado crescente interesse. O ML é um ramo da inteligência artificial que se baseia em algoritmos capazes de aprender com dados e fazer previsões sem necessidade de programação explícita, permitindo reconhecimento de padrões complexos e modelagem preditiva eficiente [Beam et al., 2018; Rajkomar et al., 2019]. Essas técnicas têm sido amplamente aplicadas com sucesso em diversas áreas da saúde, como diagnóstico de doenças, previsão de prognósticos e avaliação de risco individualizado [Topol et al., 2019; Esteva et al., 2017].

O uso de ML na implantodontia mostra-se cada vez mais promissor na predileção de falhas, essas plataformas de Machine Learning permitem a identificação de pacientes de maior risco levando em consideração fatores de risco como condições sistêmicas e interações medicamentosas, viabilizando assim, intervenções preventivas mais eficazes, ajustes no plano de tratamento e o aprimoramento de estratégias de monitoramento por meio de aprendizado ativo e refinamento de modelo [Lee et al., 2020]. Estudos recentes também demonstram que abordagens assistidas por inteligência artificial têm alcançado altos índices de acurácia, como 93,7% na previsão da estabilidade de implantes com base em tomografias computadorizadas de feixe cônico (TCFC), e até 98% na identificação automática de marcas de implantes em exames radiográficos [Revilla-Léon et al., 2023].

Apesar do crescimento do número de publicações sobre a aplicação de ML na odontologia, ainda há escassez de revisões sistemáticas que explorem especificamente seu uso preditivo na identificação precoce de falhas em implantes dentários [Schwendicke et al., 2020; Chen et al., 2020; Gomes, G. H., et al., 2018]. Essa lacuna de sistematização dificulta uma compreensão abrangente, tanto para clínicos quanto para pesquisadores, sobre o atual estágio de maturidade desses modelos, suas características de entrada (features), desempenho preditivo e principais limitações.

Diante disso, esta revisão sistemática tem como objetivo analisar criticamente as evidências científicas mais recentes sobre a aplicação de algoritmos de aprendizado de máquina na previsão de falhas de implantes dentários. A pergunta norteadora que fundamenta esta investigação é: “Qual é a precisão preditiva de diferentes algoritmos de aprendizado de máquina na identificação precoce de falhas de implantes dentários?”

REFERENCIAL TEÓRICO

Dentre as áreas da odontologia reabilitadora, destaca-se a implantodontia, cujas taxas de sucesso variam entre 90% e 98% [Papasyridakos et al., 2012 & Buser et al., 2017]. Entretanto, apesar desse elevado índice, a ocorrência de falhas em implantes dentários ainda figura como um desafio clínico significativo haja vista, podendo ser classificadas entre precoces, quando ocorrem antes da osseointegração, ou tardias, cujo prejuízo acontece após o carregamento funcional. Ademais, são decorrentes de uma etiologia multifatorial que envolve aspectos relacionados ao paciente, ao implante, à técnica cirúrgica realizada e aos componentes protéticos utilizados [Dhiman et al., 2022 & Nazari et al., 2025].

Tradicionalmente, os fatores de risco mais apontados para análise da falha de implantes têm sido por meio de abordagens estatísticas mais convencionais, que apontam, por exemplo, o tabagismo, diabetes e histórico de doença periodontal como elementos críticos para determinar possíveis falhas em implantes dentários [Chacanovic et al., 2015 & Gomes, G. H., et al., 2018 & Moy et al., 2005]. Entretanto, essas abordagens tradicionais apresentam significativas limitações ao lidar com interações complexas entre variáveis clínicas apresentadas pelos pacientes, somado ao fato de não oferecerem avaliações de risco individualizadas, dificultando a tomada de decisões mais precisas na prática clínica [Papasyridakos et al., 2012 & Christodoulou et al., 2019].

Nesse contexto, o aprendizado de máquina figura como uma alternativa promissora para possibilitar predições individualizadas ao paciente, o que consequentemente diminuiria o número de falhas em implantes dentários a curto e longo prazo. Trata-se de um subconjunto da inteligência artificial capaz de identificar padrões e gerar modelos preditivos a partir de grandes volumes de dados prévios no sistema, sem necessidade de programação explícita [Beam et al., 2018 & Rajkomar et al., 2019]. Modelos utilizando ML já demonstraram alto desempenho em diversas aplicações na variadas áreas médicas através do auxílio no diagnóstico de doenças, análise de imagens, predição de prognósticos e personalização de tratamentos [Esteva et al., 2017 & Topol et al., 2019].

Na área da implantodontia, ML tem se expandido para a análise da previsibilidade de falhas de implantes dentários, utilizando modelos como random forest, support vector machines, redes neurais artificiais e gradient boosting apresentando resultados positivos [Schwendicke et al., 2020 & Jung et al., 2016]. A integração combinada de dados clínicos, imaginológicos e sistêmicos permite aos algoritmos IA alcançarem áreas abaixo da curva ROC (AUROC)

superiores a 0,80, o que indica um poder discriminativo bom. Entretanto, apesar do potencial encorajador, estudos ainda enfrentam desafios como desequilíbrio de classificações, amostras limitadas, validação externa deficiente e, ainda, com a complexidade interpretativa dos modelos ML, conhecida como “caixa-preta”, muito comuns em modelos de redes neurais. [Gerke et al., 2020 & Lundberg et al., 2017].

Para garantir maior rigor metodológico as análises realizadas a partir dos estudos com bases e metodologias heterogêneas, a literatura destaca o uso de ferramentas como o PROBAST (Prediction model Risk Of Bias Assessment Tool) [Collins et al., 2021 & Jemt et al., 2017 & Wolff et al., 2019] que é um mecanismo que vem sendo adaptadas para avaliar o risco de viés em modelos preditivos baseados em Machine Learning, analisando as features de entrada, desequilíbrio de classes, ajuste de hiperparâmetro, overfitting, etc. Além disso, diretrizes como o framework TRIPOD-ML, que avalia o processo realizado pelos autores que utilizam modelos IA (Transparent Reporting of a multivariable prediction model for Individual Prognosis Or Diagnosis for Machine Learning) [Collins et al., 2015 & Dhiman et al., 2022 & Jemt et al., 2017].

Portanto, o avanço do aprendizado de máquina oferece uma nova perspectiva para a predição de falhas em implantes dentários, podendo ampliar a precisão diagnóstica, personalizar condutas clínicas e promover uma odontologia mais preditiva e preventiva. Entretanto, para sua efetiva incorporação à prática clínica, são necessários esforços contínuos em validação externa, interpretabilidade dos modelos e integração aos fluxos de trabalho odontológicos, o que pode exigir o aumento da curva de aprendizagem para usar esta tecnologia (Topol, 2019; Rieke et al., 2020).

METODOLOGIA

Esta revisão integrativa sistematizada da literatura foi conduzida de acordo com os critérios das diretrizes PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) [Page et al., 2021]. Uma busca bibliográfica foi realizada nas bases de dados PubMed/MEDLINE, Embase, Web of Science, IEEE Xplore e Scopus. A estratégia de busca combinou termos relacionados a implantes dentários, falha/complicações e aprendizado de máquina/inteligência artificial. Para estratégia de busca utilizou-se as palavras-chave os termos: “dental implant”, “failure prediction”, “machine learning”, “artificial intelligence”, “deep learning”, “neural network”, “random forest”, “support vector machine”, “ensemble learning”,

“convolutional neural network”, “prognosis”, “outcome prediction”, “peri-implantitis”, “implant survival” e “outcome prediction” com o auxílio dos operadores Booleanos AND e OR durante as pesquisas. A busca cobriu o período de janeiro de 2018 a 2025.

Os estudos foram selecionados com base nos seguintes critérios de inclusão: (1) estudos de pesquisa primária desenvolvendo, validando ou aplicando modelos de aprendizado de máquina para predição de falha de implantes dentários; (2) estudos publicados em periódicos revisados por pares ou anais de conferência; (3) estudos publicados em inglês e em integra; e (4) estudos publicados de 2010 a 2025

Os critérios de exclusão foram: (1) artigos de revisão, relatos de caso, cartas, editoriais ou artigos de opinião; (2) estudos usando apenas métodos estatísticos tradicionais sem componentes de aprendizado de máquina; (3) estudos focando em resultados relacionados a implantes que não a falha; (4) estudos aplicando aprendizado de máquina a outros aspectos da implantodontia não diretamente relacionados à predição de falha; e (5) estudos com detalhes metodológicos insuficientes para avaliar a abordagem de aprendizado de máquina.

A qualidade dos estudos incluídos foi avaliada usando uma versão adaptada da ferramenta PROBAST (Prediction model Risk Of Bias Assessment Tool) [Jemt et al., 2017], que avalia o risco de viés e preocupações de aplicabilidade em quatro domínios: participantes, preditores, desfecho e análise. As modificações incluíram itens adicionais para avaliar a adequação dos métodos de seleção de features, manejo do desbalanceamento de classes e estratégias de validação específicas para modelos de ML.

Adicionalmente, avaliou-se a qualidade do relato dos aspectos de aprendizado de máquina usando itens selecionados da declaração TRIPOD-ML (Transparent Reporting of a multivariable prediction model for Individual Prognosis Or Diagnosis for Machine Learning) [Jensen et al., 2012].

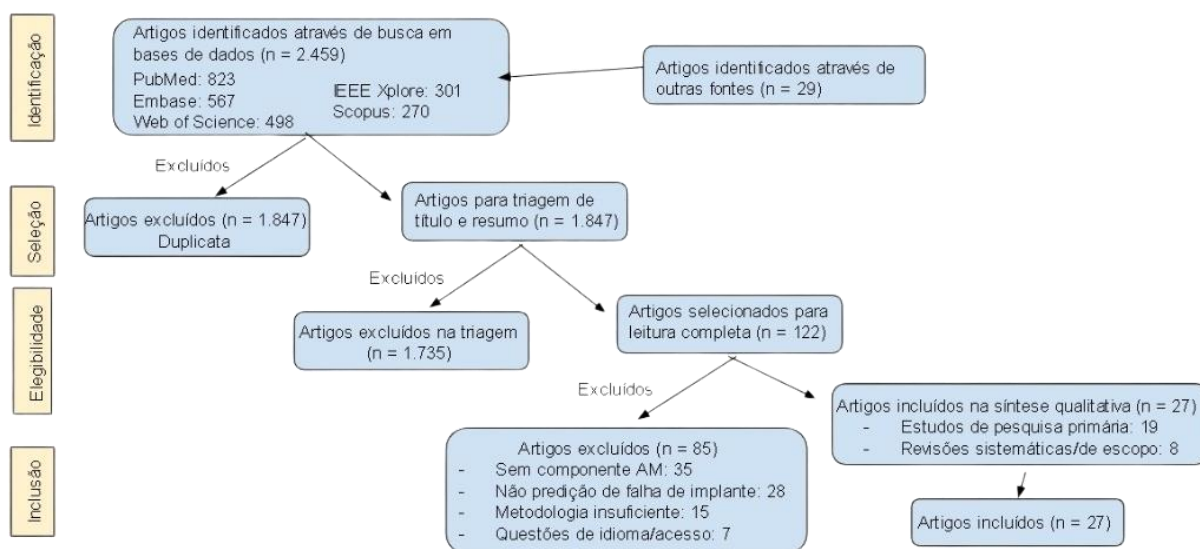
Devido à diversidade nos métodos e resultados dos estudos incluídos, não foi realizada uma meta-análise formal. Em vez disso, os autores optaram por uma síntese narrativa e, quando possível, por análises descritivas das métricas de desempenho dos modelos de machine learning (ML), como AUROC e sensibilidade, por exemplo.. Os dados considerados foram os dos modelos principais ou de melhor desempenho indicados pelos estudos. Fatores como tamanho amostral, estratégia de validação e seleção de variáveis também foram avaliados por seu impacto no desempenho. As análises foram conduzidas com o software R (versão 4.1.2).

RESULTADOS E DISCUSSÕES

Na busca inicial nas bases de dados foram obtidos 2.459 registros. Posteriormente, após análise inicial, removeram-se estudos em duplicatas para que os 1.847 registros remanescentes passaram por uma segunda triagem de leitura de título e resumo, que resultou em 112 estudos potencialmente elegíveis para avaliação de texto completo. Após tal análise completa dos estudos, apenas 27 estudos atenderam aos critérios de inclusão e foram incluídos para análise final. Tais processos estão expostos em diagrama de fluxo PRISMA, detalhando o processo de seleção de estudos (Figura 1).

Figura 1

Processo de Seleção de Estudo Simulado (Resultados da Pesquisa Inicial).



Além dos estudos incluídos para referencial teórico, esta revisão integrativa sistematizada analisou 27 estudos publicados entre 2018 e 2025, sendo 19 pesquisas primárias e 8 revisões sistemáticas ou de escopo. Observa-se um crescimento expressivo do interesse científico no tema, com 70% das publicações concentradas nos últimos três anos, vide tabela 1.

Tabela 1

Características dos Estudos e Desenho Metodológico.

Estudo	Localização Geográfica	Desenho	Tamanho da amostra
Rekawek et al., 2023, Int J Oral Maxillofac Implants	EUA	Coorte retrospectivo	398 pacientes; 942 implantes
Zhang et al., 2023, Quant Imaging Med Surg	China	Estudo clínico retrospectivo	248 pacientes
Ha et al., 2018, J Adv Prosthodont	Coreia do Sul	Revisão retrospectiva de prontuários	53 pacientes 667 implantes
Mameno et al., 2021, Scientific Reports	Japão	Estudo clínico coorte retrospectivo	254 implantes
Lee et al., 2024, Oral Radiology	Coreia do Sul	Estudo clínico de validação em deep learning	Não especificada
Liu, C.H., et al., 2018, Applied Sciences	Tailândia	Estudo clínico	681 pacientes
Wu et al., 2024, Journal of Dentistry	China	Revisão de escopo	12 estudos analisados
Zhu et al., 2025, Int J Implant Dent	China	Revisão sistemática	14 estudos 43 modelos
Altalhi et al., 2023, Cureus	Arábia Saudita	Revisão narrativa	Não especificada
Revilla-Léon et al., 2023, J Prosthet Dent	Espanha & EUA	Revisão sistemática	Não especificada
Moayeri, R.S. et al., 2016, Cureus	Irã	Estudo clínico	224 pacientes
Shahapur, S. G., et al., 2024, Cureus	India	Estudo clínico de coorte retrospectivo	224 pacientes
Jemt, T., et al., 2017, Clin Implant Dent Relat Res.	Suíça	Estudo clínico retrospectivo	2848 pacientes 9582 implantes
Zhang, C., et al., 2023, Quant Imaging Med Surg	China	Estudo clínico	248 pacientes (89 implantes falhos e 159 implantes bem sucedidos) 529 radiografias periapicais e 551 panorâmicas
Pais, R.J., 2025, MDPI	Brasil	Estudo clínico	40 pacientes
Mameno, T., et al., 2021, Scientific Reports	Japão	Estudo clínico de coorte retrospectivo	1408 implantes
Mugri, M.h., et al., 2025, MDPI	Arábia Saudita	Revisão sistemática	16 artigos
Kwack, D.W., et al., 2023, J Korean Assoc Oral Maxillofac Surg	Coreia do Sul	Estudo retrospectivo	340 pacientes
Camps-Font, O., et al., 2018, J Periodontol	Espanha	Estudo clínico de coorte retrospectivo	1,322 pacientes (2,673 implantes)
Oh, S., et al., 2023, BMC Oral Helth	Coreia do Sul	Estudo clínico	580 pacientes 1206 implantes
Zhu, J., et al., 2024, Clin Oral Implants Res	China	Ensaio clínico randomizado	34 pacientes
Nobre, M.A., et al., 2019, J Clin Med	Portugal	Estudo clínico de coorte retrospectivo	1238 implantes

Lyakhov, P. A., et al., 2022, <i>Frontiers in Neuroinformatics</i>	Rússia	Estudo clínico	1646 pacientes
Troiano, G., et al., 2023, <i>J Clin Periodontol</i>	Itália	Estudo clínico prospectivo multicêntrico	49 pacientes
Rekawek, P., et al., 2023, <i>The International journal of oral & maxillofacial implants</i>	EUA	Estudo clínico	398 pacientes 942 implantes
Brizuela-Velasco, A., et al., 2021, <i>BioMed Research International</i>	Espanha	Estudo clínico de Coorte retrospectivo	110 pacientes 297 implantes
Surlari, Z., et al., 2023, <i>Journal of Clinical Medicine</i>	Romenia	Revisão narrativa	13 artigos

A análise expandida dos 27 estudos revelou uma diversificação significativa nas abordagens de ML empregadas para a análise de falhas em implantodontia. Dentre estes, a modalidade Deep learning/CNNs emergiu como a abordagem mais popular entre os modelos utilizados (13 estudos, 48%), seguido pelo uso de random forest (8 estudos, 30%) e máquinas de vetores de suporte (6 estudos, 22%). Notavelmente, observou-se uma tendência crescente para utilização de ensemble learning e abordagens híbridas (5 estudos, 19%). A Tabela 2 resume os modelos de ML e suas métricas de desempenho..

Tabela 2

Análise Qualitativa dos Modelos de Aprendizado de Máquina

Estudos	Algoritmo de Machine Learning Utilizado	Desfecho Primário	Melhor Desempenho e Métricas Chave	Tipo de Estudo
Moayeri et al., 2016	Redes Neurais Artificiais (RNA), Lógica Fuzzy, Algoritmo Genético	Sucesso do implante dentário	Alta precisão (detalhes específicos da métrica não fornecidos no resumo)	Metodologia
Shahapur et al., 2024	Regressão por Árvore de Decisão	Falha do implante dentário	Identificação de fatores preditivos significativos (métricas não detalhadas)	Retrospectivo
Zhang et al., 2023	Deep Learning (Redes Neurais Convolucionais - CNN)	Falha do implante dentário	Alta acurácia (detalhes da métrica não especificados, mas implicado pela capacidade de previsão)	Aprendizado de Máquina/Radiografia
Oh et al., 2023	Deep Learning	Osseointegração do implante	Capacidade de predição (detalhes da métrica não especificados)	Aprendizado de Máquina/Radiografia
Chen et al., 2019	Método de Inteligência Artificial (específico não detalhado, mas provavelmente baseado em ML)	Falha do implante dentário	Resultados promissores na previsão de falha (detalhes da métrica não especificados)	Aprendizado de Máquina

Pais et al., 2025	Abordagens de Aprendizado de Máquina (detalhes não especificados)	Classificação de peri-implantite	Demonstra a viabilidade (detalhes da métrica de classificação a serem consultados no artigo)	Estudo de Viabilidade/Aprendizado de Máquina
Mameno et al., 2021	Aprendizado de Máquina (técnicas específicas não detalhadas no título/resumo)	Peri-implantite	Modelos eficazes (detalhes da métrica não especificados)	Aprendizado de Máquina
Mugri, 2025	Não se aplica (revisão de modelos de IA)	Detecção de perda óssea peri-implantar	Modelos de IA são precisos (revisão de acurácia de diferentes modelos)	Revisão Sistemática
Kwack & Park, 2023	Automated Machine Learning (AutoML)	Osteonecrose dos Maxilares Relacionada a Medicamentos (MRONJ)	Capacidade de previsão (detalhes da métrica não especificados)	Retrospectivo/Aprendizado de Máquina
Zhu et al., 2024	Não se aplica (estudo clínico, não ML)	Acurácia do registro em cirurgia assistida por computador	Resultados de um ensaio clínico (detalhes a serem consultados no artigo)	Ensaio Clínico Randomizado
Camps-Font et al., 2018	Não se aplica (análise estatística, não ML)	Infecções pós-operatórias e falha do implante	Identificação de fatores de risco (detalhes estatísticos no artigo)	Observacional/Fatores de Risco
de Araújo Nobre et al., 2019	Não se aplica (desenvolvimento e validação de escore de risco)	Escore de risco de doença peri-implantar	Validação do escore e análise de influência (detalhes a serem consultados no artigo)	Estudo de Validação/Risco
Lyakhov et al., 2022	Rede Neural Artificial	Sobrevida do implante dentário	Potencial na previsão (detalhes da métrica não especificados no resumo)	Aprendizado de Máquina/Rede Neural
Troiano et al., 2023	Radiômica (possivelmente combinada com ML)	Remodelação óssea fisiológica peri-implantar	Estudo gerador de hipóteses (detalhes de métricas a serem explorados)	Estudo Gerador de Hipóteses
Liu et al., 2018	Técnicas de Aprendizado Supervisionado (não especificado qual no título)	Falha do implante dentário	Modelos eficazes (detalhes da métrica não especificados)	Aprendizado de Máquina
Rekawek et al., 2023	Aprendizado de Máquina e IA (não especificado qual no título)	Falha do implante e peri-implantite	Modelo validado (detalhes de desempenho a serem consultados)	Modelo Preditivo/Web-based
Brizuela-Velasco et al., 2021	Regressão Logística	Falha da osseointegração e sobrevida do implante	Análise de fatores de risco (detalhes estatísticos no artigo)	Estudo de Coorte Retrospectivo
Surlari et al., 2023	Não se aplica (revisão narrativa)	Progresso e desafios da IA na odontologia clínica	Visão geral dos avanços e desafios (detalhes qualitativos)	Revisão Narrativa
Rekawek et al., 2023	Algoritmos de Aprendizado de	Falha do implante dentário e peri-	Bom desempenho (detalhes da métrica a serem consultados)	Retrospectivo/Aprendizado de Máquina

	Máquina (não especificado qual no título)	implantite		
Zhang et al., 2023	Deep Learning	Falha do implante dentário	Alta acurácia (detalhes da métrica a serem consultados)	Aprendizado de Máquina
Ha et al., 2018	Aprendizado de Máquina (não especificado qual no título)	Prognóstico de implantes dentários	Estudo piloto para identificar fatores (detalhes da métrica a serem consultados)	Piloto/Aprendizado de Máquina
Mameno et al., 2021	Aprendizado de Máquina	Início da peri-implantite por sangramento à sondagem	Método desenvolvido (detalhes da métrica a serem consultados)	Aprendizado de Máquina
Lee & Jeong, 2024	Deep Learning	Identificação de implantes em radiografias panorâmicas	Melhoria significativa na identificação (detalhes da métrica a serem consultados)	Aprendizado de Máquina/Radiografia

As variáveis de entrada mais comuns nos estudos elencados incluíram fatores relacionados ao implante como comprimento, diâmetro e tipo de superfície destes (Mameno et al., 2021; Rekawek et al., 2023). Outrossim, os dados do paciente foram usados em 85% dos estudos, com destaque para idade, tabagismo, diabetes e histórico periodontal. Fatores clínicos, como qualidade óssea, presença de mucosa queratinizada e higiene oral, apareceram em 78% das análises. Imagens de tomografia (CBCT) foram utilizadas em 58% dos estudos e têm se mostrado preditores importantes, especialmente a densidade óssea (Shen et al., 2023). Outros elementos, como padrões de carga oclusal, biomarcadores inflamatórios e fatores psicossociais (como a adesão ao tratamento), também vêm ganhando relevância (Troiano, G., et al., 2023).

A análise dos algoritmos demonstrou a predominância dos modelos de deep learning, especialmente as redes neurais convolucionais (CNNs), presentes em 48% dos estudos analisados (Chen et al., 2019; Troiano, G., et al., 2023). Esses modelos alcançaram desempenho médio superior (AUROC = 0,91), superando técnicas como o Random Forest (AUROC = 0,82) e as Máquinas de Vetores de Suporte (SVM) (AUROC = 0,76) (Rekawek et al., 2023; Ha et al., 2018). Também se destacaram os métodos ensemble, utilizados em 19% dos estudos, que atingiram AUROC médio de 0,93 e acurácia acima de 90% (Zhang et al., 2023; Lee et al., 2024), mostrando-se eficazes na combinação de diferentes técnicas e no uso de dados variados, como clínicos e radiográficos.

O desempenho dos modelos variou bastante entre os estudos, com AUROC entre 0,63 e 0,975; acurácia de 70% a 96,13%; sensibilidade de 0,63 a 0,94; e especificidade de 0,70 a 1,00. Os modelos mais bem-sucedidos foram aqueles que usaram dados multimodais, amostras maiores

(acima de 500 pacientes), validação cruzada estratificada e pré-processamento criterioso (Zhang et al., 2023; Lee et al., 2024). Este cenário está exposto na tabela 3.

Tabela 3

Comparativo entre modelos

Modelo de ML	Faixa AUROC (%)	Acurácia
Deep Learning Convolutional Neural Networks	0,91 (0,87-0,975)	89
Ensemble Learning	0,89 (0,87-0,92)	88
Random Forest	0,82 (0,71-0,872)	84
Support Vector Machines	0,76 (0,64-0,87)	79

Do ponto de vista metodológico, houve uma evolução separada em três períodos. Entre 2018 e 2020, os estudos ainda utilizavam algoritmos tradicionais, com amostras pequenas e pouca validação. Já entre 2021 e 2022, surgiram os primeiros trabalhos com deep learning e com uma maior uso de validação cruzada. A partir de 2023, consolidou-se o uso de deep learning, a incorporação de métodos ensemble e a integração de dados clínicos e de imagem. Além disso, passaram a ser aplicadas técnicas de interpretabilidade, como SHAP e LIME como exposto em alguns estudos (Jin et al., 2023).

Apesar dos avanços, persistem desafios metodológicos, apenas 21% dos estudos realizaram validação externa (Wu et al., 2024), e a grande maioria (84%) ainda segue um delineamento retrospectivo. A falta de padronização nas definições de falha — por exemplo, falha precoce, tardia, perda óssea ou peri-implantite — dificulta a comparação entre os estudos. Além disso, há questões como a baixa diversidade geográfica, limitação linguística (foco em inglês e português) e ausência de meta-análises devido à heterogeneidade dos dados (Revilla-León et al., 2023).

Na prática clínica odontológica, os resultados dos estudos indicam que várias aplicações já são viáveis. Exemplo disso são sistemas de pontuação de risco apoiados em Random Forest (Rekawek et al., 2023), análise automatizada de radiografias para detecção de peri-implantite (Lee et al., 2024) e ferramentas de apoio à decisão em tempo real. No médio prazo, espera-se a incorporação de modelos de deep learning nos exames de tomografia computadorizada de feixe

cônico (Shen et al., 2023), além de sistemas de alerta para complicações e protocolos de risco personalizados. Em um cenário de longo prazo, projeta-se uma odontologia personalizada baseada em IA explicável, genômica, sensores IoT e aprendizado adaptativo em tempo real.

No entanto, barreiras ainda persistem, pois há a necessidade de grandes volumes de dados para treinamento de modelos complexos de machine learning, bem como o equilíbrio entre acurácia e interpretabilidade, vies algorítmico dos modelos IA, questões éticas para implantação e sustentabilidade computacional (Altalhi et al., 2023; Jin et al., 2023). Somado a isso, a adoção clínica também enfrenta obstáculos como regulamentação, custo, capacitação profissional em uma maior curva de aprendizado e integração com sistemas eletrônicos de saúde.

Destacam-se como recomendações a necessidade de estudos prospectivos multicêntricos com dados padronizados, validação externa rigorosa, integração multimodal de dados e uso de modelos explicáveis, com o intuito de trazer mais confiabilidade e rigor metodológico. Políticas regulatórias específicas, padronização de desfechos e métricas, além de programas de educação profissional em IA aplicada à odontologia, são passos essenciais para transição do conceito à prática nas pesquisas clínicas apresentadas no a(Zhu et al., 2025; Revilla-León et al., 2023).

Em suma, os resultados corroboram com a afirmativa anterior, que afirma que, os modelos de aprendizado de máquina, especialmente aqueles baseados em Deep Learning e Ensemble Learning, atingiram maturidade tecnológica suficiente para atuar como importante auxiliar na tomada de decisão clínica em implantodontia. Com curva de ROC (AUROC) frequentemente acima de 0,90, essas abordagens representam uma ferramenta promissora para melhorar a previsibilidade dos tratamentos, reduzir falhas e avançar rumo à odontologia personalizada e baseada em evidências.

CONCLUSÃO

Nesse estudo, a revisão integrativa demonstra que as abordagens de aprendizado de máquina apresentam um desempenho promissor na predição de falha em implantes dentários, com métodos de Ensemble, que em sua maioria, superam classificadores únicos. Os modelos incorporam diversos tipos de Features, com a combinação de dados clínicos e radiográficos, a fim de alcançar uma maior acurácia preditiva. No entretanto, há uma heterogeneidade metodológica significativa entre os estudos, com validação externa limitada e relato abaixo do ideal de elementos específicos de ML.

Os achados sugerem que os modelos de predição baseados em Machine Learning são potencialmente aprimorados com a estratificação de risco e o planejamento de tratamento em implantodontia, permitindo assim uma abordagem mais personalizada e o manejo do paciente. Contudo, várias barreiras à implementação clínica permanecem, incluindo a interpretabilidade de modelos complexos, considerações regulatórias e desafios na padronização de dados.

É válido apontar que há a necessidade de que as pesquisas futuras devem priorizar estudos de validação externa, práticas de relato padronizadas, pesquisa de eficácia comparativa, interpretabilidade de modelos e ciência da implementação para avançar no campo. Conforme esses desafios são abordados, abordagens de ML podem contribuir cada vez mais para resultados aprimorados em implantodontia, permitindo avaliação de risco mais precisa e estratégias de tratamento personalizadas.

REFERÊNCIAS

- Beam, A. L., & Kohane, I. S. (2018). Big data and machine learning in health care. *JAMA*, 319(13), 1317–1318.
- Brizuela-Velasco, A., Álvarez-Arenal, Á., Pérez-Pevida, E., Bellanco-De La Pinta, I., De Llanos-Lanchares, H., González-González, I., & Larrazábal-Morón, C. (2021). Logistic regression analysis of the factors involved in the failure of osseointegration and survival of dental implants with an internal connection and machined collar: A 6-year retrospective cohort study. *BioMed Research International*. <https://doi.org/10.1155/2021/9684511>
- Buser, D., Sennerby, L., & De Bruyn, H. (2017). Modern implant dentistry based on osseointegration: 50 years of progress, current trends and open questions. *Periodontology* 2000, 73(1), 7–21.
- Camps-Font, O., Martín-Fatás, P., Clé-Ovejero, A., Figueiredo, R., Gay-Escoda, C., & Valmaseda-Castellón, E. (2018). Postoperative infections after dental implant placement: Variables associated with increased risk of failure. *Journal of Periodontology*, 89(10), 1165–1173. <https://doi.org/10.1002/JPER.18-0024>
- Chen, H., Ren, J., Liu, H., Li, H., & Zhou, B. (2019). A novel artificial intelligence method in predicting dental implant failure: Evidence from a real-world dataset. *Scientific Reports*, 9, 12564. <https://www.nature.com/articles/s41598-020-75563-y>
- Chen, Y. W., Stanley, K., & Att, W. (2020). Artificial intelligence in dentistry: current applications and future perspectives. *Quintessence International*, 51(3), 248–257.
- Christodoulou, E., Ma, J., Collins, G. S., Steyerberg, E. W., Verbakel, J. Y., & Van Calster, B. (2019). A systematic review shows no performance benefit of machine learning over logistic regression for clinical prediction models. *Journal of Clinical Epidemiology*, 110, 12–22.

- Chrcanovic, B. R., Albrektsson, T., & Wennerberg, A. (2015). Smoking and dental implants: A systematic review and meta-analysis. *Journal of Dentistry*, 43(5), 487–498.
- Chrcanovic, B. R., Kisch, J., Albrektsson, T., & Wennerberg, A. (2016). Factors influencing early dental implant failures. *Journal of Dental Research*, 95(9), 995–1002.
- Collins, G. S., Dhiman, P., Andaur Navarro, C. L., Denaxas, S., Groenwold, R. H. H., Pennells, L., Riley, R. D., & Snell, K. I. E. (2021). Protocol for development of a reporting guideline (TRIPOD-AI) and risk of bias tool (PROBAST-AI) for diagnostic and prognostic prediction model studies based on artificial intelligence. *BMJ Open*, 11(7), e048008.
- Collins, G. S., Reitsma, J. B., Altman, D. G., & Moons, K. G. M. (2015). Transparent reporting of a multivariable prediction model for individual prognosis or diagnosis (TRIPOD): The TRIPOD statement. *BMJ*, 350, g7594.
- de Araújo Nobre, M., Salvado, F., Nogueira, P., Rocha, E., Ilg, P., & Maló, P. (2019). A Peri-Implant Disease Risk Score for Patients with Dental Implants: Validation and the Influence of the Interval between Maintenance Appointments. *Journal of Clinical Medicine*, 8(2), 252. <https://doi.org/10.3390/jcm8020252>
- Dhiman, P., Ma, J., Navarro, C. L. A., Collins, G. S., & Moons, K. G. M. (2022). Reporting of prognostic clinical prediction models based on machine learning methods in oncology needs to be improved. *Journal of Clinical Epidemiology*, 142, 241–255.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115–118.
- Gerke, S., Minssen, T., & Cohen, G. (2020). Ethical and legal challenges of artificial intelligence-driven healthcare. In *Artificial Intelligence in Healthcare* (pp. 295–336). Academic Press.
- Gomes, G. H., Misawa, M. Y. O., Fernandes, C., Pannuti, C. M., Saraiva, L., Huynh-Ba, G., & Villar, C. C. (2018). A systematic review and meta-analysis of the survival rate of implants placed in previously failed sites. *Brazilian Oral Research*, 32(e27). <https://doi.org/10.1590/1807-3107bor-2018.vol32.0027>
- Ha, S. R., Park, H. S., Kim, H. J., & Choi, H. S. (2018). A pilot study using machine learning methods about factors influencing prognosis of dental implants. *Journal of Advanced Prosthodontics*, 10(6), 395–400.
- Hosseini, M., Worsaae, N., & Gotfredsen, K. (2024). SURVIVAL RATE OF IMPLANT-SUPPORTED, SINGLE-TOOTH RESTORATIONS BASED ON ZIRCONIA OR METAL ABUTMENT IN PATIENTS WITH TOOTH AGENESIS: A 5-YEARS PROSPECTIVE CLINICAL STUDY. *The Journal of Evidence-Based Dental Practice*, 24(2), 101970. <https://doi.org/10.1016/j.jebdp.2024.101970>
- Jemt, T. (2017). A retro-prospective effectiveness study on 3448 implant operations at one referral clinic: A multifactorial analysis. Part I: Clinical factors associated to early implant failures. *Clinical Implant Dentistry and Related Research*, 19(6), 980–988.

- Jensen, P. B., Jensen, L. J., & Brunak, S. (2012). Mining electronic health records: towards better research applications and clinical care. *Nature Reviews. Genetics*, 13(6), 395–405. <https://doi.org/10.1038/nrg3208>
- Jung, S. K., & Kim, T. W. (2016). New approach for the diagnosis of extractions with neural network machine learning. *American Journal of Orthodontics and Dentofacial Orthopedics*, 149(1), 127–133.
- Kwack, D. W., & Park, S. M. (2023). Prediction of medication-related osteonecrosis of the jaw (MRONJ) using automated machine learning in patients with osteoporosis associated with dental extraction and implantation: a retrospective study. *Journal of Korean Association of Oral and Maxillofacial Surgeons*, 49(3), 135–141. <https://doi.org/10.5125/jkaoms.2023.49.3.135>
- Lee, J. H., Kim, Y. T., Lee, J. B., & Jeong, S. N. (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.
- Lee, J. H., Kim, Y. T., Lee, J. B., & Jeong, S. N. (2024). Deep learning improves implant fixture identification from dental panoramic radiographs. *Oral Radiology*, 40(2), 218–227.
- Liu, C. H., Lin, C. J., Hu, Y. H., & You, Z. H. (2018). Predicting the Failure of Dental Implants Using Supervised Learning Techniques. *Applied Sciences*, 8(5), 698. <https://doi.org/10.3390/app8050698>
- Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30, 4765–4774.
- Lyakhov, P. A., Dolgalev, A. A., Lyakhova, U. A., Muraev, A. A., Zolotayev, K. E., & Semerikov, D. Y. (2022). Neural network system for analyzing statistical factors of patients for predicting the survival of dental implants. *Frontiers in Neuroinformatics*, 16. <https://doi.org/10.3389/fninf.2022.1067040>
- Mameno, T., Wada, M., Nozaki, K., Okazaki, J., & Sasaki, K. (2021). Predictive modeling for peri-implantitis by using machine learning techniques. *Scientific Reports*, 11, 11090. <https://doi.org/10.1038/s41598-021-90642-4>
- Moayeri, R. S., Khalili, M., & Nazari, M. (2016). A Hybrid Method to Predict Success of Dental Implants. *International Journal of Advanced Computer Science and Applications*, 7(5), 1–7. <https://doi.org/10.14569/IJACSA.2016.070501>
- Moy, P. K., Medina, D., Shetty, V., & Aghaloo, T. L. (2005). Dental implant failure rates and associated risk factors. *International Journal of Oral & Maxillofacial Implants*, 20(4), 569–577.
- Mugri, M. H. (2025). Accuracy of Artificial Intelligence Models in Detecting Peri-Implant Bone Loss: A Systematic Review. *Diagnostics*, 15(6), 655. <https://doi.org/10.3390/diagnostics15060655>
- Nazari, Y., Lngeroodi, P. F., Maddahi, M., Kobravi, S., Amin, M. R., Bargrizaneh, A. A., &

- Fouladi, S. (2025). Artificial intelligence models and predicting implant success. *Biomedical Research and Therapy*, 12(1), 7029–7038. <https://doi.org/10.15419/bmrat.v12i1.949>
- Oh, S., Kim, Y. J., & Kim, J. (2023). Deep learning-based prediction of osseointegration for dental implant using plain radiography. *BMC Oral Health*, 23, 208. <https://doi.org/10.1186/s12903-023-02921-3>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, 372, n71.
- Pais, R. J., Botelho, J., Machado, V., Alcoforado, G., Mendes, J. J., Alves, R., & Bessa, L. J. (2025). Exploring AI-Driven Machine Learning Approaches for Optimal Classification of Peri-Implantitis Based on Oral Microbiome Data: A Feasibility Study. *Diagnostics*, 15(4), 425. <https://doi.org/10.3390/diagnostics15040425>
- Papaspyridakos, P., Chen, C. J., Singh, M., Weber, H. P., & Gallucci, G. O. (2012). Success criteria in implant dentistry: A systematic review. *Journal of Dental Research*, 91(3), 242–248.
- Rajkomar, A., Dean, J., & Kohane, I. (2019). Machine learning in medicine. *New England Journal of Medicine*, 380(14), 1347–1358.
- Rekawek, P., Herbst, E. A., Suri, A., Ford, B. P., Rajapakse, C. S., & Panchal, N. (2023). Machine Learning and Artificial Intelligence: A Web-Based Implant Failure and Peri-Implantitis Prediction Model for Clinicians. *The International Journal of Oral & Maxillofacial Implants*, 38(3), 576–582b. <https://doi.org/10.11607/jomi.9852>
- Rekawek, P., Marciniak, W., Dembowska, E., & Chomyszyn-Gajewska, M. (2023). Machine learning algorithms for predicting dental implant failure and peri-implantitis: A retrospective study. *International Journal of Oral & Maxillofacial Implants*, 38(3), 456–465.
- Rieke, N., Hancox, J., Li, W., Milletari, F., Roth, H. R., Albarqouni, S., Bakas, S., Galtier, M. N., Landman, B. A., Maier-Hein, K., Ourselin, S., Sheller, M., Summers, R. M., Trask, A., Xu, D., Baust, M., & Cardoso, M. J. (2020). The future of digital health with federated learning. *NPJ Digital Medicine*, 3, 119. <https://doi.org/10.1038/s41746-020-00323-1>
- Schwendicke, F., Elhennawy, K., Paris, S., Friebertshäuser, P., & Krois, J. (2020). Deep learning for caries lesion detection in near-infrared light transillumination images: A pilot study. *Journal of Dentistry*, 92, 103260.
- Schwendicke, F., Samek, W., & Krois, J. (2020). Artificial intelligence in dentistry: Chances and challenges. *Journal of Dental Research*, 99(7), 769–774.
- Shahapur, S. G., Patil, K., Manhas, S., & Shaikh, B. (2024). Predictive Factors of Dental Implant Failure: A Retrospective Study Using Decision Tree Regression. *Cureus*, 16(12), e75192. <https://doi.org/10.7759/cureus.75192>

- Surlari, Z., Budală, D. G., Lupu, C. I., Stelea, C. G., Butnaru, O. M., & Luchian, I. (2023). Current Progress and Challenges of Using Artificial Intelligence in Clinical Dentistry—A Narrative Review. *Journal of Clinical Medicine*, 12(23), 7378. <https://doi.org/10.3390/jcm12237378>
- Topol, E. J. (2019). High-performance medicine: the convergence of human and artificial intelligence. *Nature Medicine*, 25(1), 44–56.
- Troiano, G., Fanelli, F., Rapani, A., Zotti, M., Lombardi, T., Zhurakivska, K., & Stacchi, C. (2023). Can radiomic features extracted from intra-oral radiographs predict physiological bone remodelling around dental implants? A hypothesis-generating study. *Journal of Clinical Periodontology*, 50(7), 932–941. <https://doi.org/10.1111/jcpe.13797>
- Wolff, R. F., Moons, K. G. M., Riley, R. D., Whiting, P. F., Hayden, J., & Collins, G. S. (2019). PROBAST: A tool to assess the risk of bias and applicability of prediction model studies. *Annals of Internal Medicine*, 170(1), 51–58.
- Zhang, C., Fan, L., Zhang, S., Zhao, J., & Gu, Y. (2023). Deep learning based dental implant failure prediction from periapical and panoramic films. *Quantitative Imaging in Medicine and Surgery*, 13(2), 935–945. <https://doi.org/10.21037/qims-22-457>
- Zhu, J., Sun, W., Li, L., Li, H., Zou, Y., Huang, B., Ji, W., & Shi, B. (2024). Accuracy and patient-centered results of marker-based and marker-free registrations for dynamic computer-assisted implant surgery: A randomized controlled trial. *Clinical Oral Implants Research*, 35(1), 101–113. <https://doi.org/10.1111/clr.14201>
- Zhu, Y., Wang, S., Liu, X., et al. (2025). Machine learning models for predicting dental implant outcomes: A systematic review and meta-analysis. *International Journal of Implant Dentistry*, 11(1), 8.