## **UNIVERSIDADE DE PASSO FUNDO**

Pedro Henrique Wentz Tretto

Sobrevivência em fadiga de implantes de diâmetro reduzido inseridos em diferentes materiais de suporte

> Passo Fundo 2024

#### Pedro Henrique Wentz Tretto

### Sobrevivência em fadiga de implantes de diâmetro reduzido inseridos em diferentes materiais de suporte

Tese apresentada ao Programa de Pós-Graduação em Odontologia da Faculdade de Odontologia da UPF, para obtenção do título de Doutor em Odontologia – Área de Concentração em Clínica Odontológica, sob orientação do prof. Dr. Dr. Alvaro Della Bona e coorientação do prof. Dr. Jason Alan Griggs.

Passo Fundo 2024

# Folha reservada para Ata de aprovação da Banca Examinadora

Observação:

Mantenha esta página no seu arquivo, imprimindo-a. Após, faça a substituição pela Ata de aprovação fornecida pela Secretaria para manter a correta numeração do seu trabalho. Folha reservada para Ficha catalográfica

Observação:

Mantenha esta página no seu arquivo, imprimindo-a. Após, faça a substituição pela Ficha Catalográfica fornecida pela Secretaria para manter a correta numeração do seu trabalho.

#### **BIOGRAFIA DO AUTOR**

Pedro Henrique Wentz Tretto, nascido em Passo Fundo no dia 18 de agosto de 1988. Graduado em odontologia pela Faculdade de Odontologia da Universidade de Passo Fundo (2006 – 2011). Especialista em Cirurgia e traumatologia bucomaxilofacial pela FASURGS, Passo Fundo (2012 – 2014), e em Implantodontia pela IODONTUS, Passo Fundo (2015-2017). Mestre em Odontologia pela IMED, Passo Fundo (2017-2018). Doutorando em Odontologia pela Faculdade de Odontologia da Universidade de Passo Fundo (2020-2024), com período de doutorado sanduíche na University of Mississippi Medical Center, Jackson, MS, USA (2022 – 2023). Atualmente professor na universidade URI e cirurgião-dentista em consultório particular.

### AGRADECIMENTOS

Gostaria de expressar minha profunda gratidão a todos aqueles que contribuíram para o sucesso desta jornada acadêmica. Sem o apoio e a colaboração de muitas pessoas, este trabalho não teria sido possível.

#### A Deus

Primeiramente, agradeço a Deus por me guiar e me dar força durante todo o processo. Sua orientação e proteção foram fundamentais para que eu pudesse alcançar este marco em minha vida.

#### À minha família

Minha família sempre esteve ao meu lado, apoiando-me incondicionalmente. Seu amor, incentivo e compreensão foram essenciais para que eu pudesse enfrentar os desafios e perseverar na busca pelo conhecimento.

#### Ao meu orientador

Meu sincero agradecimento ao meu orientador, que dedicou tempo e conhecimento para me guiar nesta jornada. Suas orientações e feedbacks foram inestimáveis para o desenvolvimento deste trabalho.

Ao meu coorientador

Também sou grato ao meu coorientador, cujas contribuições enriqueceram minha pesquisa. Sua expertise e visão crítica foram fundamentais para aprimorar minha compreensão e abordagem.

#### Aos meus colegas

Aos meus colegas de laboratório, turma e amigos, obrigado por compartilharem ideias, debaterem conceitos e proporcionarem um ambiente de aprendizado colaborativo. Nossas discussões e trocas de experiências foram enriquecedoras.

#### À CAPES

Por fim, expresso minha gratidão à CAPES que me concedeu a bolsa de estudos. Seu investimento em educação e pesquisa é fundamental para o avanço do conhecimento e o desenvolvimento da sociedade como um todo.

# SUMÁRIO

LISTA DE TABELAS	11
LISTA DE FIGURAS	12
RESUMO	14
ABSTRACT	15
1 INTRODUÇÃO	17
2 REVISÃO DE LITERATURA	20
3 PROPOSIÇÃO	30
4 MATERIAIS E MÉTODOS	31
5 RESULTADOS E DISCUSSÃO	48
6 CONCLUSÕES	62
REFERÊNCIAS	63
ARTIGO I	72
ARTIGO II	97

### LISTA DE TABELAS

- Tabela 1 Resultados da análise por microtomografia.
- Tabela 2 Resultados de Torque de inserção e ISQ.
- Tabela 3 Números totais de ciclos em diferentes níveis de carga.

#### LISTA DE FIGURAS

Figura 1. Representação esquemática dos dentes inferiores e da largura (diâmetro) de sua crista alveolar. Adaptado de Woelfel e Scheid, 1997.

Figura 2. Costela bovina utilizada no experimento.

Figura 3. SkyScan 1172 micro-CT, Bruker, Bélgica.

Figura 4. Biomet 3i Osseotite MicroMiniplant

Figura 5. Desenho esquemático do teste utilizado nesse estudo e proposto pela norma ISO 14801:2016

Figura 6. Motor cirúrgico e kit cirúrgico de implantes dentários 3i.

Figura 7. Análise de frequência por ressonância(Implantmed, W&H, Burmoos, Austria).

Figura 8. Pilar protético instalado(torque 32 N·cm).

Figura 9. Confecção do cilindro de resina epóxi para suporte da amostra.

Figura 10. Instalação da calota de carregamento.

Figura 11. Posicionamento 3 mm acima do nível cervical do osso.

Figura 12. Amostra posicionada no dispositivo de teste de vida útil acelerado (ALT).

Figura 13. Amostras posicionadas na máquina de testes (Flextest 60,

MTS, Eden Prairie, MN) para o teste de vida útil acelerado (ALT).

Figura 14. Amostra fraturada após o teste.

Figura 15. Limpeza das amostras em banho sônico com água deionizada.

Figura 16. Microscopia eletrônica por varredura (MEV) das amostras fraturadas .

Figura 17. Projeto esquemático (DUAN e GRIGGS, 2018) do bloco de suporte de amostra (osso simulado) com uma estrutura em camadas para

simular o osso da mandíbula humana. A camada externa (diâmetro: 25,4 mm) é feita de material composto G10 e a camada interna (diâmetro: 12,7 mm) é feita de resina epóxi.

Figura 18. Costela bovina com cortical compacta e porção medular densa. Medidas (em mm) apresentadas na imagem.

Figura 19. Exemplo de resultado de ISQ.

Figura 20. Life-stress contour para amostras com costela bovina como material de suporte.

Figura 21. Comparação entre os materiais de suporte

Figura 22. Fratura do corpo do implante observada com microscópio óptico.

Figura 23. Visão geral da superfície de fratura.

Figura 24. Área da origem da fratura.

Figura 25. Estriações de fadiga.

Figura 26. Micro cavidades na zona de fratura rápida.

Figura 27. Zona da curva de compressão (final da propagação da fratura).

#### **RESUMO<sup>1</sup>**

O estudo avaliou a sobrevivência em fadiga de implantes de diâmetro reduzido inseridos em dois materiais de suporte: costela bovina e polímero simulando osso. A costela bovina foi classificada de acordo com os critérios de Lekholm e Zarb com análise de fração óssea. Foram instalados quatorze implantes dentários em costelas bovinas como material de suporte, seguidos pela análise de frequência por ressonância e submissão ao teste de vida útil acelerado, utilizando o método step-stress. Os resultados obtidos foram comparados com os resultados de estudo anterior, no qual os implantes foram instalados em material de suporte a base de polímero simulando osso. Todas as amostras foram submetidas à análise fractográfica. Os resultados indicaram que a costela bovina apresentou semelhança com os maxilares humanos. Além disso, os implantes demonstraram um alto nível de estabilidade (75,07  $\pm$  3,81). Embora os implantes instalados em costela bovina tenham apresentado uma maior sobrevida em fadiga em comparação com aqueles instalados em polímero simulando osso, não foi observada diferença estatisticamente significativa entre os grupos. Destaca-se que todas as fraturas ocorreram no corpo do implante, caracterizando-se como fraturas por fadiga.

Palavras-chave: Implantes Dentários; Fraturas por Fadiga; Fractografia.

<sup>&</sup>lt;sup>1</sup> Pedro Henrique Wentz Tretto

### ABSTRACT<sup>2</sup>

The study aimed to evaluate the fatigue survival of reduceddiameter implants inserted into two support materials, bovine rib and polymer simulating bone. Initially, bovine ribs were classified according to Lekholm and Zarb criteria, followed by bone fraction analysis. Fourteen dental implants were installed in bovine ribs as support material, followed by resonance frequency analysis and submission to accelerated life testing using the step-stress method. The results were compared with those of a previous study, in which implants were installed in a polymer simulating bone support material. Fractographic analysis was performed for all fractured samples. The results indicated that bovine rib showed similarity to human maxillae. Additionally, the implants placed into bovine ribs showed high level of stability (75.07  $\pm$  3.81). Although implants placed into bovine ribs showed greater fatigue survival compared to those placed in polymer simulating bone, no significant difference was observed between groups. All fractures occurred in the implant body as fatigue fractures.

 $<sup>^2</sup>$  Fatigue survival of reduced-diameter implants inserted in different support materials

Palavras-chave: Dental Implants; Fatigue Fractures; Fractographic Analysis.

### 1 INTRODUÇÃO

O número de implantes colocados nos Estados Unidos aumentou em 10 vezes entre os anos de 1983 e 2002, com 150 milhões de dólares em produtos de implantes dentários vendidos a dentistas norte-americanos em 2002 (GRIGGS, 2017). No Brasil, segundo o levantamento da Associação Brasileira da Indústria Médica, Odontológica e Hospitalar (ABIMO), cerca de 800 mil implantes e 2,4 milhões de componentes de próteses dentárias são colocados por ano no País, e 90% do mercado é atendido pela indústria nacional. Em 2011, empresas brasileiras do setor odontológico exportaram aproximadamente 87 milhões de dólares e importaram 80 milhões de dólares (PENHA JUNIOR, 2017). Da mesma forma, a taxa de publicação anual sobre sucesso/falha de implantes dentários acelerou a partir de 1988, com uma média progressiva de 22 artigos/ano até o presente (GRIGGS, 2017). Essa tendência de aumento na incidência de implantes deve continuar porque a população dos Estados Unidos está envelhecendo e a taxa de pobreza entre os idosos está diminuindo (MURDOCK e HOQUE, 1998).

Na ausência de colocação de implantes, o edentulismo representa um sério problema de saúde para a população. Sem um dente ou implante para transferir carga para o osso alveolar, os pacientes experimentam reabsorção óssea com uma diminuição média de 4 mm na altura mandibular no primeiro ano e mais 0,4 mm/ano depois disso (HELKIMO *et al.*, 1977). Os resultados do censo mostram que 17% dos adultos norteamericanos sofrem de edentulismo em um ou nos dois arcos (MURDOCK e HOQUE, 1998).

Recentemente, houve mudanças significativas nos modelos de restauração de pacientes edêntulos devido à alta confiabilidade dos implantes dentários. Inicialmente utilizados para aumentar a estabilidade de próteses totais em pacientes edêntulos, os implantes passaram a ser adotados em protocolos de reabilitação mais amplos, inclusive para pacientes parcialmente edêntulos, representando até 90% dos casos atuais (DUONG *et al.*, 2022). O desenvolvimento de técnicas avançadas e novas superfícies de implantes contribuiu para resultados aceitáveis, mesmo em casos em que a estética é prioritária (DUONG *et al.*, 2022). Apesar da percepção dos pacientes de que um resultado estético satisfatório é crucial, é importante considerar as possíveis complicações associadas à colocação de implantes, visto que os índices de sobrevivência não são de 100% (ORTEGA-OLLER *et al.*, 2014), o que pode levar a um tratamento prolongado e dispendioso.

O índice de sobrevivência dos implantes dentários diminui conforme o diâmetro do implante reduz, sendo de 87% em implantes com diâmetro ≥3 mm e 75% em implantes <3 mm (ORTEGA-OLLER *et al.*, 2014). O aumento do número de falhas pode ser explicado pelo maior risco biomecânico, devido as menores propriedades mecânicas pela menor dimensão dos componentes e pela composição do material, podendo levar a faturas dos pilares protéticos e dos implantes e afrouxamento dos parafusos ou fraturas (SCHIEGNITZ e AL-NAWAS, 2018).

18

Testes mecânicos são importantes para avaliação do comportamento de implantes dentários frente a diferentes tipos de forças e cargas. É necessário determinar a resistências dos materiais para identificar a carga máxima suportável antes de fraturas como também é importante avaliar variações de cargas por longos períodos, simulando a mastigação, que podem gerar fraquezas nas estruturas gerando fissuras e rachaduras, levando a fadiga mecânica. Esses pequenos defeitos podem se desenvolver e propagar gradualmente, gerando um acúmulo de danos e, eventualmente, uma fratura por fadiga (GARCÍA-GONZÁLEZ *et al.*, 2020).

Portanto, estudos que avaliem o comportamento em fadiga de implantes dentários para aumentar a confiabilidade mecânica tem um grande potencial de impacto em pacientes e na odontologia clínica.

### 2 REVISÃO DE LITERATURA

Implantes de diâmetro reduzido são necessários para a substituição de dentes com pequeno diâmetro cervical (Figura 1), principalmente na região dos dentes anteriores inferiores. Nessa região, a largura da crista alveolar é frequentemente insuficiente para colocar um implante de diâmetro padrão (OLATE *et al.*, 2010; WOELFEL e SCHEID, 1997). A definição de um implante de diâmetro pequeno ou reduzido não é clara e varia de 3,3 mm (GLEIZNYS *et al.*, 2012; ORTEGA-OLLER *et al.*, 2014) a 3,75 mm (DEGIDI *et al.*, 2008). As taxas reais de falha dos implantes dentários são provavelmente maiores do que as taxas publicadas na literatura clínica e os implantes de diâmetro reduzido têm maior probabilidade de falha, especialmente quando o diâmetro é  $\leq$  3,75 mm (GRIGGS, 2017). Entretanto, é relevante mencionar que os implantes de diâmetro reduzido evitam a necessidade de cirurgia de aumento ósseo e, portanto, evitam o custo adicional e a espera de seis meses antes da colocação do implante.



**Figura 1**. Representação esquemática dos dentes inferiores e da largura (diâmetro) de sua crista alveolar. Adaptado de Woelfel e Scheid, 1997.

As consequências de uma falha de implantes dentários são mais graves do que a falha de outros tratamentos dentários, como próteses fixas e restaurações, especialmente quando a falha ocorre abaixo do nível ósseo. A cirurgia para correção de complicações (ex.: fratura do implante, perda óssea e danos aos tecidos moles) apresenta um elevado custo, geralmente não coberto pelos planos de saúde, e requer meses para cicatrizar com a realização de enxertia de tecido ósseo. No caso do transplante de tecido ósseo autólogo, também há chance de morbidade no local da retirada do osso (ANDERSEN *et al.*, 2002).

Fica clara a importância de trabalhar para que os tratamentos com implantes dentários não tenham complicações. Apesar de complicações mecânicas em implantes de diâmetro padrão serem raras quando os implantes são usados corretamente, os implantes de diâmetro reduzido sofrem com uma alta incidência de complicações (WIRZ *et al.*, 2020). A literatura é quase unânime neste ponto com revisões sistemáticas e metaanálises que confirmam a necessidade de maior estabilidade interna em implantes de diâmetro reduzido (ANDERSEN *et al.*, 2001; ORTEGA-OLLER *et al.*, 2014). Existem poucas publicações contradizendo esta evidência. Tais estudos foram incluídos em uma revisão recente (JAVED e ROMANOS, 2015) que concluiu que eles possuem falhas metodológicas que levam a mal-entendidos.

A maioria dos investigadores relatam uma forte associação entre o diâmetro reduzido do implante e a diminuição de sua vida útil (JAVED e ROMANOS, 2015; ORTEGA-OLLER *et al.*, 2014), e essa tendência também é apoiada por estudos in vitro (ALLUM *et al.*, 2008). Na maioria das vezes, ocorre falha na conexão entre o pilar protético e o corpo do implante dentário. Em geral, acredita-se que isso seja causado pelo micromovimento do pilar protético, provocando um afrouxamento do parafuso que fixa o pilar protético ao implante dentário. Uma conexão solta, eventualmente, sofre fratura por fadiga. Estudos clínicos abordando todos os tamanhos de implantes dentários relatam uma incidência de afrouxamento do parafuso conector entre 3 e 40% (PIATTELLI *et al.*, 1998a).

Em relação ao efeito do diâmetro do implante, o uso de implantes estreitos aumentou significativamente as falhas precoces in vivo (p = 0,035) (BAQAIN *et al.*, 2012). Um estudo in vitro mostrou que implantes de 3,3 mm de diâmetro possuem apenas 63% da resistência apresentada por implantes de 3,75 mm de diâmetro (ALLUM *et al.*, 2008). Outro estudo (QUEK *et al.*, 2006) avaliou implantes dentários com três diâmetros diferentes associados a pilares protéticos fixados com três níveis de torque no parafuso (torque recomendado pelo fabricante; torque

recomendado + 20%; e torque recomendado - 20%) submetendo a uma carga cíclica de 21 N em um ângulo de 45 graus em relação ao longo eixo das amostras. Não houve falha em implantes de diâmetro ampliado, 20% das falhas ocorreram em implantes de diâmetro padrão e 40% das falhas ocorreram em implantes de diâmetro reduzido (33% no parafuso de conexão e 7% no corpo do implante). Considerando o desenvolvimento contemporâneo de fabricação e a padronização dos parâmetros dos implantes dentários, é possível que os resultados relatados nas últimas décadas sejam diferentes das taxas de falha atuais.

Considerando o mecanismo de complicações técnicas, vários estudos in vivo utilizando microscopia avançada concluíram que as falhas em implantes dentários mostraram um mecanismo de fadiga (LINKOW et al., 1992; PIATTELLI et al., 1998b; VELÁSQUEZ-PLATA et al., 2002; TAGGER GREEN et al., 2002; CAPODIFERRO et al., 2006). Não surpreende que a fadiga seja reconhecida como um dos principais motivos associados ao insucesso dos implantes dentários, visto que estão sujeitos a repetidas cargas funcionais (mastigatórias) e parafuncionais ao longo da vida útil na cavidade bucal (DUAN et al., 2018). A fadiga pode ser definida como o enfraquecimento de um componente estrutural sob a influência de tensões mecânicas, químicas, biológicas ou a combinação destas (KELLY et al., 2017). Atualmente, não existe um método disponível para detectar e monitorar trincas por fadiga no acompanhamento clínico de rotina, o que torna importante a realização de estudos in vitro de fadiga, que sejam eficazes, clinicamente relevantes e de baixo custo, para avaliar o comportamento de longo prazo dos implantes (DUAN e GRIGGS, 2018).

O teste de fadiga cíclico é o que possui maior significância clínica entre os testes de fadiga, podendo ser realizado na forma convencional e acelerado. Os testes de fadiga acelerada foram desenvolvidos para otimizar o tempo dos testes convencionais, que utilizam, com frequência, os métodos staircase, step-stress e boundary (BORBA *et al.*, 2013; CORAZZA *et al.*, 2015; KELLY *et al.*, 2017).

O método step-stress, desenvolvido por Nelson (1980) como uma estratégia para deixar o teste mais eficiente, diminui o tempo necessário para obter informações sobre o comportamento em fadiga e a distribuição do tempo de vida de um material ou estrutura. As amostras são testadas em condições severas, falhando mais rapidamente do que em condições normais. A severidade das condições (temperatura, tensão, pressão, vibração, taxa de ciclagem, carga, etc) pode ser obtida aumentando seus valores além do normal, ou combinando algumas dessas condições.

Para padronizar o teste que simula uma reabilitação com implantes dentários unitários, a ISO (International Organization for Standardization) (2016) publicou a norma 14801 que requer, por exemplo, que (1) o dispositivo de teste deve prender a amostra a uma distância de  $3 \pm 0.5$  mm apicalmente ao nível ósseo nominal, (2) envolva materiais onde a fadiga por corrosão é esperada e (3) inclua componentes poliméricos. Água, solução salina e qualquer meio fisiológico alternativo (por exemplo, solução de Ringer) são aceitos para testes de fadiga. Tais soluções devem ser mantidas fluidas e a  $37^{\circ}C \pm 2^{\circ}C$  durante o teste (ISO 14801: 2016; DUAN e GRIGGS, 2018). É necessário descrever o padrão e, se possível, o processo de falha dos componentes do implante afetados (ISO 14801, 2016). A norma também determina que o teste deve ser realizado em uma frequência não superior a 2 Hz em meio líquido e não superior a 15 Hz em ambiente seco. Duan e Griggs (2018) testaram o efeito da frequência de carregamento no tempo de vida à fadiga de um implante dentário de titânio com diâmetro padrão. O teste de fadiga com estresse constante realizado em água deionizada a 37°C foi conduzido em duas frequências (2 Hz e 15 Hz) com uma taxa de estresse de 0,1 até a fratura. A análise fractográfica mostrou que ambos os grupos apresentavam uma fratura combinada semelhante envolvendo parafuso e abutment e que não havia diferença estatística significativa no tempo de vida em fadiga entre 2 Hz e 15 Hz de carga sob condição úmida. Dessa forma, a frequência de 15 Hz em condições úmidas é apropriada para ser usada, melhorando a eficiência do teste de fadiga do implante.

As propriedades do material de suporte também devem ser consideradas quando forem utilizados testes de fadiga para análise de implantes dentários, pois o módulo de elasticidades do material pode influenciar na vida útil em fadiga do implante dentário, e dessa forma, resultados clinicamente mais relevantes poderão ser obtidos. Importante mencionar que a norma ISO 14801 não determina o tipo de material de suporte para o implante em testes laboratoriais, apenas recomenda que o material apresente um módulo de Young maior que 3 GPa (DUAN e GRIGGS, 2018).

Costelas bovinas já vem sendo utilizadas em projetos desenvolvidos na área de implantodontia devido a semelhança com o osso mandibular humano, em especial quanto a densidade óssea e a composição do tecido ósseo cortical e esponjoso (EL-KHOLEY *et al.*, 2017; GEHRKE *et al.*, 2018; RAZAVI *et al.*, 2010; YACKER e KLEIN, 1997), sendo considerado o material que mais se aproxima ao tecido ósseo humano (BULLON *et al.*, 2015). Outros pontos favoráveis podem ser apontados,

25

como a facilidade de obtenção do material, a forma anatômica semelhante ao osso mandibular (GONZÁLEZ-MARTÍN *et al.*, 2016) e, por não ser tecido humano, facilita a análise nos comitês de ética em pesquisa (FERRI *et al.*, 2015; MONTERO-AGUILAR *et al.*, 2019).

Considerando o seu tamanho, a costela bovina pode apresentar diferentes qualidades ósseas, tornando necessário a utilização de métodos para sua classificação e posterior comparação ao osso mandibular humano. O método mais utilizado faz uma análise macroestrutural baseando-se na quantidade de osso cortical versus osso esponjoso, apresentando quatro tipos diferentes de tecido ósseo, conforme proposto por Lekholm e Zarb (PÉREZ-PEVIDA *et al.*, 2019). Para uma análise microestrutural pode-se utilizar a escala de Hounsfield através de tomografia computadorizada ou cone bean (YACKER e KLEIN, 1997) e através de microtomografia avaliando a fração de volume ósseo, ambas para comparar a densidade óssea entre os espécimes. A avaliação por meio da fração de volume ósseo com o auxílio de microtomografia apresenta uma precisão superior aos outros métodos para estimar a densidade das amostras ósseas (OVESY *et al.*, 2020; VOUMARD *et al.*, 2019).

Os métodos e análises mecânicas in vitro mais comumente utilizadas são o monotônico (de carga única) até a falha e os testes de fadiga (BONFANTE e COELHO, 2016).

Shemtov-Yona e Rittel (2016) avaliaram a influência do ambiente na integridade mecânica dos implantes dentários de titânio. Foram utilizados 4 meios: ar seco, saliva artificial, saliva artificial com 250 ppm de flúor, e solução salina (0,9%). Inicialmente foi realizado um teste monotônico quase-estático, onde os implantes foram carregados até a fratura ou deformação permanente significativa, acompanhada de queda

perceptível da carga. Essa carga foi registrada como "carga de falha" e foi usada para definir o limite no teste cíclico subsequente. Um carregamento de espectro aleatório foi utilizado para avaliar o desempenho em fadiga funcional dos implantes dentários, com o objetivo de mimetizar a dinâmica da mastigação como uma alternativa mais "natural" à fadiga cíclica de carga constante. Um total de 10 implantes foram testados em cada meio até a fratura. Todos os implantes fraturaram no mesmo local, ou seja, na segunda rosca do implante. As amostras foram analisadas por fractografia qualitativa e quantitativa. Qualitativamente, as superfícies de fratura foram divididas em regiões de fadiga e de sobrecarga, tendo início da fratura na região de fadiga, onde foi observado estrias leves indicando múltiplos locais de origem, esses elementos desaparecem gradualmente com a propagação da trinca em direção à zona de sobrecarga. De forma quantitativa, foram avaliados o comprimento da trinca por fadiga e a taxa média de propagação da trinca, dividindo o comprimento da trinca pelo tempo total até a fratura completa. Não foi encontrado diferença no comprimento das trincas por fadiga entre os grupos, porém, o grupo em solução salina apresentou taxa média de propagação da trinca significativamente superior aos demais grupos.

Um outro estudo fez uma análise macroscópica da falha, realizando uma seção longitudinal metalográfica em 80 implantes fraturados após performance em fadiga. Shemtov-Yona *et al.* (2014b). Os grupos foram divididos por implantes com diâmetro de 3,3 mm, 3,75 mm e 5 mm. A avaliação macroscópica mostrou que os implantes de 3,3 mm fraturaram na segunda (52%) e na terceira (48%) roscas do corpo do implante, os implantes de 3,75 mm fraturaram no pescoço do corpo do implante (44,5%) e na segunda rosca do corpo do implante (55,5%), já todos os implantes de 5 mm fraturaram no parafuso de fixação e no pescoço do abutment. A pouca espessura de metal e defeitos agudos podem estar associados aos modos de falha encontrados.

O estudo de Bordin *et al.* (2018) teve como objetivo avaliar a influência do diâmetro do implante na confiabilidade e no modo de falha de implantes dentários extra curtos. Foram divididos três grupos de 21 implantes dentários extra curtos com diâmetros de 4,0 mm, 5,0 mm e 6,0 mm. Três implantes de cada grupo foram submetidos ao teste monotônico até a falha para permitir o planejamento do teste das outras 18 amostras por fadiga acelerada em step-stress. Não houve influência do diâmetro do implante na confiabilidade e no modo de falha dos implantes. As falhas das amostras restringiram-se ao abutment que foram avaliados fractograficamente sob microscopia eletrônica de varredura (MEV) demonstrando que a origem da fratura foi na superfície submetida à tração, ou seja, quando a tensão ultrapassou a resistência do titânio, foi criada uma zona deformação plástica. A propagação da trinca foi em direção da área submetida a tensão de compressão.

Duan *et al.* (2018) tiveram como objetivo validar o tempo de vida de fadiga de um sistema de implante dentário de diâmetro reduzido. Quinze implantes foram submetidos ao teste de fadiga cíclica por stepstress até a fratura. Após o teste, foi realizada a análise fractografica, e o resultados mostraram que todas a amostras tinham um modo de falha idêntico. Os espécimes falharam no corpo do implante ao nível do material de suporte, os abutments e os parafusos de conexão permaneceram intactos, sem qualquer afrouxamento ou dano perceptível. A superfície de fratura era composta por duas regiões distintas: uma região lisa próxima à origem da falha e uma região rugosa próxima à curva de compressão. Essas regiões indicavam uma falha de fadiga por flexão típica do metal. A análise em MEV mostrou que a origem da falha estava localizada na rosca do corpo do implante. Em grande magnificação podia se observar estrias típicas de fadiga na área adjacente à origem da ruptura, o que indicava as etapas de propagação da trinca por fadiga.

Resumindo, a falha do implante foi relatada com base na avaliação macroestrutural e análise fractográfica, indicando o local da fratura e os componentes envolvidos, e as características da superfície da fratura, como origem, término, direção, comprimento e taxa de propagação da trinca (SHEMTOV-YONA E RITTEL, 2016; SHEMTOV-YONA *et al.*, 2014a; SHEMTOV-YONA *et al.*, 2014b; BORDIN *et al.*, 2018; DUAN *et al.*, 2018; DUAN e GRIGGS, 2018).

### **3 PROPOSIÇÃO**

3.1 Objetivos gerais

Avaliar a sobrevivência em fadiga de implantes de diâmetro reduzido inseridos em dois materiais de suporte, costela bovina e polímero simulando osso.

3.2 Objetivos específicos

3.2.1 – Verificar a compatibilidade da costela bovina com o tecido ósseo humano.

3.2.2 – Verificar o coeficiente de estabilidade dos implantes instalados.

3.2.3 – Avaliar a sobrevivência em fadiga utilizando costela bovina e polímero simulando osso como material de suporte.

3.2.4 – Caracterizar o tipo de falha nos implantes fadigados.

A hipótese é de que os implantes de diâmetro reduzido inseridos em costela bovina apresentam um comportamento de fadiga semelhante as amostras de material de suporte a base de polímero simulando o osso.

## **4 MATERIAIS E MÉTODOS**

Este projeto faz parte de um macroprojeto que está sendo desenvolvido em conjunto com a Universidade do Mississippi - Medical Center (UMMC). O desenho experimental inclui uma parte do projeto (implante Biomet 3i instalado em polímero simulando osso) já avaliado na UMMC e vários experimentos-piloto foram essenciais no desenho metodológico do presente estudo.

Costelas bovinas foram adquiridas em açougues e limpas, mantendo somente o tecido ósseo. Blocos com cerca de 15 mm foram confeccionados com serra de mão do tipo arco e armazenados em freezer (-2 °C). No momento da utilização, para confecção das amostras, os blocos de osso eram descongelados em temperatura ambiente (Figura 2).



Figura 2. Costela bovina utilizada no experimento.

Conforme corroborado pela literatura, a costela de osso bovino foi selecionada para simular o osso da mandíbula humana como estrutura de suporte para implantes dentários (controle). Além disso, também atende aos requisitos da ISO 14801 sobre o módulo de elasticidade ( $\geq$  3 GPa). Foi realizada microtomografia (SkyScan 1172 micro-CT, Bruker, Bélgica) (Figura 3) com um tamanho de pixel de 17.30 µm para avaliar a fração de volume ósseo para determinar a densidade óssea da costela bovina utilizada. A costela bovina também foi classificada de acordo com a classificação de Lekholm e Zarb.



Figura 3. SkyScan 1172 micro-CT, Bruker, Bélgica.

Quatorze implantes Biomet 3i Osseotite MicroMiniplant (Figura 4), com plataforma hexagonal externa, diâmetro de 3,25 e comprimento de 15 mm foram instalados de acordo com a ISO 14801:2016 (Figura 5) em segmentos de costela bovina.



Figura 4. Biomet 3i Osseotite MicroMiniplant



**Figura 5.** Desenho esquemático do teste utilizado nesse estudo e proposto pela norma ISO 14801:2016.

Cavidades cilíndricas com 12 mm de profundidade foram preparadas em segmentos de costela bovina com o auxílio de um motor cirúrgico com controle de torque e um módulo de análise de frequência de ressonância integrado (Implantmed, W&H, Burmoos, Austria) com uma sequência de fresas determinada pelo fabricante: 1 – Round Drill 2 – ACT<sup>®</sup> Twist Drill 2.0 mm x 15.0 mm 3 – Pilot Drill 2.0/3.0 mm 4 – ACT<sup>®</sup>

Twist Drill 2.75 mm x 15 mm (Figura 6). Essa sequência de fresas conferiu cavidades com diâmetro de 3.0 mm na região de osso cortical e 2.75 mm na região de osso trabecular. A inserção dos implantes dentários foi realizada de forma manual, com catraca, a fim de obter torque de 35 N·cm. A margem cervical do implante dentário permaneceu 3 mm acima da margem cervical do nível ósseo, conforme orientação da norma ISO 14801:2016. Na sequência, um transdutor descartável específico (SmartPeg, W&H, Burmoos, Austria) foi instalado e o coeficiente de estabilidade do implante foi registrado pela análise de frequência de ressonância (Figura 7).



Figura 6. Motor cirúrgico e kit cirúrgico de implantes dentários 3i.



**Figura 7.** Análise de frequência por ressonância (Implantmed, W&H, Burmoos, Austria).

Pilares protéticos (Gold-Tite<sup>®</sup> Square UniScrew, Biomet 3i, Palm Beach Gardens, Flórida, Estados Unidos) foram instalados com torque de 32 N·cm (Figura 8).


Figura 8. Pilar protético instalado (torque 32 N<sup>.</sup>cm).

A amostra foi posicionada no centro de um cilindro de polivinil clorado (pvc). O correto posicionamento foi obtido com uma matriz (Figura 9). A matriz, em forma de cruz, foi posicionada sobre o cilindro, definindo o centro. Foi realizada uma perfuração com o mesmo diâmetro do pilar protético que foi posicionado na perfuração da matriz. Foi inserido resina epóxi ao redor da amostra dentro do cilindro abaixo do nível superior do bloco ósseo. Aguardou-se o tempo de cura da resina epóxi e removeu-se a amostra do cilindro (Figura 9).



Figura 9. Confecção do cilindro de resina epóxi para suporte da amostra.

Uma calota de carregamento de aço inoxidável (acorn nuts, Ace Hardware, Jackson, MS, EUA) foi colada na parte superior do pilar protético, usando acrílico autopolimerizável (QuickSet Acrylic, Allied High Tech Products, Rancho Dominguez, CA, EUA) com um momento de braço de alavanca de 11 mm. Para a obtenção do correto momento de braço de alanca, um dispositivo metálico com 3,87 mm foi fabricado e posicionado previamente a inserção da calota de carregamento (Figura 10). Os implantes dentários foram posicionados 3,0 mm acima da borda do material de suporte, para simular o pior cenário de reabsorção óssea (Figura 11).



Figura 10. Instalação da calota de carregamento.



Figura 11. Posicionamento 3 mm acima do nível cervical do osso.

Os implantes dentários foram submetidos ao teste de vida útil acelerado (accelerated lifetime – ALT) usando o método *step stress* de Nelson (Figuras 12 e 13). Os dados fornecidos pelo teste previamente realizado com o modelo de polímero simulando osso, associados à análise com o software ALTA PRO (Reliasoft), foram utilizados para selecionar as amplitudes de carga para o início do teste com costelas bovinas como material de suporte (n = 14). Todos os testes (Flextest 60, MTS, Eden Prairie, MN) foram realizados em meio seco, com taxa de carregamento (R) de 0,1, frequência de 2 Hz, momento de braço de alavanca de 11 mm e ângulo de aplicação de carga de 30º, conforme norma ISO 14801.



**Figura 12.** Amostra posicionada no dispositivo de teste de vida útil acelerado (ALT).



**Figura 13.** Amostras posicionadas na máquina de testes (Flextest 60, MTS, Eden Prairie, MN) para o teste de vida útil acelerado (ALT).

O método de estresse progressivo (step stress) foi desenvolvido inicialmente por Nelson como uma estratégia rápida de teste, garantindo que os tratamentos abranjam uma ampla faixa na qual se pode basear previsões de vida útil precisas, fazendo as seguintes suposições: que a relação entre vida útil de sobrevivência e amplitude de carga segue uma lei de potência inversa (IPL) e que os danos causados em diferentes períodos de tempo em diferentes amplitudes de carga são aditivos. Com base nessas suposicões, cada amostra foi submetida a uma amplitude de carga crescente ao longo do tempo, de modo que cada amostra experimentasse múltiplas amplitudes de carga. Perfis de carga com vários níveis de agressividade foram aplicados estrategicamente com base nos resultados anteriores do estudo usando com o modelo de polímero simulando osso como material de suporte, no ALTA PRO, prevendo a amplitude de carga correspondente a uma probabilidade de falha de 5% em 2 milhões de ciclos para o grupo de costelas bovinas. Como descrito acima, conforme a taxa de carregamento aumenta, o número de ciclos até a falha é registrado. Os dados de vida útil foram ajustados a um modelo de dano cumulativo com relação de lei de potência inversa entre amplitude de carga e vida útil usando o software ALTA PRO (Reliasoft, Tucson, AZ). A distribuição Weibull foi usada para modelar a variabilidade dos dados de vida útil (DUAN et al., 2018; DUAN e GRIGGS, 2018).

Todas as amostras fraturadas (Figura 14) foram cuidadosamente coletadas e limpas (Figura 15) usando um sonificador em água deionizada (Aquasonic 150T, VWR International, Radnor, PA) e armazenadas para análise fractográfica. As superfícies de fratura foram inicialmente examinadas em microscopia óptica digital (VHX-1000, Keyence, Osaka, Japão) para determinar, aproximadamente, a localização da fratura e a posição em relação ao osso. Após foram avaliadas em microscopia eletrônica de varredura (MEV) (Supra 40, Carl Zeiss, Jena, Alemanha) (Figura 16). As análises de fratura seguiram os princípios da fractografia para determinar o modo de falha das amostras fraturadas e as falhas foram classificadas de acordo com a norma ISO 14801:2016 e relatos prévios (SHEMTOV-YONA E RITTEL, 2016; SHEMTOV-YONA *et al.*, 2014a; SHEMTOV-YONA *et al.*, 2014b; BORDIN *et al.*, 2018; DUAN *et al.*, 2018; DUAN e GRIGGS, 2018).



Figura 14. Amostra fraturada após o teste.



Figura 15. Limpeza das amostras em banho sônico com água deionizada.



Figura 16. Microscopia eletrônica por varredura (MEV) das amostras fraturadas.

O modelo ósseo de polímero, que simula as propriedades mecânicas e a estrutura em camadas do osso maxilar humano, consiste em duas camadas com diferentes módulos elásticos (Figura 17): uma camada externa feita de um compósito a base de resina reforçada com fibra de vidro (G10, Piedmont Plastics, NC, EUA) simulando o osso cortical (E = 16 GPa), e uma parte interna confeccionada em resina epóxi (EpoxySet, Allied High Tech) simulando osso esponjoso (E = 6 GPa) (DUAN e GRIGGS, 2018; Santos RB *et al.*, 2024).



**Figura 17**. Projeto esquemático (DUAN e GRIGGS, 2018) do bloco de suporte de amostra (osso simulado) com uma estrutura em camadas para simular o osso da mandíbula humana. A camada externa (diâmetro: 25,4 mm) é feita de material composto G10 e a camada interna (diâmetro: 12,7 mm) é feita de resina epóxi.

## **5 RESULTADOS E DISCUSSÃO**

De acordo com a classificação de Lekholm e Zarb (PÉREZ-PEVIDA *et al.*, 2019), o modelo ósseo selecionado como material de suporte no presente estudo, costela bovina, pode ser classificado como tipo 2, com uma cortical compacta e uma porção medular densa (Figura 18).



**Figura 18.** Costela bovina com cortical compacta e porção medular densa. Medidas (em mm) apresentadas na imagem. A classificação como tipo 2 de Lekholm e Zarb é relevante pela associação com a obtenção de uma boa estabilidade primária do implante dentário, visto que uma baixa densidade óssea e um tecido cortical fino poderiam levar a uma diminuição do torque de inserção inicial (PUTRA *et al.*, 2024), impedindo o alcance do torque de inserção ideal do implante dentário.

Os resultados da análise por microtomografia da costela bovina estão representados na Tabela 1.

Tabela 1 – Resultados da análise por microtomografia.

Volume ósseo	Valor
TV- Tissue volume	7781.75 mm <sup>3</sup>
<b>BV- Bone volume</b>	2735.10 mm <sup>3</sup>
%BV/TV	35.14%

Os valores representativos da análise da fração do volume ósseo mostram uma semelhança entre o modelo ósseo de costela bovina e o tecido ósseo humano. A percentagem de volume ósseo (%BV/TV) de 35,14% é semelhante ao reportado para tecido ósseos sadios em outros estudos (NAZARIAN *et al.*, 2008; STOPPIE *et al.*, 2006; BERTL *et al.*, 2015; KIM e HENKIN, 2015). A análise de fração de volume ósseo oferece uma correlação forte com a resistência óssea e uma associação significativa positiva aos parâmetros mecânicos (ALOMARI *et al.*, 2018).

Os valores de torque de inserção e de Quociente de Estabilidade do Implante (ISQ) (Figura 19) estão apresentados na Tabela 2. A média do torque de inserção dos implantes foi de 34,57  $\pm$  1,08 N.cm e a média de ISQ foi de 75,07  $\pm$  3,81.

Amostra	Torque de inserção	ISQ			
1	35	74			
2	35	75			
3	35	81			
4	35	79			
5	35	78			
6	35	80			
7	32	73			
8	35	70			
9	35	78			
10	35	77			
11	35	71			
12	32	73			
13	35	73			
14	35	69			
Média	34.57	75.07			
Desvio Padrão	1.08	3.81			

Tabela 2 – Resultados de Torque de inserção e ISQ.



Figura 19. Exemplo de resultado de ISQ.

A análise de frequência por ressonância é uma importante ferramenta que podemos utilizar para verificar a estabilidade do implante dentário em diferentes intervalos de tempos, assim como também pode ser utilizada no final do tempo cirúrgico para verificar a estabilidade primária obtida. Índices de ISQ acima de 70 são considerados altos e permitem o carregamento imediato (LAGES *et al.*, 2018). A média de ISQ encontrada foi de 75,07, o que a torna ideal como estabilidade primária do implante dentário. Os bons resultados podem estar relacionados com a qualidade óssea, o comprimento e o macro design do implante dentário (HUANG e HUNZIKER *et al.*, 2020).

O número total de ciclos e os níveis de cargas utilizados nas amostras estão descritas na Tabela 3.

Tabela 3 – Números totais de ciclos em diferentes níveis de carga.

Cicles Totais		4083690	3302776	2018663	2010399	8029	3270	10853	13883	1754338	71917	52978	284575	60106	655843
	800 N														843
	780 N														1000
	09L N														1000
	740 N														1000
	720 N														1000
	700 N			663						338					1000
	089 Z			1000						1010					1000
	099 N			1000						1000					1000
	N 0510			1000						1000					1000
	620 N			0001						1000					1000
Carga	N 009		676	1000						10000					1000
Niveis de	580 N		1000	1000						1000					1000
ferentes	N 960	069	1000	1000						1000					0001
os em Di	540 N	1000	1000	0001						1000					0001
Cid	520 N	1000	1000	1000	668					1000					1000
	200 N	1000	1000	1000	1500	8029	3270	10853	13883	1000					1000
	480 N	1000	1000	1000	1000					1000					000
	460 N	1000	1000	1000	1000					1000					1000
	640 N	1000	1000	1000	1000					1000					0001
	420 N	1000	1000	1000	1000					1000					0001
	400 N	1000	1000	1000	1000					1731000	71917	52975	284575	620106	636000
	380 N	1000	1000	0001	1000										
	360 N	1000	1000	1000	1000										
	340 N	1000	1000	1000	1000										
Ciclos em Diferentes Nivvis de Carga	N 021	2100100	2000100	2100100	2000100										
	90 N	1000	000												
	$^{280}$ N	1000	0001												
	0.02 N	8	8												
	240 N	1010	1000												
	220 N	1000	1000												
	200 N	0001	8												
	81 N	1000	801												
	09 N	1000	1000												
	<u>8</u> x	1000	<u>00</u>												
	N 120	1000	8												
	N 001	122000	000611												
	N 08	1940000	1160000												
Amestra		-	2	~	*	wi	٠	p.,	ж	۰	9	=	2	9	4

A curva de vida útil vs. estresse para as amostras com costela bovina como material de suporte são apresentados na Figura 20, onde as linhas pontilhadas indicam os intervalos de confiança superiores e inferiores de 95%. Os parâmetros do modelo obtidos a partir dos resultados dos testes físicos são os seguintes: módulo de Weibull m = 0.54, que descreve a variabilidade dos dados, e o intervalo de confiança inferior é de 0.31 e o superior é de 0.92, ou seja, m= 0.54 (0.31, 0.92).



**Figura 20.** Curva de vida útil para amostras com costela bovina como material de suporte.





As amostras com costelas bovinas como material de suporte apresentaram uma maior sobrevida em fadiga do que as amostras com o modelo ósseo de polímero, porém não houve diferença significativa entre os materiais de suporte, dessa forma, a hipótese de que os materiais de suporte apresentariam comportamento semelhante a fadiga foi aceita. Essa ausência de diferença estatística está, provavelmente, relacionada a grande dispersão dos dados com redução do poder da amostra do grupo testado previamente (modelo ósseo a base de polímero).

A maior sobrevivência do modelo usando costela bovina está, provavelmente, associado a melhor adaptação do conjunto implante dentário/costela bovina no início do recebimento da carga de fadiga. As características intrínsecas do tecido ósseo, como o design tridimensional do trabeculado do osso esponjoso, possibilitando a adaptação do tecido ósseo e dissipando melhor as tensões geradas pelo teste de fadiga, podem ter sido relevantes nessa diferença com o modelo ósseo a base de polímero.

Considerando que o osso cortical é a camada externa do osso, rígida e densa, e o osso trabecular ou esponjoso é a parte interna com menor rigidez e maior flexibilidade, a perda crestal que ocorre no osso cortical ao redor da região cervical do implante dentário após o carregamento funcional, pode estar relacionada ao pequeno gap nessa mesma região entre implante e costela bovina logo após o início do teste de fadiga (SATPATHY *et al.*, 2022). O valor máximo de segurança para o deslocamento axial do pistão é um dos parâmetros configurados antes de iniciar o teste de fadiga. Esse valor precisou ser alterado devido a essa deformação inicial que ocorreu no osso cortical das amostras, levando a uma micromovimentação do implante gerando um gap entre implante e costela bovina, mas em pouco tempo ocorria uma adaptação, estabilizando o sistema em teste.

Outras duas possibilidades podem ter contribuído para os melhores resultados com costela bovina como suporte: (1) a qualidade óssea, classificada como osso tipo 2 Lekholm e Zarb (PÉREZ-PEVIDA et al., 2019) e um %BV/TV comparável ao tecido ósseo humano, e (2) a utilização de um implante longo, com 15 mm de comprimento, que pode ter gerado uma melhor dissipação das tensões para o material de suporte (LIU *et al.*, 2022).

Duan *et al.* (2018) também relatam uma forte influência do modulo de elasticidade do material de suporte na vida útil em fadiga de implantes. As propriedades dos materiais de suporte devem ser levadas em consideração, a fim de obter resultados mais clinicamente relevantes mesmo que o padrão ISO exija apenas módulo de elasticidade > 3 GPa. Quanto mais próximas as propriedades dos materiais de suporte, e mais semelhantes forem ao osso humano, mais precisa será a avaliação do desempenho de implantes a longo prazo.

A análise fractográfica mostrou que todos os espécimes falharam no corpo do implante logo abaixo do nível cervical do tecido ósseo de suporte. Os intermediários e os parafusos de conexão permaneceram intactos, sem afrouxamento ou danos detectáveis em todos os implantes fraturados. A Figura 21 mostra imagem de microscopia óptica de uma superfície de fratura típica. Um lado da superfície de fratura tem uma aparência relativamente lisa e plana (origem), enquanto o lado oposto tem uma aparência mais áspera e forma uma curvatura, identificada como curva de compressão (Figura 26), que é formada pela deflexão da fissura sob estresse compressivo, e a falha geralmente se origina no local de maior estresse de tração no lado oposto ao eixo neutro do estresse compressivo. Os resultados da MEV mostraram que a origem da falha estava localizada entre as roscas do corpo do implante (Figuras 22 e 23). Com ampliação mais baixa, esta área tinha uma aparência bastante lisa. Com ampliação mais alta, foram encontradas estrias de fadiga típicas (Figura 24) nesta área lisa adjacente à origem da falha, características da propagação da fratura por fadiga. Em volta desta área, a morfologia áspera e granular com muitos pontos característicos de coalescência de micro cavidades

(Figura 25) foi observada, o que indica uma propagação rápida da fratura por sobrecarga.



Figura 22. Fratura do corpo do implante observada com microscópio óptico.



Figura 23. Visão geral da superfície de fratura.



Figura 24. Área da origem da fratura.



Figura 25. Estriações de fadiga.



Figura 26. Micro cavidades na zona de fratura rápida.



Figura 27. Zona da curva de compressão (final da propagação da fratura).

Esse modo de falha corrobora com os achados de Duan *et al.* (2018), que também avaliaram a sobrevida em fadiga de implantes de diâmetro reduzido e as falhas ocorreram adjacentes ao nível ósseo, na parte mais estreita do corpo do implante próximo a segunda rosca. Também foi demonstrado, por simulação de elementos finitos (FEA), que essa região é onde estão os maiores níveis de tensão, sugerindo que a fratura no corpo do implante, e não nos componentes protéticos, ocorre devido ao diâmetro reduzido do implante. essa observação também é corroborada por Shemtov-Yona *et al.* (2014b), eles realizaram teste de fadiga com implantes de três diâmetros diferentes, 3.3, 3.75 e 5 mm, e somente os implantes de 3.3 mm tiveram todas as falhas na segunda e

terceira roscas do corpo do implante, enquanto nos implantes de 5 mm de diâmetro, as falhas ocorreram 100% nos pilares e parafusos protéticos.

O mecanismo de falha por fadiga parece ser predominante nas falhas de implantes dentários. Um estudo (SHEMTOV-YONA e RITTEL, 2014) avaliou 18 implantes que falharam in vivo, com 90% das amostras apresentando características típicas de falha por fadiga, estriações e micro cavidades do lado oposto, sugerindo que uma trinca por fadiga se propagou sob cargas cíclicas relativamente baixas até o ponto que uma fratura catastrófica ocorresse. Toda vez que uma trinca alcança um ponto crítico, a falha catastrófica ocorre.

É possível que ocorra uma fragilidade no conjunto implante/componentes protéticos na parte interna do implante dentário no espaço remanescente entre o final do parafuso de fixação do pilar protético e o assoalho da cavidade interna do implante. O completo preenchimento desse espaço pelo parafuso de fixação do pilar protético, poderia elevar a resistência do conjunto.

A fratura do implante dentário é rara, mas pode eventualmente acontecer. Ela atinge 0,2% a cada 1000 implantes instalados e a completa remoção do fragmento do implante é o tratamento mais comum indicado (TRIBST *et al.*, 2023).

## 6 CONCLUSÕES

A costela bovina se mostrou semelhante ao tecido ósseo humano, indicando o uso em testes laboratoriais.

Os implantes dentários obtiveram um ideal nível de estabilidade primária com a utilização das costelas bovinas como material de suporte.

A costela bovina obteve uma sobrevivência a fadiga superior, porém sem significância estatística em comparação ao material de polímero simulando osso (estudo prévio).

A fadiga promoveu danos que propagaram trincas de forma catastrófica nos corpos dos implantes dentários de diâmetro reduzido.

## REFERÊNCIAS

ALARIFI, A.; ALZUBI, A. A. Memetic search optimization along with genetic scale recurrent neural network for predictive rate of implant treatment. J Med Syst, v. 42, n. 11, p. 202, 2018.

ALLUM, S. R.; TOMLINSON, R. A.; JOSHI, R. The impact of loads on standard diameter, small diameter and mini implants: a comparative laboratory study. Clin Oral Implants Res, v. 19, n. 6, p. 553–559, 2008.

ALOMARI AH, WILLE ML, LANGTON CM. Bone volume fraction and structural parameters for estimation of mechanical stiffness and failure load of human cancellous bone samples; in-vitro comparison of ultrasound transit time spectroscopy and X-ray  $\mu$ CT. Bone. v.107, p. 145-153, 2018.

ANDERSEN, E; SAXEGAARD, E.; KNUTSEN, B. M.; HAANAES, H. R. A prospective clinical study evaluating the safety and effectiveness of narrow-diameter threaded implants in the anterior region of the maxilla. Int J Oral Maxillofac Implants, v. 16, n. 2, p. 217–224, 2001.

ANDERSEN, Eivind; HAANAES, H. R.; KNUTSEN, B. M. Immediate loading of single-tooth ITI implants in the anterior maxilla: a prospective 5-year pilot study. Clin Oral Implants Res, v. 13, n. 3, p. 281–287, 2002.

BAQAIN, Z. H.; MOQBEL, W. Y.; SAWAIR, F. A. Early dental implant failure: risk factors. Br J Oral Maxillofac Surg, v. 50, n. 3, p. 239–243, 2012.

BERTL K, HEIMEL P, RÖKL-RIEGLER M, HIRTLER L, ULM C, ZECHNER W. MicroCT-based evaluation of the trabecular bone quality

of different implant anchorage sites for masticatory rehabilitation of the maxilla. J Craniomaxillofac Surg. Jul v.43, n.6, p. 961-8, 2015.

BONFANTE, E.A.; COELHO, P.G. A critical perspective on mechanical testing of implants and prostheses. Adv Dent Res, v. 28, n. 1, p. 18-27, 2016.

BORBA, M.; CESAR, P.F.; GRIGGS, J.A.; DELLA BONA, A. Stepstress analysis for predicting dental ceramic reliability. Dent Mater, v. 29, n. 8, p. 913-8, 2013.

BORDIN, D.; BERGAMO, E.T.P.; BONFANTE, E.A.; FARDIN, V.P.; COELHO, P.G. Influence of platform diameter in the reliability and failure mode of extra-short dental implants. J Mech Behav Biomed Mater, v. 77, p. 470-474, 2018.

BULLON, B.; BUENO, E. F.; HERRERO, M.; FERNANDEZ-PALACIN, A.; RIOS, J. V.; BULLON, P.; GIL, F. J. Effect of irrigation and stainless steel drills on dental implant bed heat generation. J Mater Sci Mater Med, v. 26, n. 2, p. 1–10, 2015.

CAPODIFERRO, S.; FAVIA, G.; SCIVETTI, M.; DE FRENZA, G.; GRASSI, R. Clinical management and microscopic characterization of fatigue-induced failure of a dental implant. Case report. Head Face Med, v. 2, p. 18, 2006.

CORAZZA, P.H.; DUAN, Y.; KIMPARA, E.T.; GRIGGS, J.A.; DELLA BONA, A. Lifetime comparison of Y-TZP/porcelain crowns under different loading conditions. J Dent, v. 43, n. 4, p. 450-7, 2015.

DEGIDI, M.; PIATTELLI, A.; CARINCI, F. Clinical outcome of narrow diameter implants: a retrospective study of 510 implants. J Periodontol, v. 79, n. 1, p. 49-54, 2008.

SANTOS RB, LENZ U, GRIGGS JA, ESTRELA C, BUENO MDR, PORTO OCL, DELLA BONA A. Structural and torque changes in implant components of different diameters subjected to mechanical fatigue. Dent Mater. 2024 Jan 3:S0109-5641(23)00510-9.

DUAN, Y.; GONZALEZ, J. A.; KULKARNI, P. A.; NAGY, W. W.; GRIGGS, J. A. Fatigue lifetime prediction of a reduced-diameter dental implant system: Numerical and experimental study. Dent Mater, v. 34, n. 9, p. 1299–1309, 2018.

DUAN, Y.; GRIGGS, J. A. Effect of loading frequency on cyclic fatigue lifetime of a standard-diameter implant with an internal abutment connection. Dent Mater, v. 34, n. 12, p. 1711–1716, 2018.

DUONG HY, ROCCUZZO A, STÄHLI A, Salvi GE, LANG NP, SCULEAN A. Oral health-related quality of life of patients rehabilitated with fixed and removable implant-supported dental prostheses. Periodontol 2000. Feb v.88, n.1, p. 201-237, 2022.

EL-KHOLEY, K. E.; RAMASAMY, S.; SHEETAL KUMAR, R.; ELKOMY, A. Effect of simplifying drilling technique on heat generation during osteotomy preparation for dental implant. Implant Dent, v. 26, n. 6, p. 888–891, 2017.

FERRI, M.; LANG, N. P.; ANGARITA ALFONSO, E. E.; BEDOYA QUINTERO, I. D.; BURGOS, E. M.; BOTTICELLI, D. Use of sonic instruments for implant biopsy retrieval. Clin Oral Implants Res, v. 26, n. 11, p. 1237–1243, 2015.

GARCÍA-GONZÁLEZ M, BLASÓN-GONZÁLEZ S, GARCÍA-GARCÍA I, LAMELA-REY MJ, FERNÁNDEZ-CANTELI A, ÁLVAREZ-ARENAL Á. Optimized Planning and Evaluation of Dental Implant Fatigue Testing: A Specific Software Application. Biology (Basel).; v. 9, n.11, p. 1 – 12, 2020.

GEHRKE, S. A.; ARAMBURÚ JÚNIOR, J. S.; PÉREZ-ALBACETE MARTÍNEZ, C.; RAMIREZ FERNANDEZ, M. P.; MATÉ SÁNCHEZ DE VAL, J. E.; CALVO-GUIRADO, J. L. The influence of drill length and irrigation system on heat production during osteotomy preparation for dental implants: an ex vivo study. Clin Oral Implants Res, v. 29, n. 7, p. 772–778, 2018.

GERLACH, N. L.; MEIJER, G. J.; KROON, D.-J.; BRONKHORST, E. M.; BERGÉ, S. J.; MAAL, T. J. J. Evaluation of the potential of automatic

segmentation of the mandibular canal using cone-beam computed tomography. Br J Oral Maxillofac Surg, v. 52, n. 9, p. 838–844, 2014.

GLEIZNYS, A.; SKIRBUTIS, G.; HARB, A.; BARZDZIUKAITE, I.; GRINYTE, I. New approach towards mini dental implants and smalldiameter implants: an option for long-term prostheses. Stomatologija, v. 14, n. 2, p. 39-45, 2012.

GONZÁLEZ-MARTÍN, O.; OTEO, C.; ORTEGA, R.; ALANDEZ, J.; SANZ, M.; VELTRI, M. Evaluation of peri-implant buccal bone by computed tomography: an experimental study. Clin Oral Implants Res, v. 27, n. 8, p. 950–955, 2016.

GRIGGS, J. A. Dental Implants. Dent Clin North Am, v. 61, n. 4, p. 857–871, 2017.

HA, S.-R.; PARK, H. S.; KIM, E.-H.; KIM, H.-K.; YANG, J.-Y.; HEO, J.; YEO, I.-S. L. A pilot study using machine learning methods about factors influencing prognosis of dental implants. J Adv Prosthodont, v. 10, n. 6, p. 395–400, 2018.

HELKIMO, E.; CARLSSON, G. E.; HELKIMO, M. Bite force and state of dentition. Acta Odontol Scand, v. 35, n. 6, p. 297–303, 1977.

HUANG H, WU G, HUNZIKER E. The clinical significance of implant stability quotient (ISQ) measurements: A literature review. J Oral Biol Craniofac Res. v.10, n.4, p.629-638, 2020.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. Fatigue test for endosseous dental implants. 14801. Geneva, Switzerland, 2016.

JAVED, F.; ROMANOS, G. E. Role of implant diameter on long-term survival of dental implants placed in posterior maxilla: a systematic review. Clin Oral Investig, v. 19, n. 1, p. 1–10, 2015.

JOSHI, G.V.; DUAN, Y.; DELLA BONA, A.; HILL, T.J.; ST JOHN, K.; GRIGGS, J.A. Contributions of stress corrosion and cyclic fatigue to subcritical crack growth in a dental glass-ceramic. Dent Mater, v. 30, n. 8, p. 884-890, 2014.

KELLY, J. R.; CESAR, P. F.; SCHERRER, S. S.; DELLA BONA, A.; VAN NOORT, R.; THOLEY, M.; VICHI, A.; LOHBAUER, U. ADM guidance-ceramics: Fatigue principles and testing. Dent Mater, v. 33, n. 11, p. 1192–1204, 2017.

KIM YJ, HENKIN J. Micro-computed tomography assessment of human alveolar bone: bone density and three-dimensional micro-architecture. Clin Implant Dent Relat Res. v.17, n.2, p.307-13, 2015.

KIM, J.-E.; NAM, N.-E.; SHIM, J.-S.; JUNG, Y.-H.; CHO, B.-H.; HWANG, J. J.;. Transfer learning via deep neural networks for implant fixture system classification using periapical radiographs. J Clin Med, v. 9, n. 4, 2020.

LAGES FS,DE OLIVEIRA DW, COSTA FO. Relationship between implant stability measurements obtained by insertion torque and resonance frequency analysis: A systematic review. Clin Implant Dent Relat Res. Feb v.20, n.1, p. 26-33, 2018.

LINKOW, L. I.; DONATH, K.; LEMONS, J. E. Retrieval analyses of a blade implant after 231 months of clinical function. Implant Dent, v. 1, n. 1, p. 37–43, 1992.

LIU C, XING Y, LI Y, LIN Y, XU J, WU D. Bone quality effect on short implants in the edentulous mandible: a finite element study. BMC Oral Health. v.22, n.1, 2022.

MOAYERI, R. S.; KHALILI, M.; NAZARI, M. A Hybrid Method to Predict Success of Dental Implants. Int J Adv Comp Sci Appl, v. 7, n. 5, p. 1–6, 2016.

MONTERO-AGUILAR, M.; SIBAJA-RUIZ, L.; AVENDAÑO, E.; PEREIRA-REYES, R.; POZOS-GUILLÉN, A.; CHAVARRIA-BOLAÑOS, D. Evaluation of Surgical Bur Deformation and Bone Surface Roughness After Multiple Uses. J Oral Maxillofac Surg, v. 77, n. 9, p. 1894–1903, 2019.

MURDOCK, S. H.; HOQUE, M. N. Current patterns and future trends in the population of the United States: implications for dentistry and the dental profession in the twenty-first century. J Am Coll Dent, v. 65, n. 4, p. 29–35, 1998.

NAZARIAN A, VON STECHOW D, ZURAKOWSKI D, MÜLLER R, SNYDER BD. Bone volume fraction explains the variation in strength and stiffness of cancellous bone affected by metastatic cancer and osteoporosis. Calcif Tissue Int. Dec v.83, n.6, p. 368-79, 2008.

NELSON, W. Accelerated Life Testing - Step-Stress Models and Data Analyses. IEEE Trans Rehabil, v. R-29, n. 2, p. 103–108, 1980.

OLATE, S.; LYRIO, M. C. N.; DE MORAES, M.; MAZZONETTO, R.; MOREIRA, R. W. F. Influence of diameter and length of implant on early dental implant failure. J Oral Maxillofac Surg, v. 68, n. 2, p. 414–419, 2010.

ORTEGA-OLLER, I.; SUÁREZ, F.; GALINDO-MORENO, P.; TORRECILLAS-MARTÍNEZ, L.; MONJE, A.; CATENA, A.; WANG, H.-L. The influence of implant diameter on its survival: a meta-analysis based on prospective clinical trials. J Periodontol, v. 85, n. 4, p. 569–580, 2014.

OVESY, M.; AESCHLIMANN, M.; ZYSSET, P. K. Explicit finite element analysis can predict the mechanical response of conical implant press-fit in homogenized trabecular bone. J Biomech, v. 107,, 2020.

PENHA JUNIOR, N.L. Valor, mercado e preço em implantodontia. Implantes são todos iguais? Rev. Odontol. Univ. Cid. São Paulo, v. 29, n. 3, p. 260-7, 2017.

PÉREZ-PEVIDA, E.; BRIZUELA-VELASCO, A.; CHÁVARRI-PRADO, D.; DIÉGUEZ-PEREIRA, M.; JIMÉNEZ-GARRUDO, A.; MONTALBÁN-VADILLO, O.; VITERI-AGUSTÍN, I.; ESTRADA-MARTÍNEZ, A.; SANTAMARÍA-ARRIETA, G. Influence of time on primary stability of dental implants placed with osteotomes due to the elastic properties of peri-implant bone. J Dent Sci, v. 14, n. 4, p. 358–364, 2019. PIATTELLI, A.; PIATTELLI, M.; SCARANO, A.; MONTESANI, L. Light and scanning electron microscopic report of four fractured implants. Int J Oral Maxillofac Implants, v. 13, n. 4, p. 561–564, 1998a.

PIATTELLI, A.; SCARANO, A.; PIATTELLI, M.; VAIA, E.; MATARASSO, S. Hollow implants retrieved for fracture: a light and scanning electron microscope analysis of 4 cases. J Periodontol, v. 69, n. 2, p. 185–189, 1998b.

PUTRA RH, COORAY U, NURRACHMAN AS, YODA N, JUDGE R, PUTRI DK, ASTUTI ER. Radiographic alveolar bone assessment in correlation with primary implant stability: A systematic review and metaanalysis. Clinical Oral Implants Research, v.35, n.1, p. 1–20, 2024.

QUEK, C. E.; TAN, K. B.; NICHOLLS, J. I. Load fatigue performance of a single-tooth implant abutment system: effect of diameter. Int J Oral Maxillofac Implants, v. 21, n. 6, p. 929–936, 2006.

RAZAVI, T.; PALMER, R. M.; DAVIES, J.; WILSON, R.; PALMER, P. J. Accuracy of measuring the cortical bone thickness adjacent to dental implants using cone beam computed tomography. Clin Oral Implants Res, v. 21, n. 7, p. 718–725, 2010.

SATPATHY M, DUAN Y, BETTS L, PRIDDY M, GRIGGS JA. Effect of Bone Remodeling on Dental Implant Fatigue Limit Predicted Using 3D Finite Element Analysis. J Dent Oral Epidemiol. v. 2, v.1, 2022.

SCHIEGNITZ E, AL-NAWAS B. Narrow-diameter implants: A systematic review and meta-analysis. Clin Oral Impl Res. V.29, n.16, p. 21–40, 2018. Suplemento.

SHEMTOV-YONA, K.; RITTEL, D.; LEVIN, L.; MACHTEI, E.E. The effect of oral-like environment on dental implants' fatigue performance. Clin Oral Implants Res, v. 25, n. 2, p. 166-170, 2014a.

SHEMTOV-YONA K, RITTEL D, MACHTEI EE, LEVIN L. Effect of dental implant diameter on fatigue performance. Part II: failure analysis. Clin Implant Dent Relat Res. Apr v.16, n.2, p. 178-84, 2014b.

SHEMTOV-YONAN, K.; RITTEL, D. Fatigue failure of dental implants in simulated intraoral media. J Mech Behav Biomed Mater, v. 62, p. 636-644, 2016.

SHEMTOV-YONA K., RITTEL D., Identification of failure mechanisms in retrieved fractured dental implants, Engineering Failure Analysis. v.38, p. 58-65, 2014.

STOPPIE N, PATTIJN V, VAN CLEYNENBREUGEL T, WEVERS M, VANDER SLOTEN J, IGNACE N. Structural and radiological parameters for the characterization of jawbone. Clin Oral Implants Res. Apr v.17, n.2, p. 124-33, 2006.

SUKEGAWA, S.; YOSHII, K.; HARA, T.; YAMASHITA, K.; NAKANO, K.; YAMAMOTO, N.; NAGATSUKA, H.; FURUKI, Y. Deep neural networks for dental implant system classification. Biomolecules, v. 10, n. 7, 2020.

TAGGER GREEN, N.; MACHTEI, E. E.; HORWITZ, J.; PELED, M. Fracture of dental implants: literature review and report of a case. Implant Dent, v. 11, n. 2, p. 137–143, 2002.

TAKAHASHI, T.; NOZAKI, K.; GONDA, T.; MAMENO, T.; WADA, M.; IKEBE, K. Identification of dental implants using deep learning-pilot study. Int J Implant Dent, v. 6, n. 1, p. 53, 2020.

TRIBST JPM, WERNER A, BLOM EJ. Failed Dental Implant: When Titanium Fractures. Diagnostics (Basel). v.13, n.12, 2023.

VELÁSQUEZ-PLATA, D.; LUTONSKY, J.; OSHIDA, Y.; JONES, R. A close-up look at an implant fracture: a case report. Int J Periodontics Restor Dent, v. 22, n. 5, p. 483–491, 2002.

VOUMARD, B.; MAQUER, G.; HEUBERGER, P.; ZYSSET, P. K.; WOLFRAM, U. Peroperative estimation of bone quality and primary dental implant stability. J Mech Behav Biomed Mater, v.92, p. 24–32, 2019.

WIRZ, H.; TEUFELHART, S.; MCBETH, C.; GYURKO, R.; DIBART, S.; SAUER-BUDGE, A. Design and ex vivo characterization of narrow

implants with custom piezo-activated osteotomy for patients with substantial bone loss. Clin Exp Dent Res, v.6, n.3, p. 336–344, 2020.

WOELFEL, J. B.; SCHEID, R. C. Dental Anatomy: Its Relevance to Dentistry. 5.ed. Filadélfia: Williams & Wilkins, 1997. 459p.

YACKER, M. J.; KLEIN, M. The effect of irrigation on osteotomy depth and bur diameter. Int J Oral Maxillofac Implants, v.11, n.5, p. 634–8, 1997.

### **ARTIGO I**

Artigo a ser submetido a Dental Materials

# Sobrevivência em fadiga de implantes de diâmetro reduzido inseridos em diferentes materiais de suporte

#### Resumo

Objetivo: O estudo avaliou a sobrevivência em fadiga de implantes de diâmetro reduzido inseridos em dois materiais de suporte: costela bovina e polímero simulando osso.

Materiais e métodos: A costela bovina foi classificada de acordo com os critérios de Lekholm e Zarb com análise de fração óssea. Foram instalados quatorze implantes dentários em costelas bovinas como material de suporte, seguidos pela análise de frequência por ressonância e submissão ao teste de vida útil acelerado, utilizando o método step-stress. Os resultados obtidos foram comparados com os resultados de estudo anterior, no qual os implantes foram instalados em material de suporte a base de polímero simulando osso. Todas as amostras foram submetidas à análise fractográfica.

Resultados: Os resultados indicaram que a costela bovina apresentou semelhança com os maxilares humanos. Além disso, os implantes demonstraram um alto nível de estabilidade ( $75,07 \pm 3,81$ ). Embora os implantes instalados em costela bovina tenham apresentado uma maior sobrevida em fadiga em comparação com aqueles instalados em polímero simulando osso, não foi observada diferença estatisticamente significativa
entre os grupos. Destaca-se que todas as fraturas ocorreram no corpo do implante, caracterizando-se como fraturas por fadiga.

Significância: A costela bovina parece se mostrar um material de suporte superior para realização do teste de vida útil acelerado do que o material de polímero devido a um maior poder de confiança na dispersão dos dados da amostra.

Palavras-chave: Implantes Dentários; Fraturas por Fadiga; Fractografia.

#### 1. Introdução

Implantes de diâmetro reduzido são necessários para a substituição de dentes com pequeno diâmetro cervical, principalmente na região dos dentes anteriores inferiores. Nessa região, a largura da crista alveolar é frequentemente insuficiente para colocar um implante de diâmetro padrão [1,2]. A definição de um implante de diâmetro pequeno ou reduzido não é clara e varia de 3,3 mm [3,4] a 3,75 mm [5]. As taxas reais de falha dos implantes dentários são provavelmente maiores do que as taxas publicadas na literatura clínica e os implantes de diâmetro reduzido têm maior probabilidade de falha, especialmente quando o diâmetro é  $\leq$  3,75 mm [6]. Entretanto, é relevante mencionar que os implantes de diâmetro reduzido evitam a necessidade de cirurgia de aumento ósseo, o que, por conseguinte, elimina o custo adicional e a espera de seis meses antes da colocação do implante.

Considerando o mecanismo de complicações técnicas, vários estudos in vivo utilizando microscopia avançada concluíram que as falhas em implantes dentários mostraram um mecanismo de fadiga [7,8,9,10,11]. Não surpreende que a fadiga seja reconhecida como um dos principais motivos associados ao insucesso dos implantes dentários, visto que estão sujeitos a repetidas cargas funcionais (mastigatórias) e parafuncionais ao longo da vida útil na cavidade bucal [12]. A fadiga pode ser definida como o enfraquecimento de um componente estrutural sob a influência de tensões mecânicas, químicas, biológicas ou a combinação destas [13]. Atualmente, não existe um método disponível para detectar e monitorar trincas por fadiga no acompanhamento clínico de rotina, o que torna importante a realização de estudos in vitro de fadiga, que sejam eficazes, clinicamente relevantes e de baixo custo, para avaliar o comportamento de longo prazo dos implantes [14].

Para padronizar o teste que simula uma reabilitação com implantes dentários unitários, a ISO (International Organization for Standardization) (2016) [15] publicou a norma 14801 que requer, por exemplo, que (1) o dispositivo de teste deve prender a amostra a uma distância de  $3 \pm 0.5$  mm apicalmente ao nível ósseo nominal, (2) envolva materiais onde a fadiga por corrosão é esperada e (3) inclua componentes poliméricos. Água, solução salina e qualquer meio fisiológico alternativo (por exemplo, solução de Ringer) são aceitos para testes de fadiga. Tais soluções devem ser mantidas fluidas e a  $37^{\circ}C \pm 2^{\circ}C$  durante o teste [14,15]. É necessário descrever o padrão e, se possível, o processo de falha dos componentes do implante afetados (ISO 14801, 2016). A norma também determina que o teste deve ser realizado em uma frequência não superior a 2 Hz em meio líquido e não superior a 15 Hz em ambiente seco[15].

As propriedades do material de suporte também devem ser consideradas quando forem utilizados testes de fadiga para análise de implantes dentários, pois o módulo de elasticidades do material pode influenciar na vida útil em fadiga do implante dentário, e dessa forma, resultados clinicamente mais relevantes poderão ser obtidos. Importante mencionar que a norma ISO 14801 não determina o tipo de material de suporte para o implante em testes laboratoriais, apenas recomenda que o material apresente um módulo de Young maior que 3 GPa [14].

O objetivo deste trabalho foi avaliar a sobrevivência em fadiga de implantes de diâmetro reduzido inseridos em dois materiais de suporte, costela bovina e polímero simulando osso.

#### 2. Materiais e métodos

Quatorze amostras foram submetidas ao teste de vida útil acelerado (Flextest 60, MTS, Eden Prairie, MN) usando o método step stress de Nelson (2Hz, R = 0.1) até a fratura em ambiente seco. O teste foi realizado de acordo com a ISO 14801:2016 [15] (Figura 1). Cavidades cilíndricas com 3,0 mm de diâmetro e 12 mm de profundidade foram preparadas ) com uma sequência de fresas determinada pelo fabricante do implante utilizado (Biomet 3i Osseotite MicroMiniplant).em blocos de costela bovina com o auxílio de um motor cirúrgico com controle de torque e módulo de análise de frequência de ressonância integrado (Implantmed, W&H, Burmoos, Austria). O implante foi instalado com catraca, a fim de obter torque de 35 Ncm. Na sequência foi realizada análise de frequência por ressonância. Pilares protéticos (Gold-Tite® Square UniScrew, Biomet 3i, Palm Beach Gardens, Flórida, Estados Unidos) foram instalados com torque de 32 Ncm e calotas de carregamento de aço inoxidável foram coladas usando acrílico autopolimerizável (QuickSet Acrylic, Allied High Tech Products, Rancho Dominguez, CA, EUA) (Figura 2 e 3).



**Figura 1.** Desenho esquemático do teste utilizado nesse estudo e proposto pela norma ISO 14801:2016 [15].



**Figura 2.** Amostra posicionada no dispositivo de teste de vida útil acelerado (ALT).



**Figura 3.** Amostras posicionadas na máquina de testes (Flextest 60, MTS, Eden Prairie, MN) para o teste de vida útil acelerado (ALT).

Para avaliar a semelhança entre a estrutura da costela bovina e os ossos maxilares humanos, foram empregadas a análise de fração óssea e a classificação de Lekholm e Zarb [16].

Informações provenientes de um teste prévio, conduzido com um modelo de polímero simulando osso (Figura 4) como material de suporte para a instalação do implante, foram inseridas no software ALTA PRO (Reliasoft, Tucson, AZ) para análise. Em seguida, a amplitude de carga para o início do teste com costelas bovinas como material de suporte foi determinada com base nessa análise. Os dados de vida útil de ambos os grupos foram ajustados a um modelo de dano cumulativo, com relação de lei de potência inversa entre amplitude de carga e vida útil, utilizando o software ALTA PRO (Reliasoft, Tucson, AZ). Além disso, a distribuição Weibull foi empregada para modelar a variabilidade dos dados de vida útil, conforme descrito por DUAN et al. (2018) e DUAN e GRIGGS (2018)[12,14].



**Figura 4**. Projeto esquemático do bloco de suporte de amostra (osso simulado) com uma estrutura em camadas para simular o osso da mandíbula humana. A camada externa (diâmetro: 25,4 mm) é feita de material composto G10 e a camada interna (diâmetro: 12,7 mm) é feita de resina epóxi [14].

Todas as amostras fraturadas foram cuidadosamente coletadas e limpas utilizando um sonificador em água deionizada (Aquasonic 150T, VWR International, Radnor, PA) antes de serem armazenadas para análise fractográfica. As superfícies de fratura foram inicialmente examinadas em microscopia óptica digital (VHX-1000, Keyence, Osaka, Japão) para determinar, aproximadamente, a localização da fratura e sua relação com o osso. Em seguida, foram avaliadas em microscopia eletrônica de varredura (MEV) (Supra 40, Carl Zeiss, Jena, Alemanha).

#### 3. Resultados

De acordo com a classificação de Lekholm e Zarb [16], o modelo ósseo selecionado como material de suporte no presente estudo, a costela bovina, pode ser classificado como tipo 2, caracterizado por uma cortical compacta e uma porção medular densa (Figura 5).



**Figura 5.** Costela bovina com cortical compacta e porção medular densa. Medidas (em mm) apresentadas na imagem.

Os valores representativos da análise da fração do volume ósseo (conforme apresentado na Tabela 1) indicam uma similaridade entre o modelo ósseo de costela bovina e o tecido ósseo humano.

Tabela 1 - Resultados da análise por microtomografia.

Volume ósseo	Valor
TV- Tissue volume	7781.75 mm <sup>3</sup>
<b>BV- Bone volume</b>	2735.10 mm <sup>3</sup>
%BV/TV	35.14%

A média do torque de inserção dos implantes foi de  $34,57 \pm 1,08$ N·cm, enquanto a média do Índice de Estabilidade de Implantes (ISQ) foi de  $75,07 \pm 3,81$ .

A curva de vida útil vs. estresse para as amostras com costela bovina como material de suporte são apresentados na Figura 20, onde as linhas pontilhadas indicam os intervalos de confiança superiores e inferiores de 95%. Os parâmetros do modelo obtidos a partir dos resultados dos testes físicos são os seguintes: módulo de Weibull m = 0.54, que descreve a variabilidade dos dados, e o intervalo de confiança inferior é de 0.31 e o superior é de 0.92, ou seja, m= 0.54 (0.31, 0.92).



**Figura 6.** Curva de vida útil para amostras com costela bovina como material de suporte.

As amostras com costelas bovinas como material de suporte apresentaram uma maior sobrevida em fadiga em comparação com as amostras contendo o modelo ósseo de polímero; contudo, não foi observada diferença estatisticamente significativa entre os materiais de suporte (Figura 7).



**Figura 7.** Comparação entre os materiais de suporte. Linha verde – polímero simulando ósseo. Linha vermelha – costela bovina.

A análise fractográfica revelou que todos os espécimes falharam no corpo do implante logo abaixo do nível cervical do tecido ósseo de suporte. Os intermediários e os parafusos de conexão permaneceram intactos, sem afrouxamento ou danos detectáveis em todos os implantes fraturados. A Figura 8 mostra uma imagem de microscopia óptica de uma superfície de fratura típica. Uma das partes da superfície de fratura apresenta uma aparência relativamente lisa e plana (origem), enquanto o lado oposto exibe uma textura mais áspera e forma uma curvatura, identificada como curva de compressão, resultante da deflexão da fissura sob estresse compressivo. A falha geralmente se origina no local de maior estresse de tração, no lado oposto ao eixo neutro do estresse compressivo. Os resultados da Microscopia Eletrônica de Varredura (MEV) revelaram que a origem da falha estava localizada entre as roscas do corpo do implante (Figuras 9 e 10). Com uma ampliação mais baixa, essa área apresentava uma superfície relativamente lisa. Com uma ampliação mais alta, foram observadas estrias de fadiga típicas (Figura 11) nesta área lisa adjacente à origem da falha, características da propagação da fratura por fadiga. Ao redor dessa área, observou-se uma morfologia áspera e granular, com muitos pontos característicos de coalescência de microcavidades (Figura 12), indicando uma propagação rápida da fratura por sobrecarga, e a Zona da curva de compressão no lado oposto a origem da falha (Figura 13)



Figura 8. Fratura do corpo do implante observada com microscópio óptico.



Figura 9. Visão geral da superfície de fratura.



Figura 10. Área da origem da fratura.



Figura 11. Estriações de fadiga.



Figura 12. Micro cavidades na zona de fratura rápida.



Figura 13. Zona da curva de compressão (final da propagação da fratura).

#### 4. Discussão

A costela bovina foi classificada como tipo 2 de Lekholm e Zarb, isso é relevante devido à sua associação com a obtenção de uma boa estabilidade primária do implante dentário. Uma baixa densidade óssea e um tecido cortical fino poderiam levar a uma diminuição do torque de inserção inicial [17], o que por sua vez poderia comprometer o alcance do torque de inserção ideal do implante dentário. Da mesma forma, a percentagem de volume ósseo (%BV/TV) de 35,14% foi comparável aos valores relatados para tecidos ósseos saudáveis em outros estudos [18,19,20,21]. Vale ressaltar que a análise da fração de volume ósseo apresenta uma forte correlação com a resistência óssea e uma associação significativa positiva com os parâmetros mecânicos [22].

A análise de frequência por ressonância é uma ferramenta importante para avaliar a estabilidade do implante dentário em diferentes intervalos de tempo, sendo útil também ao final do procedimento cirúrgico para verificar a estabilidade primária alcançada. Índices de ISQ acima de 70 são considerados elevados e indicativos de condições favoráveis para carregamento imediato [23]. A média de ISQ encontrada, de 75,07, sugere uma estabilidade primária ideal para o implante dentário. Esses bons resultados podem estar associados à qualidade óssea, ao comprimento e ao macrodesign do implante dentário [24].

As costelas bovinas apresentaram um comportamento em fadiga semelhante ao modelo ósseo à base de polímero, não demonstrando diferença estatística entre eles. Essa similaridade pode estar relacionada à grande dispersão dos dados encontrados no grupo testado previamente (modelo ósseo à base de polímero), o que resultou na redução do poder da amostra do grupo.

Dado que o osso cortical constitui a camada externa do osso, caracterizada por sua rigidez e densidade, enquanto o osso trabecular ou esponjoso representa a parte interna, menos rígida e mais flexível, a perda crestal observada no osso cortical ao redor da região cervical do implante dentário após o carregamento funcional pode estar associada ao pequeno espaço nessa mesma região entre o implante e a costela bovina logo no

89

início do teste de fadiga [25]. O valor máximo de segurança para o deslocamento axial do pistão é um dos parâmetros pré-configurados antes de iniciar o teste de fadiga. Esse valor precisou ser ajustado devido à deformação inicial ocorrida no osso cortical das amostras, que resultou em uma micromovimentação do implante e na formação de um espaço entre o implante e a costela bovina. No entanto, com o passar do tempo, ocorreu uma adaptação, estabilizando o sistema em teste.

Outras duas possibilidades podem ter contribuído para os melhores resultados com a costela bovina como suporte: (1) a qualidade óssea, classificada como osso tipo 2 segundo a classificação de Lekholm e Zarb [16], e um percentual de volume ósseo comparável ao tecido ósseo humano; e (2) a utilização de um implante longo, com 15 mm de comprimento, o que pode ter proporcionado uma melhor dissipação das tensões para o material de suporte [26].

Duan et al. (2018) [12] também destacam a forte influência do módulo de elasticidade do material de suporte na vida útil em fadiga dos implantes. É crucial considerar as propriedades dos materiais de suporte para obter resultados clinicamente relevantes, mesmo que o padrão ISO exija apenas um módulo de elasticidade superior a 3 GPa. Quanto mais próximas as propriedades dos materiais de suporte estiverem das do osso humano, mais precisa será a avaliação do desempenho dos implantes a longo prazo.

Todas as falhas foram catastróficas e ocorreram no corpo do implante logo abaixo do nível cervical do tecido ósseo de suporte. Os intermediários e os parafusos de conexão permaneceram intactos, sem afrouxamento ou danos detectáveis em todos os implantes fraturados. Esse modo de falha corrobora com os achados de Duan et al. (2018) [12], que também avaliaram a sobrevida em fadiga de implantes de diâmetro reduzido, onde as falhas ocorreram adjacentes ao nível ósseo, na parte mais estreita do corpo do implante próximo à segunda rosca. Além disso, por meio de simulação de elementos finitos (FEA), foi demonstrado que essa região apresenta os maiores níveis de tensão, sugerindo que a fratura no corpo do implante, e não nos componentes protéticos, ocorre devido ao diâmetro reduzido do implante. Essa observação também é corroborada por Shemtov-Yona et al. (2014) [27], que realizaram teste de fadiga com implantes de três diâmetros diferentes (3.3, 3.75 e 5 mm), sendo que apenas os implantes de 3.3 mm apresentaram falhas nas segunda e terceira roscas do corpo do implante, enquanto nos implantes de 5 mm de diâmetro, as falhas ocorreram exclusivamente nos pilares e parafusos protéticos.

O mecanismo de falha por fadiga parece ser predominante nas falhas de implantes dentários. Um estudo conduzido por Shemtov-Yona e Rittel (2014) [28] avaliou 18 implantes que falharam in vivo, constatando que 90% das amostras apresentavam características típicas de falha por fadiga, como estriações e microcavidades no lado oposto. Isso sugere que uma trinca por fadiga se propagou sob cargas cíclicas relativamente baixas até o ponto em que ocorreu uma fratura catastrófica. Toda vez que uma trinca atinge um ponto crítico, a falha catastrófica ocorre.

É possível que ocorra uma fragilidade no conjunto implante/componentes protéticos na parte interna do implante dentário no espaço remanescente entre o final do parafuso de fixação do pilar protético e o assoalho da cavidade interna do implante. O completo preenchimento desse espaço pelo parafuso de fixação do pilar protético, poderia elevar a resistência do conjunto.

A fratura do implante dentário é um evento raro, mas pode ocorrer eventualmente. Estima-se que atinja 0,2% a cada 1000 implantes instalados, conforme indicado por Tribst et al. (2023) [29]. O tratamento mais comum recomendado para essa situação é a completa remoção do fragmento do implante.

#### 5. Conclusão

A costela bovina demonstrou semelhança com o tecido ósseo humano, sugerindo sua utilidade em testes laboratoriais. Os implantes dentários alcançaram um nível ideal de estabilidade primária com o uso de costelas bovinas como material de suporte. Embora as costelas bovinas tenham apresentado uma maior resistência à fadiga em comparação ao material de polímero simulando osso em um estudo prévio, essa diferença não foi estatisticamente significativa. Durante os testes de fadiga, observou-se a propagação catastrófica de trincas nos corpos dos implantes dentários de diâmetro reduzido.

#### Referências

[1] OLATE, S.; LYRIO, M. C. N.; DE MORAES, M.; MAZZONETTO, R.; MOREIRA, R. W. F. Influence of diameter and length of implant on early dental implant failure. J Oral Maxillofac Surg, v. 68, n. 2, p. 414–419, 2010.

[2] WOELFEL, J. B.; SCHEID, R. C. Dental Anatomy: Its Relevance to Dentistry. 5.ed. Filadélfia: Williams & Wilkins, 1997. 459p.

[3] GLEIZNYS, A.; SKIRBUTIS, G.; HARB, A.; BARZDZIUKAITE, I.; GRINYTE, I. New approach towards mini dental implants and small-diameter implants: an option for long-term prostheses. Stomatologija, v. 14, n. 2, p. 39-45, 2012.

[4] ORTEGA-OLLER, I.; SUÁREZ, F.; GALINDO-MORENO, P.; TORRECILLAS-MARTÍNEZ, L.; MONJE, A.; CATENA, A.; WANG, H.-L. The influence of implant diameter on its survival: a metaanalysis based on prospective clinical trials. J Periodontol, v. 85, n. 4, p. 569–580, 2014.

[5] DEGIDI, M.; PIATTELLI, A.; CARINCI, F. Clinical outcome of narrow diameter implants: a retrospective study of 510 implants. J Periodontol, v. 79, n. 1, p. 49-54, 2008.

[6] GRIGGS, J. A. Dental Implants. Dent Clin North Am, v. 61, n. 4, p. 857–871, 2017.

[7] LINKOW, L. I.; DONATH, K.; LEMONS, J. E. Retrieval analyses of a blade implant after 231 months of clinical function. Implant Dent, v. 1, n. 1, p. 37–43, 1992.

[8] PIATTELLI, A.; SCARANO, A.; PIATTELLI, M.; VAIA, E.; MATARASSO, S. Hollow implants retrieved for fracture: a light and scanning electron microscope analysis of 4 cases. J Periodontol, v. 69, n. 2, p. 185–189, 1998b.

[9] VELÁSQUEZ-PLATA, D.; LUTONSKY, J.; OSHIDA, Y.; JONES, R. A close-up look at an implant fracture: a case report. Int J Periodontics Restor Dent, v. 22, n. 5, p. 483–491, 2002.

[10] TAGGER GREEN, N.; MACHTEI, E. E.; HORWITZ, J.; PELED, M. Fracture of dental implants: literature review and report of a case. Implant Dent, v. 11, n. 2, p. 137–143, 2002.

[11] CAPODIFERRO, S.; FAVIA, G.; SCIVETTI, M.; DE FRENZA, G.; GRASSI, R. Clinical management and microscopic characterization of fatigue-induced failure of a dental implant. Case report. Head Face Med, v. 2, p. 18, 2006.

[12] DUAN, Y.; GONZALEZ, J. A.; KULKARNI, P. A.; NAGY,
W. W.; GRIGGS, J. A. Fatigue lifetime prediction of a reduced-diameter dental implant system: Numerical and experimental study. Dent Mater, v. 34, n. 9, p. 1299–1309, 2018.

[13] KELLY, J. R.; CESAR, P. F.; SCHERRER, S. S.; DELLA
BONA, A.; VAN NOORT, R.; THOLEY, M.; VICHI, A.; LOHBAUER,
U. ADM guidance-ceramics: Fatigue principles and testing. Dent Mater,
v. 33, n. 11, p. 1192–1204, 2017.

[14] DUAN, Y.; GRIGGS, J. A. Effect of loading frequency on cyclic fatigue lifetime of a standard-diameter implant with an internal abutment connection. Dent Mater, v. 34, n. 12, p. 1711–1716, 2018.

[15] INTERNATIONAL ORGANIZATION FORSTANDARDIZATION. Fatigue test for endosseous dental implants.14801. Geneva, Switzerland, 2016.

[16] PÉREZ-PEVIDA, E.; BRIZUELA-VELASCO, A.; CHÁVARRI-PRADO, D.; DIÉGUEZ-PEREIRA, M.; JIMÉNEZ-GARRUDO, A.; MONTALBÁN-VADILLO, O.; VITERI-AGUSTÍN, I.; ESTRADA-MARTÍNEZ, A.; SANTAMARÍA-ARRIETA, G. Influence of time on primary stability of dental implants placed with osteotomes due to the elastic properties of peri-implant bone. J Dent Sci, v. 14, n. 4, p. 358–364, 2019.

[17] PUTRA RH, COORAY U, NURRACHMAN AS, YODA N, JUDGE R, PUTRI DK, ASTUTI ER. Radiographic alveolar bone assessment in correlation with primary implant stability: A systematic review and meta-analysis. Clinical Oral Implants Research, v.35, n.1, p. 1–20, 2024.

[18] NAZARIAN A, VON STECHOW D, ZURAKOWSKI D, MÜLLER R, SNYDER BD. Bone volume fraction explains the variation in strength and stiffness of cancellous bone affected by metastatic cancer and osteoporosis. Calcif Tissue Int. Dec v.83, n.6, p. 368-79, 2008.

[19] STOPPIE N, PATTIJN V, VAN CLEYNENBREUGEL T, WEVERS M, VANDER SLOTEN J, IGNACE N. Structural and radiological parameters for the characterization of jawbone. Clin Oral Implants Res. Apr v.17, n.2, p. 124-33, 2006.

[20] BERTL K, HEIMEL P, RÖKL-RIEGLER M, HIRTLER L, ULM C, ZECHNER W. MicroCT-based evaluation of the trabecular bone quality of different implant anchorage sites for masticatory rehabilitation of the maxilla. J Craniomaxillofac Surg. Jul v.43, n.6, p. 961-8, 2015.

[21] KIM YJ, HENKIN J. Micro-computed tomography assessment of human alveolar bone: bone density and three-dimensional micro-architecture. Clin Implant Dent Relat Res. Apr v.17, n.2, p.307-13, 2015.

[22] ALOMARI AH, WILLE ML, LANGTON CM. Bone volume fraction and structural parameters for estimation of mechanical stiffness and failure load of human cancellous bone samples; in-vitro comparison of ultrasound transit time spectroscopy and X-ray  $\mu$ CT. Bone. Feb v.107, p. 145-153, 2018.

[23] LAGES FS,DE OLIVEIRA DW, COSTA FO. Relationship between implant stability measurements obtained by insertion torque and resonance frequency analysis: A systematic review. Clin Implant Dent Relat Res. Feb v.20, n.1, p. 26-33, 2018. [24] HUANG H, WU G, HUNZIKER E. The clinical significance of implant stability quotient (ISQ) measurements: A literature review. J Oral Biol Craniofac Res. Oct-Dec v.10, n.4, p.629-638, 2020.

[25] SATPATHY M, DUAN Y, BETTS L, PRIDDY M, GRIGGS JA. Effect of Bone Remodeling on Dental Implant Fatigue Limit Predicted Using 3D Finite Element Analysis. J Dent Oral Epidemiol. 2022; v. 2,( v.1):10.54289/jdoe2200102, 2022.

[26] LIU C, XING Y, LI Y, LIN Y, XU J, WU D. Bone quality effect on short implants in the edentulous mandible: a finite element study.BMC Oral Health. Apr 26;v.22, (n.1):139, 2022.

[27] SHEMTOV-YONA K, RITTEL D, MACHTEI EE, LEVIN L. Effect of dental implant diameter on fatigue performance. Part II: failure analysis. Clin Implant Dent Relat Res. Apr v.16, n.2, p. 178-84, 2014.

[28] SHEMTOV-YONA K., RITTEL D., Identification of failure mechanisms in retrieved fractured dental implants, Engineering Failure Analysis. v.38, p. 58-65, 2014.

[29] TRIBST JPM, WERNER A, BLOM EJ. Failed Dental Implant: When Titanium Fractures. Diagnostics (Basel). Jun 20;v.13, (n.12, ):2123. 2023.

# **ARTIGO II**

Submetido ao Journal of Periodontal & Implant Science

# The state of the art on the artificial intelligence applied to dental implantology: a systematic review

Pedro Henrique Wentz Tretto; Giovani Enderle Morandi; Jason Alan Griggs; Alvaro Della Bona

# Abstract

This systematic review aimed to identify and discuss AI applications in implant dentistry. A comprehensive search was conducted on three databases (MEDLINE/PubMed, Embase, and Web of Science) with no restriction on the year of publication. The last search was performed on July 21st, 2023, to compile the available literature regarding the role of AI in implant dentistry. Out of 7828 articles initially screened, 53 papers met the eligibility criteria. AI is making significant contributions in five key domains: dental implant identification, treatment planning, treatment outcome predictions, patient and implant parameter evaluations, and design optimization. The identification of dental implants

emerged as the most extensively studied subject, showing the most promising results.

**Keywords**: Artificial intelligence; Dental implant; Computer neural networks

## **1. Introduction**

The use of artificial intelligence (AI) is a reality in our daily lives, even if it goes unnoticed on most occasions. Movie suggestions on Netflix, virtual assistants on our cell phones and advertisements for products or services of interest while browsing social networks are examples of this technology as part of daily activities.

AI presents the ability of machines or computer systems to simulate human behavior or intelligence, performing tasks that require cognition, such as decision-making, speech recognition and visual perception (1,2). In healthcare, the focus is on specific AI systems to address a unique or limited task, with human guidance still required. However, due to a lack of genuine intellectual autonomy, limited AI systems are allied to human knowledge and clinical practice, making the man/machine set more proficient in complex decision-making tasks (3).

For the majority of applications, AI can be implemented through machine learning (ML), where deep learning (DL) is a specific subset that utilizes artificial neural networks (ANNs). ML focuses on how computers learn from data (4,5). Learning can be supervised, unsupervised, or reinforced. It is supervised whenever data and data labels (outputs) are provided and the ML model is interactively optimized to represent the pair of data labels. It can be unsupervised, being developed to understand the structure and relationships between input resources, and identifying patterns. Reinforcement learning identifies a sequence of actions to increase the probability of reaching a predetermined aim.

DL is a subset of ML that has a complex layer arrangement system and a greater number of interconnected artificial neurons in the convolutional layers, which makes it capable of visualizing simple features such as lines, edges, corners and macroscopic patterns in a hierarchical structure (6,7), which favors its use for dimensional analysis and diagnostics.

ANN was also created based on the brain structure and can mimic the human brain (7,8). The main constituent of any ANN is the artificial neuron, which is usually a non-linear mathematical model inspired by the human neuron. A network is designed to solve tasks, such as stacking and concatenating artificial neurons, and connecting the layers using mathematical operations (9).

In health sciences, AI has already encompassed several medical specialties. A systematic review (10) on the impact of ML on patient care showed that 17% of the literature is related to oncology, however, neurology, cardiology, intensive care,

99

neurosurgery and general surgery are also important fields on the subject representing more than 50% of the literature. Although AI is not yet a popular subject in Dentistry, it is being applied for disease identification, image segmentation, image correction and color biomimetic analysis and modeling, creating robust systems to facilitate high-performance decision-making by dentists (10,11). In implant dentistry, a 2021 systematic review identified seventeen studies on the subject. Seven studies scrutinized AI models for the recognition of dental implant types, using periapical and panoramic radiographic images and achieving an accuracy level between 93.8% and 98%. Seven additional studies investigated AI models developed to predict the success of dental implants, yielding results ranging from 62.4% to 80.5%, and three studies assessed AI for the optimization of implant designs, demonstrating the applicability of AI for this purpose (12).

In daily practice, dentists must use their best knowledge to diagnose and offer the best treatment options, predicting adequate prognosis. Therefore, AI can be of great assistance for better performance in dental clinical care (10). Thus, the objective of this systematic review was to identify and evaluate the effectiveness of AI applications on implant dentistry.

### 2. Materials and methods

This review was conducted based on the following question: "What are the state-of-the-art applications of artificial intelligence in dental implantology?"

## 2.1. Protocol and registration

The protocol of this review was based on PRISMA-P for systematic review protocols (13). The present review was not registered.

## 2.2. Eligibility criteria

The present review included clinical and laboratory studies published in English language that used artificial intelligence focusing on dental implantology. In contrast, studies not applying AI to dental implantology, reviews, systematic reviews, specialist opinion, manufacturer reports, editorials, conference abstracts and in-press papers were excluded from this review.

## 2.3. Information sources and search strategy

Electronic search was conducted in three different databases (MEDLINE/PubMed, Embase and Web of Science) with no restriction for year of publication, and the last search was performed on July 21st, 2023. The search strategy was outlined based on PubMed MeSH terms and adapted for each database.

MEDLINE/PubMed: "Artificial Intelligence" [MESH] OR "Intelligence, Artificial" OR "Computational Intelligence" OR "Intelligence, Computational" OR "Machine Intelligence" OR "Intelligence, Machine" OR "Computer Reasoning" OR "Reasoning, Computer" OR "AI (Artificial Intelligence)" OR "Computer Vision Systems" OR "Computer Vision System" OR "System, Computer Vision" OR "Systems, Computer Vision" OR "Vision System, Computer" OR "Vision Systems, Computer" OR "Knowledge Acquisition (Computer)" OR "Acquisition, Knowledge (Computer)" OR "Knowledge Representation (Computer)" OR "Knowledge Representations (Computer)" OR "Representation, Knowledge (Computer)" "Machine OR Learning" [MESH] OR "Learning, Machine" OR "Transfer Learning" OR "Learning, Transfer" OR "Deep Learning" [MESH] OR "Learning, Deep" OR "Hierarchical Learning" OR "Learning, Hierarchical" AND Dentistry [MESH] OR "Dental Equipment" OR "Dental Instruments" OR "Economics, Dental" OR "Education, Dental" OR "History of Dentistry" OR "Legislation, Dental" OR "Oral Medicine" OR "Dental Implants" [MESH] OR "Implants, Dental" OR "Dental Implant" OR "Implant, Dental" OR "Dental Prostheses, Surgical" OR "Dental Prosthesis, Surgical" OR "Surgical Dental Prostheses" OR "Surgical Dental Prosthesis" OR "Prostheses, Surgical Dental" OR "Prosthesis, Surgical Dental" OR "Dental Surgery" OR "Surgery, Oral" [MESH] OR "Maxillofacial Surgery" OR "Surgery, Maxillofacial" OR "Oral Surgery" OR "Exodontics"

Embase and Web of Science: "Artificial Intelligence" OR "Intelligence, Artificial" OR "Computational Intelligence" OR "Intelligence, Computational" OR "Machine Intelligence" OR "Intelligence, Machine" OR "Computer Reasoning" OR "Reasoning, Computer" OR "AI (Artificial Intelligence)" OR "Computer Vision Systems" OR "Computer Vision System" OR "System, Computer Vision" OR "Systems, Computer Vision" OR "Vision System, Computer" OR "Vision Systems, Computer" OR Acquisition (Computer)" OR "Acquisition, "Knowledge Knowledge (Computer)" OR "Knowledge Representation (Computer)" OR "Knowledge Representations (Computer)" OR (Computer)" OR "Machine "Representation, Knowledge Learning" OR "Learning, Machine" OR "Transfer Learning" OR "Learning, Transfer" OR "Deep Learning" OR "Learning, Deep" OR "Hierarchical Learning" OR "Learning, Hierarchical" AND Dentistry OR "Dental Equipment" OR "Dental Instruments" OR "Economics, Dental" OR "Education, Dental" OR "History of Dentistry" OR "Legislation, Dental" OR "Oral Medicine" OR "Dental Implants" OR "Implants, Dental" OR "Dental Implant" OR "Implant, Dental" OR "Dental Prostheses, Surgical " OR "Dental Prosthesis, Surgical" OR "Surgical Dental Prostheses" OR "Surgical Dental Prosthesis" OR "Prostheses, Surgical Dental" OR

"Prosthesis, Surgical Dental" OR "Dental Surgery" OR "Surgery, Oral" OR "Maxillofacial Surgery" OR "Surgery, Maxillofacial" OR "Oral Surgery" OR "Exodontics"

### 2.4. Screening and selection

The search was initially conducted using Mendeley Program. Two researchers (P.H.W.T. and G.E.M.) independently identified articles analyzing titles and abstracts for relevance and the presence of eligibility criteria. Retrieved records were classified as "include", "exclude", or "uncertain". The full-text articles of the "include" and "uncertain" records were selected for further screening by eligibility the same researchers (acting independently). Discrepancies in the screening of titles/abstracts and full-text articles were resolved through discussion. In case of disagreement, the opinion of a third reviewer (A.D.B.) was obtained. In case of missing information or data, the corresponding author from such papers was contacted up to three times by e-mail.

## 2.5. Data extraction

The articles meeting the inclusion criteria were subjected to critical appraisal, which was carried out by two reviewers (P.H.W.T. and G.E.M.) independently. A standardized data extraction form was used to collect the following data:

- Publication information: authors, Country where the work was executed (based on the Institution location of the corresponding author), year and journal of publication.
- Artificial intelligence methods used: Convolutional Neural Network (CNN), Artificial Neural Network (ANN), Deep Learning (DL), which are subsets of Machine Learning (ML). Although CNNs, ANNs, and DL are considered subsets of machine learning (ML) methodologies, the present review is using the terminology employed by the original studies.
- Applications: reasons for using AI.
- Original data used: Type of data used to power the AI.
- Study objectives: The main objective of the included studies.
- Study results: Reported results from the included studies.

# 2.6 Data analysis

This study focused on describing the use of AI applications in implant dentistry. A descriptive analysis based on a systematic review of the literature was performed considering the data extracted mentioned above (2.5), which are presented in Tables 1 to 5.

# 3. Results



Figure 1. PRISMA flow diagram showing the flow of information through the different phases of the present systematic review.

Figure 1 presents the flow chart for the study selection. The initial search resulted in 7828 potentially relevant citations (PubMed: n = 1462; Embase: n = 3252; Web of Science: n = 3114). After removing duplicates (2261) and irrelevant articles (5499) that did not meet the inclusion criteria, 68 citations met the eligibility criteria based on title and abstract. These papers were obtained and

full-text screened, resulting in 53 studies that were included in the analysis (qualitative synthesis).

Considering the included studies, the first study using artificial intelligence in implant dentistry was published in 2009. After a 6-year hiatus, the artificial intelligence applied to implant dentistry was published in 2015, 2016, and 2017. There was a significant increase in AI publications in 2018 (n=3), 2020 (n=6), 2021 (n=12), 2022 (n=12) and sixteen publications until the search date August 2, 2023. Most studies were carried out in Asia (43), mainly in South Korea (16), followed by Japan (6), China (5), Saudi Arabia (3), India (3), Turkey (3), Iran (2), Taiwan (2), Russia (1), Singapore (1) and Thailand (1). Six studies were carried out in Europe, two from France, and one from the following Countries: Portugal, Italy, Spain, and Greece. Two studies are from the United States and another from Brazil. South Africa (Africa) published one study. Studies were found in 39 different scientific journals, most of them were published in dental journals (22), eleven in multidisciplinary journals, eight in medical journals, four in engineering journals, three in computer science journals, two in imaging journals, two in natural sciences journals, and one in a neuroscience journal.

Nineteen studies are related to the identification of dental implants (Table 1), seven are related to dental implant planning (Table 2), fifteen studies are related to predictions of success and failure (Table 3), eight studies are related to the assessment of osseointegration, marginal bone level, stability and fracture detection (Table 4), and four studies are related to the dental implant design (Table 5).

From the 53 included studies, 26 studies used convolution neural networks for data analysis, 13 studies used machine learning, 7 studies used artificial neural networks, 6 studies used deep learning, and 1 study used convolutional neural networks and machine learning. Eight different types of databases were analyzed by the following artificial intelligence methods: X-ray exams; cone beam computed tomography (CBCT); scan data; interview and literature review; resonance frequency analysis; patient records; finite element analysis and data about etching time and etching solution media temperature effects on surface characteristics.

## 4. Discussion

The interest in using artificial intelligence (AI) in implantology has been increasing in recent years, showing a rapid evolution that can bring benefits to our patients, but still with limitations of use and reliability.

AI was developed to imitate human logic to perform tasks, such as problem-solving, object recognition, and decision-making (14). Most of the reviewed studies used convolutional neural networks, which are learning algorithms that try to mimic
biological neural networks using interconnected nodes or neurons in a layered structure, similar to the human brain (14). The neural network creates an adaptive system used by computers to learn from mistakes and continually improve, trying to solve complicated problems and may contribute to the development of highperformance decision support systems allowing for the identification of specific patterns from large databases of information. Convolutional neural networks are an evolution of this process, presenting a greater number of layers and greater complexity (2). Perhaps the easiest way to think about artificial intelligence, machine learning, neural networks, and deep learning is to think of them like Russian nesting dolls. Each is essentially a component of the prior term. That is, machine learning is a subfield of artificial intelligence. Deep learning is a subfield of machine learning, and neural networks make up the backbone of deep learning algorithms. In fact, it is the number of node layers, or depth, of neural networks that distinguishes a single neural network from a deep learning algorithm, which must have more than three (15).

The number of dental implants performed in the world is increasing. Annually, an estimated number of more than 5 million implants are placed in the United States and the United Kingdom. In Brazil, this figure has risen to approximately 800,000 implants and 2.4 million prosthetic components (16). Identifying the dental implants is one of the clinical difficulties encountered when patients are looking for prosthetic rehabilitation or retreatment. This clinical challenge may justify the great number of studies on the subject, which revealed good accuracy for the identification of dental implants (16-20). In this regards, the lowest average accuracy achieved was 67% (21). When comparing AI performance to that of experienced professionals and novices, AI consistently outperformed them. Additionally, when professionals received assistance from AI to identify dental implants, their accuracy in identification significantly improved (22,23). As a clinician often does not have information on the treatment previously performed by another professional, the use of artificial intelligence to assist on implant identification does not cause any harm to the patient. Actually, there are commercially available tools that require minimum programming knowledge to use AI to identify implants.

AI has also been used in treatment planning, but it still shows limitations. The AI can satisfactorily identify edentulous sites in imaging exams or stone casts, suggesting the use of specific dental implants for a rehabilitation (24-26). The use of AI to assist on defining the position planning and the size of dental implants it is still unsatisfactory because a minor error can cause harm to the patient (25,27). A promising topic involves AI-driven planning for implant drilling protocols, aiming to achieve enhanced primary stability of dental implants, using cone-beam computed tomography (CBCT) images (28). AI is currently perceived as an assistance tool for the dentist, speeding up decision making processes and presenting new treatment options, but the final treatment planning must be carried out by the professional.

In contrast, using AI during patient evaluation can successfully assist on predicting a clinical success or failure (29-35), which would be a powerful information to help the professional and the patient on the decision making process.

The use of AI on predicting the development of periimplantitis (35-37) and bone remodeling around the implant (38,39) also showed promising results. Peri-implantitis, an inflammatory condition with a high prevalence, poses a risk of dental implant loss (40). Successful automated assessment of this condition has been achieved, offering potential benefits to patients through early diagnosis (40-44). AI demonstrated similar performance in detecting peri-implantitis compared to novice dentists and performed at an inferior level to experienced professionals (43,44). Additionally, the evaluation of dental implant fracture (45) and osseointegration (46) also yielded positive results. Further, AI showed favorable outcomes in predicting the occurrence of medication-related jaw osteonecrosis, a postoperative complication of significant concern in clinical practice (47). The design optimization aims to find the best parameters that satisfy the design requirements, which can be used to improve the design of an structure, such as a dental implant (48-50), as well to optimize the analysis methodologies used during the development of the designs (51). Project optimization allows for the replacement of the finite element analysis, achieving less analysis time and less computational requirements (51). The optimization of the projects provided a better design of the dental implant, obtaining better von Mises stress numbers and lower levels of deformation in the cancellous bone (50). It was also possible to use design optimization to design different dental implant surfaces and obtain better levels of osseointegration (49). In addition, it can be used in association with AI to select the best option for projects that were developed in a traditional way (48-51).

The present study introduces significant innovations, presenting additional data from previous similar study (12), mostly because of using a broader search strategy with different keywords, and distinct inclusion criteria. The present study resulted in a significantly larger number of identified studies and tripled the included articles. This larger and updated systematic review revealed new purposes for AI in implantology, such as: treatment planning with dental implants and assessments of bone level, stability, osseointegration, and dental implant fracture detection. In addition, this reviewed showed a wider range of accuracy results. For example, in the implant identification, the lowest accuracy level found in the present study was 67%, while the previous study (12) found 93.8%.

A common reported limitation was inadequate data in the databases. This limitation was associated with a low number of data points in a database (16,52,53) or the absence of data for a variable when two variables were necessary for correct diagnosis (26,43), the low number of different models and brands of dental implants found in the databases (16,54,55), or the non-utilization of external databases (44,54). A suggested (26,55) method to address this issue is the use of a synthetic database, although it may pose a limitation in terms of data diversity.

In conclusion, the results obtained in this study highlight the practical applicability of AI in clinical settings, particularly in the identification of implant brands and fractured dental implants. Furthermore, AI can serve as a valuable tool to assist dentists in the formulation of treatment plans and prognostic assessments for specific patients, providing relevant information to clinicians and patients. The primary challenge currently hindering the advancement of AI predictability and reliability in implant dentistry is the limited availability of comprehensive databases for AI development.

## Acknowledgments

This study was partially supported by Capes do Brasil (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Finance Code 001), CNPq do Brasil grant #302587/2017-9; Fapergs grant #19/2551-0000928-3; and the National Institute of Science and Technology in 3D printing and Advanced Materials Applied to Human and Veterinary Health - INCT \_3D-Saúde, funded by CNPq, Brazil (Grant #406436/2022-3).

## References

1. Friedman CP. A "fundamental theorem" of biomedical informatics. J Am Med Inform Assoc. 2009;16(2):169–70.

2. Carrillo-Perez F, Pecho OE, Morales JC, Paravina RD, Della Bona A, Ghinea R, et al. Applications of artificial intelligence in dentistry: A comprehensive review. J Esthet Restor Dent. 2022 Jan;34(1):259-280.

3. Rodrigues JA, Krois J, Schwendicke F. Demystifying artificial intelligence and deep learning in dentistry. Braz Oral Res [Internet]. 2021;35:e094.

4. Lip GYH, Nieuwlaat R, Pisters R, Lane DA, Crijns HJGM. Refining clinical risk stratification for predicting stroke and thromboembolism in atrial fibrillation using a novel risk factorbased approach: the euro heart survey on atrial fibrillation. Chest. 2010 Feb;137(2):263–72.

5. O'Mahony C, Jichi F, Pavlou M, Monserrat L, Anastasakis A, Rapezzi C, et al. A novel clinical risk prediction model for sudden cardiac death in hypertrophic cardiomyopathy (HCM risk-SCD). Eur Heart J. 2014 Aug;35(30):2010–20.

6. Yagi M, Ohno H, Takada K. Decision-making system for orthodontic treatment planning based on direct implementation of expertise knowledge. Annu Int Conf IEEE Eng Med Biol Soc. 2010;2010:2894-7.

7. Tandon D, Rajawat J. Present and future of artificial intelligence in dentistry. J oral Biol craniofacial Res. 2020;10(4):391–6.

8. McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. Bull Math Biophys. 1943;5(4):115–33.

9. Schwendicke F, Samek W, Krois J. Artificial Intelligence in Dentistry: Chances and Challenges. J Dent Res. 2020 Jul;99(7):769–74.

10. Khanagar SB, Al-Ehaideb A, Maganur PC, Vishwanathaiah S, Patil S, Baeshen HA, et al. Developments, application, and performance of artificial intelligence in dentistry - A systematic review. J Dent Sci. 2021 Jan;16(1):508–22.

11. Shan T, Tay FR, Gu L. Application of Artificial Intelligence in Dentistry. J Dent Res. 2021 Mar;100(3):232–44.

12. Revilla-León M, Gómez-Polo M, Vyas S, Barmak BA, Galluci GO, Att W, et al. Artificial intelligence applications in implant dentistry: A systematic review. J Prosthet Dent. 2023 Feb;129(2):293–300.

13. Moher D, Shamseer L, Clarke M, Ghersi D, Liberati A, Petticrew M, et al. Preferred reporting items for systematic review and meta-analysis protocols (PRISMA-P) 2015 statement. Syst Rev. 2015 Jan;4(1):1.

14. Miloglu O, Guller MT, Tosun ZT. The Use of Artificial Intelligence in Dentistry Practices. Vol. 54, Eurasian Journal of Medicine. 2022 Dec;54(Suppl1):34-42.

15. Yamashita R, Nishio M, Do RKG, Togashi K. Convolutional neural networks: an overview and application in radiology. Insights Imaging. 2018 Aug;9(4):611-629.

da Mata Santos RP, Vieira Oliveira Prado HE,
 Soares Aranha Neto I, Alves de Oliveira GA, Vespasiano Silva AI,
 Zenóbio EG, et al. Automated Identification of Dental Implants
 Using Artificial Intelligence. Int J Oral Maxillofac Implants.
 2021;36(5):918–23.

17. Hsiao CY, Bai H, Ling H, Yang J. Artificial Intelligence in Identifying Dental Implant Systems on Radiographs. Int J Periodontics Restorative Dent. 2023;43(3):363–8. 18. Kong H-J, Eom S-H, Yoo J-Y, Lee J-H. Identification of 130 Dental Implant Types Using Ensemble Deep Learning. Int J Oral Maxillofac Implants. 2023;38(1):150–6.

19. Park W, Huh J-K, Lee J-H. Automated deep learning for classification of dental implant radiographs using a large multi-center dataset. Sci Rep. 2023 Mar; 24;13(1):4862.

20. Sukegawa S, Yoshii K, Hara T, Yamashita K, Nakano K, Yamamoto N, et al. Deep neural networks for dental implant system classification. Biomolecules. 2020 Jul 1;10(7):1–13.

21. Benakatti VB, Nayakar RP, Anandhalli M. Machine learning for identification of dental implant systems based on shape - A descriptive study. J Indian Prosthodont Soc. 2021;21(4):405–11.

22. Lee JH, Kim YT, Lee JB, Jeong SN. Deep learning improves implant classification by dental professionals: a multi-center evaluation of accuracy and efficiency. J PERIODONTAL Implant Sci. 2022;52(3):220–9.

23. Park W, Schwendicke F, Krois J, Huh J-K, Lee JH. Identification of Dental Implant Systems Using a Large-Scale
Multicenter Data Set. J Dent Res. 2023 Jul;102(7):727–33.

24. Alsomali M, Alghamdi S, Alotaibi S, Alfadda S, Altwaijry N, Alturaiki I, et al. Development of a deep learning model for automatic localization of radiographic markers of

proposed dental implant site locations. Saudi Dent J. 2022;34(3):220–225.

25. Bayrakdar SK, Orhan K, Bayrakdar IS, Bilgir E, Ezhov M, Gusarev M, et al. A deep learning approach for dental implant planning in cone-beam computed tomography images. BMC Med Imaging. 2021 May 19;21(1):86.

26. Park J, Lee J, Moon S, Lee K. Deep Learning Based Detection of Missing Tooth Regions for Dental Implant Planning in Panoramic Radiographic Images. Appl Sci. 2022 Feb 1;12(3).

27. Hwang I-K, Kang S-R, Yang S, Kim J-M, Kim J-E, Huh K-H, et al. SinusC-Net for automatic classification of surgical plans for maxillary sinus augmentation using a 3D distance-guided network. Sci Rep. 2023; Jul 19;13(1):11653.

28. Sakai T, Li HF, Shimada T, Kita S, Iida M, Lee C, et al. Development of artificial intelligence model for supporting implant drilling protocol decision making. J Prosthodont Res. 2022 Jul;67(3):360–5.

29. Huang N, Liu P, Yan Y, Xu L, Huang Y, Fu G, et al. Predicting the risk of dental implant loss using deep learning. J Clin Periodontol 2022; 49(9), 872–883

30. Reyhaneh Sadat Moayeri and Mehdi Khalili and Mahsa Nazari. A Hybrid Method to Predict Success of Dental Implants. Int J Adv Comput Sci Appl [Internet]. 2016;7(5). 31. Alarifi A, AlZubi AA. Memetic Search Optimization Along with Genetic Scale Recurrent Neural Network for Predictive Rate of Implant Treatment. J Med Syst. 2018 Nov;42(11).

32. Zhang CA, Fan LF, Zhang SS, Zhao J, Gu YX. Deep learning based dental implant failure prediction from periapical and panoramic films. Quant Imaging Med Surg. 2023;13(2):935–45.

33. Lyakhov PA, Dolgalev AA, Lyakhova UA, Muraev AA, Zolotayev KE, Semerikov DY. Neural network system for analyzing statistical factors of patients for predicting the survival of dental implants. Front Neuroinform. 2022; Dec 7;16:1067040.

34. Oh S, Kim YJ, Kim J, Jung JH, Lim HJ, Kim BC, et al. Deep learning-based prediction of osseointegration for dental implant using plain radiography. BMC Oral Health. 2023 Apr; 8;23(1):208.

35. Rekawek P, Herbst EA, Suri A, Ford BP, Rajapakse CS, Panchal N. Machine Learning and Artificial Intelligence: A Web-Based Implant Failure and Peri-implantitis Prediction Model for Clinicians. Int J Oral Maxillofac Implants. 2023;38(3):576-582b.

36. Mameno T, Wada M, Nozaki K, Takahashi T, Tsujioka Y, Akema S, et al. Predictive modeling for peri-

implantitis by using machine learning techniques. Sci Rep. 2021 May 27;11(1):11090.

37. Cetiner D, Isler SC, Bakirarar B, Uraz A. Identification of a Predictive Decision Model Using Different Data Mining Algorithms for Diagnosing Peri-implant Health and Disease: A Cross-Sectional Study. Int J Oral Maxillofac Implant. 2021;36(5):952–65.

38. Troiano G, Fanelli F, Rapani A, Zotti M, Lombardi T, Zhurakivska K, et al. Can radiomic features extracted from intraoral radiographs predict physiological bone remodelling around dental implants? A hypothesis-generating study. J Clin Periodontol. 2023 Jul;50(7):932–41.

39. Kung P-C, Hsu C-W, Yang A-C, Chen N-Y, Tsou N-T. Prediction of Bone Healing around Dental Implants in Various Boundary Conditions by Deep Learning Network. Int J Mol Sci. 2023 Jan;24(3).

40. Vera M, Gómez-Silva MJ, Vera V, López-González CI, Aliaga I, Gascó E, et al. Artificial Intelligence Techniques for Automatic Detection of Peri-implant Marginal Bone Remodeling in Intraoral Radiographs. J Digit Imaging. 2023 Oct;36(5):2259-2277.

41. Chen YC, Chen MY, Chen TY, Chan ML, Huang YY, Liu YL, et al. Improving Dental Implant Outcomes: CNN-Based System Accurately Measures Degree of Peri-Implantitis Damage on Periapical Film. Bioengineering (Basel). 2023 May 25;10(6):640.

42. Ertas K, Pence I, Cesmeli MS, Ay ZY. Determination of the stage and grade of periodontitis according to the current classification of periodontal and peri-implant diseases and conditions (2018) using machine learning algorithms. J PERIODONTAL Implant Sci. 2023;53(1):38–53.

43. Cha JY, Yoon HI, Yeo IS, Huh KH, Han JS. Periimplant bone loss measurement using a region-based convolutional neural network on dental periapical radiographs. J Clin Med. 2021 Mar 1;10(5):1–12.

44. Liu M, Wang S, Chen H, Liu Y. A pilot study of a deep learning approach to detect marginal bone loss around implants. BMC Oral Health. 2022 Jan 16;22(1):11.

45. Lee D-W, Kim S-Y, Jeong S-N, Lee J-H. Artificial intelligence in fractured dental implant detection and classification: Evaluation using dataset from two dental hospitals. Diagnostics (Basel). 2021 Feb 3;11(2):233.

46. Kwak Y, Nguyen V-H, Hériveaux Y, Belanger P, Park J, Haïat G. Ultrasonic assessment of osseointegration phenomena at the bone-implant interface using convolutional neural network. J Acoust Soc Am. 2021 Jun;149(6):4337.

47. Kwack DW, Park SM. Prediction of medicationrelated osteonecrosis of the jaw (MRONJ) using automated

machine learning in patients with osteoporosis associated with dental extraction and implantation: a retrospective study. J Korean Assoc Oral Maxillofac Surg. 2023;49(3):135–41.

48. Roy S, Dey S, Khutia N, Roy Chowdhury A, Datta S. Design of patient specific dental implant using FE analysis and computational intelligence techniques. Appl Soft Comput J. 2018;65:272–9.

49. Sadati Tilebon SM, Emamian SA, Ramezanpour H, Yousefi H, Özcan M, Naghib SM, et al. Intelligent modeling and optimization of titanium surface etching for dental implant application. Sci Rep. 2022 May 3;12(1):7184.

50. Choudhury S, Rana M, Chakraborty A, Majumder S, Roy S, RoyChowdhury A, et al. Design of patient specific basal dental implant using Finite Element method and Artificial Neural Network technique. Proc Inst Mech Eng Part H, J Eng Med. 2022 Sep;236(9):1375–87.

51. Shi ML, Zong CY, Li HY, Shi YY. A multi-output model based on extreme learning machine with application in the multi-objective optimization of a dental implant. Eng Optim. 2023 55:(11):1978-1995.

52. Chen Z, Liu Y, Xie X, Deng F. Influence of bone density on the accuracy of artificial intelligence-guided implant surgery: An in vitro study. J Prosthet Dent [Internet]. 2022 Apr 22:S0022-3913(21)00414-5.

53. Roongruangsilp P, Khongkhunthian P. The Learning Curve of Artificial Intelligence for Dental Implant Treatment Planning: A Descriptive Study. Appl Sci. 2021; 11(21):10159.

54. Kim HS, Ha EG, Kim YH, Jeon KJ, Lee C, Han SS. Transfer learning in a deep convolutional neural network for implant fixture classification: A pilot study. IMAGING Sci Dent. 2022;52(2):219–24.

55. Sukegawa S, Yoshii K, Hara T, Matsuyama T, Yamashita K, Nakano K, et al. Multi-task deep learning model for classification of dental implant brand and treatment stage using dental panoramic radiograph images. Biomolecules. 2021 May 30;11(6):815.

56. Hadj Saïd M, Le Roux M-K, Catherine J-H, Lan R. Development of an Artificial Intelligence Model to Identify a Dental Implant from a Radiograph. Int J Oral Maxillofac Implants. 2020 Nov;35(6):1077–82.

57. Lee J-H, Kim Y-T, Lee J-B, Jeong S-N. A performance comparison between automated deep learning and dental professionals in classification of dental implant systems from dental imaging: A multi-center study. Diagnostics (Basel). 2020 Nov 7;10(11):910.

58. Sukegawa S, Yoshii K, Hara T, Tanaka F, Yamashita K, Kagaya T, et al. Is attention branch network effective

in classifying dental implants from panoramic radiograph images by deep learning? PLoS One. 2022 Jul 27;17(7):e0269016.

59. Kim JE, Nam NE, Shim JS, Jung YH, Cho BH, Hwang JJ. Transfer learning via deep neural networks for implant fixture system classification using periapical radiographs. J Clin Med. 2020 Apr 14;9(4):1117.

60. Chandrashekar G, AlQarni S, Bumann EE, Lee Y. Collaborative deep learning model for tooth segmentation and identification using panoramic radiographs. Comput Biol Med. 2022 Sep;148:105829.

61. Lee JH, Jeong SN. Efficacy of deep convolutional neural network algorithm for the identification and classification of dental implant systems, using panoramic and periapical radiographs: A pilot study. Medicine (Baltimore). 2020 Jun 26;99(26):e20787.

62. Morais P, Queirós S, Moreira AHJ, Ferreira A, Ferreira E, Duque D, et al. Computer-aided recognition of dental implants in X-ray images. In: Medical Imaging 2015: Computer-Aided Diagnosis. SPIE; 2015. p. 94142E.

63. Kohlakala A, Coetzer J, Bertels J, VandermeulenD. Deep learning-based dental implant recognition using syntheticX-ray images. Med Biol Eng Comput. 2022 Oct;60(10):2951–68.

64. Kong HJ. Classification of dental implant systems using cloud-based deep learning algorithm: an experimental study. J Yeungnam Med Sci. 2023 Nov;40(Suppl):S29-S36.

65. Sakai T, Li H, Shimada T, Kita S, Iida M, Lee C, et al. Development of artificial intelligence model for supporting implant drilling protocol decision making. J Prosthodont Res. 2023 Jul;67(3):360–5.

66. Ha SR, Park HS, Kim EH, Kim HK, Yang JY, Heo J, et al. A pilot study using machine learning methods about factors influencing prognosis of dental implants. J Adv Prosthodont. 2018 Dec 1;10(6):395–400.

67. Papantonopoulos G, Gogos C, Housos E, Bountis T, Loos BG. Prediction of individual implant bone levels and the existence of implant "phenotypes." Clin Oral Implants Res. 2017 Jul 1;28(7):823–32.

68. Alharbi MT, Almutiq MM. Prediction of Dental Implants Using Machine Learning Algorithms. J Healthc Eng. 2022 Jun 20;2022:7307675.

69. Zaw K, Liu GR, Deng B, Tan KBC. Rapid identification of elastic modulus of the interface tissue on dental implants surfaces using reduced-basis method and a neural network. J Biomech. 2009 Mar 26;42(5):634–41.

Article	Objective	Technique	Data type used	Results
da Mata Santos et al., 2021 [16]	To analyze the accuracy of a model developed by means of artificial intelligence based on CNNs to identify dental implant brands placed in a given patient's mouth by means of digital periapical radiographs	CNN	Periapical radiograph	Accuracy of 85.29% (78.4% to 90.5%) was obtained for dental implant manufacturer identification. The sensitivity was 89.9% (81.1% to 95.6%), specificity was 82.4% (73.7% to 87.3%), positive predictive value was 82.6% (74.1% to 86.6%), and negative predictive value was 88.5% (79.8% to 93.9%). The network performance with unknown data showed an accuracy of 85.29%.
Kim et al., 2022 [54]	To evaluate the performanc e of transfer	CNN	Periapical radiograph	When YOLOv3 was trained for 200 epochs, the sensitivity,

Table 1 – Publications related to implant identification

	learning in a deep CNN to classify implant fixtures.			specificity, accuracy, and confidence scores were the highest for all systems, with overall results of 94.4%, 97.9%, 96.7%, and 0.75, respectively. Overall, 100 epochs (89.2%), 200 epochs (96.7%), and 300 epochs (87.8%)
Sukega	To build	CNN	Panoramic	CNNs showed
wa et al.,	and		radiograph	very high
2021	evaluate a			performance to
[22]	method to			classify dental
	classify			and treatment
	hipiant			stages The multi
	treatment			task learning of
	stages from			implant brand and
	dental			treatment stage
	panoramic			classification
	radiographi			enabled more
	c images			accurate analysis
	using a			with a very small
	multi-task			number of
	deep			parameters.
	learning			
	approach.			
1	1	1	1	

Saïd et al., 2020 [56]	To develop a CNN able to identify the brand and model of a dental implant from a	CNN	Intraoral radiograph	The deep CNN model showed a very good performance to identify a dental implant from a radiograph. It is necessary a huge
	radiograph.			database of radiographs to identify any dental implant. Overall, accuracy (93.8%) and 99.9% after 1000 epochs
Lee et al., 2020 [57]	To evaluate the efficacy of the automated CNN to classify various types of dental implant systems and compare the performanc e accuracy with dental professional s using	CNN	Panoramic and periapical radiograph ic images	The accuracy of the automated CNN based on area under the curve (AUC), Youden index, sensitivity, and specificity, were 0.95, 0.81, 0.95, and 0.85, respectively. The automated CNN outperformed most participating dental professionals, including board-

	dental radiographi c images.			certified periodontists, periodontal residents, and residents not specialized in
				periodontology.
Benakatt iet al., 2021 [21]	To evaluate the efficacy of machine learning to identify dental implant systems from panoramic radiographs based on implant shape.	ML	Panoramic radiograph ic images	The classifier methods tested were able to identify dental implant systems extracted from digital panoramic radiographs with good accuracy, even with a small dataset. The logistic regression and SVM classifiers showed excellent performance.
Sukega wa et al., 2022 [58]	to evaluate the performanc e of the attention branch network (ABN) for implant	CNN	Panoramic radiograph ic images	ResNet18 showed considerably high compatibility with the ABN model for dental implant classification (AUC = 0.9993) despite the small

	classificatio n using CNNs.			number of parameters.
Lee et al., 2021 [22]	To evaluate and compare the accuracy performanc e of dental professional s in the classificatio n of different types of dental implant systems (DISs) using panoramic radiographi c images with and without the assistance of a deep learning (DL) algorithm.	CNN	Panoramic radiograph ic images	Using the DL algorithm led to a significant improvement in the average classification accuracy of DISs (78.88%) compared to no DL algorithm assistance (63.13%). When using DL algorithm assistance, board- certified periodontists showed higher accuracy (88.56%). Dentists not specialized in implantology (77.83%) showed the largest improvement.

Kim et	To evaluate	CNN	Panoramic	CNNs classified
al., 2020	whether		radiograph	the implants with
[59]	deep neural		ic images	high accuracy
	networks		-	even with
	can identify			relatively small
	four			network and
	different			number of images.
	types of			This may assist in
	implants on			solving
	intraoral			inconveniences
	radiographs			associated with
				unnecessary
				treatments and
				medical expenses
				caused by lack of
				knowledge on the
				type of implant.
Sukega	To assess	CNN	Panoramic	Among models
wa et al.,	the		radiograph	tested, the finely
2020	accuracy of		ic images	tuned VGG16
[20]	using digital			showed the
	nanoramic			
	panoranne			highest implant
	radiograph			highest implant classification
	radiograph images to			highest implant classification performance. The
	radiograph images to classify and			highest implant classification performance. The finely tuned
	radiograph images to classify and identify			highest implant classification performance. The finely tuned VGG19 was
	radiograph images to classify and identify dental			highest implant classification performance. The finely tuned VGG19 was second best,
	radiograph images to classify and identify dental implants			highest implant classification performance. The finely tuned VGG19 was second best, followed by the
	radiograph images to classify and identify dental implants using deep			highest implant classification performance. The finely tuned VGG19 was second best, followed by the normal transfer-
	radiograph images to classify and identify dental implants using deep convolution			highest implant classification performance. The finely tuned VGG19 was second best, followed by the normal transfer- learning VGG16.
	radiograph images to classify and identify dental implants using deep convolution al network			highest implant classification performance. The finely tuned VGG19 was second best, followed by the normal transfer- learning VGG16. Thus, the finely
	radiograph images to classify and identify dental implants using deep convolution al network transfer-			highest implant classification performance. The finely tuned VGG19 was second best, followed by the normal transfer- learning VGG16. Thus, the finely tuned VGG16 and

	fine-tuning strategies.			accurately classify dental implant systems from 11 types of panoramic X-ray images.
Takahas hi et al., 2020 [60]	To identify dental implant systems using a deep learning method.	CNN	Panoramic radiograph ic images	Implants can be identified from panoramic radiographic images using deep learning-based object detection.
Lee et al., 2020 [61]	To evaluate the efficacy of deep CNN algorithm for the identificatio n and classificatio n of dental implant systems.	CNN	Panoramic and periapical radiograph ic images	Deep CNN architecture is useful for the identification and classification of dental implant systems using panoramic and periapical radiographic images.
Morais et al., 2015 [62]	To evaluate a novel computer- aided framework for dental implant	ML	radiograph ic images	The segmentation strategy showed accurate and robust results in a large number of

	recognition			dental implant
	that relies			images
	on image			
	processing			
	concepts			
	involving			
	(i) a			
	segmentatio			
	n strategy			
	for semi-			
	automatic			
	implant			
	delineation:			
	and (ii) a			
	ML			
	approach			
	for implant			
	model			
	recognition.			
		2.02		
Kohlaka	То	ML	radiograph	Α
la et al.,	investigate		ic images	segmentation/dete
2022	the			ction accuracy of
[63]	feasibility			94.0% and a
	of deep			classification/reco
	learning			gnition accuracy
	techniques			of 71.7% was
	for the			reached using the
	purpose of			proposed fully
	automaticall			automated system.
	y assigning			
	а			
	questioned			
	dental			

	implant within an actual X-ray image to a specific connection type.			
Hyun Jun Kong, 2023 [64]	To evaluate the accuracy and clinical usability of implant system classificatio n using CNN-based AutoML on the Google Cloud platform.	ML	Periapical radiograph ic images	The accuracy, precision, recall, specificity, and F1 score of the AutoML Vision model were 0.981, 0.963, 0.961, 0.985, and 0.962, respectively. Osstem TSIII had an accuracy of 100%. Osstem USII and 3i Osseotite External were most often confused in the confusion matrix.
Park et al., 2023 [23]	To evaluate the efficacy of deep learning (DL) for the identificatio n and classificatio	DL	Panoramic and periapical radiograph ic images	When comparing the accuracy performance for classification of DISs, DL (82.0%) out performed most of the participants

	n of various			(23.5%), including
	types of			dentists
	dental			specialized
	implant			(43.3%) and not
	systems			specialized
	(DISs)			(16.8%) in
	using a			implantology. In
	large-scale			addition, DL tends
	multicenter			to require lesser
	data set.			reading and
	The study			classification time
	also			(4.5 min) than
	compared			dentists who
	the			specialized (75 ±
	classificatio			31 min) and did
	n accuracy			not specialize (91
	of DL and			$\pm$ 38 min) in
	dental			implantology.
	professional			
	s.			
Devile et	The second sector	DI	Demonstra	TT1
Park et	To evaluate	DL	Panoramic	The performance
al., 2023	the		and	metrics of the
[19]	accuracy of		periapical	automated DL
	automated		radiograph	based on accuracy,
	leep		ic images	precision, recall,
	(DL)			and F1 score for $116.756$
	(DL)			nonoramia and
	identify and			40.200 porionical
	classify			radiographic
	various			images word
	types of			88 53% 85 70%
	dental			8730%, $05.70%$ , and
	uciliai			62.30%, and

	implant systems using a large-scale multicenter dataset.			84.00%, respectively. Using only panoramic or periapical images, the DL algorithm achieved similar values.
Kong et al., 2023 [18]	To evaluate the accuracy and clinical usability of an identificatio n model using ensemble deep learning for 130 dental implant types.	DL	Panoramic radiograph ic images	The top-1 accuracy, top-5 accuracy, precision, recall, and F1 scores were 75.27, 95.02, 78.84, 75.27, and 74.89, respectively. In all cases, the ensemble model performed better than EfficientNet and Res2Next. When using the ensemble model, the accuracy increased as the number of types decreased.
Hsiao et al., 2023 [17]	To use CNN to identify implants placed at	CNN	Periapical radiograph ic images	The average implant- identification accuracy for the

Temple		test group was
University		above 90%, with
Kornberg		several of the
School of		CNN networks
Dentistry.		achieving a
		training accuracy
		greater than 95%.
		The highest testing
		accuracy
		(ShuffleNet7)
		achieved a
		successful
		prediction rate of
		96.8%.

Article	Objective	Technique	Data type used	Results
Chen et al., 2021 [52]	To determine the clinical reliability of an AI- assisted implant planning software with an in vitro model, and to determine the effect of bone density on the accuracy of static computer- assisted implant surgery (CAIS).	CNN	Radiograp hy; cone- beam computed tomograph y (CBCT) images	The AI-assisted implant planning software can automatically design an ideal implant position through self- learning. Higher bone density showed greater chances of implant apex and angular deviations in guided implant surgery.
Alsomal i et al., 2022 [24]	To use axial CBCT sections to develop an AI model	CNN	CBCT images	The AI model correctly identified 83% of the markers. From the areas labelled

Table 2 – Publications related to dental implant planning

	that automaticall y localizes markers in radiographi c stents to identify proposed implant sites within CBCT images.			by the AI model as markers, 28% were not truly markers. Therefore, the false positive performance of the AI model was 2.8%.
Bayrakd ar et al., 2021 [25]	To evaluate the success of the AI system in implant planning using three- dimensional CBCT images.	CNN	CBCT images	There were no significant differences in bone height measurements between AI and manual measurements. In the bone thickness measurements, there were significant differences between AI and manual measurements in all regions of maxilla and mandible. The correct detection was 72% for

				canals, 66% for sinuses/fossae and 95% for missing tooth regions.
Roongru angsilp et al., 2021 [53]	To investigate the learning curve of the developed AI for dental implant planning in the posterior maxillary region by using CBCT images.	CNN	CBCT images	The number of each image category used in AI development is positively related to the AI interpretation. Fifty images are the minimum image requirement for over 70% positive prediction. Data augmentation techniques to improve the ability of AI are still questionable.
Park et al., 2022 [26]	Proposing a deep- learning- based method for the detection of missing tooth regions and	CNN	Panoramic radiograph ic images	A deep learning model can provide a great contribution to the automation of implant placement. The study constructed a dataset for tooth instance

	tooth instance segmentatio n in panoramic radiographi c images.			segmentation and missing tooth region detection in panoramic radiographic images.
Sakai et al., 2023 [65]	To develop an AI model to determine an appropriate implant drilling protocol using CBCT images.	CNN	CBCT images	The AI model was an effective method of predicting drilling protocols from CBCT images before surgery, suggesting the possibility of developing a decision-making support system to acquire primary stability.
Hwang et al., 2023 [27]	To automaticall y classify surgical plans for maxillary sinus floor augmentatio n in implant placement at the	DL	CBCT images	The mean radial error for landmark detection was 0.87 mm, and successful detection rate for 2 mm or lower, 95.47%. The mean accuracy, sensitivity, specificity, and

maxillary		AUC for
posterior		classification by
edentulous		the SinusC-Net
region using		were 0.97, 0.92,
a 3D		0.98, and 0.95,
distance		respectively. The
guided		DL model showed
network on		accurate detection
CBCT		of 3D anatomical
images.		landmarks, and
		automatic and
		accurate
		classification of
		surgical
		approaches for
		sinus floor
		augmentation in
		implant placement
		at the maxillary
		posterior
		edentulous region.

Article	Objective	Technique	Data type used	Results
Mameno et al., 2021 [36]	To create a model for predicting the onset of periimplanti tis by using ML methods and to clarify interactions between risk indicators.	ML	Treatment records, direct interviews, and oral examinati on at follow-up.	peri-implantitis onset was predicted by random forests in 70% of cases. The most influencing predicting factors were implant functional time and oral hygiene. In addition, plaque control record of more than 50% to 60%, smoking more than 3 cigarettes/day, keratinized mucosa width less than 2 mm, and the presence of less than two occlusal supports tended to be associated with an increased risk of peri-implantitis.
Cetiner et al.,	Determine a predictive decision model for	ANN	Patients' questionna ire, data from their	The J48 model presented an acceptable predictive

Table 3 – Publications on predicting implant problems

2021 [37]	peri-implant health and disease and to reveal the highest accuracy of prediction using three different data mining methods.		charts, and clinical and radiograph ic data	accuracy of peri- implant health and disease. The model revealed bleeding on probing (BOP) as a major predictive clinical parameter.
Huang et al., 2022 [29]	To investigate the feasibility of predicting dental implant loss risk using DL based on preoperativ e CBCT images.	CNN	CBCT images	Both the DL model and the integrated model performed well in predicting implant fate within 5 years and thus may greatly facilitate implant practitioners in assessing preoperative risks.
Moayeri et al., 2016 [30]	To determine whether combinatio n of algorithms has higher	ML	Patient records	The hybrid algorithm showed higher accuracy than using a singular algorithm for classification of records. It also
	performanc e than the singular ones, and to increase the prediction of implants that are not successful.			increased the sensitivity to identify the patients whose implant is unsuccessful.
---	---	-----	--	---
Alarifi and Alzubi, 2018 [31]	To evaluate the memetic search optimizatio n along with Genetic scale recurrent neural network (MSGSRN N) in recognizing the success of the implant treatment process.	ANN	Patient records	The MSGSRNN showed the higher accuracy (99.2%) due to the minimum error rate. Further the implant treatment prediction process is enhanced in terms of advanced Dental Implant Predictive System using fuzzy systems with successful manner.
Ha et al., 2018 [66]	To search the determinant location factors of an	ML	systematic search of chart files	The mesio-distal position of the inserted implant is the most significant factor

	inserted implant, which influences implant survival or complicatio n, and whether there was a new factor affecting the implant prognosis.			determining its prognosis. Both ML methods, the decision tree model and support vector machine, yielded similar results.
Papanto nopoulo s et al., 2017 [67]	To cluster implants placed in patients of a private practice and identify possible implant "phenotype s" and predictors of individual implant mean bone levels	ML	Clinic and radiograph ic variables	Two implant "phenotypes" were identified, one with susceptibility and another with resistance to peri- implantitis. Prediction of IIMBL could be achieved by using six variables.

Lyakhov et al., 2022 [33]	To evaluate an AI system to analyze various patient statistics to predict the success of single implant survival.	ANN	Patient records.	The accuracy to recognize statistical factors from patients for predicting the success of single implants was 94.5%.
Troiano et al., 2023 [38]	To extract radiomic features from 2D intra-oral radiographs to develop ML models capable of predicting physiologic al bone remodelling (PBR) around dental implants.	ML	Patient records and intra- oral radiograph ic images	The best algorithm performance was a naive Bayes model (AUC = 0.751) followed by either a random forest (AUC = 0.691) or a gradient boosting model. The naive Bayes model had the best specificity value (68.4%), while the random forest showed the best sensitivity (70%).
Alharbi and Almutiq,	To develop a set of four ML	ML	Interviews and	Six factors were identified: patient age and healthcare

2022 [68]	algorithms to predict when a patient might need dental implants.		literature review:	insurance, level of dental care, dental crowns, type of food, and patient's other diseases. The improved AdaBoost algorithm increases the level of prediction accuracy (91.7%).
Kwack and Park, 2023 [47]	To develop and validate ML models that can predict medication- related osteonecros is of the jaw occurrence with information obtained from a questionnair e.	ML	Medical and dental history (questionn aire)	Gradient boosting showed the best diagnostic accuracy, with an area under the receiver operating characteristic curve (AUC) of 0.8283 and a stable AUC= 0.7526. The most important variables were time of medication, age, number of teeth operated, and operation site.
Kung et al., 2023 [39]	To evaluate a DL network to	DL	History of tissue differentia	The accuracy of day-by-day tissue differentiation

	provide an engineering design guideline for dental implants by predicting the history of tissue differentiati on throughout 35 days around the implant under various bone properties and occlusal		tion with various levels of occlusal force and bone properties	prediction was 82%, and the area under the curve value of the five tissue phenotypes (fibrous tissue, cartilage, immature bone, and resorption) was above 0.86, showing a high prediction accuracy.
Zhang et al., 2023 [32]	To develop an effective implant outcome prediction model using dental periapical and panoramic films.	CNN	Periapical and panoramic radiograph ic images	The model achieved an area under the curve of 0.972 for failure with marginal bone loss, 0.947 for failure without marginal bone loss and 0.975 for success. For periapical images alone, the

				diagnostic
				accuracy was
				78.6%; the
				precision was
				0.84, recall was
				0.73, and F1-score
				was 0.75. For
				panoramic images
				alone, the
				diagnostic
				accuracy was
				78.7%; the
				precision was
				0.87, recall was
				0.63, and F1-score
				was 0.66. Both
				periapical and
				panoramic images
				were used in the
				novel method,
				with a prediction
				accuracy of 87%,
				precision of 0.85,
				recall of 0.88, and
				F1-score of 0.85.
Oh et al.,	То	CNN	Panoramic	The mean values
2023	investigate		and	for specificity,
[34]	whether		periapical	sensitivity, and
	radiographi		radiograph	accuracy from the
	c images		ic images	DL models ranged
	can help			as follows: 0.780-
	predicting			0.857, 0.811–
	osseointegr			0.833, and 0.799–

	ation of dental implants.			0.836, respectively. Furthermore, the mean AUC values ranged from to 0.890–0.922. The best and worst models showed an accuracy of 0.896 and 0.702, respectively.
Rekawe k et al., 2023 [35]	To develop a ML model that can predict dental implant failure and peri- implantitis as a tool for maximizing implant success.	ML	Patients' records and radiograph ic images.	The random forest model showed the highest predictive performance on test sets, with receiver operating characteristic area under curves (ROC AUC) of 0.872 and 0.840 for dental implant failures and peri- implantitis, respectively.

Article	Objective	Technique	Data type used	Results
Cha et al., 2021 [43]	To determine the peri- implant marginal bone level on radiographi c images.	CNN	Periapical radiograph ic images.	No significant difference was found between the modified R-CNN model and dental clinician for detecting landmarks around dental implants.
Kwak et al., 2021 [46]	To develop a method to assess the soft tissue thickness at the bone- implant interface (BII) based on ultrasonic response using a simulation based- CNN.	CNN	Time- frequency spectrogra ms and synthesize d ultrasound responses	The reported assessment network for the osseointegration phenomena supports the feasibility of ultrasound analysis to be transformed to noninvasive applications for the bone-implant domain.

Table 4 – Publications related to assessments of bone level, stability, osseointegration and dental implant fracture detection

Liu et	To develop	CNN	Periapical	The Faster R-CNN
al., 2022	an		radiograph	model performed
[44]	automated system to identify marginal bone loss around dental implants in periapical radiographs using a DL- based object detection method.		ic images.	similarly to the resident dentist, but less well than the experienced dentist. The model could detect peri- implant bone loss on periapical radiographs and may facilitate the development of accurate diagnostic tools.
Lee et al., 2021 [45]	To evaluate the reliability and validity of DL to detect and classify implant facture based on three different DCNN architecture s	CNN	Panoramic and periapical radiograph ic images	The three CNNs showed acceptable accuracy in the detection and classification of fractured implants, with the best accuracy performance achieved by the CNN using periapical images.

Zaw et	To evaluate	ANN	Data from	Based on
al., 2009	a rapid		the RBM	numerical
[69]	inverse		model	simulation and
	analysis			actual
	approach			experiments, it is
	based on the			confirmed that the
	reduced-			identified results
	basis			are very accurate,
	method			reliable, and the
	(RBM) and			computational
	neural			saving is very
	network			significant.
	(NN) to			
	identify the			
	''unknown'			
	' elastic			
	modulus of			
	the			
	interfacial			
	tissue			
	between a			
	dental			
	implant and			
	the			
	surrounding			
	bone.			
Char at	To	CNIN	Dominution1	
$\frac{1}{2022}$	TO use a	CININ	Periapical	model achieved an
ai., 2023	to evaluate		Kaulograp	nouel achieved an
[41]	the degree		images	80.3% in conturing
	of		mages.	69.5% III capturing
	UI pariodontal			ne inplant
	democra			A lawNat
	uamage			Alexiner damage

	around implants using periapical images.			detection model achieved an accuracy rate of 90.4%.
Ertaş et al., 2023 [42]	To design a decision system based on ML algorithms by using clinical measureme nts and radiographi c images to determine and facilitate the staging and grading of periodontiti s.	ML and CNN	Clinical and radiograph ic data.	Using clinical data, the accuracy of staging with the tree algorithm reached 97.2%, while the random forest and k- nearest neighbor algorithms reached 98.6% accuracy. The best staging accuracy for processing panoramic radiographic images was provided by a hybrid network model algorithm combining the ResNet50 architecture and the support vector machine algorithm. The radiographic images provided a low level of

				success (accuracy) for modeling the grading of periodontitis.
Vera et al., 2023 [40]	To develop an automatic image processing approach based on two AI techniques in intraoral radiographs to assist dentists in determining bone loss.	DL	Periapical and bitewing radiograph ic images	The YOLOv3 deep learning- based object detector demonstrated its ability to detect crowns and screws on implants assuming an important contribution in the initial phase of the strategy. This allowed the application of techniques to identify the edges of the screws and damaged areas also allowing for identification of bone resorption degree, representing a relevant assistance for the diagnosis of the severity of peri-implantitis.

Article	Objective	Technique	Data type used	Results
Tilebon et al., 2022 [49]	To investigate the surface characteristi cs of implants when etching solution temperature and etching process time varies.	ANN	H <sub>2</sub> SO <sub>4</sub> temperatur e and etching time.	The ANN models can properly predict the surface characteristics variations during etching as a function of process temperature and time. The ANN model was able to predict the optimized etching conditions.
Roy et al., 2018 [48]	To use finite element analysis (FEA), ANN, desirability function and genetic algorithms to design the shape and geometry of	ANN	FEA prediction data to develop two ANN models.	Genetic algorithm is successfully used for designing dental implant to achieve the desired microstrain and implant stress. Surrogate models using ANN were shown to be a good method to convert the FEA

Table 5 – Publications related to design optimization

	dental implant.			findings for design optimization.
Shi et al., 2022 [51]	To use a multi- output model based on extreme learning machine model to replace the FEA to ease the computatio nal cost in the multi- objective optimizatio n of a dental implant.	ML	FEA data	The model produced more competitive performance to predict accuracy and computational cost than the benchmark multi- output models. The model has potential for engineering design and optimization.
Choudh ury et al., 2022 [50]	To evaluate optimum basal dental implant according to patient- specific bone height, width, and bone condition	ANN	FEA data	TheANNmetamodeldevelopedfromtheFEAsimulationdatawas foundto becapabletoformulatethefitness function forthe optimization toachievedesired

using FEA data and relevant AI- based optimizatio n techniques so that a more osseointegr ation friendly mechanical environmen t can be achieved at the bone- implant interface and surrounding bone may		microstrain in the peri-implant bone, achieving better osseointegration.
and surrounding bone may provide better stability to the implant.		