

UNIVERSIDADE TUIUTI DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ODONTOLOGIA –
MESTRADO
ÁREA DE CONCENTRAÇÃO: DISFUNÇÃO TEMPOROMANDIBULAR
E DOR OROFACIAL

INTELIGÊNCIA ARTIFICIAL APLICADA À TRIAGEM DE CEFALÉIAS
SECUNDÁRIAS E À ESTIMATIVA DA IDADE CRONOLÓGICA POR
MEIO DE MEDIDAS MANDIBULARES

PEDRO FELIPE DE JESUS FREITAS

CURITIBA

2026

PEDRO FELIPE DE JESUS FREITAS

**INTELIGÊNCIA ARTIFICIAL APLICADA À TRIAGEM DE CEFALÉIAS
SECUNDÁRIAS E À ESTIMATIVA DA IDADE CRONOLÓGICA POR
MEIO DE MEDIDAS MANDIBULARES**

Dissertação apresentada como requisito parcial para obtenção do título de Mestre em Odontologia pela Universidade Tuiuti do Paraná, no curso de mestrado em Odontologia – área de concentração: disfunção temporomandibular e dor orofacial.

ORIENTADOR: PROF. DRA. BIANCA
MARQUES DE MATTOS DE ARAUJO

CO-ORIENTADOR: PROF. DR.
CRISTIANO MIRANDA DE ARAUJO

CURITIBA

2026

Dados Internacionais de Catalogação na fonte Biblioteca
"Sidnei Antonio Rangel Santos" Universidade Tuiuti do
Paraná

F862 Freitas, Pedro Felipe de Jesus.

Inteligência artificial aplicada à triagem de cefaleias secundárias e à estimativa da idade cronológica por meio de medidas mandibulares/ Pedro Felipe de Jesus Freitas; orientadora Prof.^a Dra. Bianca Marques de Mattos de Araujo; coorientador Prof. Dr. Cristiano Miranda de Araujo.
72f.

Dissertação (Mestrado) – Universidade Tuiuti do Paraná, Curitiba, 2026

1. Inteligência artificial. 2. Transtornos da cefaleia secundários. 3. Diagnóstico. 4. Aprendizado de máquina. 5. Determinação da idade pelo esqueleto. I. Dissertação (Mestrado) Programa de Pós-Graduação em Odontologia/Mestrado em Odontologia. II Título.

CDD – 006.3

Bibliotecária responsável: Heloisa Jacques da Silva – CRB 9/1212


TERMO DE APROVAÇÃO

PEDRO FELIPE DE JESUS FREITAS

INTELIGÊNCIA ARTIFICIAL APLICADA À TRIAGEM DE CEFALÉIAS SECUNDÁRIAS E À ESTIMATIVA DA IDADE CRONOLÓGICA POR MEIO DE MEDIDAS MANDIBULARES

Esta dissertação apresentada ao Programa de Pós-Graduação, Mestrado em Odontologia, área de concentração em disfunção temporomandibular e dor orofacial, da Universidade Tuiuti do Paraná, como requisito parcial, para a obtenção do título de Mestre em Odontologia.

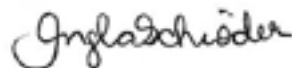
Curitiba, 25 de março de 2026



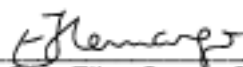
Orientadora: Profa. Dra. Bianca Marques de Mattos de Araújo
Instituição: Universidade Tuiuti do Paraná



Co-orientador Prof. Dr. Cristiano Mirando de Araújo
Instituição: Universidade Tuiuti do Paraná



Profa. Dra. Angela Deliga Schroeder
Instituição: Universidade Tuiuti do Paraná



Profa. Dra. Elisa Souza Camargo
Instituição: Membro Externo - PUCPR



**Universidade
Tuiuti do
Paraná**



Esta dissertação foi desenvolvida no Núcleo de Inteligência Artificial em Saúde (NIAS) da Universidade Tuiuti do Paraná – UTP.

DEDICATÓRIA

Dedico esta dissertação,

Primeiramente a Deus, por me sustentar e renovar minha força nos momentos mais difíceis, iluminando meu caminho e mantendo viva a vontade de seguir aprendendo e evoluindo.

A minha esposa Raiane, nenhuma palavra é suficiente para expressar minha gratidão por caminhar ao meu lado mesmo quando as escolhas exigiram renúncias e esforço de nós dois.

A minha mãe, por ser um exemplo de perseverança para mim, pelo incentivo silencioso, pela confiança constante e por nunca deixar de acreditar em mim, mesmo diante das incertezas.

E ao meu filho Gabriel, que chegou para transformar minha vida e é um dos motivos pelos quais eu não desisti e nunca vou desistir.

Às minhas irmãs, Luana e Ana Paula, por tornarem o percurso mais leve, o carinho e presença, lembrando-me sempre que nunca estarei sozinho.

AGRADECIMENTOS

Começo agradecendo ao Prof. Dr. Cristiano Miranda de Araújo, que tornou os momentos de encontro mais leves, conduzindo este trabalho com excelência e sendo o principal responsável pela minha chegada até aqui.

À Profa. Dra. Bianca Marques de Mattos de Araujo, que me ajudou de várias formas, indo além da produção deste trabalho.

À Profa. Dra. Angela Graciela Deliga Schroder, por todo o auxílio na construção deste trabalho.

À Dra. Thalita Paris de Matos e ao Dr. Flares Baratto-Filho, que tiveram grande influência ao me apoiar na realização do mestrado.

À Universidade Tuiuti do Paraná, por todos os anos de acolhimento, desde a graduação até a pós-graduação, e por me acompanhar em mais uma etapa da minha vida.

A todos que, de alguma forma, me ajudaram ao longo deste percurso.

Freitas PFJ. Inteligência artificial aplicada à triagem de cefaleias secundárias e à estimativa da idade cronológica por meio de medidas mandibulares. Curitiba: Universidade Tuiuti do Paraná; 2026.

RESUMO

Introdução: A inteligência artificial tem demonstrado crescente aplicabilidade na área da saúde, oferecendo ferramentas capazes de auxiliar no raciocínio clínico e na análise preditiva de dados. Na odontologia, sua utilização pode contribuir para a triagem de cefaleias secundárias de origem orofacial e para a análise de exames de imagem relacionados ao crescimento craniofacial e à estimativa da idade cronológica. **Objetivo:** Desenvolver e avaliar aplicações baseadas em inteligência artificial voltadas à odontologia, incluindo um chatbot para auxiliar cirurgiões-dentistas na triagem de cefaleias secundárias e modelos de aprendizado de máquina para estimativa da idade cronológica a partir de medidas mandibulares. **Métodos:** A dissertação foi composta por dois estudos. No primeiro, foi desenvolvido o Head-Dent, um chatbot baseado em processamento de linguagem natural estruturado a partir dos critérios da Classificação Internacional de Distúrbios de Cefaleia (ICHD-3), seguido de validação qualitativa por especialistas e avaliação quantitativa em cenários simulados em ambiente controlado. No segundo estudo, foram analisados dados de 385 indivíduos com idades entre 5 e 18 anos, utilizando algoritmos de aprendizado de máquina supervisionado para estimar a idade cronológica com base em medidas morfométricas mandibulares obtidas em exames de imagem. O desempenho foi avaliado por métricas estatísticas e validação cruzada. **Resultados:** O chatbot apresentou desempenho máximo em ambiente controlado na identificação e classificação de cefaleias secundárias relevantes,

além de elevada concordância com os critérios diagnósticos estabelecidos e validação positiva por especialistas. No estudo de estimativa de idade, as medidas mandibulares apresentaram associação significativa com a idade cronológica, e os modelos de aprendizado de máquina demonstraram boa capacidade preditiva, com baixos erros médios e desempenho consistente entre os diferentes algoritmos avaliados. **Conclusão:** A inteligência artificial demonstrou potencial como ferramenta de apoio à prática odontológica, tanto na triagem de cefaleias quanto na estimativa da idade cronológica por meio de exames de imagem. O chatbot desenvolvido apresentou elevado desempenho em ambiente controlado, enquanto os modelos preditivos mostraram resultados promissores na análise do crescimento mandibular. Estudos futuros em ambiente clínico real são necessários para ampliar a validação e a aplicabilidade dessas tecnologias.

Freitas PFJ. Artificial intelligence applied to the screening of secondary headaches and the estimation of chronological age through mandibular measurements. Curitiba: Universidade Tuiuti do Paraná; 2026.

ABSTRACT

Introduction: Artificial intelligence has demonstrated increasing applicability in healthcare, offering tools capable of assisting clinical reasoning and predictive data analysis. In dentistry, its use may contribute to the screening of secondary headaches of orofacial origin and to the analysis of imaging exams related to craniofacial growth and chronological age estimation. Objective: To develop and evaluate artificial intelligence–based applications in dentistry, including a chatbot to assist dentists in screening secondary headaches and machine learning models to estimate chronological age from mandibular measurements. Methods: The dissertation consisted of two studies. In the first, Head-Dent was developed, a chatbot based on natural language processing structured according to the criteria of the International Classification of Headache Disorders (ICHD-3), followed by qualitative validation by specialists and quantitative evaluation in simulated scenarios in a controlled environment. In the second study, data from 385 individuals aged 5 to 18 years were analyzed using supervised machine learning algorithms to estimate chronological age based on mandibular morphometric measurements obtained from imaging exams. Performance was evaluated using statistical metrics and cross-validation. Results: The chatbot achieved maximum performance in a controlled environment in identifying and classifying relevant secondary headaches, in addition to high agreement with established diagnostic criteria and positive validation by specialists. In the age estimation study, mandibular measurements showed a significant association

with chronological age, and machine learning models demonstrated good predictive capability, with low mean errors and consistent performance across the different algorithms evaluated. Conclusion: Artificial intelligence demonstrated potential as a support tool for dental practice, both in headache screening and in chronological age estimation through imaging exams. The developed chatbot showed high performance in a controlled environment, while predictive models showed promising results in the analysis of mandibular growth. Future studies in real clinical settings are necessary to expand the validation and applicability of these technologies.

LISTA DE FIGURAS

Artigo 1 – Head-Dent – UM ASSISTENTE VIRTUAL IMPULSIONADO POR INTELIGÊNCIA ARTIFICIAL PARA A TRIAGEM NO DIAGNÓSTICO DE CEFALÉIAS SECUNDÁRIAS RELACIONADAS À ODONTOLOGIA

Figura 1 - Árvore de decisão do chatbot.....25

Figura 2 - Fluxo de desenvolvimento do Head-Dent.....26

Figura 3 - Desempenho do chatbot Head-Dent na fase de testes, com taxas de respostas corretas e completas em três cenários clínicos.....30

Artigo 2 – CRESCIMENTO CONDILAR E MEDIDAS MANDIBULARES ASSOCIADAS COMO MARCADORES PARA DETERMINAÇÃO DA IDADE CRONOLÓGICA EM CRIANÇAS E ADOLESCENTES UTILIZANDO APRENDIZADO DE MÁQUINA

Figura 1 - Medidas morfométricas utilizadas no estudo. (A) Radiografia panorâmica mostrando a altura e a largura do côndilo, bem como a altura e a largura do ramo mandibular, obtidas utilizando uma linha de referência paralela à base da incisura sigmoide. (B) Telerradiografia lateral mostrando o comprimento condílio-gnátio (Co-Gn), medido entre o Condílio (Co) e o Gnátio (Gn), e o comprimento condílio-Ponto A (Co-A), medido entre o Condílio (Co) e o Ponto A (Subspinale).....49

Figura 2 - Fluxograma das etapas de construção, treinamento e validação dos diferentes modelos.....56

Figura 3 - Idade real versus idade predita para os modelos de aprendizado de máquina avaliados. Os pontos representam predições individuais, a linha tracejada indica a linha de identidade ($y = x$), e os gradientes de cor denotam a densidade das predições. MAE, RMSE e R^2 são apresentados para cada modelo.....58

Figura 4 - Diferenças no erro absoluto médio (MAE) entre pares de modelos, apresentadas com intervalos de confiança de 95%.....60

Figura 5 – Análise da importância das variáveis para cada algoritmo.....61

LISTA DE TABELAS

Tabela 1 - Estatísticas descritivas (média \pm desvio-padrão) das medidas mandibulares e condilares e sua correlação de Pearson com a idade cronológica, incluindo valores de p e poder estatístico pós-hoc.....	577
Tabela 2 - Desempenho dos modelos de regressão (valores com IC de 95%).	59

SUMÁRIO

1 INTRODUÇÃO	14
1.1 MODELOS DE INTELIGÊNCIA ARTIFICIAL APLICADOS À ODONTOLOGIA CLÍNICA E FORENSE	14
1.2 INTELIGÊNCIA ARTIFICIAL APLICADA À TRIAGEM DE CEFALIAS SECUNDÁRIAS E APLICADA À ESTIMATIVA DA IDADE CRONOLÓGICA POR MEIO DE MEDIDAS MANDIBULARES	15
REFERÊNCIAS	17
MANUSCRITO 1	19
Head-Dent – UM ASSISTENTE VIRTUAL IMPULSIONADO POR INTELIGÊNCIA ARTIFICIAL PARA A TRIAGEM NO DIAGNÓSTICO DE CEFALIAS SECUNDÁRIAS RELACIONADAS À ODONTOLOGIA	19
1 INTRODUÇÃO	22
2 MATERIAIS E MÉTODOS	24
2.1 DESENVOLVIMENTO DO CHATBOT	24
2.2 DESENVOLVIMENTO DO SISTEMA DE TRIAGEM E DIAGNÓSTICO DIFERENCIAL	24
2.3 DESENVOLVIMENTO DA INTERFACE	25
2.4 VALIDAÇÃO E AVALIAÇÃO DO CHATBOT	26
2.5 AVALIAÇÃO QUANTITATIVA DE ADERÊNCIA AS DIRETRIZES	27
2.6 APERFEIÇOAMENTOS COM BASE NO FEEDBACK DE ESPECIALISTAS E NA ANÁLISE DE DESEMPENHO	28
3 RESULTADOS	29
3.1 FEEDBACK DE ESPECIALISTA	29
3.2 AVALIAÇÃO DE ADERÊNCIA AS DIRETRIZES	29
4 DISCUSSÃO	31
5 CONCLUSÃO	35
REFERÊNCIAS	36
APÊNDICE A – PROMPT HEAD-DENT	39
MANUSCRITO 2	43
CRESCIMENTO CONDILAR E MEDIDAS MANDIBULARES ASSOCIADAS COMO MARCADORES PARA DETERMINAÇÃO DA IDADE CRONOLÓGICA EM CRIANÇAS E ADOLESCENTES UTILIZANDO APRENDIZADO DE MÁQUINA	43
1 INTRODUÇÃO	46
2 MATERIAIS E MÉTODOS	47
2.1 DESENHO DO ESTUDO	47
2.2 PARTICIPANTES	48
2.3 VARIÁVEIS E COLETA DE DADOS	48

2.4 CALIBRAÇÃO E REPRODUTIBILIDADE DAS MEDIÇÕES	50
2.5 TAMANHO DA AMOSTRA	50
2.6 SELEÇÃO DE CARACTERÍSTICAS.....	51
2.7 DESENVOLVIMENTO DE MODELOS PREDITIVOS	51
2.8 TREINAMENTO, VALIDAÇÃO CRUZADA E TESTE	52
2.9 CONTROLE DE OVERFITTING E OTIMIZAÇÃO DO MODELO.....	53
2.10 MÉTRICAS DE AVALIAÇÃO DO MODELO	53
2.11 COMPARAÇÃO ENTRE OS MODELOS.....	55
2.12 IMPORTÂNCIA DAS CARACTERÍSTICAS.....	55
3 RESULTADOS.....	57
3.1 CARACTERIZAÇÃO DA AMOSTRA E SELEÇÃO DE CARACTERÍSTICAS	57
3.2 DESEMPENHO DO MODELO	57
3.3 COMPARAÇÃO PAREADA ENTRE OS MODELOS.....	60
3.4 IMPORTÂNCIA DAS CARACTERÍSTICAS.....	60
4 DISCUSSÃO	61
5 CONCLUSÃO	64
REFERÊNCIAS.....	65
CONCLUSÃO FINAL.....	68

1 INTRODUÇÃO

1.1 MODELOS DE INTELIGÊNCIA ARTIFICIAL APLICADOS À ODONTOLOGIA CLÍNICA E FORENSE

Os sistemas de saúde em âmbito mundial enfrentam um cenário desafiador, marcado pelo crescimento exponencial dos custos assistenciais, que já superam as taxas de expansão do Produto Interno Bruto (PIB). Essa conjuntura tornou-se ainda mais evidente durante a pandemia de COVID-19, iniciada em 2019 (1). Nesse contexto, a inteligência artificial (IA) tem assumido crescente relevância, atraindo a atenção de médicos e pesquisadores em virtude de seu potencial como ferramenta robusta na gestão de pacientes e de sua eficiência na administração dos cuidados em saúde. A Associação Americana de Informática Médica (AMIA) define a IA como a disciplina responsável pelo desenvolvimento de sistemas computacionais capazes de executar atividades tradicionalmente associadas ao esforço cognitivo humano (2). No campo da odontologia, a IA foi incorporada com o propósito de aprimorar o atendimento ao paciente, contribuindo para a otimização do planejamento terapêutico de forma geral. Destacam-se, ainda, os chatbots baseados em IA, empregados no agendamento de consultas, no esclarecimento de dúvidas e na promoção de educação em saúde bucal, além de sua aplicação na detecção de pontos de referência cefalométricos (3). Os chatbots são sistemas desenvolvidos com base em IA e processamento de linguagem natural (PLN), capazes de se comunicar com o usuário por meio de mensagens, sem exigir a participação humana direta (4). Nesse cenário, as ferramentas proporcionadas por essa tecnologia, especialmente aquelas fundamentadas em PLN, podem ser utilizadas de maneira altamente eficiente para a obtenção de informações confiáveis e de qualidade, otimizando a interação e a organização dos dados coletados. (5).

O subcampo dos chatbots passou a configurar uma alternativa viável às intervenções comportamentais convencionais, tendo em vista que essas abordagens exigem elevada demanda de recursos. Esses chatbots, também denominados agentes conversacionais ou sistemas de diálogo inteligentes, correspondem a ferramentas capazes de interagir com seres humanos por meio de texto ou voz, podendo ser organizados em diferentes níveis de complexidade

de interação. Sistemas com maior liberdade de diálogo possibilitam comunicações mais amplas e naturais com o usuário, enquanto sistemas de funcionamento mais estruturado operam a partir de perguntas previamente elaboradas e opções de respostas fixas e predefinidas (6). Já o aprendizado de máquina (ML) tem sido amplamente aplicado na identificação de pontos de referência anatômicos, bem como em sistemas de diagnóstico assistido por computador e na extração e análise de grandes volumes de dados clínicos. Estudos apontam que o ML favorece a realização de análises cefalométricas a partir de imagens com elevado nível de definição e detalhamento das estruturas, o que resulta em maior precisão na localização desses pontos anatômicos (7).

1.2 INTELIGÊNCIA ARTIFICIAL APLICADA À TRIAGEM DE CEFALIAS SECUNDÁRIAS E APLICADA À ESTIMATIVA DA IDADE CRONOLÓGICA POR MEIO DE MEDIDAS MANDIBULARES

Existem diversos instrumentos de triagem e de avaliação do impacto de doenças empregados mundialmente, cuja finalidade é auxiliar no diagnóstico e na classificação da gravidade de diferentes condições clínicas. Entre essas condições, destacam-se as cefaleias, reconhecidas como distúrbios neurológicos de elevada frequência na população global, com prevalência que pode alcançar aproximadamente 50% dos adultos. Além de sua ampla ocorrência, configuram-se como condições potencialmente incapacitantes, associadas a significativo ônus social e econômico. Nesse contexto, os métodos de coleta de dados e de interação com os pacientes passam a demandar novas abordagens. O avanço contínuo da tecnologia da informação tem favorecido o surgimento de distintas formas de comunicação entre profissionais de saúde e pacientes, entre as quais se destacam os chatbots, caracterizados como softwares baseados em IA e PLN, capazes de interagir com o usuário por meio de mensagens, sem a necessidade de intervenção humana direta (4).

Os chatbots têm se mostrado ferramentas promissoras em diversos setores, especialmente na área da saúde. Nesse cenário, são amplamente empregados para oferecer suporte clínico, apresentando uma relação custo-benefício favorável, principalmente por sua disponibilidade contínua e acessibilidade em diferentes contextos. Ademais, podem contribuir para o

aprimoramento das consultas ao auxiliar tanto pacientes quanto profissionais de saúde, estimulando mudanças comportamentais, oferecendo apoio a idosos em ambiente domiciliar e demonstrando potencial para o cumprimento de metas específicas, como o acompanhamento contínuo da própria saúde e a redução de dificuldades associadas ao autocuidado (8). PLN consiste em uma tecnologia capaz de automatizar a análise qualitativa de textos, possibilitando sua compreensão e manipulação em linguagem natural. Essa abordagem permite a leitura e o processamento de grandes volumes de dados textuais de forma mais ampla e eficiente quando comparada aos métodos tradicionais (9).

A área forense tem como finalidade auxiliar na administração da justiça, beneficiando a sociedade de modo geral por meio de sua confiabilidade e eficiência. Quando adequadamente estruturado, esse sistema pode contribuir para a elucidação de crimes, a produção de evidências periciais qualificadas e a prevenção de ocorrências criminais e acidentes. Nesse contexto, o ML destaca-se como uma abordagem em que algoritmos são capazes de identificar padrões e realizar inferências a partir de dados, sem a necessidade de extensos conjuntos de regras previamente estabelecidas. Tal processo baseia-se no treinamento de modelos com conjuntos de dados específicos, o que possibilita o aprimoramento progressivo de seu desempenho (10).

Na aplicação da IA, o treinamento refere-se à etapa em que o algoritmo é preparado para desempenhar, de forma acurada, as funções para as quais foi projetado, incluindo a delimitação e a mensuração de estruturas anatômicas, bem como a determinação de seus pontos de referência. Esse processo ocorre por meio da utilização de conjuntos de dados fornecidos previamente, que orientam o aprimoramento do desempenho do sistema (11).

Nesse contexto, esta dissertação teve como objetivo desenvolver e avaliar aplicações baseadas em IA no contexto da odontologia, incluindo a implementação de um chatbot para auxiliar cirurgiões-dentistas na identificação de cefaleias secundárias e a aplicação de algoritmos de ML para estimar a idade por meio de marcadores morfométricos mandibulares obtidos em exames de imagem.

REFERÊNCIAS

1. Al Kuwaiti A, Nazer K, Al-Reedy A, Al-Shehri S, Al-Muhanna A, Subbarayalu AV, et al. A Review of the Role of Artificial Intelligence in Healthcare. *J Pers Med*. 2023;13(6).
2. Ihara K, Dumkrieger G, Zhang P, Takizawa T, Schwedt TJ, Chiang CC. Application of Artificial Intelligence in the Headache Field. *Curr Pain Headache Rep*. 2024;28(10):1049-57.
3. Vodanović M, Subašić M, Milošević D, Savić Pavičin I. Artificial Intelligence in Medicine and Dentistry. *Acta Stomatol Croat*. 2023;57(1):70-84.
4. Chaix B, Bibault JE, Romain R, Guillemassé A, Neeral M, Delamon G, et al. Assessing the performances of a chatbot to collect real-life data of patients suffering from primary headache disorders. *Digit Health*. 2022;8:20552076221097783.
5. Eguia H, Sánchez-Bocanegra CL, Vinciarelli F, Alvarez-Lopez F, Saigí-Rubió F. Clinical Decision Support and Natural Language Processing in Medicine: Systematic Literature Review. *J Med Internet Res*. 2024;26:e55315.
6. Chen J, Hu RZ, Zhuang YX, Zhang JQ, Shan R, Yang Y, et al. Natural Language Processing Chatbot-Based Interventions for Improvement of Diet, Physical Activity, and Tobacco Smoking Behaviors: Systematic Review. *JMIR Mhealth Uhealth*. 2025;13:e66403.
7. Londono J, Ghasemi S, Hussain Shah A, Fahimipour A, Ghadimi N, Hashemi S, et al. Evaluation of deep learning and convolutional neural network algorithms accuracy for detecting and predicting anatomical landmarks on 2D

lateral cephalometric images: A systematic review and. Saudi Dent J. 2023;35(5):487-97.

8. Kurniawan MH, Handiyani H, Nuraini T, Hariyati RTS, Sutrisno S. A systematic review of artificial intelligence-powered (AI-powered) chatbot intervention for managing chronic illness. Ann Med. 2024;56(1):2302980.

9. Anweigi L, Naceur IB, Awad J, Ahmeda M, Barhom N, Tamimi F. Natural Language Understanding to Assess Oral Health-Related Quality of Life: A Cross-Sectional Study Incorporating a Mixed Methods Approach. J Oral Rehabil. 2025;52(9):1377-85.

10. Ketsekioulafis I, Filandrianos G, Katsos K, Thomas K, Spiliopoulou C, Stamou G, et al. Artificial Intelligence in Forensic Sciences: A Systematic Review of Past and Current Applications and Future Perspectives. Cureus. 2024;16(9):e70363.

11. Polizzi A, Leonardi R. Automatic cephalometric landmark identification with artificial intelligence: An umbrella review of systematic reviews. J Dent. 2024;146:105056.

MANUSCRITO 1

Head-Dent – UM ASSISTENTE VIRTUAL IMPULSIONADO POR INTELIGÊNCIA ARTIFICIAL PARA A TRIAGEM NO DIAGNÓSTICO DE CEFALEIAS SECUNDÁRIAS RELACIONADAS À ODONTOLOGIA¹

¹ Manuscrito foi submetido ao periódico: *REVISTA CLINICAL ORAL INVESTIGATIONS*. Manuscrito formatado de acordo com as normas específicas do periódico (acessado em: 04/03/2026).

Freitas PFJ. Inteligência artificial aplicada à triagem de cefaleias secundárias e à estimativa da idade cronológica por meio de medidas mandibulares. Curitiba: Universidade Tuiuti do Paraná; 2026.

RESUMO

Objetivos: Desenvolver e avaliar o Head-Dent, um chatbot baseado em inteligência artificial, para auxiliar cirurgiões-dentistas na triagem de cefaleias, verificando sua capacidade de aplicar os critérios da ICHD-3 na diferenciação entre cefaleias de possível origem odontogênica e aquelas que requerem encaminhamento médico. **Metodologia:** O Head-Dent foi desenvolvido em Python, integrado à API ChatGPT-4o, com suporte a mais de 50 idiomas e interface construída no Streamlit. O sistema utilizou um modelo baseado em regras derivadas da ICHD-3 (*International Classification of Headache Disorders*), adaptadas para linguagem natural, possibilitando a simulação de uma árvore de decisão diagnóstica. A validação qualitativa foi realizada por quatro especialistas em dor orofacial e disfunção temporomandibular, que avaliaram usabilidade, clareza e pertinência clínica das respostas. Para análise quantitativa, o desempenho foi testado em 114 interações representando diferentes cenários clínicos, avaliando-se o desempenho máximo em ambiente controlado e a completude das recomendações. **Resultados:** O chatbot demonstrou 100% de desempenho máximo em ambiente controlado na identificação do provável diagnóstico conforme os critérios da ICHD-3. Em 113 das 114 interações (99,12%), as respostas foram consideradas completas, incluindo as opções relevantes de diagnóstico diferencial. Ajustes após feedback dos especialistas resultaram em melhorias na clareza das perguntas e no detalhamento das

recomendações. Em casos de suspeita de cefaleias não relacionadas ao âmbito odontológico, o Head-Dent indicou encaminhamento para outras especialidades médicas. **Conclusão:** O Head-Dent demonstrou desempenho confiável na triagem de cefaleias secundárias em odontologia, evidenciando potencial como ferramenta de apoio à decisão clínica e ao encaminhamento adequado de pacientes.

Palavras-chave: Inteligência Artificial; Transtornos da Cefaleia Secundários; Diagnóstico

1 INTRODUÇÃO

As cefaleias representam uma queixa frequente entre pacientes em todo o mundo. Estima-se que aproximadamente 47% dos episódios sejam graves ou incapacitantes, interferindo no sono, nas atividades diárias, no desempenho profissional e no bem-estar emocional, o que resulta em impactos mentais, sociais e econômicos expressivos (12). O neurologista é, em geral, o primeiro profissional a avaliar os quadros de cefaleia, especialmente aqueles que acometem regiões inervadas pela primeira divisão do nervo trigêmeo, sendo responsável por definir se se trata de uma dor primária ou secundária. Já as dores que envolvem os demais ramos do trigêmeo apresentam diagnóstico e tratamento mais complexos, e a dor orofacial não dentária é frequentemente subdiagnosticada e conduzida de forma inadequada (13). Como o nervo trigêmeo é um dos principais nervos cranianos, ele está envolvido na maioria dos casos de cefaleia e também na condução das dores de origem odontogênica (14). Além do sofrimento individual, esses quadros geram custos consideráveis para os pacientes, familiares e sistemas de saúde, afetando diretamente a qualidade de vida (15).

Nesse cenário, torna-se relevante considerar a interação entre cefaleias e disfunções orofaciais. Alterações do movimento mandibular e dor na região temporomandibular, são frequentemente associadas a quadros de cefaleia. Indivíduos com cefaleia relacionada à disfunção temporomandibular (DTM) tendem a relatar maior intensidade dolorosa em comparação àqueles que apresentam apenas DTM (16). Além disso, condições bucais aparentemente discretas, como cáries, abscessos, doenças periodontais, cistos, tumores e dentes impactados, também podem contribuir para o desencadeamento das cefaleias (17). Contudo, há uma lacuna no manejo clínico, uma vez que dentistas, em geral, não estão familiarizados com a abordagem das cefaleias, ao passo que médicos muitas vezes não reconhecem os distintos tipos de dor odontogênica. Essa falta de integração, somada à complexidade anatômica da região, favorece diagnósticos equivocados (18). Nesse contexto, a Classificação Internacional de Distúrbios de Cefaleia (ICHD-3) tem se destacado por fornecer critérios clínicos robustos para a definição da cefaleia, sendo padrão de

referência e contribuindo para melhores resultados em pesquisas científicas e para a condução de tratamentos adequados (13).

Considerando esses desafios, novas estratégias tecnológicas têm sido exploradas para aprimorar o suporte clínico. A inteligência artificial (IA) destaca-se por sua capacidade de analisar grandes volumes de dados, reconhecer padrões e auxiliar na tomada de decisões clínicas. Entre suas subáreas, o processamento de linguagem natural (PLN) permite que sistemas computacionais compreendam e utilizem a linguagem humana em tarefas como análise de registros clínicos, extração de informações relevantes, reconhecimento de voz e apoio diagnóstico (19, 20). Os chatbots, definidos como assistentes virtuais conversacionais baseados em PLN, conseguem interagir de forma fluida com os usuários, compreender sintomas relatados em linguagem natural e oferecer orientações fundamentadas em protocolos clínicos. Ao contrário de sistemas estáticos, como formulários ou planilhas, possibilitam uma comunicação dinâmica e individualizada, simulando o raciocínio clínico inicial e fornecendo respostas consistentes e contextualizadas (21, 22). Apesar dos avanços na área, ainda não foram encontrados estudos que empreguem chatbots baseados em PLN como ferramenta de apoio aos profissionais na identificação de cefaleias relacionadas à odontologia. Dessa forma, a proposta de desenvolver um chatbot com essa finalidade busca suprir essa lacuna, fornecendo um suporte ágil, padronizado e fundamentado em evidências científicas.

Diante desse contexto, o presente estudo tem como objetivo apresentar o desenvolvimento do Head-Dent, um chatbot baseado em IA projetado para auxiliar cirurgiões-dentistas na identificação de cefaleias clinicamente relevantes para a prática odontológica.

2 MATERIAIS E MÉTODOS

2.1 DESENVOLVIMENTO DO CHATBOT

Para viabilizar uma interação dinâmica e adaptada ao contexto do usuário, foi desenvolvido um chatbot utilizando a linguagem de programação Python no ambiente de desenvolvimento PyCharm (versão 2023.2.3). A solução integrou a biblioteca *openai* à API do ChatGPT-4o, possibilitando a criação de um sistema responsivo e orientado ao diagnóstico.

Nesse contexto, foram estabelecidas duas condições principais para o funcionamento do chatbot:

- a) *Concentração no diagnóstico diferencial em pacientes com cefaleia secundária* – o chatbot, denominado Head-Dent, foi projetado para fornecer informações relevantes sobre essas condições. Ele disponibiliza detalhes com base no diagnóstico diferencial estabelecido para cada caso e orienta o paciente quanto à busca de atendimento profissional adequado.
- b) *Estratégia interativa* – o chatbot conduz a conversa de forma ativa, realizando perguntas necessárias para diferenciar o diagnóstico do paciente, atuando como um assistente virtual de apoio.

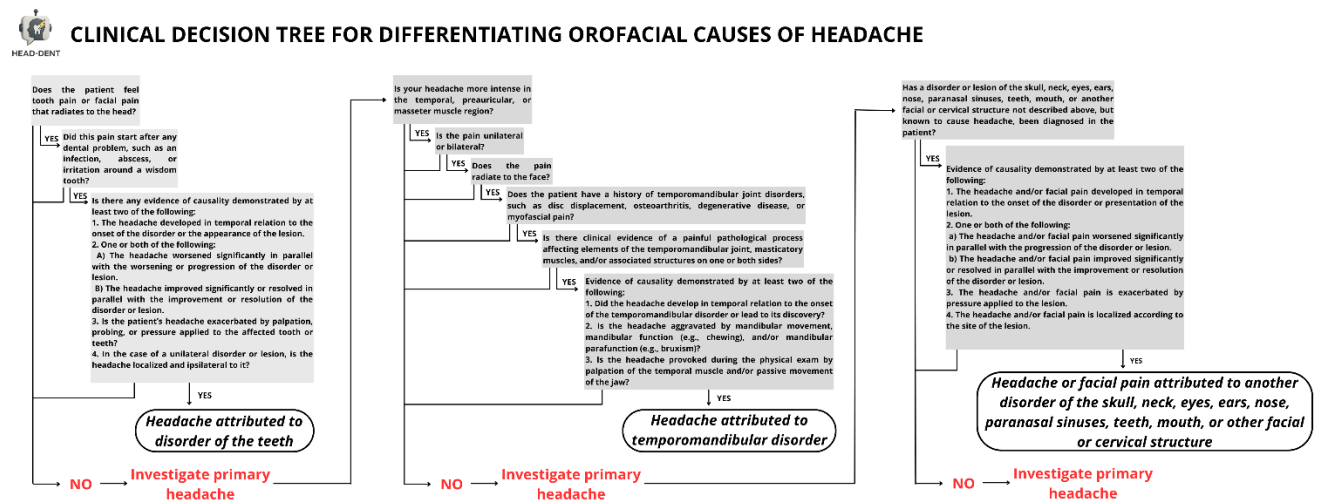
2.2 DESENVOLVIMENTO DO SISTEMA DE TRIAGEM E DIAGNÓSTICO DIFERENCIAL

O sistema de triagem foi implementado utilizando um sistema baseado em regras textuais, incorporado diretamente no código-fonte do chatbot. Para isso, as instruções foram estruturadas em um prompt, armazenadas em uma variável dentro do pipeline de execução do chatbot, contendo os critérios diagnósticos da ICHD-3 em linguagem natural. Esse prompt é transmitido a cada interação para a API do ChatGPT, garantindo que o modelo siga uma lógica pré-determinada em todas as etapas da conversa.

As regras foram organizadas em formato de cadeias condicionais, em que determinadas expressões de entrada ativam respostas específicas. Essa

técnica, conhecida como *rule-based prompting*, permite reproduzir a estrutura de uma árvore de decisão. A codificação dos critérios clínicos foi feita por meio de blocos textuais com instruções explícitas do tipo “se a resposta contiver X, prossiga para Y; caso contrário, avance para Z”. Assim, a lógica do protocolo é preservada e aplicada de forma determinística pelo modelo. A árvore de decisão para tomada de decisão do chatbot pode ser visualizada na Figura 1.

Figura 1 - Árvore de decisão do chatbot.



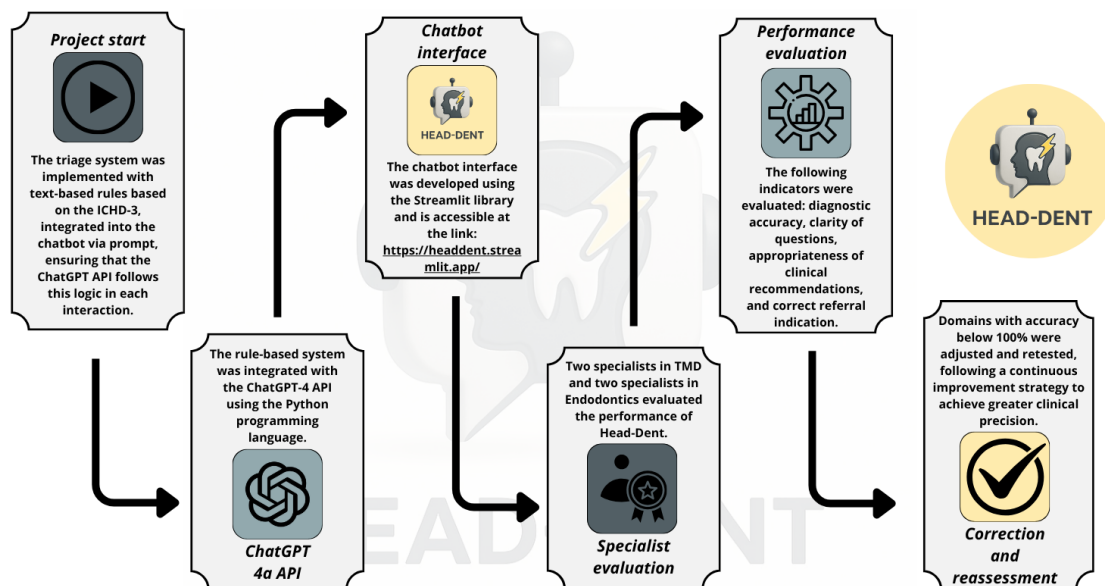
2.3 DESENVOLVIMENTO DA INTERFACE

O chatbot foi desenvolvido como uma aplicação web interativa, com capacidade de suportar mais de 50 idiomas e de ajustar automaticamente suas respostas de acordo com o idioma utilizado pelo usuário. A interface foi implementada com o Streamlit, uma biblioteca de código aberto em Python voltada para o desenvolvimento de aplicações web interativas.

Para manter a fluidez da conversa e preservar o contexto da interação, foi implementada a função 'render_chat' em Python. Essa função tem como objetivo gerenciar a comunicação entre o usuário e o chatbot, utilizando um registro de conversas para distinguir entre as mensagens enviadas pelo usuário e as respostas geradas pelo chatbot. Isso permite que as mensagens sejam exibidas de forma clara na interface, proporcionando uma experiência de usuário mais intuitiva e compreensível. Além disso, a função 'session_state' foi utilizada para armazenar o histórico completo da conversa entre o usuário e o chatbot, garantindo uma interação contínua. Dessa forma, o chatbot consegue manter o

contexto das perguntas anteriores ao longo da conversa, o que contribuiu significativamente para a eficiência e a qualidade da interação (Figura 2).

Figura 2 - Fluxo de desenvolvimento do Head-Dent.



2.4 VALIDAÇÃO E AVALIAÇÃO DO CHATBOT

Feedback qualitativo de especialistas

O chatbot Head-Dent foi avaliado por quatro especialistas, dois com expertise em DTM e Dor Orofacial e dois em Endodontia, todos com mais de 10 anos de experiência clínica. Embora fizessem parte da equipe de pesquisa, esses profissionais não participaram do desenvolvimento nem da programação do chatbot, limitando sua atuação à etapa de validação. Dessa forma, sua análise permaneceu isenta em relação ao processo de elaboração da ferramenta.

A avaliação teve caráter qualitativo, baseada no feedback dos especialistas, e contemplou os seguintes aspectos:

- 1) *Usabilidade*: análise do desempenho geral do chatbot, incluindo a interface, o fluxo de interação e a adequação das informações apresentadas.
- 2) *Clareza da orientação*: verificação da objetividade e da forma de apresentação das recomendações fornecidas pelo chatbot, assegurando uma comunicação clara e de fácil compreensão.

3) Sugestões de melhoria: identificação de oportunidades de aprimoramento, contemplando ajustes na formatação das respostas, na interação com o usuário e na experiência geral de uso.

Com o objetivo de assegurar o cegamento entre os avaliadores na etapa de validação qualitativa, cada especialista realizou sua análise de forma independente, sem qualquer troca de informações ao longo do processo. Todas as avaliações foram realizadas utilizando a mesma versão pública do chatbot, sem que os especialistas tivessem acesso ao sistema de regras subjacente ou à lógica interna da ferramenta. Devido ao caráter qualitativo e exploratório desta fase, voltada à usabilidade, clareza e aperfeiçoamento do conteúdo, não foi possível utilizar métricas de confiabilidade entre os avaliadores.

2.5 AVALIAÇÃO QUANTITATIVA DE ADERÊNCIA AS DIRETRIZES

Para avaliar a aderência do chatbot às diretrizes diagnósticas, foram criados cenários clínicos fictícios, sem a utilização de dados reais de pacientes. Esses cenários foram elaborados com base nos critérios diagnósticos da ICHD-3, bem como em descrições clínicas típicas encontradas na literatura científica. As informações de cada cenário foram inseridas no chatbot por meio de respostas simuladas às perguntas do sistema, permitindo avaliar se o assistente virtual aplica os critérios diagnósticos e conduz a triagem de forma consistente com as recomendações da ICHD-3, de maneira comparável ao processo de raciocínio clínico humano.

Para avaliar quantitativamente o desempenho do chatbot em termos de aderência, foi determinado o número de testagens necessárias por meio de um cálculo amostral, tomando como referência o domínio de indicação que apresentou o menor índice de acerto em um teste piloto. Esse teste piloto consistiu em 50 interações simuladas com o chatbot, realizadas para identificar possíveis inconsistências nas respostas e estimar a taxa inicial de acertos. Considerando uma taxa de acerto de 92,8%, margem de erro de 5% e intervalo de confiança de 95%, estimou-se que seriam necessárias 114 testagens para garantir a consistência e a precisão da análise quantitativa, correspondendo a 33 casos de teste por tipo de diagnóstico.

Dois indicadores principais foram utilizados para avaliar o desempenho do chatbot:

- a) Aderência – refere-se à habilidade do chatbot de indicar corretamente o provável diagnóstico de cefaleia, seguindo rigorosamente as classificações do IHCD-3. Cada resposta foi avaliada manualmente e considerada precisa quando o diagnóstico sugerido correspondia à classificação indicada na diretriz. A precisão foi registrada de forma binária (correto ou incorreto).
- b) Completude – avaliada qualitativamente e categorizada como "completa" ou "incompleta", refere-se ao quanto o chatbot incluiu todas as opções de diagnóstico clinicamente relevantes listadas nas classificações do IHCD-3 para cada caso. Mesmo que uma resposta fosse precisa, poderia ser considerada incompleta se deixasse de contemplar recomendações secundárias ou alternativas.

Todas as avaliações foram realizadas por um único avaliador calibrado. Para garantir a consistência dos julgamentos, a concordância intra-avaliador foi verificada através da reavaliação de um subconjunto aleatório de 10% das interações, após um intervalo de 14 dias. O coeficiente Kappa de Cohen foi calculado e apresentou valores superiores a 0,90 para aderência e completude, evidenciando excelente confiabilidade intra-avaliador.

2.6 APERFEIÇOAMENTOS COM BASE NO FEEDBACK DE ESPECIALISTAS E NA ANÁLISE DE DESEMPENHO

Após a testagem do chatbot, todos os domínios que não atingiram 100% de acerto foram revisados. Nesses casos, foram realizados ajustes nas regras de decisão e na estrutura das respostas geradas, seguidos por uma nova rodada de testes para reavaliar o desempenho. Esse procedimento foi definido no planejamento metodológico como estratégia de aprimoramento contínuo, assegurando maior precisão e aderência às recomendações clínicas estabelecidas.

3 RESULTADOS

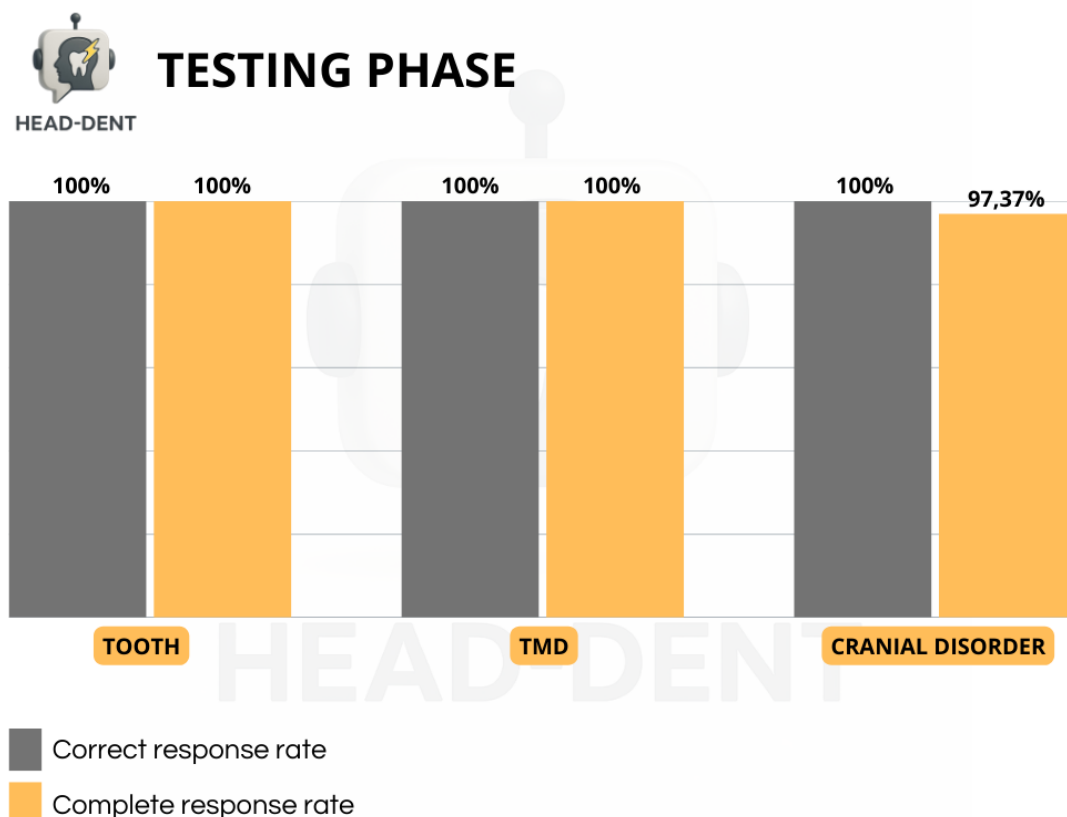
3.1 FEEDBACK DE ESPECIALISTA

Os especialistas destacaram aspectos-chave da terminologia, recomendando a adoção rigorosa dos critérios de diagnósticos do ICHD-3. Recomendaram ajustes no fluxo da conversa e no formato das perguntas para aumentar a clareza e a interação. Essas sugestões foram aceitas e revisadas, e as atualizações necessárias foram implementadas. Após essas modificações, o conteúdo e as respostas receberam a aprovação dos especialistas.

3.2 AVALIAÇÃO DE ADERÊNCIA AS DIRETRIZES

Ao avaliar a aderência as diretrizes em ambiente controlado, o chatbot Head-Dent demonstrou 100% de desempenho em todos os tipos de cefaleias analisados. No entanto, o nível de detalhamento das respostas variou em alguns casos específicos. Foram realizados 114 testes com o chatbot Head-Dent e em 113 ocasiões, as respostas foram completas, correspondendo a 99,12% de desempenho total (Figura 3).

Figura 3 - Desempenho do chatbot Head-Dent na fase de testes, com taxas de respostas corretas e completas em três cenários clínicos.



Em situações em que a causa da cefaleia poderia estar relacionada a outras estruturas fora da área de atuação do cirurgião-dentista, o chatbot indicou corretamente profissionais de outras especialidades, como otorrinolaringologista, oftalmologista e neurologista. Em alguns casos, quando o diagnóstico provável correspondia a uma cefaleia primária, o chatbot indicou o encaminhamento para avaliação neurológica. Em outras situações, observou-se resposta diferentes, na qual o chatbot apenas orientou a busca por um especialista, sem indicar a especialidade médica ou odontológica específica.

Com a identificação dos erros, o código passou por revisão para corrigir as lacunas e assegurar que todas as opções de diagnóstico fossem fornecidas de maneira completa e precisa. Na fase de reteste, todos os diagnósticos apresentaram 100% de detalhamento adequado.

4 DISCUSSÃO

A cefaleia tornou-se um problema de alcance mundial, sendo uma das principais causas de incapacidade e comprometendo a produtividade dos indivíduos afetados. Nos últimos anos, a conscientização sobre essa condição tem aumentado significativamente (15). O diagnóstico pode apresentar dificuldades, uma vez que a dor pode originar-se de diferentes causas, envolvendo mecanismos inflamatórios, nociceptivos, nociplásticos ou neuropáticos. Além disso, pode ter origem em estruturas como dentes, articulações, mucosas e músculos, ou ainda estar relacionada a alterações no sistema nervoso periférico e a interação neurovascular (23). De modo geral, os cirurgiões-dentistas não possuem experiência aprofundada no manejo das cefaleias, enquanto os médicos têm pouca familiaridade com as diferentes manifestações de dor odontogênica, e a complexa anatomia da região orofacial contribui ainda mais para a ocorrência de equívocos diagnósticos (18).

Os chatbots exercem um papel fundamental na interpretação de textos, transformando as informações recebidas em dados digitais que podem ser processados e analisados. O uso do PLN permite que essas interações ocorram de forma mais fluida e natural, aproximando-se da comunicação humana (21). Além disso, os modelos de linguagem (LLMs) apresentam alta eficiência em diferentes tarefas, como resumir textos, traduzi-los para outros idiomas e responder a perguntas formuladas pelos usuários com base em determinado conteúdo. Entre eles, destaca-se o ChatGPT, um dos chatbots mais utilizados no mundo, capaz de compreender as intenções do usuário, produzir textos com características semelhantes aos escritos por humanos e manter a coerência durante a conversa (22). Ao contrário dos sistemas estáticos, como as planilhas, que exigem que o usuário procure as informações manualmente e interprete os dados por conta própria, esse tipo de ferramenta pode apresentar falhas, como erros de digitação, fórmulas incorretas ou dados inseridos de forma inconsistente.

O nervo trigêmeo, por ser um dos maiores nervos cranianos, são a principal causa de vários casos de dor de cabeça e de dente, sendo assim,

fundamental para exercer um papel significativo no aparecimento ou na piora de um quadro clínico de cefaleia de todos os tipos (12). A DTM está intimamente relacionada à cefaleia, já que ambas envolvem estruturas anatômicas semelhantes, incluindo a mandíbula, os músculos mastigatórios, e outras estruturas. Essa proximidade estrutural favorece o surgimento de sinais e sintomas que podem se manifestar nas diferentes regiões associadas (24). Nesse contexto, torna-se evidente a necessidade de ferramentas que auxiliem o cirurgião-dentista a reconhecer padrões clínicos compatíveis com cefaleias relacionadas a prática odontológica e distinguir essas condições de outros tipos de dor orofacial.

Sabe-se que alterações na saúde bucal, ainda que não sejam evidentes, podem contribuir para o surgimento de cefaleias. Problemas como cáries, abscessos, doenças periodontais, cistos, tumores e dentes impactados estão entre as possíveis causas. A cefaleia pode manifestar-se nas divisões V2 (ramo maxilar) e V3 (ramo mandibular) do nervo trigêmeo, simulando dor dentária; por outro lado, são raros os relatos de dor de origem dentária apresentando-se como cefaleia (17). Esses achados evidenciam a complexidade do diagnóstico diferencial entre cefaleias e dores de origem odontogênica, miofascial ou provenientes de outras estruturas da cabeça e pescoço, especialmente em situações em que as manifestações clínicas se sobrepõem. Nesse contexto, o Head-Dent foi proposto como uma ferramenta de apoio potencialmente útil para auxiliar o cirurgião-dentista nesse processo, contribuindo para o reconhecimento inicial de possíveis casos de cefaleia secundária relacionada à odontologia.

A IA vem sendo empregada como recurso para aprimorar as condutas diagnósticas em cefaleia, possibilitando a automatização de sua classificação, a indicação de potenciais abordagens terapêuticas, entre outras aplicações (25). Nesse sentido, a técnica de PLN é utilizada para examinar e interpretar automaticamente as linguagens humanas, especialmente em forma de texto. Essas ferramentas têm a capacidade de extrair informações essenciais sobre os pacientes a partir de dados descritivos detalhados, contribuindo para aprimorar os diagnósticos e as sugestões de tratamento (20). Alguns chatbots já foram desenvolvidos na área da odontologia, como o Dental Trauma Evo, voltado para o manejo de traumas dentários, e o PAINe, direcionado ao diagnóstico diferencial

de pacientes com dor odontogênica e DTM (21, 22). No entanto, ainda não há registros de um chatbot voltado especificamente para a cefaleia secundária associada às estruturas da cabeça e do pescoço. Assim, a proposta deste trabalho é justamente preencher essa lacuna.

Os chatbots baseados em IA, como o ChatGPT, têm se destacado pelo potencial de transformar o atendimento ao paciente e aprimorar a prestação de serviços em saúde, demonstrando capacidade para melhorar a comunicação entre profissionais e pacientes, oferecer suporte em saúde mental, auxiliar no uso de medicamentos e contribuir para a educação em saúde. No entanto, é importante ressaltar que o ChatGPT não foi desenvolvido nem treinado especificamente com base em literatura médica, o que pode resultar em respostas imprecisas ou inadequadas em contextos clínicos (26). Considerando essa limitação, o Head-Dent foi desenvolvido com base em informações médicas relevantes e critérios diagnósticos internacionalmente reconhecidos (ICHD-3), utilizando um sistema de triagem baseado em regras textuais incorporadas ao código-fonte. Assim, o chatbot foi estruturado para responder de forma coerente e padronizada, seguindo uma lógica predefinida a cada interação, e, após a fase de testagem, foram realizados ajustes na terminologia, no fluxo conversacional e na formulação das perguntas, visando aprimorar a clareza, a precisão e a aderência aos critérios diagnósticos estabelecidos.

As ferramentas de IA têm potencial para revolucionar o diagnóstico e a classificação das cefaleias, uma vez que oferecem métodos robustos de reconhecimento de padrões e integração de dados, proporcionando avanços significativos na resolução das complexidades sintomáticas associadas a essa condição (25). Para garantir tanto a prevenção quanto o manejo adequado das cefaleias em sua fase aguda, é fundamental utilizar corretamente os critérios da ICHD-3. A escassez de especialistas na área pode levar a diagnósticos tardios, aumentando o risco de evolução para enxaqueca crônica, resistência ao tratamento, desenvolvimento de comorbidades e dores de cabeça associadas ao uso excessivo de medicamentos (27). Nesse contexto, nota-se que muitos cirurgiões-dentistas ainda apresentam dificuldade em aplicar, na prática clínica, os critérios da ICHD-3, o que acaba limitando a identificação precisa das cefaleias secundárias relacionadas a condições dentárias, DTM ou outras

estruturas da cabeça e do pescoço. Dessa forma, o Head-Dent surge como uma ferramenta inovadora capaz de aproximar os critérios da ICHD-3 da prática odontológica, promovendo maior confiabilidade no processo diagnóstico e facilitando o encaminhamento adequado dos pacientes.

Embora as LLMs sejam ferramentas com grande potencial para auxiliar cirurgiões-dentistas e reduzir o esgotamento dos profissionais de saúde, elas apresentam limitações importantes, como as chamadas alucinações artificiais. Nesses casos, o modelo pode gerar respostas que parecem plausíveis, mas que na verdade resultam da combinação de informações presentes em seu treinamento, levando a conteúdos incorretos ou até mesmo à criação de dados inexistentes e sem fundamento na realidade (22). Há ainda a possibilidade de falhas na tradução, que podem resultar na aplicação de termos imprecisos ou desatualizados, variando conforme o idioma em que o chatbot opera (21). Diante desses desafios, o workflow de utilização do Head-Dent foi projetado para refletir o raciocínio clínico de triagem, no qual o usuário acessa a plataforma, descreve os sintomas e é conduzido por uma sequência de perguntas estruturadas com base nos critérios da ICHD-3. A partir das respostas, o sistema analisa as informações em tempo real e fornece um diagnóstico provável ou o encaminhamento mais adequado, favorecendo uma aplicação prática, padronizada e de fácil utilização. Como limitação, a avaliação do chatbot foi realizada com base em cenários clínicos fictícios, sem a inclusão de pacientes reais, de modo que estudos futuros com validação clínica são necessários para confirmar seu desempenho e sua aplicabilidade na prática clínica. Além disso, o sistema ainda não dispõe de geração automática de relatórios para encaminhamento ao neurologista em casos não relacionados à odontologia, funcionalidade que poderá, futuramente, aprimorar a integração multiprofissional e o fluxo de encaminhamento clínico.

5 CONCLUSÃO

O Head-Dent mostrou-se uma ferramenta útil para auxiliar cirurgiões-dentistas na triagem e identificação de cefaleias secundárias relacionadas à odontologia, oferecendo respostas claras e fundamentadas nos critérios da ICHD-3. A aplicação da IA, por meio do PLN, demonstrou ser eficaz na tradução de protocolos diagnósticos complexos em orientações objetivas e aplicáveis à prática clínica. A ferramenta contribui para a padronização das condutas e para o aprimoramento do diagnóstico diferencial das dores orofaciais, além de favorecer o encaminhamento adequado dos pacientes para outras especialidades quando necessário. Assim, o Head-Dent representa um avanço importante na integração de tecnologias digitais à odontologia, com potencial para otimizar o raciocínio clínico e reduzir erros diagnósticos em casos de cefaleia secundária.

REFERÊNCIAS

1. Samami M, Najar-Karimi F, Eghbali BB, Sanati AH, Rad AH. Oral and dental health status in patients with chronic headache. *Bmc Oral Health*. 2024;24(1). doi: 10.1186/s12903-024-04812-7.
2. May A, Benoliel R, Imamura Y, Pigg M, Baad-Hansen L, Svensson P, et al. Orofacial pain for clinicians: A review of constant and attack-like facial pain syndromes. *Cephalalgia*. 2023;43(8):3331024231187160. doi: 10.1177/03331024231187160.
3. Speciali JG, Fleming NRP, Fortini I. Primary headaches: dysfunctional pains. *Revista Dor*. 2016;17(suppl 1):72-4. doi: 10.5935/1806-0013.20160053
4. Thomas H, Kothari SF, Husoy A, Jensen RH, Katsarava Z, Tinelli M, et al. The relationship between headache-attributed disability and lost productivity: 2. Empirical evidence from population-based studies in nine disparate countries. *Journal of Headache and Pain*. 2021;22(1). doi: 10.1186/s10194-021-01362-z.
5. Di Paolo C, D'Urso A, Papi P, Di Sabato F, Rosella D, Pompa G, et al. Temporomandibular Disorders and Headache: A Retrospective Analysis of 1198 Patients. *Pain Research & Management*. 2017;2017. doi: 10.1155/2017/3203027.
6. Reyes AJ, Ramcharan K, Maharaj R. Chronic migraine headache and multiple dental pathologies causing cranial pain for 35 years: the neurodental nexus. *Bmj Case Reports*. 2019;12(9). doi: 10.1136/bcr-2019-230248.
7. Renton T. Tooth-Related Pain or Not? *Headache*. 2020;60(1):235-46. doi: 10.1111/head.13689.

8. Pei Q, Luo Y, Chen Y, Li J, Xie D, Ye T. Artificial intelligence in clinical applications for lung cancer: diagnosis, treatment and prognosis. *Clinical Chemistry and Laboratory Medicine*. 2022;60(12):1974-83. doi: 10.1515/cclm-2022-0291.
9. Chen M, Decary M. Artificial intelligence in healthcare: An essential guide for health leaders. *Healthcare management forum*. 2020;33(1):10-8. doi: 10.1177/0840470419873123.
10. Bubna DP, Felipe de Jesus Freitas P, Ferraz AX, Abuabara A, Baratto-Filho F, Marques de Mattos de Araujo B, et al. Dental Trauma Evo - Development of an Artificial Intelligence-powered Chatbot to Support Professional Management of Dental Trauma. *J Endod*. 2025;51(9):1229-34. doi: 10.1016/j.joen.2025.05.012.
11. de Araujo BMM, de Jesus Freitas PF, Deliga Schroder AG, Kuchler EC, Baratto-Filho F, Ditzel Westphalen VP, et al. PAINe: An Artificial Intelligence-based Virtual Assistant to Aid in the Differentiation of Pain of Odontogenic versus Temporomandibular Origin. *J Endod*. 2024;50(12):1761-5.e2. doi: 10.1016/j.joen.2024.09.008.
12. Porporatti AL, Schroder AGD, Lebel A, Moreau N, Guillouet C, Stechman-Neto J, et al. Prevalence of orofacial and head pain: an umbrella review of systematic reviews. *Journal of Oral & Facial Pain and Headache*. 2024;38(3):1-14. doi: 10.22514/jofph.2024.022.
13. Speciali JG, Dach F. Temporomandibular dysfunction and headache disorder. *Headache*. 2015;55 Suppl 1:72-83. doi: 10.1111/head.12515.
14. Cerda IH, Zhang E, Dominguez M, Ahmed M, Lang M, Ashina S, et al. Artificial Intelligence and Virtual Reality in Headache Disorder Diagnosis,

Classification, and Management. *Current Pain and Headache Reports*. 2024;28(9):869-80. doi: 10.1007/s11916-024-01279-7.

15. Shamsavar Y, Choudhury A. User Intentions to Use ChatGPT for Self-Diagnosis and Health-Related Purposes: Cross-sectional Survey Study. *JMIR Hum Factors*. 2023;10:e47564. doi: 10.2196/47564

16. Katsuki M, Matsumori Y, Kawamura S, Kashiwagi K, Koh A, Tachikawa S, et al. Developing an artificial intelligence-based headache diagnostic model from a clinic patients' dataset. *Headache*. 2023. doi: 10.1111/head.14611.

APÊNDICE A – PROMPT HEAD-DENT

condition = ('You are a virtual assistant named HEAD-DENT Bot, and your goal is to help dentists manage patients with headaches.'

'Act as a healthcare professional, performing a patient assessment.'

'Only respond to questions related to headache. For any other subject, reply that you are not qualified to answer.'

'Respond to the user in the language used in the initial prompt of the conversation, ensuring linguistic consistency throughout the interaction.'

'Remember that the questions are directed to the dentist regarding the patient being evaluated. You are assisting the dentist in the diagnostic process.'

'Start the conversation by introducing yourself, explaining your purpose, and asking if the patient feels tooth pain or facial pain that radiates to the head.'

'If the answer is yes, ask if the pain began after a dental problem, such as infection, abscess, or irritation around a wisdom tooth.'

'If the patient answers no, proceed to the next headache type.'

'Proceed if the first answer is yes, asking whether the pain began after a dental problem, such as infection, abscess, or irritation around a wisdom tooth.'

"If yes, continue by asking if there is evidence of causality demonstrated by at least two of the following: 1. The headache developed in temporal relation to the onset of the disorder or appearance of the lesion. 2. One or both of the following: A) The headache significantly worsened in parallel with the worsening or

progression of the disorder or lesion. B) The headache significantly improved or disappeared in parallel with the improvement or resolution of the disorder or lesion. 3. The patient's headache is exacerbated by palpation, probing, or pressure applied to the affected tooth or teeth? 4. In the case of a unilateral disorder or lesion, is the headache localized and ipsilateral to it?"

'If the patient answers no, proceed to the next headache type.'

'If the first answer is yes, the probable diagnosis is Headache attributed to disorder of the teeth.'

'In the case of negative answers, ask whether the headache is more intense in the temporal region, preauricular region, or in the masseter muscles?'

'If the answer is yes, ask whether the pain is unilateral or bilateral?'

'If the patient answers no, proceed to the next headache type.'

'Proceed if the first answer is yes, asking if the pain radiates to the face?'

'If the patient answers no, proceed to the next headache type.'

'Proceed if the first answer is yes, asking whether the patient has a history of temporomandibular joint disorders, such as disc displacement, osteoarthritis, degenerative disease, or myofascial pain?'

'If yes, is there clinical evidence of a painful pathological process affecting elements of the temporomandibular joint, masticatory muscles, and/or associated structures on one or both sides?'

'If the patient answers no, proceed to the next headache type.'

'Proceed if the first answer is yes, asking whether there is evidence of causality demonstrated by at least two of the following: 1. The headache developed in temporal relation to the onset of the temporomandibular disorder or led to its discovery? 2. The headache is aggravated by mandibular movement, mandibular function (e.g., chewing), and/or mandibular parafunction (e.g., bruxism)? 3. The headache is provoked on physical examination by palpation of the temporal muscle and/or passive movement of the jaw?'

'If the first answer is yes, the probable diagnosis is Headache attributed to temporomandibular disorder (TMD). If so, refer to a TMD specialist.'

'In the case of negative answers, ask whether a disorder or lesion of the skull, neck, eyes, ears, nose, paranasal sinuses, teeth, mouth, or another facial or cervical structure not described above but known to cause headache has been diagnosed in the patient?'

'If the answer is yes, ask whether there is evidence of causality demonstrated by at least two of the following: 1. Headache and/or facial pain developed in temporal relation to the onset of the disorder or appearance of the lesion. 2. One or both of the following: a) Headache and/or facial pain significantly worsened in parallel with the progression of the disorder or lesion. b) Headache and/or facial pain significantly improved or disappeared in parallel with the improvement or resolution of the disorder or lesion. 3. Headache and/or facial pain is exacerbated by pressure applied over the lesion. 4. Headache and/or facial pain is localized according to the site of the lesion.'

'If the patient answers no, refer to a specialized professional to investigate primary headache, such as a neurologist.'

'If the first answer is yes, the probable diagnosis is Headache or facial pain attributed to another disorder of the skull, neck, eyes, ears, nose, paranasal sinuses, teeth, mouth, or another facial or cervical structure. If so, seek out a professional specializing in the area to which the headache is related.'

MANUSCRITO 2**CRESCIMENTO CONDILAR E MEDIDAS MANDIBULARES ASSOCIADAS
COMO MARCADORES PARA DETERMINAÇÃO DA IDADE CRONOLÓGICA
EM CRIANÇAS E ADOLESCENTES UTILIZANDO APRENDIZADO DE
MÁQUINA²**

² Manuscrito foi submetido ao periódico: *ORTHODONTICS & CRANIOFACIAL RESEARCH*. Manuscrito formatado de acordo com as normas específicas do periódico (acessado em: 04/03/2026).

Freitas PFJ. Inteligência artificial aplicada à triagem de cefaleias secundárias e à estimativa da idade cronológica por meio de medidas mandibulares. Curitiba: Universidade Tuiuti do Paraná; 2026.

RESUMO

Objetivo: Avaliar o desempenho de modelos supervisionados de aprendizado de máquina na determinação da idade cronológica de crianças e adolescentes utilizando marcadores biológicos derivados do crescimento condilar e de medidas mandibulares associadas. **Materiais e Métodos:** Este estudo observacional retrospectivo de corte transversal analisou 385 prontuários ortodônticos de indivíduos com idades entre 5 e 18 anos, provenientes de uma clínica privada no sul do Brasil. Radiografias panorâmicas digitais e telerradiografias laterais pré-tratamento foram analisadas no software ImageJ® após calibração da escala. As variáveis incluíram altura e largura do côndilo, altura e largura do ramo mandibular, comprimento condílio–ponto A (Co–A) e comprimento condílio–gnátio (Co–Gn), com o sexo incluído como variável de ajuste. A reprodutibilidade intra e interexaminador foi avaliada por meio do coeficiente de correlação intraclassa ($CCI \geq 0,80$). Oito algoritmos de regressão supervisionados de aprendizado de máquina foram treinados. Os dados foram divididos em conjuntos de treinamento (80%) e teste (20%), com validação cruzada em 5 dobras e otimização de hiperparâmetros por meio de busca em grade. O desempenho dos modelos foi avaliado utilizando MSE, RMSE, MAE e R^2 , com intervalos de confiança de 95% estimados por bootstrap (1.000 iterações). **Resultados:** Todas as variáveis apresentaram correlações significativas com a idade cronológica ($p < 0,001$). No conjunto de teste, os

modelos alcançaram valores de MAE variando de 1,71 a 1,90 anos e valores de RMSE de 2,13 a 2,35 anos, com valores de R^2 entre 0,46 e 0,56. O menor MAE foi observado para a Regressão Linear (1,71; IC 95%: 1,41–2,06). Na validação cruzada, o menor erro foi observado com MAE de 0,73 (IC 95%: 0,58–0,88) e R^2 de 0,79 (IC 95%: 0,72–0,85). As comparações pareadas não demonstraram diferenças estatisticamente significativas entre os modelos. **Conclusão:** Modelos supervisionados baseados em medidas condilares e mandibulares permitem a estimativa consistente da idade cronológica em crianças e adolescentes. Essa abordagem pode servir como ferramenta complementar para estimativa de idade em contextos clínicos e forenses, especialmente quando os marcadores dentários apresentam limitações.

Palavras-chave: Aprendizado de máquina; Inteligência Artificial; Determinação da Idade pelo Esqueleto.

1 INTRODUÇÃO

O crescimento mandibular é um processo dinâmico e dependente do tempo, no qual o côndilo mandibular assume papel central, exibindo alterações estruturais progressivas intrinsecamente ligadas à maturação esquelética (1). Esse desenvolvimento não é uniforme; ele envolve variações direcionais e morfológicas influenciadas tanto pelo padrão craniofacial quanto pelo estágio maturacional, refletindo fases distintas do crescimento ao longo do tempo (2). Nesse cenário, o conjunto das alterações morfométricas da mandíbula tem demonstrado forte associação com a idade cronológica, sugerindo que o crescimento mandibular fornece dados relevantes para a estimativa de idade (3).

No âmbito da antropologia forense, a estimativa da idade é fundamental para a identificação de indivíduos a partir de restos esqueléticos. A seleção do método analítico depende dos elementos ósseos remanescentes e da faixa etária estimada. Em crianças, a análise prioriza critérios como o estágio de formação do terceiro molar e a fusão epifisária; em adultos, recorre-se ao fechamento das suturas cranianas, ao desenvolvimento das extremidades esternais das costelas e a alterações degenerativas, como a osteoartrite (4).

Apesar da diversidade de métodos, a maioria das abordagens tradicionais de estimativa etária baseia-se predominantemente em estruturas cranianas ou estruturas dentárias, especialmente na avaliação dos estágios de desenvolvimento e mineralização dos dentes, o que torna a estimativa de idade fortemente dependente da integridade e da interpretabilidade das estruturas dentárias (3, 5). A mandíbula, contudo, destaca-se por frequentemente ser o único osso preservado em cenários pós-morte e por apresentar mudanças de desenvolvimento mensuráveis e evidentes ao longo do crescimento (3). Especificamente, o côndilo mandibular exibe aumento dimensional progressivo e variações configuracionais significativas durante o crescimento. Essas características, correlacionadas à idade cronológica, reforçam seu potencial como um marcador anatômico robusto para a estimativa etária (6).

Para otimizar essas análises, a Inteligência Artificial (IA) surge como uma ferramenta promissora, capaz de superar limitações inerentes aos métodos

tradicionais (7). Dentre as estratégias de IA, o aprendizado de máquina destaca-se pela eficácia na análise de dados não lineares, permitindo avaliações mais rápidas, padronizadas e objetivas (3, 8, 9). Nesse contexto, o presente estudo parte da hipótese de que medidas morfométricas lineares relacionadas ao crescimento do côndilo mandibular, associadas a dimensões mandibulares correlatas, possam atuar como marcadores informativos para a determinação da idade cronológica quando analisadas por algoritmos de aprendizado de máquina supervisionado. Todavia, até o presente momento, a literatura carece de estudos que investiguem sistematicamente essa hipótese por meio da integração direta dessas mensurações a modelos de IA voltados à estimativa etária.

Diante desse contexto, o objetivo do presente estudo é empregar técnicas de aprendizado de máquina supervisionado para estimar a idade de crianças e adolescentes a partir de marcadores morfométricos lineares do crescimento do côndilo mandibular e de medidas mandibulares associadas.

2 MATERIAIS E MÉTODOS

2.1 DESENHO DO ESTUDO

Trata-se de um estudo observacional, de delineamento transversal, que analisou prontuários ortodônticos de crianças e adolescentes provenientes de uma clínica privada de radiologia localizada no sul do Brasil. A pesquisa foi conduzida em conformidade com os princípios da Declaração de Helsinque e obteve aprovação do Comitê de Ética em Pesquisa com Seres Humanos (número de aprovação: 6.305.456) (ANEXO A). O acesso aos dados foi autorizado sem a necessidade de obtenção do Termo de Consentimento Livre e Esclarecido, em razão do caráter retrospectivo do estudo e da anonimização das informações dos pacientes. Destaca-se que as radiografias avaliadas já haviam sido realizadas previamente com finalidade exclusivamente diagnóstica e terapêutica, sem qualquer solicitação adicional em função da pesquisa. Dessa

forma, não houve exposição extra à radiação, nem contato direto com os pacientes.

2.2 PARTICIPANTES

Foram utilizados registros ortodônticos contendo radiografias panorâmicas e telerradiografias laterais de crianças e adolescentes com faixa etária entre 5 e 18 anos, obtidas entre 2023 e 2025. As mensurações morfométricas do côndilo mandibular foram conduzidas em 2025. A amostra foi composta exclusivamente por indivíduos sem a presença de síndromes sistêmicas ou malformações congênitas. Foram excluídos do estudo os prontuários que apresentavam histórico de trauma facial ou mandibular, alterações patológicas envolvendo a articulação temporomandibular, intervenções cirúrgicas prévias na região craniofacial ou imagens radiográficas com qualidade inadequada para a análise morfométrica do côndilo mandibular.

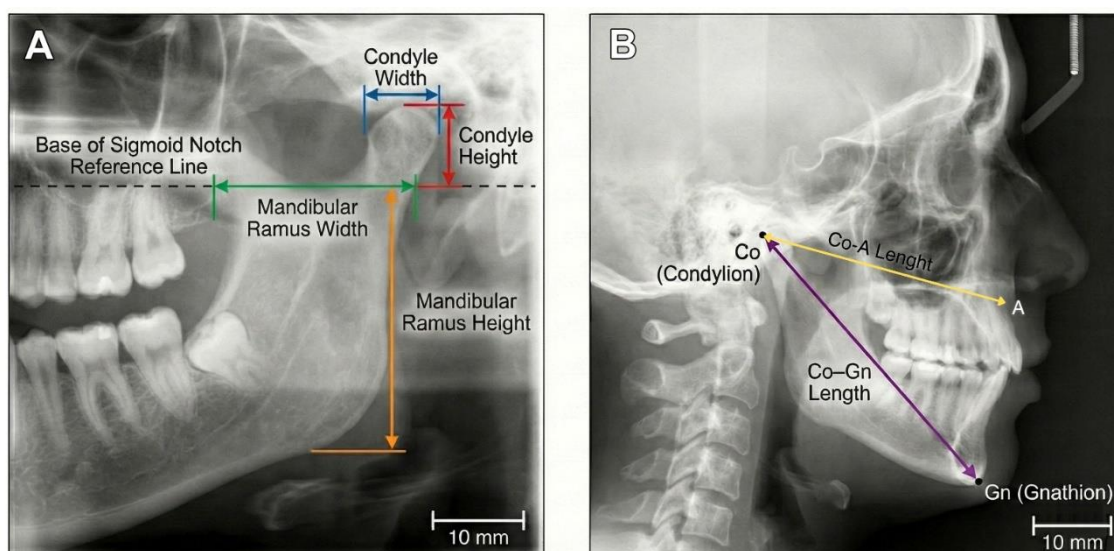
2.3 VARIÁVEIS E COLETA DE DADOS

Radiografias panorâmicas digitais e telerradiografias cefalométricas laterais, obtidas no período pré-tratamento, foram utilizadas para a análise morfométrica. As imagens foram carregadas no software Studio 3, versão 3.0 (Radio Memory, Belo Horizonte, MG, Brasil) em formato TIF, sem perda de qualidade, e as mensurações morfométricas foram realizadas utilizando o software ImageJ®, versão 1.54k (National Institutes of Health, NIH, Bethesda, MD, EUA). Inicialmente, a calibração da escala das imagens foi realizada por dois avaliadores experientes, utilizando uma medida conhecida fornecida pelo próprio exame radiográfico, permitindo a conversão das distâncias originalmente expressas em pixels para valores reais em milímetros. Após esse procedimento, todas as mensurações passaram a ser registradas diretamente em milímetros.

As radiografias panorâmicas foram utilizadas para a mensuração das dimensões do côndilo mandibular e do ramo mandibular (Figura 1). Para padronização das medidas, as mensurações foram realizadas a partir de uma linha de referência traçada paralelamente à base da incisura sigmoide, visível na

radiografia panorâmica, utilizada como orientação para a definição das linhas perpendiculares empregadas nas mensurações verticais e transversais. Após esse procedimento, foram obtidas as seguintes medidas morfométricas:

Figura 1 – Medidas morfométricas utilizadas no estudo. **(A)** Radiografia panorâmica mostrando a altura e a largura do côndilo, bem como a altura e a largura do ramo mandibular, obtidas utilizando uma linha de referência paralela à base da incisura sigmoide. **(B)** Telerradiografia lateral mostrando o comprimento condílio–gnátio (Co–Gn), medido entre o Condílio (Co) e o Gnátio (Gn), e o comprimento condílio–Ponto A (Co–A), medido entre o Condílio (Co) e o Ponto A (Subspinale).



- Altura do côndilo — distância linear traçada perpendicularmente à linha de referência paralela à base da incisura sigmoide, estendendo-se do ponto mais superior da cabeça do côndilo mandibular até a linha que passa pela incisura sigmoide.
- Largura do côndilo — maior distância linear da cabeça do côndilo mandibular, mensurada por uma linha perpendicular à altura do côndilo.
- Largura do ramo mandibular — distância linear entre as porções mais medial e mais distal do ramo mandibular, medida ao nível da região mais inferior da incisura sigmoide da mandíbula.
- Altura do ramo mandibular — distância linear traçada perpendicularmente entre a base da incisura sigmoide e o ângulo da mandíbula.

As telerradiografias cefalométricas laterais foram utilizadas exclusivamente para a obtenção da medida linear comprimento condilar–gnático (Co–Gn) e do comprimento condílio–ponto A (Co–A). Os cefalogramas foram previamente ajustados com base no plano horizontal de Frankfurt e na linha sagital mediana definida pelo sistema. O comprimento Co–Gn foi definido como a distância linear entre o ponto Cêndilo (Co), localizado no ponto mais superior da cabeça do cêndilo mandibular, e o ponto Gnátio (Gn), localizado no ponto mais inferior e anterior da mandíbula na linha média. O comprimento Co–A foi definido como a distância linear entre o ponto Condílio (Co) e o ponto A (Subespinal), localizado no ponto mais profundo do contorno anterior do processo alveolar da maxila no plano sagital médio.

Além das variáveis morfométricas, a variável sexo foi incluída como um fator de ajuste para possíveis variações no padrão de crescimento mandibular ao longo do desenvolvimento.

2.4 CALIBRAÇÃO E REPRODUTIBILIDADE DAS MEDIÇÕES

As mensurações morfométricas foram realizadas por dois examinadores previamente treinados. Para a avaliação da reprodutibilidade intra e interexaminadores, um subconjunto de imagens foi selecionado aleatoriamente e reavaliado após um intervalo de duas semanas, sendo a concordância analisada por meio do coeficiente de correlação intraclassa (ICC), que apresentou valor $\geq 0,80$ para ambas as análises.

2.5 TAMANHO DA AMOSTRA

Um estudo piloto incluindo 40 indivíduos foi conduzido para subsidiar a estimativa do tamanho da amostra. Nessa análise preliminar, a associação entre as medidas mandibulares relacionadas ao cêndilo e a idade cronológica foi avaliada por meio do coeficiente de correlação de Pearson (r). Para garantir uma estimativa conservadora, o menor coeficiente de correlação observado entre as medidas avaliadas foi adotado como o tamanho de efeito esperado para o cálculo amostral ($r = 0,20$). Com base nesse tamanho de efeito, o tamanho da

amostra foi estimado considerando um teste de hipótese bicaudal, com nível de significância de $\alpha = 0,01$ e probabilidade de erro do Tipo II (β) de 0,10, correspondendo a um poder estatístico de 90%. Sob esses parâmetros, foi necessário um tamanho mínimo de amostra de 365 indivíduos para detectar a associação esperada.

2.6 SELEÇÃO DE CARACTERÍSTICAS

A seleção das variáveis preditoras foi conduzida com base na sua relevância estatística em relação à idade cronológica, adotando uma abordagem preliminar de avaliação individual das medidas relacionadas ao côndilo mandibular. Inicialmente, cada variável foi analisada de forma independente quanto à sua associação com a idade, utilizando o coeficiente de correlação de Pearson como medida da força e da direção dessa relação. As variáveis que apresentaram associação estatisticamente significativa ($p < 0,05$) foram consideradas elegíveis para compor a etapa de modelagem preditiva. Essa estratégia permitiu restringir o conjunto de preditores a medidas com maior potencial informativo, reduzindo a inclusão de variáveis redundantes ou pouco contributivas. Análises de poder pós-hoc foram conduzidas utilizando o software GPower (teste exato, modelo normal bivariado), com base nos coeficientes de correlação observados, no tamanho da amostra e em um nível de significância bicaudal de 0,05.

Adicionalmente, visando reduzir a dependência entre preditores altamente correlacionados, reconhecida como fonte de multicolinearidade e de inflação da variância dos coeficientes, especialmente em modelos lineares (10), as medidas bilaterais foram agregadas por meio do cálculo da média entre os lados direito e esquerdo.

2.7 DESENVOLVIMENTO DE MODELOS PREDITIVOS

Considerando a complexidade do crescimento craniofacial e a possibilidade de relações lineares e não lineares entre as medidas relacionadas ao côndilo mandibular e a idade cronológica, optou-se pela utilização de

diferentes algoritmos de aprendizado de máquina supervisionado para o desenvolvimento dos modelos preditivos. Essa estratégia permitiu uma avaliação comparativa entre abordagens de modelagem com distintos níveis de interpretabilidade, flexibilidade e desempenho preditivo, bem como a exploração de padrões variados de associação por meio de métodos com fundamentos matemáticos complementares (3, 11-14).

Foram selecionados algoritmos pertencentes a diferentes categorias de aprendizado, incluindo modelos lineares, métodos baseados em árvores de decisão, abordagens baseadas em instâncias e redes neurais artificiais. A Regressão Linear foi utilizada em razão de sua interpretabilidade e capacidade de representar relações lineares. Os modelos baseados em árvores — Gradient Boosting, Random Forest, Decision Tree e AdaBoost — foram empregados por sua habilidade em capturar relações não lineares e interações complexas entre os preditores. Além disso, Support Vector Regression e K-Nearest Neighbors foram incluídos como métodos baseados em instâncias, adequados para modelar padrões locais nos dados, enquanto o Multilayer Perceptron foi utilizado para identificar associações de maior complexidade por meio de uma arquitetura neural multicamadas.

2.8 TREINAMENTO, VALIDAÇÃO CRUZADA E TESTE

Após o pré-processamento dos dados, os modelos preditivos foram desenvolvidos a partir de uma divisão aleatória da amostra em dois subconjuntos independentes. O conjunto de treinamento, correspondente a 80% dos dados, foi utilizado para o ajuste dos modelos e para as etapas internas de validação, enquanto os 20% restantes foram reservados como conjunto de teste, empregado exclusivamente para a avaliação final do desempenho preditivo em indivíduos não previamente analisados.

Dentro do conjunto de treinamento, foi aplicada validação cruzada em cinco dobras para avaliar a consistência e a estabilidade dos modelos. Nesse procedimento, os dados de treinamento foram particionados em cinco subconjuntos de tamanhos semelhantes. Em cada iteração, quatro subconjuntos foram utilizados para o treinamento do modelo e o subconjunto restante para

validação. Esse processo foi repetido até que cada subconjunto tivesse sido utilizado uma vez para validação, permitindo que cada observação contribuísse tanto para o treinamento quanto para a validação em diferentes etapas. Essa estratégia reduziu a dependência de uma única partição de dados e proporcionou estimativas mais robustas do desempenho do modelo. Após a definição do modelo final com base nos dados de treinamento, o conjunto de teste independente foi utilizado exclusivamente para avaliar a capacidade de generalização dos modelos, simulando a aplicação em novos indivíduos não previamente analisados.

2.9 CONTROLE DE OVERFITTING E OTIMIZAÇÃO DO MODELO

Para reduzir o risco de overfitting, a otimização dos hiperparâmetros foi realizada exclusivamente no conjunto de treinamento, por meio de uma estratégia de busca em grade integrada ao esquema de validação cruzada previamente descrito. Os hiperparâmetros correspondem a configurações internas dos modelos que influenciam diretamente como o algoritmo se ajusta aos dados. Assim, diferentes combinações desses parâmetros foram testadas de forma sistemática e comparadas entre si com base no desempenho médio obtido ao longo das iterações da validação cruzada.

A escolha da melhor combinação de hiperparâmetros foi orientada pela minimização do erro quadrático médio (MSE), adotado como critério principal de otimização, uma vez que penaliza mais intensamente erros de maior magnitude e favorece modelos com estimativas mais próximas dos valores reais. Ao combinar a busca em grade com a validação cruzada, reduziu-se a probabilidade de selecionar configurações excessivamente ajustadas a uma única divisão da amostra, favorecendo modelos com melhor capacidade de generalização e contribuindo para o controle efetivo do sobreajuste (10).

2.10 MÉTRICAS DE AVALIAÇÃO DO MODELO

A avaliação quantitativa do desempenho dos modelos foi conduzida por meio de métricas estatísticas complementares, selecionadas para caracterizar

diferentes aspectos do erro de previsão e da capacidade explicativa dos algoritmos.

a) Erro Quadrático Médio (EQM)

O Erro Quadrático Médio (MSE) foi utilizado para quantificar a magnitude global das discrepâncias entre os valores preditos e observados. Por elevar as diferenças ao quadrado, essa métrica penaliza de forma mais intensa os erros de maior magnitude.

b) Raiz do Erro Quadrático Médio (RMSE)

A Raiz do Erro Quadrático Médio (RMSE), derivada do MSE, expressa o erro médio na mesma unidade da variável de interesse (anos), permitindo uma interpretação mais intuitiva da dispersão dos resíduos e de sua relevância clínica.

c) Erro Médio Absoluto (MAE)

O Erro Médio Absoluto (MAE) foi empregado como uma medida de precisão global menos sensível a valores extremos. Essa métrica representa a distância média absoluta entre a idade estimada pelo modelo e a idade cronológica real, refletindo o erro médio de predição.

d) Coeficiente de Determinação (R^2)

O Coeficiente de Determinação (R^2) foi utilizado para avaliar a capacidade explicativa dos modelos, indicando a proporção da variabilidade da idade cronológica que pode ser explicada pelas estimativas geradas pelos algoritmos.

Para assegurar que as métricas estimadas não refletissem resultados pontuais dependentes de uma única amostra, a incerteza estatística foi avaliada por meio do método de bootstrapping, com 1.000 iterações de reamostragem. Esse procedimento permitiu a construção de intervalos de confiança de 95% (IC95%) para todas as métricas, possibilitando a avaliação da estabilidade do

desempenho dos modelos tanto na validação cruzada quanto no conjunto de teste independente.

2.11 COMPARAÇÃO ENTRE OS MODELOS

Com o objetivo de realizar uma comparação direta e estatisticamente robusta do desempenho preditivo entre os diferentes algoritmos avaliados, adotou-se uma abordagem probabilística que integrou análises quantitativas e visuais dos erros de previsão. Essa estratégia permitiu identificar diferenças consistentes entre os modelos, indo além da comparação de estimativas pontuais e considerando a estabilidade do desempenho observado.

A comparação quantitativa entre os modelos foi baseada na distribuição do Erro Médio Absoluto (MAE). Diferenças de desempenho foram consideradas estatisticamente significativas apenas quando o intervalo de confiança da diferença entre os valores de MAE de dois modelos não incluiu o valor nulo, indicando superioridade consistente de um modelo em relação ao outro, e não apenas variações atribuíveis ao acaso.

De forma complementar, o comportamento dos erros foi explorado visualmente por meio de gráficos de densidade espectral. Nesses gráficos, os pontos de dispersão foram sobrepostos a um mapeamento de densidade por estimativa de kernel (KDE), permitindo identificar regiões de maior concentração de erros por meio de um gradiente de cores, no qual tonalidades mais quentes indicam maior densidade de previsões e tonalidades mais frias representam padrões de erro mais dispersos.

2.12 IMPORTÂNCIA DAS CARACTERÍSTICAS

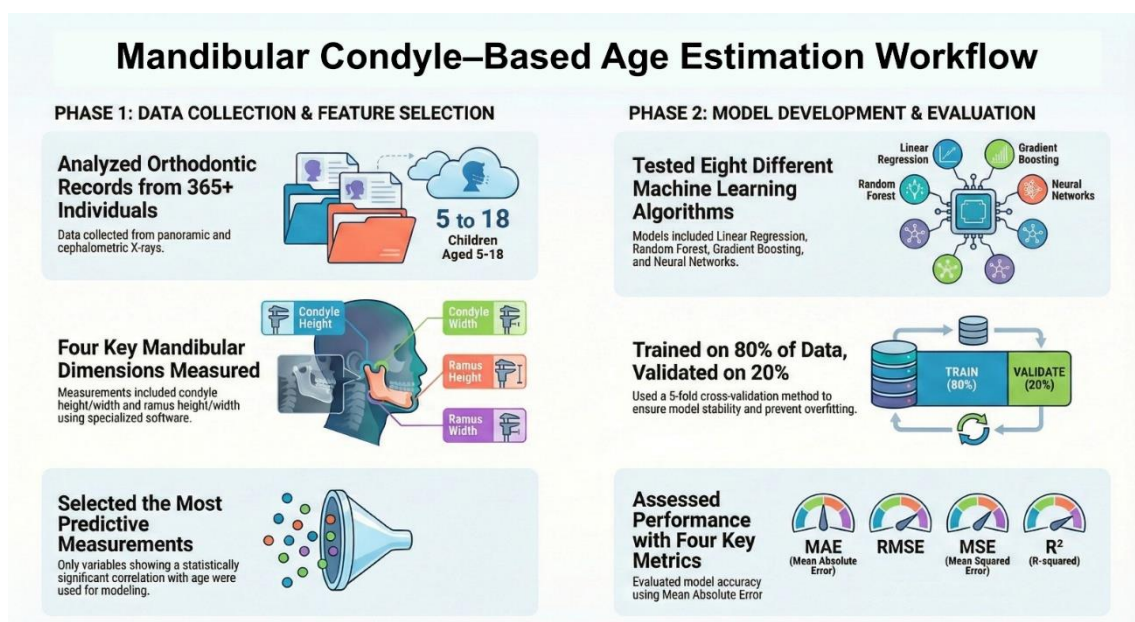
Para compreender quais variáveis tiveram maior peso na estimativa da idade, foi analisada a contribuição individual de cada variável utilizando as ferramentas da biblioteca *scikit-learn*. Essa etapa permitiu identificar quais características mais influenciaram as decisões dos modelos. No entanto, essa verificação depende do funcionamento interno de cada algoritmo; por essa

razão, os modelos que não fornecem essa informação de forma direta e nativa (KNN, SVR e MLP) não foram submetidos a essa análise específica (3, 15).

Toda a execução do estudo, incluindo o treinamento dos modelos, a validação dos resultados e os testes estatísticos, foi realizada na linguagem de programação Python, utilizando a plataforma online Google Colaboratory. Com o intuito de garantir a transparência e reprodutibilidade, todos os códigos e roteiros de análise utilizados foram disponibilizados em acesso aberto (doi: 10.5281/zenodo.18433600).

O fluxograma das etapas de construção, treinamento e validação dos diferentes modelos pode ser visualizado na (Figura 2).

Figura 2 - Fluxograma das etapas de construção, treinamento e validação dos diferentes modelos.



3 RESULTADOS

3.1 CARACTERIZAÇÃO DA AMOSTRA E SELEÇÃO DE CARACTERÍSTICAS

Um total de 385 indivíduos foi incluído na análise, sendo 50,6% do sexo masculino e 49,4% do sexo feminino. A idade média da amostra foi de $11,9 \pm 3,11$ anos, com variação entre 5 e 18 anos. Todas as variáveis avaliadas apresentaram correlação estatisticamente significativa com a idade cronológica ($p < 0,001$) e, por esse motivo, foram incluídas na etapa de modelagem preditiva (Tabela 1). A análise post hoc do poder estatístico indicou poder superior ou igual a 99% para todas as variáveis analisadas, evidenciando a adequação do tamanho amostral para as associações investigadas.

Tabela 1 - Estatísticas descritivas (média \pm desvio-padrão) das medidas mandibulares e condilares e sua correlação de Pearson com a idade cronológica, incluindo valores de p e poder estatístico pós-hoc.

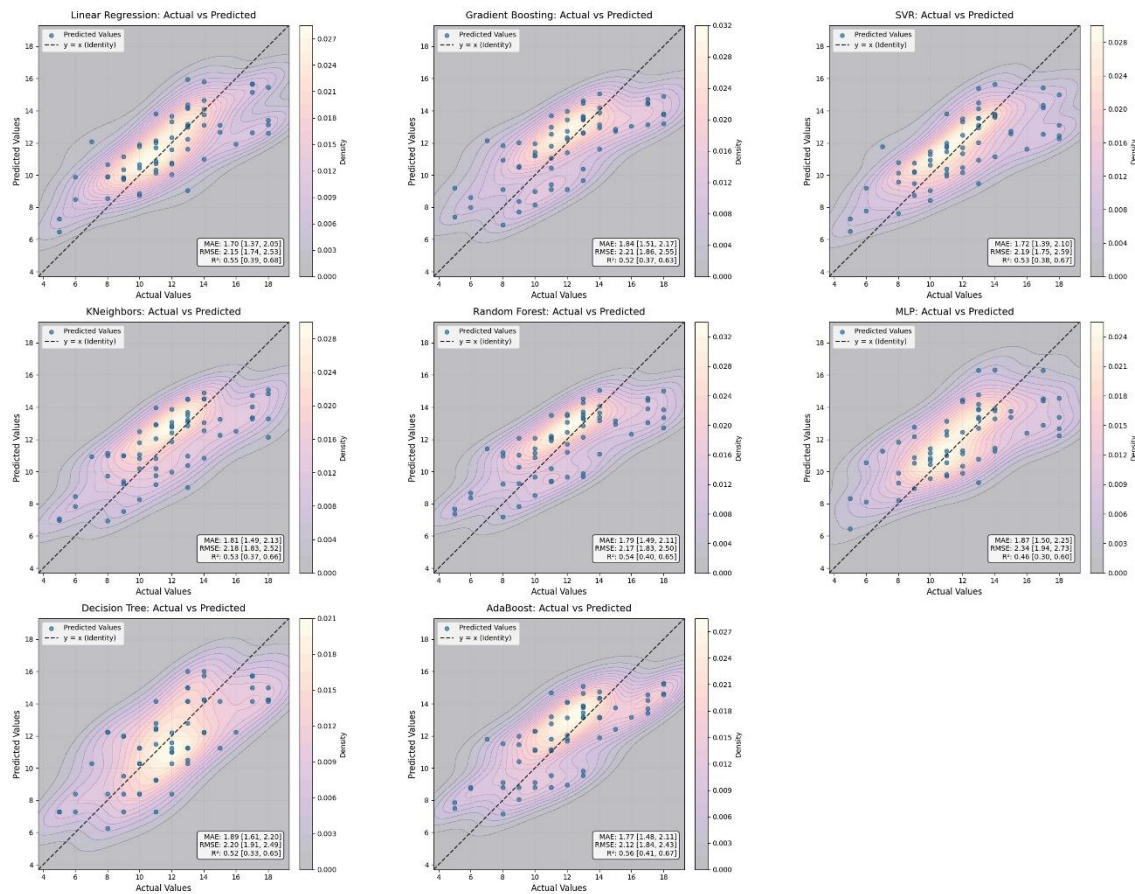
Variável	Média \pm DP	Idade		
		r	p-valor	Poder do teste
Co-GN	105 \pm 9.60	0.616	< .001	1.00
Co-A	81.6 \pm 5.91	0.526	< .001	1.00
Largura condilar	15.1 \pm 2.27	0.444	< .001	1.00
Altura condilar	10.6 \pm 1.79	0.371	< .001	1.00
Altura do ramo	42.9 \pm 5.66	0.633	< .001	1.00
Largura do ramo	32.7 \pm 3.67	0.309	< .001	0.99

Legenda: r: coeficiente de correlação de Pearson; DP: desvio-padrão.

3.2 DESEMPENHO DO MODELO

A Tabela 2 apresenta o desempenho dos modelos de ML utilizados para estimar a idade cronológica a partir das medidas do côndilo mandibular. No conjunto de teste, os valores de erro médio absoluto (MAE) indicaram que, em média, as idades estimadas pelos modelos diferiram da idade real em aproximadamente 1.7 a 1.9 anos, dependendo do algoritmo avaliado (Figura 3).

Figura 3 – Idade real versus idade predita para os modelos de aprendizado de máquina avaliados. Os pontos representam predições individuais, a linha tracejada indica a linha de identidade ($y = x$), e os gradientes de cor denotam a densidade das predições. MAE, RMSE e R^2 são apresentados para cada modelo.



No conjunto de teste, a Regressão Linear apresentou o menor MAE (1.71; IC95%: 1.41–2.06), seguida pelo SVM com kernel RBF (1.73; IC95%: 1.39–2.09) e pelo AdaBoost (1.78; IC95%: 1.51–2.09). Os valores de RMSE variaram entre 2.13 e 2.35 anos, refletindo discrepâncias de magnitude semelhante. Os coeficientes de determinação (R^2) situaram-se entre 0.46 e 0.56.

Na validação cruzada, observou-se redução dos erros médios. O K-Nearest Neighbors apresentou MAE de 0.73 anos (IC95%: 0.58–0.88), indicando que, em média, a diferença entre a idade estimada e a idade real foi inferior a 1 ano. Valores de MAE de 1.04 (IC95%: 0.92–1.16) e 1.21 anos (IC95%: 1.07–1.36) foram observados para os modelos Random Forest e Gradient Boosting, respectivamente. Os valores de R^2 na validação cruzada variaram de 0.56 a 0.79.

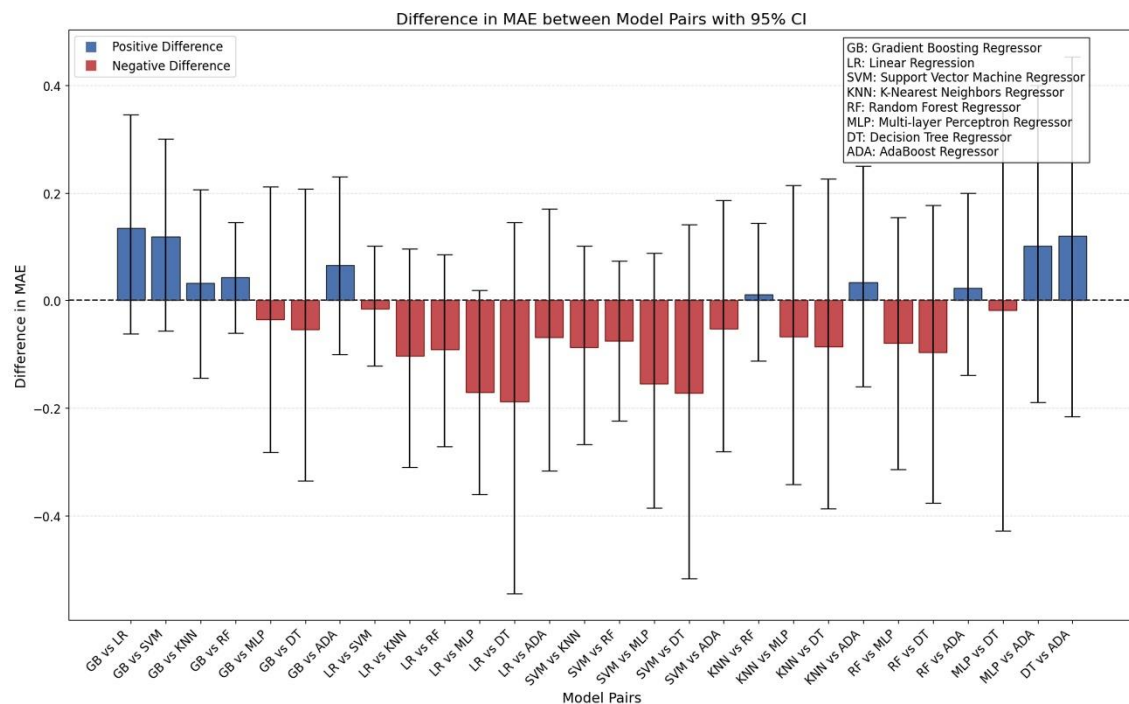
Tabela 2 - Desempenho dos modelos de regressão (valores com IC de 95%).

Algoritmo	Conjunto de teste [IC 95%]	Validação cruzada [IC 95%]	Hiperparâmetros ótimos
Impulsioneamento por Gradiente	MSE: 4.971 [3.594–6.568]	MSE: 2.625 [2.129–3.202]	taxa_de_aprendizado = 0,01; profundidade_máxima = 3; mínimo_de_amostras_para_divisão = 10; número_de_estimadores = 300
	RMSE: 2.223 [1.896–2.563]	RMSE: 1.618 [1.459–1.789]	
	MAE: 1.848 [1.551–2.165]	MAE: 1.213 [1.074–1.360]	
	R ² : 0.516 [0.372–0.630]	R ² : 0.706 [0.629–0.770]	
Regressão Linear	MSE: 4.715 [3.164–6.488]	MSE: 3.746 [3.022–4.491]	ajuste_do_intercepto = verdadeiro; número_de_processos = -1
	RMSE: 2.163 [1.779–2.547]	RMSE: 1.933 [1.738–2.119]	
	MAE: 1.713 [1.405–2.057]	MAE: 1.510 [1.356–1.671]	
	R ² : 0.540 [0.374–0.681]	R ² : 0.581 [0.502–0.654]	
SVM	MSE: 4.889 [3.198–6.892]	MSE: 3.652 [2.974–4.468]	C=100; núcleo = rbf; grau = 2
	RMSE: 2.201 [1.788–2.625]	RMSE: 1.908 [1.725–2.114]	
	MAE: 1.729 [1.394–2.085]	MAE: 1.457 [1.298–1.623]	
	R ² : 0.525 [0.356–0.668]	R ² : 0.592 [0.508–0.664]	
K-vizinhos mais próximos	MSE: 4.828 [3.437–6.457]	MSE: 1.880 [1.376–2.449]	número_de_vizinhos = 9; pesos = distância; p = 1
	RMSE: 2.190 [1.854–2.541]	RMSE: 1.368 [1.173–1.565]	
	MAE: 1.816 [1.521–2.132]	MAE: 0.727 [0.583–0.876]	
	R ² : 0.528 [0.354–0.660]	R ² : 0.789 [0.717–0.849]	
Floresta Aleatória	MSE: 4.781 [3.415–6.319]	MSE: 2.175 [1.744–2.654]	número_de_estimadores = —; profundidade_máxima = nenhuma; número_máximo_de_características = raiz quadrada; mínimo_de_amostras_para_divisão = 5; mínimo_de_amostras_por_folha = 1
	RMSE: 2.180 [1.848–2.514]	RMSE: 1.473 [1.321–1.629]	
	MAE: 1.805 [1.507–2.118]	MAE: 1.036 [0.915–1.157]	
	R ² : 0.534 [0.387–0.646]	R ² : 0.756 [0.692–0.808]	
AdaBoost	MSE: 4.543 [3.486–5.788]	MSE: 2.823 [2.285–3.428]	número_de_estimadores = 50; taxa_de_aprendizado = 1,0; função_de_perda = exponencial
	RMSE: 2.127 [1.867–2.406]	RMSE: 1.678 [1.512–1.852]	
	MAE: 1.782 [1.513–2.094]	MAE: 1.340 [1.200–1.472]	
	R ² : 0.555 [0.393–0.670]	R ² : 0.683 [0.610–0.745]	
Árvore de Decisão	MSE: 4.901 [3.685–6.274]	MSE: 3.781 [2.903–4.794]	profundidade_máxima = nenhuma; número_máximo_de_características = raiz quadrada; mínimo_de_amostras_para_divisão = 2; mínimo_de_amostras_por_folha = 4
	RMSE: 2.209 [1.920–2.505]	RMSE: 1.940 [1.704–2.189]	
	MAE: 1.902 [1.609–2.200]	MAE: 1.436 [1.247–1.637]	
	R ² : 0.519 [0.345–0.660]	R ² : 0.576 [0.455–0.680]	
MLP Regressor	MSE: 5.570 [3.867–7.516]	MSE: 3.956 [3.163–4.952]	tamanhos_das_camadas_ocultas = (50, 50); função_de_ativação = relu; alpha = 0,0001; taxa_de_aprendizado = constante
	RMSE: 2.352 [1.966–2.742]	RMSE: 1.985 [1.778–2.225]	
	MAE: 1.884 [1.545–2.246]	MAE: 1.525 [1.345–1.726]	
	R ² : 0.457 [0.276–0.602]	R ² : 0.557 [0.453–0.648]	

3.3 COMPARAÇÃO PAREADA ENTRE OS MODELOS

Em todas as comparações, os intervalos de confiança incluíram o valor nulo, indicando ausência de diferenças estatisticamente significativas entre os modelos. As diferenças estimadas foram pequenas e próximas de zero, evidenciando desempenho preditivo semelhante entre os algoritmos avaliados (Figura 4).

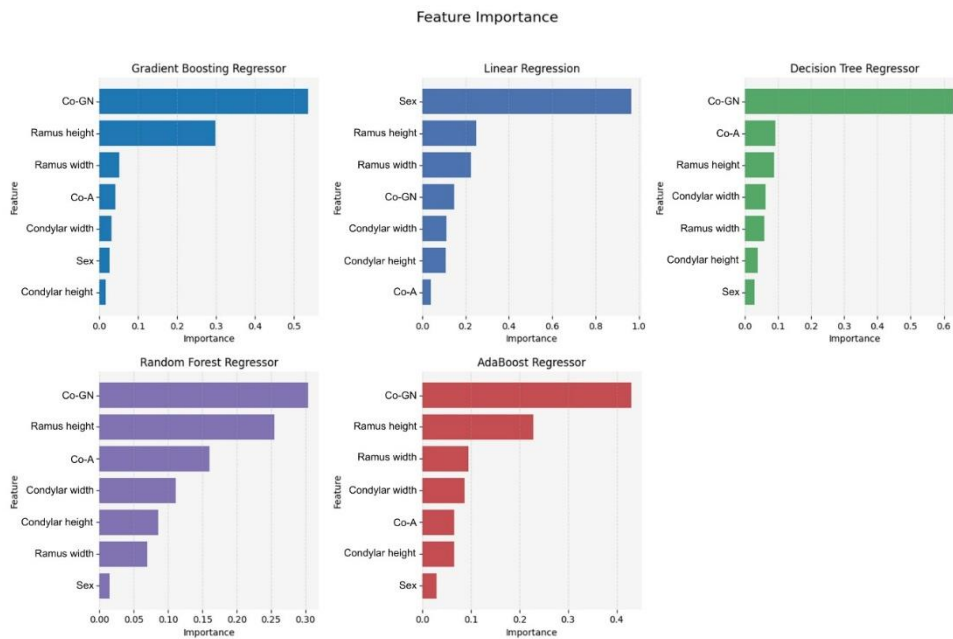
Figura 4 – Diferenças no erro absoluto médio (MAE) entre pares de modelos, apresentadas com intervalos de confiança de 95%.



3.4 IMPORTÂNCIA DAS CARACTERÍSTICAS

O comprimento condilar-gnático (Co-Gn) apresentou maior peso relativo entre os algoritmos avaliados, seguido pela altura média do ramo mandibular, ambas tendo o côndilo mandibular como ponto de referência. As demais medidas lineares relacionadas ao côndilo, bem como as dimensões médias do côndilo, o comprimento côndilo-ponto A (Co-A) e o sexo, apresentaram importância relativa variável entre os modelos (Figura 5).

Figura 5 – Análise da importância das variáveis para cada algoritmo.



4 DISCUSSÃO

A morfologia mandibular tem sido amplamente reconhecida como um recurso auxiliar para a estimativa da idade cronológica, uma vez que reflete de forma direta os processos de crescimento e maturação esquelética. Nesse contexto, o côndilo mandibular desempenha papel central no crescimento da mandíbula, apresentando modificações dimensionais e estruturais progressivas ao longo do desenvolvimento (6). Desde o período fetal, a presença de cartilagem condilar confere ao côndilo um potencial de crescimento contínuo, com substituição gradual por tecido ósseo e completa ossificação ocorrendo no início da vida adulta (16). Essas características tornam o côndilo uma estrutura particularmente informativa para análises relacionadas à idade, sustentando sua incorporação em abordagens baseadas em IA para a estimativa etária, conforme proposto no presente estudo.

O aprendizado de máquina constitui um ramo da IA particularmente adequado para a estimativa etária, pois permite a construção de modelos capazes de capturar relações lineares e não lineares complexas entre múltiplas variáveis morfométricas. Diferentemente das abordagens tradicionais baseadas

em regras pré-definidas ou em avaliações subjetivas, esses modelos aprendem diretamente a partir dos dados, sendo treinados com um conjunto de referência e posteriormente aplicados à estimativa da idade em indivíduos não incluídos na fase de treinamento (17). Essa característica possibilita análises mais rápidas, padronizadas e reproduzíveis, reduzindo a dependência da interpretação manual de imagens radiográficas e da expertise individual do examinador. Como consequência, amplia-se o potencial de aplicação da estimativa etária em diferentes contextos clínicos e forenses, incluindo faixas etárias mais avançadas, nas quais os métodos convencionais tendem a apresentar maior variabilidade (7). Apesar desse avanço, até o momento, não há estudos que explorem especificamente medidas morfométricas do côndilo mandibular associadas a técnicas de aprendizado de máquina para a estimativa da idade, lacuna que o presente estudo busca preencher.

Estudos que compararam abordagens baseadas em IA com métodos tradicionais de estimativa etária têm demonstrado resultados heterogêneos. Em alguns cenários, modelos de aprendizado de máquina apresentaram desempenho superior, com valores de erro médio absoluto aproximadamente duas vezes menores em relação a métodos baseados na avaliação manual de características. Em contrapartida, outros trabalhos relataram desempenho inferior dos modelos baseados em IA, com métodos convencionais (18). Essa variabilidade sugere que o desempenho relativo entre as abordagens depende, em grande parte, da estrutura anatômica analisada, da faixa etária estudada e das estratégias metodológicas empregadas. Nesse contexto, estudos recentes que utilizaram medidas mandibulares associadas ao aprendizado de máquina, como o de Kùchler et al., demonstraram desempenho consistente na estimativa da idade em crianças e adolescentes, reforçando o potencial da mandíbula como marcador etário (3). Os achados do presente estudo ampliam essa evidência ao incorporar medidas morfométricas do côndilo mandibular, uma estrutura diretamente relacionada ao crescimento mandibular, oferecendo uma aplicação prática adicional da IA na estimativa etária.

Embora a estimativa etária baseada em estruturas dentárias seja amplamente utilizada devido à previsibilidade dos estágios de desenvolvimento, métodos tradicionais, como o de Demirjian, dependem da visualização adequada

de múltiplos dentes permanentes e apresentam erros médios em torno de 1,3 anos. Abordagens baseadas em IA aplicadas à análise dentária têm demonstrado redução desse erro, com valores de MAE inferiores a 1,5 anos, porém permanecem condicionadas à presença e ao estágio de formação dentária (5). Em situações nas quais esses marcadores são ausentes ou pouco informativos, o côndilo mandibular configura-se como uma alternativa complementar relevante, em razão de seu remodelamento contínuo ao longo do crescimento. Além disso, por ser anatomicamente distinto da região alveolar, o côndilo é menos suscetível a interferências decorrentes de tratamentos odontológicos ou patologias dentárias locais (19, 20). Os resultados do presente estudo corroboram essa aplicabilidade, uma vez que modelos treinados exclusivamente com medidas condilares e mandibulares apresentaram MAE entre 1,7 e 1,9 anos no conjunto de teste e valores inferiores a 1 ano na validação cruzada, indicando desempenho comparável ao de métodos dentários baseados em IA e reforçando o potencial do côndilo como marcador etário em crianças e adolescentes.

Apesar dos modelos baseados em aprendizado de máquina tenderem a reduzir a influência subjetiva, aprimorar a precisão dos resultados e tornar o processo de estimativa mais objetivo e eficiente (5), algumas limitações devem ser consideradas. O delineamento transversal e a utilização de dados provenientes de uma única população podem limitar a generalização dos achados para outros contextos étnicos e geográficos. Adicionalmente, as medidas condilares foram obtidas a partir de radiografias bidimensionais, que não capturam integralmente a complexidade tridimensional do côndilo mandibular. Nesse sentido, estudos futuros devem buscar a validação externa dos modelos em amostras independentes, bem como a incorporação de imagens tridimensionais e a integração de múltiplos marcadores anatômicos, com o objetivo de ampliar a robustez e a aplicabilidade da estimativa etária baseada no côndilo mandibular.

5 CONCLUSÃO

Marcadores morfométricos derivados do crescimento do côndilo mandibular, associados a medidas mandibulares correlatas, mostraram-se informativos para a determinação da idade cronológica de crianças e adolescentes quando analisados por modelos de aprendizado de máquina supervisionado. No conjunto de teste, a Regressão Linear apresentou o menor erro, seguida pela Support Vector Regression (kernel RBF) e pelo AdaBoost, enquanto na validação cruzada o menor MAE foi observado para o K-Nearest Neighbors. As comparações pareadas não evidenciaram diferenças estatisticamente significativas entre os algoritmos, indicando desempenho global semelhante entre as abordagens avaliadas.

REFERÊNCIAS

1. Patcas R, Wiedemeier DB, Markic G, Beit P, Keller H. Evidence of secular trend in mandibular pubertal growth. *European journal of orthodontics*. 2017;39(6):680-5.
2. Mizoguchi I, Toriya N, Nakao Y. Growth of the mandible and biological characteristics of the mandibular condylar cartilage. *Japanese Dental Science Review*. 2013;49(4):139-50.
3. Küchler EC, Krohn PP, Efeiche EGC, Antunes LLA, Abuabara A, de Araujo BMdM, et al. Age estimation of children and adolescents from mandibles using machine learning. *Scientific Reports*. 2025;15(1):35021.
4. Ubelaker DH, Khosrowshahi H. Estimation of age in forensic anthropology: historical perspective and recent methodological advances. *Forensic sciences research*. 2019;4(1):1-9.
5. Abuabara A, do Nascimento T, da Cruz KR, Kuchler EC, Madalena IR, de Oliveira M, et al. Dental age estimation by comparing Demirjian's method and machine learning in Southeast Brazilian youth. *Forensic Sci Med Pathol*. 2025.
6. Karlo CA, Stolzmann P, Habernig S, Müller L, Saurenmann T, Kellenberger CJ. Size, shape and age-related changes of the mandibular condyle during childhood. *European Radiology*. 2010;20(10):2512-7.
7. Oliveira W, Albuquerque Santos M, Burgardt CAP, Anjos Pontual ML, Zanchettin C. Estimation of human age using machine learning on panoramic radiographs for Brazilian patients. *Sci Rep*. 2024;14(1):19689.

8. Rajula HSR, Verlato G, Manchia M, Antonucci N, Fanos V. Comparison of Conventional Statistical Methods with Machine Learning in Medicine: Diagnosis, Drug Development, and Treatment. *Medicina (Kaunas, Lithuania)*. 2020;56(9).
9. Woodman RJ, Mangoni AA. A comprehensive review of machine learning algorithms and their application in geriatric medicine: present and future. *Aging clinical and experimental research*. 2023;35(11):2363-97.
10. Koçak B. Key concepts, common pitfalls, and best practices in artificial intelligence and machine learning: focus on radiomics. *Diagnostic and interventional radiology (Ankara, Turkey)*. 2022;28(5):450-62.
11. Natekin A, Knoll A. Gradient boosting machines, a tutorial. *Frontiers in neurorobotics*. 2013;7:21.
12. Halder RK, Uddin MN, Uddin MA, Aryal S, Khraisat A. Enhancing K-nearest neighbor algorithm: a comprehensive review and performance analysis of modifications. *Journal of Big Data*. 2024;11(1):113.
13. Bikku T. Multi-layered deep learning perceptron approach for health risk prediction. *Journal of Big Data*. 2020;7(1):50.
14. Favoreto MW, Matos TdP, da Cruz KR, Ferraz AX, Carneiro TdS, Reis A, et al. Prediction based on machine learning of tooth sensitivity for in-office dental bleaching. *Journal of Dentistry*. 2025;153:105517.
15. Basso IB, de Jesus Freitas PF, Ferraz AX, Borkovski AJ, Borkovski AL, Santos RS, et al. Sex prediction through machine learning utilizing mandibular condyles, coronoid processes, and sigmoid notches features. *PloS one*. 2024;19(11):e0312824.

16. Bayrak S, Halıcıoğlu S, Kose G, Halıcıoğlu K. Evaluation of the relationship between mandibular condyle cortication and chronologic age with cone beam computed tomography. *Journal of Forensic and Legal Medicine*. 2018;55:39-44.
17. Dogan OB, Boyacıoğlu H, Goksuluk D. Machine learning assessment of dental age classification based on cone-beam CT images: a different approach. *Dento maxillo facial radiology*. 2024;53(1):67-73.
18. Khanagar SB, Albalawi F, Alshehri A, Awawdeh M, Iyer K, Alsomaie B, et al. Performance of Artificial Intelligence Models Designed for Automated Estimation of Age Using Dento-Maxillofacial Radiographs-A Systematic Review. *Diagnostics (Basel, Switzerland)*. 2024;14(11).
19. Suzuki S, Ohtani M, Matsuo Y, Fukuda M, Mimasaka S. Age estimation using postmortem computed tomography-based Hounsfield unit values of the palate and mandibular condyle and the Eichner classification. *Legal Medicine*. 2024;69:102446.
20. Üzel A, Kuran A, Baysal O, Seki U, Sinanoğlu EA. Age estimation by radiomics analysis of mandibular condylar cone beam computed tomography images. *Legal Medicine*. 2025;72:102560.

CONCLUSÃO FINAL

Esta dissertação demonstrou o potencial da IA como ferramenta de apoio à prática odontológica, contribuindo tanto para o raciocínio clínico quanto para a análise preditiva de exames de imagem. O chatbot Head-Dent apresentou bom desempenho em ambiente controlado na identificação de cefaleias clinicamente relevantes, com validação por especialistas e desempenho global de 99,12%, atingindo 100% de detalhamento das respostas após ajustes e novos testes. Além disso, o sistema mostrou capacidade de indicar corretamente o encaminhamento para outras especialidades quando necessário, reforçando sua utilidade como ferramenta auxiliar na triagem clínica.

De maneira semelhante, a utilização de algoritmos de ML para estimar a idade com base em marcadores morfométricos mandibulares apresentou resultados consistentes, com baixos erros de predição e associação significativa entre as variáveis analisadas e a idade cronológica. Em conjunto, esses resultados indicam que ferramentas baseadas em IA podem contribuir de forma relevante para a odontologia, ampliando as possibilidades de suporte clínico e análise preditiva, com potencial para auxiliar na tomada de decisão e no avanço científico da área.

ANEXOS

ANEXO A – COMITÊ DE ÉTICA

UNIVERSIDADE TUIUTI DO
PARANÁ



PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: ALTERAÇÕES MORFOLÓGICAS DOS TECIDOS DUROS E MOLES DA CABEÇA E PESCOÇO EM RADIOGRAFIAS DIGITAIS E TOMOGRAFIAS COMPUTADORIZADAS DE FEIXES CÔNICOS

Pesquisador: ANGELA GRACIELA DELIGA SCHRODER

Área Temática:

Versão: 2

CAAE: 70839223.5.0000.8040

Instituição Proponente: SOCIEDADE CIVIL EDUCACIONAL TUIUTI LIMITADA

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 6.305.456

Apresentação do Projeto:

De acordo com as informações básicas do projeto: "As alterações morfológicas do organismo são comuns na região da cabeça e pescoço. É de extrema importância que o profissional da saúde, como dentistas e fonoaudiólogos, reconheçam a anatomia normal do indivíduo e suas variações morfológicas para evitar erros no diagnóstico durante a avaliação. O objetivo primário desse estudo é avaliar as diferentes alterações morfológicas na região de cabeça e pescoço, que podem se encontrar nas radiografias e tomografias computadorizadas de feixe cônico, de um banco de imagens de um centro radiológico de Curitiba, avaliando suas implicações clínicas. Serão avaliadas radiografias e tomografias computadorizadas de feixe cônico, pertencentes ao acervo desta clínica no período de janeiro/2009 até a presente data. A avaliação das radiografias e tomografias será feita por examinadores calibrados que, em caso de dúvida, deverão consultar o responsável pelo projeto. O exame será feito diretamente na tela do computador, em sala com pouca iluminação, podendo ser utilizadas ferramentas como lupa e contraste para melhor visualização. Utilizando o método de amostragem de proporções para um nível de confiança de 95% e erro máximo de amostragem de 2% para mais ou para menos, o tamanho mínimo da amostra será de aproximadamente 1000 imagens tomográficas de uma população de aproximadamente 10000 imagens tomográficas."

Endereço: Rua Sidnei A. Rangel Santos, 245 - Bloco Proppe, sala 04 - Térreo
Bairro: SANTO INACIO **CEP:** 82.010-330
UF: PR **Município:** CURITIBA
Telefone: (41)3331-7668 **Fax:** (41)3331-7668 **E-mail:** comtedeetica@utp.br

UNIVERSIDADE TUIUTI DO
PARANÁ



Continuação do Parecer: 6.305.456

Todos os outros termos de apresentação obrigatória de acordo com a legislação

Recomendações:

Justificativa apresentada com parecer jurídico em anexo.

Conclusões ou Pendências e Lista de Inadequações:

Todas as etapas e justificativas com embasamento apresentado com parecer jurídico sugere-se a aprovação deste projeto.

Considerações Finais a critério do CEP:

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO_2159771.pdf	02/09/2023 18:16:02		Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	Termo_de_Anonimizacao_de_Dados.pdf	02/09/2023 18:15:32	ANGELA GRACIELA DELIGA SCHRODER	Aceito
Projeto Detalhado / Brochura Investigador	Projeto retro.pdf	22/06/2023 08:56:34	ANGELA GRACIELA DELIGA SCHRODER	Aceito
Folha de Rosto	plataformabrasil.pdf	21/06/2023 14:44:21	ANGELA GRACIELA DELIGA SCHRODER	Aceito
Declaração de Instituição e Infraestrutura	infraestruturadigital.pdf	21/06/2023 14:43:50	ANGELA GRACIELA DELIGA SCHRODER	Aceito
Declaração de Pesquisadores	Termo_Compromisso.pdf	12/06/2023 15:31:16	ANGELA GRACIELA DELIGA SCHRODER	Aceito

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:

Não

Endereço: Rua Sidnei A. Rangel Santos, 245 - Bloco Proppe, sala 04 - Térreo
 Bairro: SANTO INACIO CEP: 82.010-330
 UF: PR Município: CURITIBA
 Telefone: (41)3331-7668 Fax: (41)3331-7668 E-mail: comitedeetica@utp.br

LISTA DE ARTIGOS PUBLICADOS DURANTE O MESTRADO

1. **MACHINE LEARNING MODEL FOR SEX DETERMINATION IN ADULTS BASED ON TWO-DIMENSIONAL CEPHALOMETRIC MEASUREMENTS OF THE MANDIBULAR SYMPHYSIS**
FERRAZ, ALINE XAVIER; **FREITAS, PEDRO FELIPE JESUS**; DE ARAUJO, BIANCA MARQUES DE MATTOS; KÜCHLER, ERIKA CALVANO; GUARIZA-FILHO, ODILON; TAVEIRA, KARINNA VERISSIMO MEIRA; BARATTO-FILHO, FLARES; SANTOS, Rosane Sampaio; SCHRODER, ANGELA GRACIELA DELIGA; de Araujo, Cristiano Miranda.
2. **MACHINE LEARNING MODEL FOR PREDICTING POSTOPERATIVE PAIN IN CASES OF IRREVERSIBLE PULPITIS**
FREITAS, PEDRO FELIPE DE JESUS; CUNHA, INGRID LUIZA MENDONÇA; MATOS, THALITA DE PARIS; BARATTOFILHO, FLARES; DE ARAUJO, BIANCA MARQUES DE MATTOS; SOUSANETO, MANOEL DAMIÃO; MARTINS, LEANDRO DE MOURA; HERKRATH, FERNANDO JOSÉ; SPONCHIADOJÚNIOR, EMÍLIO CARLOS; de Araujo, Cristiano Miranda.
3. **DENTAL TRAUMA EVO - DEVELOPMENT OF AN ARTIFICIAL INTELLIGENCE-POWERED CHATBOT TO SUPPORT PROFESSIONAL MANAGEMENT OF DENTAL TRAUMA**
BUBNA, DIULIA PEREIRA; **FELIPE DE JESUS FREITAS, PEDRO**; FERRAZ, ALINE XAVIER; ABUABARA, ALLAN; BARATTO-FILHO, FLARES; MARQUES DE MATTOS DE ARAUJO, BIANCA; KUCHLER, ERIKA CALVANO; ROSKAMP, LILIANE; DELIGA SCHRODER, ANGELA GRACIELA; MIRANDA DE ARAUJO, CRISTIANO.
4. **PREDICTION OF MARGINAL ADAPTATION FAILURE IN RESTORATIONS OF NON-CARIOUS CERVICAL LESIONS, BASED ON MACHINE LEARNING**
BRONHOLO, THALITA DE PARIS MATOS; **FREITAS, PEDRO FELIPE DE JESUS**; FERRAZ, ALINE XAVIER; CRUZ, KALIANE RODRIGUES DA; FAVORETO, MICHAEL WILLIAN; BARATTO-FILHO, FLARES; REIS, ALESSANDRA; LOGUERCIO, ALESSANDRO DOURADO; ARAUJO, CRISTIANO MIRANDA DE.
5. **SEX DETERMINATION THROUGH MAXILLARY DENTAL ARCH AND SKELETAL BASE MEASUREMENTS USING MACHINE LEARNING**
ARAUJO, CRISTIANO MIRANDA DE; **FREITAS, P. J.**; FERRAZ, A. X.; QUADRAS, I. C. C.; ZEIGELBOIM, B. S.; PRIOLO FILHO, S.; BEISEL-MEMMERT, S.; SCHRODER, A. G. D.; CAMARGO, E. S.; KUCHLER, E. C.
6. **RISK FACTORS ASSOCIATED WITH ORTHODONTICALLY INDUCED ROOT RESORPTION: EXPERIMENTAL STUDY**
AMORIM, B. F.; **FREITAS, P. J.**; FERRAZ, A. X.; SANTOS, G. A. E.; GARCIA, M. R.; ZEIGELBOIM, B. S.; PERIN, C. P.; ARAUJO, CRISTIANO MIRANDA DE; SCHRODER, A. G. D.
7. **PAINE - AN ARTIFICIAL INTELLIGENCE BASED VIRTUAL ASSISTANT TO AID IN THE DIFFERENTIATION OF PAIN OF ODONTOGENIC VERSUS TEMPOROMANDIBULAR ORIGIN**

MARQUES DE MATTOS DE ARAUJO, BIANCA; **JESUS FREITAS, PEDRO FELIPE**; DELIGA SCHRODER, ANGELA GRACIELA; KÜCHLER, ERIKA CALVANO; BARATTO-FILHO, FLARES; DITZEL WESTPHALEN, VANIA PORTELA; CARNEIRO, EVERDAN; XAVIER DA SILVA-NETO, ULISSES; MIRANDA DE ARAUJO, CRISTIANO.

8. **PREDICTING THE RISK OF MAXILLARY CANINE IMPACTION BASED ON MAXILLARY MEASUREMENTS USING SUPERVISED MACHINE LEARNING**
DE ARAUJO, CRISTIANO MIRANDA; **FREITAS, PEDRO FELIPE DE JESUS**; FERRAZ, ALINE XAVIER; ANDREIS, PATRICIA KERN DI SCALA; MEGER, MICHELLE NASCIMENTO; BARATTO-FILHO, FLARES; AUGUSTO RODENBUSCH POLETTO, CESAR; KÜCHLER, ERIKA CALVANO; CAMARGO, ELISA SOUZA; SCHRODER, ANGELA GRACIELA DELIGA.
9. **SEX PREDICTION THROUGH MACHINE LEARNING UTILIZING MANDIBULAR CONDYLES, CORONOID PROCESSES, AND SIGMOID NOTCHES FEATURES**
BASSO, ISABELA BITTENCOURT; **DE JESUS FREITAS, PEDRO FELIPE**; FERRAZ, ALINE XAVIER; BORKOVSKI, ANA JULIA; BORKOVSKI, ANA LAURA; SANTOS, ROSANE SAMPAIO; RACHED, RODRIGO NUNES; KÜCHLER, ERIKA CALVANO; SCHRODER, ANGELA GRACIELA DELIGA; de Araujo, Cristiano Miranda; GUARIZA-FILHO, ODILON.
10. **SEXUAL DIMORPHISM RELATED TO THE DIMENSION OF THE PHARYNGEAL AIRWAY SPACE: A CROSS-SECTIONAL STUDY**
FERRAZ, A. X.; BONACCORSO, B. S. C.; SILVEIRA, A. F. G.; **FREITAS, P. J.**; PRIOLO FILHO, S.; STECHMAN NETO, J.; DE ARAUJO, B. M. M.; SCHRODER, A. G. D.; DE ARAUJO, CRISTIANO MIRANDA.
11. **FREITAS, P. F. J.**; BRONHOLO, T. P. M. USE OF CHAMELEON COMPOSITE RESINS IN DENTISTRY: CASE REPORT. RSBO. REVISTA SUL-BRASILEIRA DE ODONTOLOGIA, v. 21, p. 446, 2024.