



UNIVERSIDADE EVANGÉLICA DE GOIÁS
PROGRAMA DE PÓS-GRADUAÇÃO EM ODONTOLOGIA

Alex da Rocha Gonçalves

**USO DE UM ALGORITMO BASEADO EM INTELIGÊNCIA ARTIFICIAL PARA
AVALIAR A POSIÇÃO DE TERCEIROS MOLARES INFERIORES**

Anápolis, 2026

Alex da Rocha Gonçalves

**USO DE UM ALGORITMO BASEADO EM INTELIGÊNCIA ARTIFICIAL PARA
AVALIAR A POSIÇÃO DE TERCEIROS MOLARES INFERIORES**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Odontologia da Universidade Evangélica de Goiás – UniEVANGÉLICA, como requisito para obtenção do Título de Mestre em Odontologia. Área de concentração: Clínica Odontológica. Orientador: Prof. Dr. Helder Fernandes de Oliveira.

Anápolis, 2026

FICHA CATALOGRÁFICA

G635

Gonçalves, Alex da Rocha.

Uso de um algoritmo baseado em inteligência artificial para avaliar a posição de terceiros molares inferiores / Alex da Rocha Gonçalves - Anápolis: Centro Universitário de Anápolis – UniEvangélica, 2026.

36 p.; il.

Orientador: Prof. Dr. Helder Fernandes de Oliveira.

Dissertação (mestrado) – Programa de pós-graduação em Odontologia – Centro Universitário de Anápolis – UniEvangélica, 2026.

1. Inteligência Artificial	2. Terceiro molar	3. Cirurgia bucal
4. Radiografia panorâmica convolucionais	5. Aprendizado profundo	6. Redes neurais
I. Oliveira, Helder Fernandes		II. Título

CDU 616.314

Catálogo na Fonte
Elaborado por Rosilene Monteiro da Silva CRB1/3038



FOLHA DE APROVAÇÃO

USO DE UM NOVO MÉTODO PREDITIVO PARA AVALIAR A DIFICULDADE DE EXTRAÇÃO EM CIRURGIA DE TERCEIROS MOLARES INFERIORES POR MEIO DE UM ALGORITMO BASEADO EM INTELIGÊNCIA ARTIFICIAL

Alex da Rocha Gonçalves

Dissertação apresentada ao
Programa de Pós-graduação em
Odontologia - PPGO da
Universidade Evangélica de Goiás
- Unievangelica como requisito
parcial à obtenção do grau de
MESTRE.

Aprovado em 04 de março de 2026.

Linha de Pesquisa: Etiopatogenia, Diagnóstico e Tratamento das Doenças Bucais

Banca examinadora

Documento assinado digitalmente
HELDER FERNANDES DE OLIVEIRA
Data: 04/03/2026 15:20:43 -0300
Certificado em: <https://validar.jf.gov.br>

Prof. Dr. Helder Fernandes de Oliveira
Orientador / Unievangelica

Documento assinado digitalmente
ORLANDO AGUIRRE GUEDES
Data: 04/03/2026 11:34:04 -0300
Certificado em: <https://validar.jf.gov.br>

Prof. Dr. Orlando Aguirre Guedes
Examinador Interno / Unievangelica

Documento assinado digitalmente
MÔNICA MISAÊ ENDO
Data: 04/03/2026 09:20:23 -0300
Certificado em: <https://validar.jf.gov.br>

Profa. Dra. Mônica Misaê Endo
Examinadora Externa / Unievangelica

DEDICATÓRIA

Aos meus pais, pelo exemplo de dedicação e caráter.

À minha família, pelo amor incondicional.

Este título também é de vocês.

AGRADECIMENTOS

A Deus, pela força e sabedoria concedidas ao longo desta trajetória.

Ao Professor Helder Fernandes de Oliveira, meu orientador, pela orientação segura, paciência, confiança e valiosas contribuições para o desenvolvimento desta pesquisa.

Ao Professor Orlando Aguirre Guedes, coordenador do Programa de Pós-Graduação, pelo apoio, incentivo e contribuição significativa para a realização deste trabalho.

Aos professores do Programa de Pós-Graduação, aos professores convidados Ismar Nery Neto, Raoni Florentino da Silva Teixeira e Olavo Cesar Lyra Porto, pelos ensinamentos compartilhados e pela contribuição essencial à minha formação acadêmica e ao trabalho.

Aos colegas de curso, pela parceria, troca de experiências e apoio durante esta caminhada.

À minha família, pelo apoio incondicional, incentivo constante e compreensão nos momentos dedicados a este trabalho.

A todos que, de alguma forma, contribuíram para a execução desta pesquisa, meu sincero agradecimento.

SUMÁRIO

LISTA DE ABREVIATURAS E SIGLAS	8
RESUMO	9
ABSTRACT	10
1. INTRODUÇÃO	11
2. REVISÃO DA LITERATURA	13
3. OBJETIVOS	19
4. HIPÓTESES	20
5. MATERIAL E MÉTODOS	21
6. RESULTADOS	26
7. DISCUSSÃO	30
REFERÊNCIAS	33
PARECER CEP	Erro! Indicador não definido.

LISTA DE ABREVIATURAS E SIGLAS

AI – Artificial Intelligence

BDU-Net – Bidirectional Decoder U-Net

BoVW – Bag of Visual Words

CAAE – Certificado de Apresentação para Apreciação Ética

CBCT – Cone Beam Computed Tomography

CDI – Centro de Diagnóstico por Imagem

CEP – Comitê de Ética em Pesquisa

CNN – Convolutional Neural Network

CNS – Conselho Nacional de Saúde

Grad-CAM – Gradient-weighted Class Activation Mapping

IA – Inteligência Artificial

IDC – Imaging Diagnostic Center

ImageNet – Image Database for Visual Recognition

kVp – Quilovolt pico

mA – Miliampère

NIH – National Institutes of Health

RP – Radiografia panorâmica

RGB – Red, Green and Blue

RNC – Redes Neurais Convolucionais

ROC – Receiver Operating Characteristic

TCLE – Termo de Consentimento Livre e Esclarecido

TTA – Test-Time Augmentation

RESUMO

Objetivo: Desenvolver e validar um modelo preditivo baseado em inteligência artificial para classificação da posição de terceiros molares inferiores em radiografias panorâmicas, segundo a subclassificação de Pell & Gregory. **Material e Métodos:** Foram analisadas 950 radiografias panorâmicas digitais, distribuindo os elementos dentários em três classes (Classe I: n = 684; Classe II: n = 639; Classe III: n = 435). Foi implementada uma arquitetura do tipo *ensemble*, combinando duas redes neurais convolucionais pré-treinadas (ResNet-18 e EfficientNet-B0) com estratégia de *transfer learning* progressivo. As imagens monocromáticas foram adaptadas para canal único, preservando os pesos do pré-treinamento. Para mitigação do desbalanceamento entre classes, foram empregadas amostragem ponderada, ponderação na função de perda e *label smoothing*. Aplicaram-se técnicas de aumento de dados específicas para imagens médicas, incluindo rotações controladas, transformações afins, ajustes de nitidez, equalização histográfica e técnica *mixup*. A fusão das arquiteturas foi realizada por concatenação das representações extraídas, seguida de camadas totalmente conectadas com *dropout* progressivo e normalização por lote. O treinamento utilizou o otimizador AdamW com taxas de aprendizado discriminativas, agendador CosineAnnealingWarmRestarts, validação cruzada estratificada (80/20), *early stopping* e *test-time augmentation*. A avaliação incluiu acurácia, precisão, recall, F1-score e curva ROC, adotando-se nível de significância de 5%. **Resultados:** O modelo alcançou acurácia global de 82,7% no conjunto de validação (n = 352). A Classe I apresentou os melhores indicadores (precisão = 0,895; recall = 0,934; F1-score = 0,914), seguida da Classe II (F1-score = 0,769) e Classe III (F1-score = 0,768). O F1-score médio macro foi de 0,817 e o ponderado de 0,826, indicando desempenho consistente mesmo diante da distribuição desigual das classes. A análise das curvas de treinamento demonstrou adequada convergência, com redução progressiva do *loss* e ausência de sobreajuste significativo. **Conclusão:** O modelo *ensemble* baseado em redes neurais convolucionais demonstrou desempenho robusto e potencial aplicabilidade clínica como ferramenta auxiliar na avaliação pré-operatória da posição de terceiros molares inferiores.

Palavras-chave: inteligência artificial; terceiro molar; cirurgia bucal; radiografia panorâmica; aprendizado profundo; redes neurais convolucionais.

ABSTRACT

Objective: To develop and validate a deep learning–based predictive model for automated classification of mandibular third molar surgical difficulty on panoramic radiographs according to the Pell and Gregory system. **Materials and Methods:** A dataset of 1,758 digital panoramic radiographs was retrospectively collected and categorized into three classes (Class I: n = 684; Class II: n = 639; Class III: n = 435). An ensemble architecture combining two pre-trained convolutional neural networks (ResNet-18 and EfficientNet-B0) was implemented using progressive transfer learning. Class imbalance was addressed through weighted sampling, class-weighted loss functions, and label smoothing. Medical image–specific data augmentation techniques, including controlled rotations, affine transformations, histogram equalization, and mixup, were applied to enhance robustness. Feature embeddings from both networks were concatenated and processed by fully connected layers with dropout and batch normalization. Optimization employed AdamW with discriminative learning rates and cosine annealing scheduling. Stratified 80/20 cross-validation, early stopping, and test-time augmentation were incorporated. Model performance was assessed using accuracy, precision, recall, F1-score, and ROC curve analysis. **Results:** The model achieved an overall validation accuracy of 82.7% (n = 352). Class I demonstrated superior performance (precision = 0.895; recall = 0.934; F1-score = 0.914), whereas Class II and Class III achieved F1-scores of 0.769 and 0.768, respectively. The macro-averaged F1-score was 0.817 and the weighted F1-score was 0.826, indicating stable predictive performance despite moderate class imbalance. Training curves demonstrated progressive loss reduction and no significant overfitting. **Conclusion:** The proposed ensemble model showed robust performance and potential clinical applicability as a decision-support tool for preoperative assessment of third molar extraction difficulty.

KEYWORDS: Artificial Intelligence; Third Molar; Oral Surgery; Panoramic Radiography; Deep Learning; Convolutional Neural Networks.

1. INTRODUÇÃO

A exodontia de terceiros molares inferiores parcialmente e/ou totalmente impactados representa um dos procedimentos cirúrgicos mais comumente abordados na prática clínica. Suas indicações devem ser criteriosamente avaliadas para a tomada de decisão. Estudos apontam que a decisão sobre a exodontia deve ser tomada antes dos 25 anos de idade, devido ao fato de que pacientes mais jovens apresentam um risco menor de complicações e tempo operatório reduzido em comparação aos pacientes com idade mais avançada¹.

A radiografia panorâmica (RP) é uma radiografia extraoral comumente utilizada para a identificação dos tecidos duros da cavidade oral, fornecendo uma visão geral, baixa dose de radiação e baixo custo².

Embora as radiografias panorâmicas apresentem uma sensibilidade limitada, são as primeiras radiografias radiológicas básicas a serem realizadas. Em um estudo retrospectivo foi realizado a acurácia diagnóstica de radiografias panorâmicas na detecção de alterações dentárias mostrando boa acurácia diagnóstica, alta especificidade e baixa sensibilidade. Portanto, continua ainda hoje a desempenhar um papel fundamental³.

A avaliação da complexidade cirúrgica da extração de terceiros molares é um passo crucial para formular um plano de tratamento ideal, equilibrando vantagens e desvantagens do procedimento cirúrgico. Uma avaliação precisa também é essencial para planejar uma intervenção cirúrgica adequada, a fim de minimizar e gerenciar complicações intraoperatórias. Além disso, o paciente deve receber uma previsão precisa e confiável sobre a complexidade cirúrgica e os riscos de complicações, a fim de obter um consentimento por parte do paciente. Por fim, a previsão confiável do tempo cirúrgico é um fator importante para otimizar a programação diária tanto dos operadores quanto dos pacientes. Várias classificações para cirurgia de terceiros molares impactados foram propostas para prever a complexidade cirúrgica e/ou o risco de complicações intraoperatórias¹.

A estimativa da dificuldade de extração, têm sido estabelecidas por fatores dentários evidentes na avaliação radiológica da dentição. Isto é feito a partir de três sistemas de classificação baseados em fatores dentários (WHARFE-Macgregor 1985, linhas Winters-Winter 1926 e classificação Pell & Gregory 1933)^{4,5,6}. Apesar dessa avaliação radiológica, a literatura sugere que

os fatores do paciente também têm um impacto importante no aumento da dificuldade da cirurgia de terceiros molares; particularmente idade, sexo, tamanho e origem étnica⁶.

A extração dos terceiros molares inferiores também está associada a várias complicações e erros. Entre as complicações mais comuns estão infecção pós-operatória, alvéolo seco, lesão nervosa, edema prolongado e hemorragia. Fatores como a posição anatômica do dente, a idade do paciente e a experiência do cirurgião podem influenciar diretamente o risco dessas complicações. Lesões ao nervo alveolar inferior e ao nervo lingual são problemas significativos, podendo levar a parestesia temporária ou permanente. Além disso, erros técnicos durante a cirurgia, como manipulação excessiva de tecidos ou limitações indiretas, aumentam o risco de complicações inflamatórias⁷.

A inteligência artificial (IA) nos últimos anos vem mostrando progressos graduais e constantes na interpretação das informações. Isso levou a grandes avanços e sua aplicação em várias áreas, não sendo diferente na Odontologia. A fim de melhorar a eficiência da interpretação, reduzir diagnósticos incorretos e diminuir a frequência de diagnósticos perdidos causados por fatores humanos, hoje já podemos ter acesso a alguns algoritmos de IA para diagnosticar múltiplas doenças dentárias em radiografias panorâmicas⁸.

Em 2023, Zhu *et al.*,⁸ desenvolveram uma estrutura de IA baseada em nnU-Net e BDU-Net com sucesso e demonstraram alta eficiência e especificidade no diagnóstico de dentes impactados, coroas completas, dentes perdidos, raízes residuais e cáries em seu estudo. Com isso podemos buscar melhora na precisão e agilidade do diagnóstico de doenças dentárias e da execução do tratamento, conduzindo potencialmente a melhores resultados para os pacientes e menores custos. Corroborando com o que foi observado em outros estudos, em 2022, Putra *et al.*,⁹ realizou uma revisão a respeito da aplicabilidade da IA para radiografia dentária a partir dos estudos atuais e concluiu que o uso da Inteligência artificial na radiologia tem demonstrado grande potencial para uma ampla variedade de finalidades e pode desempenhar um papel importante no auxílio aos profissionais no processo de tomada de decisão.

O propósito do presente estudo foi realizar a associação de duas redes neurais para identificar e classificar a posição de terceiros molares inferiores.

2. REVISÃO DA LITERATURA

Indicações para exodontias de terceiros molares inferiores

Os terceiros molares possuem indicações para exodontias bem delimitadas na literatura, incluindo cáries, pericoronarites, defeitos periodontais envolvendo a raiz distal dos segundos molares, cistos odontogênicos e apinhamento dentário¹. De acordo com as recomendações do National Institutes of Health (NIH), tanto os terceiros molares inferiores impactados como os parcialmente erupcionados com evidência de aumento do espaço folicular devem ser removidos e o tecido mole associado deve ser colhido para exame histológico¹⁰. A Associação Americana de Cirurgiões Orais e Maxilofaciais afirmam que também pacientes livres de doença com terceiros molares inferiores devem ser monitorados¹¹.

Quando indicados para exodontia, o correto planejamento e diagnóstico tem direta influência no prognóstico obtido. A complexidade da exodontia dos terceiros molares pode levar em consideração dentes que se encontram disto angulados, com raízes curvas, longas e finas, presença de um tecido ósseo circundante denso e inelástico, com proximidade do canal do nervo alveolar inferior, espaço do ligamento periodontal estreito e folículo pequeno são indicativos de dificuldade cirúrgica aumentada¹².

Classificações quanto ao posicionamento dos terceiros molares inferiores

A classificação de Pell e Gregory também é muito utilizada para auxiliar na determinação do grau de dificuldade, sendo avaliado o relacionamento do terceiro molar com a borda anterior do ramo, onde se encontra, em ordem crescente de dificuldade: Classe 1: Diâmetro mesiodistal da coroa totalmente anterior a borda anterior do ramo da mandíbula; Classe 2: Diâmetro mesiodistal da coroa $\frac{1}{2}$ coberto pelo ramo anterior da mandíbula; Classe 3: Diâmetro mesiodistal da coroa totalmente coberto pelo ramo anterior da mandíbula¹³.

Assim como a relação do terceiro molar com a borda anterior da mandíbula nos fornece uma previsibilidade da dificuldade de remoção, a relação com o plano oclusal também foi objeto de classificação segundo Pell e Gregory, sendo: Classe A: A superfície oclusal do dente impactado é no nível ou próximo ao nível do plano oclusal do segundo molar adjacente; Classe B: Superfície oclusal entre o plano oclusal e a linha cervical do segundo molar adjacente; Classe C: Superfície oclusal do terceiro molar está abaixo da linha cervical do segundo molar¹³.

Técnicas de exodontia de terceiros molares inferiores

A complexidade cirúrgica é estipulada pelo grau de dificuldade e impacta na técnica de escolha para exodontia, podendo ou não incluir, além das técnicas convencionais de elevação e luxação, a osteotomia e/ou odontosecção. A escolha do retalho também é influenciada pelo grau de dificuldade pré-estabelecido¹⁵. Em seu trabalho Gay *et al.*¹⁴, propôs um questionário pré-cirúrgico que auxilia na determinação do grau de dificuldade de exodontia baseando-se em informações clínicas e radiográficas. Munido de tais informações, o cirurgião-dentista se encontra habilitado para realizar a escolha adequada da técnica,

Exames por imagens no planejamento para exodontia de terceiros molares inferiores (panorâmicas e CBCT)

As radiografias panorâmicas fornecem informações importantes para o diagnóstico de lesões, incluindo cáries, doenças periodontais, cistos/tumores mandibulares, doenças do seio maxilar, entre outras. Porém, existem obstáculos quanto à interpretação dos achados como a sobreposição de outras estruturas da face ou inexperiência do profissional. Com isso, iniciou-se uma busca para introdução da inteligência artificial (IA) na análise destas imagens visando aprimorar e facilitar a avaliação desses dados radiográficos¹⁵.

O estudo desenvolvido por Vesala *et al.*¹⁶ aponta que a radiografia panorâmica segue sendo um exame acurado e indicado para a avaliação e monitoramento dos terceiros molares, incluindo aqueles em que não há sintomatologia associada.

Complicações cirúrgicas em exodontia de terceiros molares inferiores

A extração de terceiros molares é um procedimento odontológico comum que pode resultar em diversas complicações pós-operatórias. De acordo com o estudo de Wang *et al.*,¹⁷ as infecções são uma das complicações mais frequentes, atribuídas à presença de bactérias na cavidade oral e à complexidade do procedimento cirúrgico. Além disso, dor e inchaço são reações comuns resultantes do trauma tecidual e da resposta inflamatória, frequentemente observadas nos primeiros dias após a extração. A alveolite, uma condição dolorosa caracterizada pela desintegração prematura do coágulo

sanguíneo no alvéolo dental, também é uma complicação significativa, com fatores de risco como tabagismo e uso de contraceptivos orais.

O estudo de Rizqiawan A *et al.*,¹⁸ complementa essas alterações, destacando a influência da idade do paciente e da complexidade da cirurgia no risco de complicações. Infecções pós-operatórias são mais frequentes em pacientes mais velhos devido à menor capacidade de cicatrização e condições sistêmicas comprometedoras. A dor e o inchaço são mais intensos e prolongados em pacientes submetidos a procedimentos mais complexos. A alveolite, mais comum em extrações difíceis e em pacientes fumantes, e o trismo, associado à complexidade cirúrgica, também são complicações observadas.

Complicações pós-operatórias da extração de terceiros molares são influenciadas por vários fatores, incluindo a presença de bactérias, a complexidade do procedimento, a idade do paciente e hábitos como o tabagismo. A literatura sugere que uma abordagem cuidadosa e personalizada para cada paciente pode ajudar a minimizar o risco de complicações e melhorar os resultados cirúrgicos^{17,18}.

Uso da Inteligência Artificial para escolha da técnica cirúrgica de terceiros molares inferiores

Para além da escolha do método de avaliação radiográfica do terceiro molar, é importante compreender que novos métodos têm sido desenvolvidos para as mais diversas tarefas diagnósticas e sistemas de apoio de decisões. Um exemplo disso é o uso de modelos de inteligência artificial (IA) que possam auxiliar o cirurgião-dentista a tornar a prática clínica mais previsível e com melhores prognósticos¹⁹.

Zhu *et al.*,⁹ desenvolveram uma estrutura de IA para diagnosticar múltiplas doenças dentárias em radiografias panorâmicas e avaliar inicialmente seu desempenho. A avaliação diagnóstica foi realizada em um conjunto de dados de avaliação separado, incluindo 282 radiografias panorâmicas. Dentistas com 3 níveis diferentes de senioridade (H: alto, M: médio, L: baixo) diagnosticaram o mesmo conjunto de dados de avaliação de forma independente. A estrutura de IA demonstrou alta especificidade no diagnóstico de dentes inclusos, coroas totais, dentes perdidos, raízes residuais e cáries com alta eficiência. A viabilidade clínica da estrutura de IA foi verificada preliminarmente, uma vez que seu

desempenho foi semelhante ou até melhor do que os dentistas com 3 a 10 anos de experiência.

Ha *et al.*,²⁰ criaram um modelo de aprendizado profundo para classificar automaticamente pseudocistos de retenção nos seios maxilares em radiografias panorâmicas. O modelo desenvolvido foi treinado 200 vezes nos conjuntos de dados de treinamento e validação (342 seios), e o desempenho do modelo foi avaliado em termos de precisão, sensibilidade e especificidade no conjunto de dados de teste (21 pseudocistos de retenção, 43 seios saudáveis e 20 cistos ou tumores). O modelo proposto para classificar automaticamente os pseudocistos de retenção nos seios maxilares em radiografias panorâmicas mostrou excelente desempenho diagnóstico.

Watanabe *et al.*,²¹ avaliaram o desempenho da tecnologia de detecção de objetos de aprendizagem profunda para detectar e identificar lesões semelhantes a cistos maxilares na radiografia panorâmica. Concluíram a partir deste trabalho que o diagnóstico mais preciso foi nas regiões anteriores e para cistos radiculares. Usando a tecnologia de detecção de objetos de aprendizagem profunda, lesões semelhantes a cistos maxilares podem ser detectadas em aproximadamente 75–77%.

Zadrozny *et al.*,² buscou observar e verificar a confiabilidade da avaliação automática de radiografias panorâmicas por inteligência artificial. Sendo assim, foram selecionadas trinta radiografias panorâmicas e carregadas na conta Diagnocat (LLC Diagnocat, Moscou, Rússia), e o laudo radiológico de cada um foi gerado como base para avaliação automática. As mesmas radiografias foram avaliadas manualmente por três avaliadores independentes com 12, 15 e 28 anos de experiência em odontologia, respectivamente. O protocolo automático para avaliação radiográfica utilizado neste estudo mostrou sensibilidade alta ou muito alta para obturações dentárias, dentes tratados endodonticamente, raízes residuais, perda óssea periodontal, dentes perdidos e restaurações protéticas. Baixa sensibilidade foi obtida para lesões periapicais, cáries, bem como canais super e insuficientemente preenchidos. O Diagnocat não detectou nenhum dos três cistos periapicais, nem nenhum dos dois cistos intramaxilares ou dois instrumentos endodônticos quebrados.

Putra *et al.*¹⁰, revisou a aplicabilidade da IA para radiografia dentária a partir dos estudos atuais e chegou à conclusão de que embora a maioria dos estudos revisados tenha demonstrado um grande potencial de aplicação de IA para

radiografia dentária, ainda é necessário um maior desenvolvimento antes da implementação na rotina clínica devido a vários desafios e limitações. Citou como exemplo a falta de justificativa do tamanho dos conjuntos de dados e o formato de relatórios não padronizados. Considerando as limitações e desafios atuais, a futura investigação em IA em radiografia dentária deve seguir formatos de relatórios padronizados, a fim de alinhar os desenhos de investigação e aumentar o impacto do desenvolvimento da IA a nível global.

Quando pensando na aplicabilidade da IA no tratamento de terceiros molares, inúmeras possibilidades são descritas, como no estudo de Choi *et al.*²², que buscou determinar se um modelo de IA é capaz de determinar a relação espacial entre o nervo alveolar inferior e o terceiro molar inferior de acordo com duas possíveis relações: contato verdadeiro e o posicionamento bucolingual. Para testar a validade do modelo desenvolvido, especialistas em cirurgia bucomaxilo facial foram convidados a participar do estudo e realizar a mesma avaliação. Em conclusão, o estudo apontou que o modelo de IA utilizado por ser uma válida ferramenta para determinar a relação de posição entre o terceiro molar inferior e o nervo alveolar inferior e pode ser usado como complemento na tomada de decisões para o tratamento dos terceiros molares inferiores. De modo semelhante, Kempers *et al.*²³ buscou com seu modelo classificar a posição do nervo alveolar inferior em três diferentes classes de risco para danos ao nervo durante a remoção dos terceiros molares inferiores, sabendo que esta é uma das complicações mais frequentemente encontrada em exodontias dos terceiros molares. Seus resultados fortalecem a ideia de que o uso de modelos de IA, proporcionam uma avaliação mais facilitada, confiável e reproduzível para os cirurgiões-dentistas no geral.

Um modelo de inteligência artificial extremamente válido na tomada de decisão frente a terceiros molares é o de redes neurais convolucionais. Chopra *et al.*¹⁹ aponta o uso de redes neurais convolucionais, essas que possuem a capacidade de mimetizar o processo de captação, aprendizado, resolução de problemas e tomada de decisões. Essas que podem ser utilizadas na radiologia

oral para o diagnóstico, fornecendo uma previsão estimada a partir dos dados coletados nas imagens radiográficas.

Em seu estudo, as redes neurais convolucionais (RNC) são utilizadas para prever a erupção do terceiro molar inferior, e como desfecho secundário observar a incidência de terceiros molares inferiores completamente erupcionados com capacidade de higienização adequada. Concluiu-se que embora não seja possível a predição da erupção dos terceiros molares inferiores, o modelo é sólido como uma ferramenta para a predição de verticalização e fornece uma ferramenta valiosa para tomada de decisão clínica^(19,24) também utiliza as redes neurais convolucionais, mas combinadas com o bag of visual words (BoVW).

As redes neurais convolucionais também foram utilizadas nos estudos de ^(25,26) para determinação de estágios utilizando-se como referência as imagens panorâmicas, demonstrando a extensa aplicação do modelo na odontologia.

3. OBJETIVOS

OBJETIVO GERAL

Desenvolver e validar um modelo baseado em inteligência artificial para classificação automática da posição dos terceiros molares inferiores em radiografias panorâmicas, segundo a subclassificação de Pell & Gregory relativa às classes I, II e III.

OBJETIVOS ESPECÍFICOS

Desenvolver um modelo de classificação baseado em arquitetura ensemble de redes neurais convolucionais para identificação automática da posição dos terceiros molares inferiores em radiografias panorâmicas, segundo as classes I, II e III da classificação de Pell & Gregory.

Empregar técnicas de transfer learning, balanceamento de classes e aumento de dados (data augmentation) para otimizar o desempenho do modelo durante o treinamento.

Avaliar o desempenho do modelo por meio de métricas como acurácia, precisão, recall, F1-score e curva ROC, verificando sua capacidade de classificação das posições dos terceiros molares inferiores.

4. HIPÓTESES

Hipótese nula (H0)

O uso de um algoritmo baseado em inteligência artificial para análise de radiografias panorâmicas não apresenta desempenho adequado na classificação da posição dos terceiros molares inferiores, segundo as classes I, II e III da classificação de Pell & Gregory.

Hipótese conceitual (H1)

O uso de um algoritmo baseado em inteligência artificial para análise de radiografias panorâmicas apresenta desempenho adequado na classificação da posição dos terceiros molares inferiores, segundo as classes I, II e III da classificação de Pell & Gregory..

5. MATERIAL E MÉTODOS

O estudo foi aprovado pelo comitê de ética em pesquisa [(CAAE 53107721.0.0000.5076)].

5.1 Tipologia do estudo

Este estudo transversal e com amostra por conveniência, foi desenvolvido por meio da avaliação de radiografias panorâmicas de brasileiros adultos realizadas entre os meses de janeiro de 2019 e janeiro de 2021.

a) Local da pesquisa

Esta pesquisa foi realizada no Centro de Diagnóstico por Imagem (CDI) do curso de odontologia da Universidade Evangélica de Goiás (UNIEVANGÉLICA), laboratório de imagens do programa de pós-graduação em Odontologia da Universidade Evangélica de Goiás (UNIEVANGÉLICA) e laboratório de Engenharia elétrica da Universidade Federal do Mato Grosso(UFMT).

b) Obtenção da amostra

A amostra foi obtida a partir de um levantamento em um banco de dados de imagens de radiografias panorâmicas digitais retrospectivamente coletadas entre o período compreendido de janeiro de 2019 a janeiro de 2021 provenientes de pacientes que foram submetidos ao exame no Centro de Diagnóstico por Imagem (CDI) do curso de Odontologia da Universidade Evangélica de Goiás (UNIEVANGÉLICA). As informações referentes ao gênero e faixa etária foram coletados para se ter um perfil demográfico da subpopulação avaliada.

c) Critérios de inclusão

Os critérios de inclusão envolveram a presença de pelo menos um terceiro molar inferior, presença de ápice completamente formado; sem distúrbios de desenvolvimento e processos patológicos. Imagens sem nitidez, com distorções e baixo grau de densidade e contraste foram excluídas.

O arquivo de cada paciente foi composto por uma radiografia panorâmica digital.

d) Aquisição das imagens

As imagens panorâmicas foram adquiridas utilizando um aparelho de radiografia extrabucal Kodak® 8000C (Carestream Dental LLC, Atlanta, GA, EUA) configurado para a realização de radiografias panorâmicas de acordo com as recomendações do fabricante e com as características físicas de cada paciente. A tensão máxima do tubo foi de 90 kVp e a corrente máxima de 10 mA. Cada imagem radiográfica foi salva em um computador, no formato JPEG de alta resolução e organizadas em pastas individuais, numeradas e depois importadas para o software de edição de imagem Adobe Photoshop CS4® (Adobe Systems Incorporated, San Jose, CA, EUA) do qual dois radiologistas identificarão manualmente áreas de interesse nas radiografias panorâmicas digitais.

O método de recorte da imagem panorâmica foi realizada por um especialista em radiologia odontológica e compreendeu recortar o segundo molar inferior e o ramo da mandíbula no sentido méso-distal e incluir completamente o ápice do terceiro molar inferior no sentido vertical (figura 1). As imagens recortadas possuem resolução de 96 dpi/polegada e dimensões 512 x 512 pixels e cada imagem recortada foi salva em formato gráfico de rede portátil.




Figura 1. Uma representação do método de corte para pré-processamento de dados.

5.2 Desenvolvimento e Treinamento do Modelo Preditivo baseado em inteligência artificial (IA)

O conjunto de dados foi composto por 1.758 elementos dentários selecionados, distribuídos dentro da subclassificação das três classes de Pell e Gregory: Classe I (n = 684), Classe II (n = 639) e Classe III (n = 435). Observou-se desbalanceamento moderado entre as classes, sendo necessárias estratégias específicas para mitigação desse viés durante o treinamento.

Foi implementada uma arquitetura do tipo *ensemble*, combinando duas redes neurais convolucionais (CNNs) pré-treinadas: ResNet-18²⁷ e EfficientNet-B0²⁸. Ambas foram originalmente treinadas na base ImageNet e amplamente empregadas em aplicações de imagem médica baseadas em transferência de aprendizado.

Considerando que as radiografias consistiam em imagens monocromáticas, as camadas convolucionais iniciais das arquiteturas foram adaptadas para processamento de canal único. Essa modificação foi realizada por meio do cálculo da média dos pesos previamente treinados nos três canais RGB, preservando o conhecimento adquirido no pré-treinamento e garantindo compatibilidade estrutural com as imagens em escala de cinza.

Foi adotada estratégia de *transfer learning* progressivo. Durante as primeiras 20 épocas, apenas as camadas finais permaneceram treináveis, mantendo-se congelados os parâmetros convolucionais. Posteriormente, todos os parâmetros foram liberados para *fine-tuning*, com redução da taxa de aprendizado para 1×10^{-5} , permitindo adaptação gradual às características radiográficas específicas. Para mitigar o desbalanceamento entre classes, foram empregadas três abordagens complementares: (1) amostragem ponderada (*WeightedRandomSampler*) durante o carregamento dos dados; (2) aplicação de pesos de classe inversamente proporcionais à frequência na função de perda; e (3) utilização de *label smoothing* ($\epsilon = 0,15$), técnica destinada a reduzir superconfiança preditiva.

As estratégias de *data augmentation* respeitaram as particularidades de imagens médicas, incluindo rotações de até 15°, transformações afins com translação máxima de 8%, ajustes de nitidez e equalização histográfica. Adicionalmente, aplicou-se a técnica *mixup*, promovendo combinação linear de pares de imagens e respectivos rótulos, favorecendo maior robustez e capacidade de generalização.

A etapa de fusão consistiu na concatenação das representações extraídas das duas arquiteturas (512 atributos provenientes da ResNet-18 e 1.280 da EfficientNet-B0), seguida por camadas totalmente conectadas com aplicação de *dropout* progressivo (0,5; 0,4; 0,25) e normalização por lote (*batch normalization*).

A otimização foi conduzida por meio do algoritmo AdamW, com taxas de aprendizado discriminativas (5×10^{-5} para os *backbones* convolucionais e 2×10^{-4} para as camadas de fusão). Utilizou-se o agendador de taxa de aprendizado *CosineAnnealingWarmRestarts*.

Foi empregada validação cruzada estratificada na proporção 80/20, garantindo representatividade proporcional das classes nos subconjuntos de treino e validação. Durante a inferência, aplicou-se *test-time augmentation* (TTA), com cálculo da média de cinco predições obtidas a partir de variações leves das imagens originais. O treinamento incluiu critério de *early stopping* (paciência de 25 épocas) e monitoramento do diferencial entre acurácia de treino e validação para detecção de sobreajuste.

O desenvolvimento foi realizado na plataforma Google Colab (Google LLC, Mountain View, CA, EUA, versão 2025), utilizando a linguagem Python (Python Software Foundation, Wilmington, DE, EUA, versão 3.10, 2024) e o framework PyTorch (Meta Platforms, Inc., Menlo Park, CA, EUA, versão 2.2, 2024), com suporte da biblioteca Torchvision (Meta Platforms, Inc., Menlo Park, CA, EUA, versão 0.17, 2024). O treinamento foi executado em ambiente com GPU NVIDIA Tesla T4 (NVIDIA Corporation, Santa Clara, CA, EUA), com 16 GB de memória, permitindo processamento em lotes de 16 imagens.

5.3 Análise dos dados

A análise dos dados foi conduzida por meio da linguagem de programação Python (versão 3.12.1), utilizando as bibliotecas PyTorch (versão 2.10.0) para implementação e treinamento das redes neurais convolucionais e Scikit-learn (versão 1.6.1) para avaliação do desempenho do modelo e cálculo das métricas estatísticas. Foi empregada uma arquitetura do tipo *ensemble*, combinando duas redes neurais convolucionais pré-treinadas, ResNet-18 e EfficientNet-B0, originalmente treinadas na base de dados ImageNet e amplamente utilizadas em aplicações de aprendizado por transferência em imagens médicas. Após o treinamento e a etapa de teste, a acurácia do modelo foi calculada automaticamente pelo algoritmo e expressa em porcentagem. O desempenho do modelo foi avaliado por meio da construção da curva Receiver Operating

Characteristic (ROC), permitindo a análise da capacidade discriminativa do sistema. Adicionalmente, gráficos representando a evolução do desempenho durante as *epochs* de treinamento foram gerados para monitoramento do aprendizado da rede neural. O nível de significância adotado para as análises foi de 5% ($p < 0,05$).

6. RESULTADOS

A amostra do estudo foi composta por 950 participantes, cujas radiografias panorâmicas foram utilizadas para análise. A idade dos participantes variou de 16 a 38 anos, com média de idade aproximada de 27 anos. Em relação ao gênero, observou-se predominância do sexo feminino (59,1%), enquanto (40,9%) eram do sexo masculino.

As radiografias panorâmicas analisadas foram utilizadas para avaliação da posição dos terceiros molares inferiores segundo a classificação de Pell & Gregory, considerando as classes I, II e III. O modelo ensemble alcançou acurácia global de 82,7% no conjunto de validação ($n = 352$), demonstrando desempenho equilibrado entre as três classes (Tabela 1). Os indicadores de desempenho por modelo evidenciaram que a Classe I apresentou os melhores resultados, com precisão de 0,895, recall de 0,934 e F1-score de 0,914 ($n = 137$). A Classe II apresentou desempenho intermediário, com precisão de 0,758, recall de 0,781 e F1-score de 0,769 ($n = 128$). Já a Classe III, apesar de ser a minoritária no conjunto de dados, demonstrou precisão de 0,818, recall de 0,724 e F1-score de 0,768 ($n = 87$), conforme detalhado na Tabela 1.

A análise da matriz de confusão revelou padrões específicos de erro (Tabela 1). A Classe I foi raramente confundida com outras categorias (9 casos classificados como Classe II), sugerindo que suas características radiográficas foram adequadamente capturadas pelo modelo. As principais confusões ocorreram entre Classe II e Classe III (14 casos em cada direção), indicando possível sobreposição morfológica entre essas categorias. Observou-se ainda que a Classe III apresentou 23 falsos negativos classificados como Classe II, o que pode refletir tanto sua menor representatividade no conjunto de treinamento quanto similaridade anatômica entre essas classificações.

As métricas agregadas reforçam a consistência do desempenho do modelo. O F1-score médio macro foi de 0,817, enquanto a média ponderada atingiu 0,826 (Tabela 1), indicando estabilidade preditiva mesmo diante da distribuição desigual das amostras e confirmando a eficácia das estratégias de balanceamento adotadas.

A análise das curvas de treinamento demonstrou redução progressiva do loss e aumento consistente da acurácia ao longo das épocas, com discreto gap

entre treino e validação, sem evidência de overfitting significativo (Gráfico 1). A estabilização das métricas nas últimas épocas reforça a adequada convergência do modelo.

Tabela 1. Métricas de desempenho do modelo ensemble no conjunto de validação (n=352).

Classe	Precisão	Recall	F1-score	n
Classe I	0,895	0,934	0,914	137
Classe II	0,758	0,781	0,769	128
Classe III	0,818	0,724	0,768	87
Acurácia global	–	–	0,827	352
Média macro	0,824	0,813	0,817	352
Média ponderada	0,826	0,827	0,826	352




Gráfico 1. Dinâmica do treinamento do modelo ensemble: evolução do loss e da acurácia ao longo das épocas, com comparação entre os conjuntos de treino e validação, evidenciando o gap de generalização.

7. DISCUSSÃO

A extração de terceiros molares mandibulares constitui um procedimento rotineiro e relevante na prática cirúrgica odontológica, sendo amplamente influenciada por variáveis anatômicas individuais e pela relação do dente com estruturas nobres adjacentes, especialmente o nervo alveolar inferior^(1,7). Desde os princípios clássicos da exodontia aplicados aos terceiros molares impactados⁴, diferentes sistemas de classificação foram propostos para orientar o planejamento cirúrgico, destacando-se a classificação de Pell & Gregory⁵, amplamente utilizada na avaliação da posição do dente. Apesar de consolidadas, essas classificações dependem da interpretação do examinador e da qualidade da imagem radiográfica, podendo apresentar variabilidade diagnóstica^{6,13,14}.

A avaliação pré-operatória baseia-se tradicionalmente em exames de imagem, principalmente a radiografia panorâmica, que permanece amplamente utilizada por sua acessibilidade e capacidade de visualização global das estruturas maxilomandibulares^{3,16}. Entretanto, a complexidade anatômica e a ocorrência de complicações cirúrgicas, como parestesias e outras intercorrências pós-operatórias, evidenciam a necessidade de ferramentas mais precisas para estimar o grau de dificuldade cirúrgica e o risco associado ao procedimento^(7,18). Nesse contexto, a evolução da inteligência artificial (IA) aplicada à radiologia odontológica tem demonstrado potencial para aprimorar a interpretação de imagens e reduzir a subjetividade diagnóstica^{2,9,10}.

O uso de algoritmos baseados em aprendizado profundo, particularmente redes neurais convolucionais (CNN), tem se expandido rapidamente em diferentes áreas da odontologia, incluindo detecção de patologias, identificação de estruturas anatômicas e análise de radiografias panorâmicas^{15,20,21}. Esses modelos têm demonstrado elevada capacidade de reconhecimento de padrões complexos, permitindo não apenas o diagnóstico automatizado de alterações radiográficas, mas também a predição de condições clínicas relevantes, como a relação entre o terceiro molar e o canal mandibular ou a probabilidade de complicações associadas à extração^{22,23,24}. Estudos recentes indicam que a IA pode alcançar níveis de desempenho comparáveis ou superiores aos de avaliadores humanos em tarefas específicas de interpretação radiográfica^{25,26}.

No presente estudo, foi desenvolvido um modelo baseado em Deep Learning para classificação da posição de terceiros molares mandibulares segundo os critérios de Pell & Gregory relacionados ao ramo da mandíbula, utilizando radiografias panorâmicas. O algoritmo demonstrou acurácia global de 82,67%, valor compatível com os intervalos relatados na literatura para tarefas semelhantes, geralmente entre 78% e 82%²⁹. Esse desempenho reforça a aplicabilidade clínica de modelos de IA como ferramenta auxiliar no planejamento cirúrgico, contribuindo para maior padronização da avaliação radiográfica.

A análise detalhada do desempenho do modelo revelou maior precisão na identificação de dentes classificados como Classe I, com elevada capacidade de reconhecer características radiográficas associadas à presença de espaço coronário suficiente em relação ao ramo mandibular. Em contraste, foram observadas maiores taxas de confusão entre as Classes II e III, possivelmente decorrentes da sobreposição morfológica e da sutileza das diferenças anatômicas nessas regiões de transição. Esse achado está em consonância com estudos que utilizam métodos de interpretabilidade, como o Grad-CAM, demonstrando que a região superior ao terceiro molar representa área crítica para a tomada de decisão do modelo²³.

Do ponto de vista metodológico, a utilização de uma arquitetura de ensemble combinando diferentes redes pré-treinadas contribuiu para maior estabilidade na generalização dos resultados, especialmente diante de desbalanceamentos moderados entre as classes. Estratégias de regularização, como label smoothing e amostragem ponderada, também auxiliaram na manutenção de desempenho consistente entre as categorias, refletido em f1-score global elevado. Esses achados corroboram a crescente evidência de que abordagens baseadas em múltiplas arquiteturas podem melhorar a robustez dos modelos de aprendizado profundo em tarefas de classificação radiográfica^{24,26}.

Clinicamente, a sensibilidade de aproximadamente 81% observada neste estudo possui relevância significativa, uma vez que a identificação adequada de casos mais complexos é essencial para prevenir falhas diagnósticas que possam comprometer o planejamento cirúrgico e aumentar o risco de complicações, como injúrias neurosensoriais. A capacidade do modelo de reconhecer a maioria dos casos positivos sugere potencial utilidade como ferramenta de triagem e apoio à decisão, especialmente em contextos com menor disponibilidade de especialistas ou recursos diagnósticos avançados^{2,10}.

Embora a tomografia computadorizada de feixe cônico represente o padrão-ouro para avaliação tridimensional detalhada, seu custo mais elevado e maior exposição à radiação limitam seu uso indiscriminado^{3,16}. Nesse cenário, a aplicação de IA à radiografia panorâmica surge como alternativa viável para avaliação inicial e seleção de casos que necessitam investigação complementar, ampliando a eficiência do fluxo diagnóstico^{9,22}.

Apesar dos resultados promissores, algumas limitações devem ser consideradas. A análise baseada exclusivamente em imagens bidimensionais está sujeita a distorções e sobreposições anatômicas inerentes à técnica radiográfica, o que pode reduzir a precisão da avaliação espacial das estruturas³. A integração de dados clínicos e radiográficos em modelos preditivos multimodais pode representar um avanço importante para aumentar a sensibilidade e a especificidade dessas ferramentas.

Outro aspecto relevante é que, embora a IA apresente elevado potencial diagnóstico, seu papel deve ser compreendido como complementar ao julgamento clínico, funcionando como um “segundo observador” capaz de reduzir vieses individuais e melhorar a consistência da interpretação radiográfica^{2,19}. A incorporação dessas tecnologias pode também favorecer a comunicação com o paciente, permitindo melhor explicação dos riscos e da complexidade do procedimento.

Em síntese, os resultados obtidos indicam que modelos baseados em Deep Learning aplicados a radiografias panorâmicas podem contribuir significativamente para a avaliação da posição de terceiros molares mandibulares, com desempenho comparável ao relatado em estudos prévios e potencial aplicação clínica como ferramenta de triagem e suporte à decisão^{26,29,30}. Futuras investigações multicêntricas, com amostras mais amplas e integração de variáveis clínicas adicionais, poderão aprimorar a acurácia preditiva e ampliar a aplicabilidade desses sistemas na prática clínica diária.

REFERÊNCIAS

1. Vig KWL. Patient specific variables are a consideration in the decision to extract asymptomatic third molars. *J Evid Based Dent Pract*. 2012;12(2):92–4.
2. Zadrozny Ł, Regulski P, Brus-Sawczuk K, Czajkowska M, Parkanyi L, Ganz S, et al. Artificial intelligence application in assessment of panoramic radiographs. *Diagnostics*. 2022;12(1):1–11.
3. Nardi C, Calistri L, Grazzini G, Desideri I, Lorini C, Occhipinti M, et al. Is panoramic radiography an accurate imaging technique for the detection of endodontically treated asymptomatic apical periodontitis? *J Endod*. 2018;44(10):1500–8.
4. Pigott JP. Principles of exodontia as applied to the impacted mandibular third molar. *Yale J Biol Med*. 1928;1:63.
5. Pell GJ, Gregory GT. Impacted mandibular third molars: classification and modified technique for removal. *Dent Dig*. 1933;39:330–8.
6. Chandler LP, Laskin DM. Accuracy of radiographs in classification of impacted third molar teeth. *J Oral Maxillofac Surg*. 1988;46(8):656–60.
7. Zuniga JR, Chen N. Cirurgia do terceiro molar e complicações associadas. *Oral Maxillofac Surg Clin North Am*. 2020;32(3).
8. Zhu J, Chen Z, Zhao J, Yu Y, Li X, Shi K, et al. Artificial intelligence in the diagnosis of dental diseases on panoramic radiographs: a preliminary study. *BMC Oral Health*. 2023;23(1):1–11.
9. Putra RH, Doi C, Yoda N, Astuti ER, Sasaki K. Current applications and development of artificial intelligence for digital dental radiography. *Dentomaxillofac Radiol*. 2022;51(1).
10. Removal of third molars. Sponsored by the National Institute of Dental Research, November 28-30, 1979. Natl Inst Health Consens Dev Conf Summ. 1979; 2:65–8
11. Haug RH, Perrott DH, Gonzalez ML, Talwar RM. The American Association of Oral and Maxillofacial Surgeons Age-Related Third Molar Study. *J oral Maxillofac Surg Off J Am Assoc Oral Maxillofac Surg*. 2005 Aug;63(8):1106–14.
12. Sifuentes-Cervantes JS, Carrillo-Morales F, Castro-Núñez J, Cunningham LL, Van Sickels JE. Third molar surgery: Past, present, and the future. *Oral Surg Oral Med Oral Pathol Oral Radiol*. 2021;132(5):523–31.

13. Santosh P. Impacted mandibular third molars: review of literature and a proposal of a combined clinical and radiological classification. *Ann Med Health Sci Res.* 2015;5(4):229–34.
14. Gay-Escoda C, Sánchez-Torres A, Borrás-Ferreres J, Valmaseda-Castellón E. Third molar surgical difficulty scales: systematic review and preoperative assessment form. *Med Oral Patol Oral Cir Bucal.* 2022;27(1):e68–76.
15. Mori M, Arijji Y, Katsumata A, et al. A deep transfer learning approach for the detection and diagnosis of maxillary sinusitis on panoramic radiographs. *Odontology.* 2021;109(4):941–8.
16. Vesala T, Ekholm M, Ventä I. Is dental panoramic tomography appropriate for all young adults because of third molars? *Acta Odontol Scand.* 2021;79(1):52–8.
17. Wang XW, Yang HF, Wang EB, Cui XY, Zhao YJ, Jiang JH. Slim the face or not: 3D change of facial soft and hard tissues after third molars extraction: a pilot study. *BMC Oral Health.* 2023;23:508
18. Rizqiawan A, Lesmaya YD, Rasyida AZ, et al. Postoperative complications of impacted mandibular third molar extraction related to patient's age and surgical difficulty level. *Int J Dent.* 2022;2022:7239339.
19. Chopra S, Vranckx M, Ockerman A, et al. A retrospective longitudinal assessment of artificial intelligence-assisted radiographic prediction of lower third molar eruption. *Sci Rep.* 2024;14(1):1–7.
20. Ha E-G, Jeon KJ, Choi H, et al. Automatic diagnosis of retention pseudocyst in the maxillary sinus on panoramic radiographs using a convolutional neural network algorithm. *Sci Rep.* 2023;13(1):2734.
21. Watanabe H, Arijji Y, Fukuda M, et al. Deep learning object detection of maxillary cyst-like lesions on panoramic radiographs: preliminary study. *Oral Radiol.* 2021;37(3):487–93.
22. Choi E, Lee S, Jeong E, et al. Artificial intelligence in positioning between mandibular third molar and inferior alveolar nerve on panoramic radiography. *Sci Rep.* 2022;12(1):1–7.
23. Kempers S, van Lierop P, Hsu TMH, et al. Positional assessment of lower third molar and mandibular canal using explainable artificial intelligence. *J Dent.* 2023;133.
24. Ngoc VTN, Agwu AC, Son LH, et al. The combination of adaptive convolutional neural network and bag of visual words in automatic diagnosis of third molar complications on dental X-ray images. *Diagnostics.* 2020;10(4).

25. Guo YC, Han M, Chi Y, et al. Accurate age classification using manual method and deep convolutional neural network based on orthopantomogram images. *Int J Legal Med.* 2021;135(4):1589–97.
26. Yoo JH, Yeom HG, Shin W, et al. Deep learning based prediction of extraction difficulty for mandibular third molars. *Sci Rep.* 2021;11(1):1954.
27. Alzubaidi L, Duan Y, Al-Dujaili A, et al. Deepening into the suitability of using pre-trained models of ImageNet against a lightweight convolutional neural network in medical imaging: an experimental study. *PeerJ Comput Sci.* 2021;7:e715. PMID: 34722871.
28. Chen X, Pu X, Chen Z, et al. Application of EfficientNet-B0 and GRU-based deep learning on classifying the colposcopy diagnosis of precancerous cervical lesions. *Cancer Med.* 2023;12(7):8690-8699.
29. Akdogan S, Öziç MÜ, Tassoker M. Development of an AI-supported clinical tool for assessing mandibular third molar tooth extraction difficulty using panoramic radiographs and YOLO11 sub-models. *Diagnostics.* 2025;15:462.
30. Issa J, et al. Diagnostic test accuracy of artificial intelligence in detecting periapical periodontitis on two-dimensional radiographs: a retrospective study and literature review. *Medicina (Kaunas).* 2023;59:76



UNIVERSIDADE EVANGÉLICA
DE GOIÁS - UNIEVANGÉLICA



PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: Estimativa de idade da população brasileira adulta através de radiografias Panorâmicas e Periapicais.

Pesquisador: ISMAR NERY NETO

Área Temática:

Versão: 2

CAAE: 53107721.0.0000.5076

Instituição Proponente: ASSOCIACAO EDUCATIVA EVANGELICA

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 5.288.660

Apresentação do Projeto:

Em conformidade com o número do parecer: 5.267.120

Objetivo da Pesquisa:

Objetivo geral

Determinar a estimativa de idade da população brasileira adulta baseada no cálculo da fração polpa / dente do canino superior e do segundo pré-molar inferior em radiografias panorâmicas e periapicais de indivíduos vivos utilizando o método proposto por Cameriere e verificar a sua efetividade.

Objetivos específicos

Comparar os resultados obtidos nas radiografias periapicais com os resultados obtidos nas radiografias panorâmicas.

Gerar uma equação populacional específica.

Avaliar qual resultado é mais eficiente em relação à idade cronológica

Avaliação dos Riscos e Benefícios:

Em conformidade com o número do parecer: 5.267.120

Comentários e Considerações sobre a Pesquisa:

Trata-se de um Projeto de Pesquisa desenvolvido pela Faculdade de Odontologia da Universidade

Endereço: Av. Universitária, Km 3,5

Bairro: Cidade Universitária

CEP: 75.083-515

UF: GO

Município: ANAPOLIS

Telefone: (62)3310-6736

Fax: (62)3310-6636

E-mail: cep@unievangelica.edu.br



Continuação do Parecer: 5.288.660

Evangelica de Goiás - UniEVANGÉLICA, sob a orientação do Professor Ismar Nery Neto e que aborda a estimativa de idade da população brasileira adulta através de radiografias panorâmicas e periapicais.

Considerações sobre os Termos de apresentação obrigatória:

De acordo com as recomendações previstas pela RESOLUÇÃO CNS No 466/2012 ou No 510/2016 e demais complementares o protocolo permitiu a realização da análise ética. Todos os documentos listados abaixo foram analisados.

Recomendações:

Não se aplica.

Conclusões ou Pendências e Lista de Inadequações:

Lista de pendências

QUANTO AO PROJETO DETALHADO

(PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO_1844693.pdf de 08/11/2021 e Projeto_para_CEP.docx de 06/11/2021)

PENDÊNCIA 1: No item “Riscos e Benefícios” são abordados os riscos e benefícios envolvidos na pesquisa. Os autores precisam deixar claro quais são os possíveis benefícios do presente estudo (indireto, ex. comunidade científica). Foi descrito no projeto : “A partir dos dados encontrados espera-se a construção e elaboração de fórmulas específicas para estimar a idade da amostra destes pacientes brasileiros...”. Adequar. ANÁLISE: Foi realizada a adequação (sublinhada) na página 08 do seguinte modo: Os benefícios esperados estão em consonância com os objetivos da pesquisa e com a construção de uma fórmula específica para a população adulta brasileira, propiciando a realização de mais pesquisas com populações brasileiras e outros povos miscigenados. PENDÊNCIA ATENDIDA.

PENDÊNCIA 2: No item “Cronograma de Execução” - Os autores devem atualizar as informações do cronograma. O formato atual não permite a execução da pesquisa. ANÁLISE: Cronograma atualizado. PENDÊNCIA ATENDIDA.

PENDÊNCIA 3: No item “Tipo de estudo” é apresentada a informação de que o projeto será enviado ao Comitê de Ética em Pesquisa da Universidade Federal de Goiás. No entanto, a Universidade

Endereço: Av. Universitária, Km 3,5

Bairro: Cidade Universitária

CEP: 75.083-515

UF: GO

Município: ANAPOLIS

Telefone: (62)3310-6736

Fax: (62)3310-6636

E-mail: cep@unievangelica.edu.br



Continuação do Parecer: 5.288.660

Evangelica de Goiás é a instituição proponente (informação obtida na folha de rosto). Dessa forma, o pesquisador deverá atualizar a informação sobre o comitê. ANÁLISE: O texto foi alterado e ficou desta forma: Este trabalho será encaminhado ao Comitê de Ética em Pesquisa da Universidade Evangélica de Goiás. PENDÊNCIA ATENDIDA.

QUANTO A OUTROS (Termoautorizacaomanuseiobancodados.pdf de 08/11/2021)

PENDÊNCIA 1: O termo de autorização para utilização e manuseio de dados não deve ser assinado pelo pesquisador responsável pelo projeto de pesquisa pois gera conflito de interesse. O pesquisador deverá apresentar os documentos de autorização para manuseio dos dados e da instituição coparticipante assinados por pessoa não envolvida na pesquisa, mas que também se responsabiliza com a instituição coparticipante e adequar o benefício nos documentos. ANÁLISE: O documento foi refeito e a autorização para o manuseio dos dados da instituição coparticipante foi assinada pela administradora da empresa e a responsável administrativa da instituição coparticipante PENDÊNCIA ATENDIDA.

Considerações Finais a critério do CEP:

Solicitamos ao pesquisador responsável o envio do RELATÓRIO FINAL a este CEP, via Plataforma Brasil, conforme cronograma de execução apresentado.

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO_1844693.pdf	10/03/2022 15:15:35		Aceito
Outros	Termoautorizacaomanuseiobancodados.pdf	10/03/2022 15:15:05	ISMAR NERY NETO	Aceito
Projeto Detalhado / Brochura Investigador	Projeto.pdf	10/03/2022 14:59:56	ISMAR NERY NETO	Aceito
Projeto Detalhado / Brochura Investigador	Projeto_para_CEP.docx	10/03/2022 14:58:58	ISMAR NERY NETO	Aceito
Outros	Carta_de_atendimento_as_pendencias2.docx	10/03/2022 14:57:08	ISMAR NERY NETO	Aceito
Outros	Carta_de_atendimento_as_pendencias.docx	10/03/2022 08:18:28	ISMAR NERY NETO	Aceito
Declaração de concordância	Declaracao_de_Compromisso.pdf	03/03/2022 11:41:35	ISMAR NERY NETO	Aceito

Endereço: Av. Universitária, Km 3,5

Bairro: Cidade Universitária

CEP: 75.083-515

UF: GO

Município: ANAPOLIS

Telefone: (62)3310-6736

Fax: (62)3310-6636

E-mail: cep@unievangelica.edu.br



UNIVERSIDADE EVANGÉLICA
DE GOIÁS - UNIEVANGÉLICA



Continuação do Parecer: 5.288.660

Declaração de Instituição e Infraestrutura	Declaracao_Instituicao_Coparticipante.pdf	03/03/2022 11:39:36	ISMAR NERY NETO	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	Justificativa_nao_apresentacao_TCLE.pdf	03/03/2022 11:33:36	ISMAR NERY NETO	Aceito
Folha de Rosto	Folha_de_Rosto_Pesquisa_Envolvendo Seres Humanos.pdf	03/03/2022 11:24:50	ISMAR NERY NETO	Aceito
Brochura Pesquisa	Estimativa_idade_radiografias.pdf	20/10/2021 09:14:54	ISMAR NERY NETO	Aceito

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:

Não

ANAPOLIS, 13 de Março de 2022

Assinado por:
Constanza Thaise Xavier Silva
(Coordenador(a))

Endereço: Av. Universitária, Km 3,5

Bairro: Cidade Universitária

CEP: 75.083-515

UF: GO

Município: ANAPOLIS

Telefone: (62)3310-6736

Fax: (62)3310-6636

E-mail: cep@unievangelica.edu.br