



**UNIVERSIDADE ESTADUAL DA PARAÍBA  
CENTRO DE CIÊNCIAS BIOLÓGICAS E DA SAÚDE  
DEPARTAMENTO DE ODONTOLOGIA  
MESTRADO EM ODONTOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ODONTOLOGIA**

**DOUGLAS PEREIRA DE SOUSA**

**INTELIGÊNCIA ARTIFICIAL COMO MÉTODO AUXILIAR NA ESTIMATIVA DE  
IDADE EM RADIOGRAFIA PANORÂMICA**

**CAMPINA GRANDE**

**2022**

DOUGLAS PEREIRA DE SOUSA

**INTELIGÊNCIA ARTIFICIAL COMO MÉTODO AUXILIAR NA ESTIMATIVA DE  
IDADE EM RADIOGRAFIA PANORÂMICA**

Dissertação apresentada ao Programa de Pós-Graduação em Odontologia da Universidade Estadual da Paraíba em cumprimento às exigências para obtenção do título de Mestre em Odontologia.

**Área de concentração:** Clínicas odontológicas.

**Orientadora:** Prof. Dr<sup>a</sup> Daniela Pita de Melo

CAMPINA GRANDE

2022

É expressamente proibido a comercialização deste documento, tanto na forma impressa como eletrônica. Sua reprodução total ou parcial é permitida exclusivamente para fins acadêmicos e científicos, desde que na reprodução figure a identificação do autor, título, instituição e ano do trabalho.

S725i Sousa, Douglas Pereira de.  
Inteligência artificial como método auxiliar na estimativa de idade em radiografia panorâmica [manuscrito] / Douglas Pereira de Sousa. - 2022.  
80 p. : il. colorido.

Digitado.

Dissertação (Odontologia - Universidade Estadual da Paraíba, Centro de Ciências Biológicas e da Saúde , 2023.

"Orientação : Profa. Dra. Daniela Pita de Melo ,  
Departamento de Odontologia - CCBS."

1. Inteligência artificial. 2. Odontologia legal. 3. Diagnóstico por imagem. I. Título

21. ed. CDD 614.1

DOUGLAS PEREIRA DE SOUSA

**INTELIGÊNCIA ARTIFICIAL COMO MÉTODO AUXILIAR NA ESTIMATIVA DE  
IDADE EM RADIOGRAFIA PANORÂMICA**

Dissertação apresentada ao Programa de Pós-Graduação em Odontologia da Universidade Estadual da Paraíba em cumprimento às exigências para obtenção do título de Mestre em Odontologia.

Área de concentração: Clínicas odontológicas.

DATA DA DEFESA: 15/12/2022.

**BANCA EXAMINADORA**



---

Profa. Dra. Patrícia Meira Bento

MEMBRO TITULAR (EXAMINADORA INTERNA)



---

Profa. Dra. Janaina Araújo Dantas

MEMBRO TITULAR (EXAMINADORA EXTERNA)



---

Profa. Dra. Daniela Pita de Melo

MEMBRO TITULAR (ORIENTADORA)

## AGRADECIMENTOS

A **Deus** agradeço por todas as dádivas que me foram concedidas, assim como pelas pessoas certas colocadas no meu caminho durante a minha vida. Só tenho a agradecer por tudo que venho conquistando.

Aos **meus pais** que sempre fizeram de tudo pela minha formação. Meus maiores incentivadores. Não existem palavras que possam agradecê-los. Essa conquista é nossa!

À **Profª Drª Daniela Pita de Melo**, minha orientadora, por toda atenção e carinho para comigo. Agradeço por me entender e por acreditar na minha capacidade. Seu astral é único e seu comprometimento é inspirador. “*You rock!*”

À **Prof.ª Dr.ª. Patrícia Meira Bento** por se fazer mais uma vez presente em outra etapa da minha formação. Agradeço por abraçar meu empenho, por confiar no meu trabalho, pelos ensinamentos e pelas oportunidades a mim cedidas desde a especialização.

Às **Profas. Patrícia Meira Bento e Janaina Araújo Dantas** pela disponibilidade em participar da banca.

Às **minhas colegas de turma**, sim, fui bendito entre as mulheres e fico muito feliz por ter tido a oportunidade de dividir essa história com elas.

À **Drª Elisa Diniz de Lima**, integrante assídua do grupo de pesquisa da Radiologia e a **José Alberto Souza Paulino**, cientista de dados e doutorando em computação. Pessoas comprometidas e responsáveis que foram fundamentais para a conclusão deste estudo. Sem elas jamais teria conseguido.

A **Edmilson Mazza**, consultor estatístico que me auxiliou com parte dos dados.

Ao **grupo de pesquisa da Radiologia e aos demais alunos** do Programa de Pós-graduação em Odontologia da Universidade Estadual da Paraíba pela convivência e pelo trabalho desempenhado nas disciplinas práticas.

Ao **corpo docente** do Programa de Pós-Graduação em Odontologia da Universidade Estadual da Paraíba que contribuíram para minha formação.

Aos **funcionários** do Departamento de Odontologia da Universidade Estadual da Paraíba pela presteza.

Aos **pacientes e aos alunos da graduação** que são importantes para o nosso crescimento profissional e pessoal.

À **Universidade Estadual da Paraíba** pelas oportunidades durante os últimos anos.

*"Era uma vez um escritor que morava numa praia tranquila, junto à uma colônia de pescadores. Todas as manhãs ele passeava à beira-mar para se inspirar e à tarde ficava em casa, a escrever. Um dia, ao caminhar pela praia, ele viu um vulto. Quando chegou perto, era um jovem a pegar estrelas-do-mar que estavam na areia, uma a uma, e a lançá-las de volta ao mar:*

*- Por que você está fazendo isso? - perguntou o escritor.*

*- Você não vê? A maré está baixa e o sol está a brilhar. Elas vão secar e morrer se ficarem aqui na areia.- disse o jovem. O escritor o indagou:*

*- Meu jovem, existem milhares de quilômetros de praia por esse mundo afora e centenas de milhares de estrelas-do-mar espalhadas pelas praias. Que diferença faz?*

*O jovem pegou uma estrela da areia, atirou-a de volta ao mar, olhou para o escritor e disse:*

*- Para esta, eu fiz diferença!*

*Naquela noite, o escritor não conseguiu dormir nem sequer conseguiu escrever. De manhãzinha foi à praia, reuniu-se ao jovem e juntos começaram a atirar estrelas-do-mar de volta ao oceano."*

**Autor desconhecido**

## RESUMO

O conhecimento da idade dos indivíduos vivos é de fundamental importância no que concerne à responsabilidade criminal e à imigração ilegal, assim como na reconstrução do perfil biológico de cadáveres não identificados em desastres em massa. Abordagens relativamente não invasivas para a previsão da idade vem sendo utilizadas há bastante tempo, por exemplo, a razão entre medidas do dente e da cavidade pulpar utilizando radiografias odontológicas, também chamado de método de Kvaal. Entretanto, estimar a idade por meio de métodos radiográficos pode apresentar uma margem de erro alta, além de exigir abordagens complexas, tempo e treinamento dos examinadores. Sendo assim, surge a possibilidade de aumentar a precisão da estimativa com a utilização da inteligência artificial que vem alcançando resultados em diversas áreas do conhecimento. Este estudo teve como objetivo estimar a idade por meio do método radiográfico de Kvaal em radiografias panorâmicas utilizando a inteligência artificial como abordagem auxiliar. Tratou-se de um estudo observacional transversal aprovado pelo Comitê de Ética em Pesquisa sob o CAAE: 56455322.6.0000.5187. Foram selecionadas 554 radiografias panorâmicas do banco de dados de uma clínica privada de radiologia odontológica do nordeste brasileiro coletadas entre os anos de 2017 a 2019 e realizadas nos equipamentos Carestream® CS 8100 3D e no Carestream® CS 9000 3D. As radiografias foram de pacientes com idades entre 13 e 57 anos apresentando o incisivo central superior esquerdo e o canino superior esquerdo irrompidos e hígidos. A concordância intraobservador para o método de Kvaal foi estabelecida através do teste *Kappa de Cohen*, no qual o coeficiente demonstrou confiabilidade de moderada a perfeita. Para a estimativa da idade através do método de Kvaal foram realizadas medidas lineares nas imagens utilizando o *software* ImageJ®. A fim de compensar qualquer diferença na ampliação das imagens radiográficas, as proporções entre as medidas realizadas no dente e na cavidade pulpar foram calculadas. Os dados do método de Kvaal foram analisados estatisticamente através do teste de Mann-Whitney, do coeficiente de correlação de Spearman, do teste t-Student e da regressão linear para estimar as idades e analisar a variabilidade dos dados da estimativa. A margem de erro utilizada na decisão dos testes estatísticos foi de 5% e os intervalos com 95% de confiança. Em relação à previsão de idade através da inteligência artificial foram utilizadas três abordagens: semântica, radiômica e a concatenação dos atributos semânticos e radiômicos. O particionamento da amostra foi realizado na proporção 85/15 (85% da amostra para treinamento e 15% para testes) nas três abordagens. A partir do treinamento, os algoritmos de regressão com os melhores desempenhos foram selecionados e utilizados no grupo de testes: *Logistic Regression*, *Linear Regression*, *Random Forest Reg*, *Gradient Boost Reg* e *XG Boosting Reg*. Foram extraídos os dados tabulados do método de Kvaal gerando dezenove atributos semânticos. Os incisivos centrais superiores e os caninos superiores foram segmentados das radiografias panorâmicas manualmente através do *software* GIMP® e geraram sete atributos radiômicos (contraste, correlação, energia, homogeneidade, entropia, média e desvio) para cada dente, totalizando quatorze atributos. Por fim, a concatenação dos dados resultou em trinta e três atributos (semânticos e radiômicos). Para analisar os resultados estatísticos do aprendizado de máquina foi aplicado o Erro Médio Absoluto (EMA). O método de Kvaal isolado é aplicável na população estudada (EMA 5,68) com destaque para o incisivo superior (EPE 7,10) que obteve maior precisão de estimativa que o canino (EPE 7,38). No tocante ao aprendizado de máquina aplicado, a extração de atributos semânticos e radiômicos apresentaram desempenho semelhante na base completa (EMA 5,23), enquanto a concatenação desses atributos obteve precisão superior na estimativa das idades (EMA 4,77). O classificador *XG Boosting Reg* demonstrou performance promissora. O aprendizado de máquina apresentou precisão mais alta (EMA 4,77) ao estimar as idades da população estudada quando em relação ao método de Kvaal

(EMA 5,68). Portanto, a inteligência artificial pode ser aplicada como abordagem auxiliar na estimativa de idade utilizando radiografias panorâmicas.

**Palavras-chave:** Determinação da idade pelos dentes; Inteligência artificial; Odontologia legal.



## ABSTRACT

The knowledge of the age of the living corpses is of criminal importance to the illegal responsibility, as the disaster and the creation of the biological of so not identified in mass profile. Relatively non-invasive approach to the methodology used, well known as the Kvaal age method. However, estimating age through radiographic methods can present a high margin, in addition to error approaches, time and training of examiners. Thus, the possibility of increasing the accuracy of the estimate with the use of artificial intelligence that has been achieving results in several areas of knowledge. This study aimed to estimate age using the Kvaal radiographic method on radiographs using an auxiliary artificial intelligence. This was a cross-sectional observational study approved by the Research Ethics Committee under CAAE: 56455322.6.0000.5187. A total of 554 radiographs were selected from a private clinic from a database in northeastern Brazil collected between 2017 and 2019 and taken on Carestream® CS 8100 3D and Carestream® CS 900 3D equipment. The radiographs were of patients aged between 13 and 57 years with the left maxillary central incisor and left maxillary canine erupted and healthy. The intraobserver agreement of the Kvaal method was defined through a Kappa test, without which the flow of confirmation of an adequate pattern. To estimate age using the Kvaal method, linear measurements were performed on the images using ImageJ® software. In order to compensate for any difference in the magnification of the radiographic images, the proportions between the measurements performed on the tooth and the pulp cavity were calculated. Data from the Kvaal method were statistically analyzed using the Mann-Whitney test, the Spearman correlation coefficient, the Student's t test and linear regression with its respective coefficient of determination to estimate the ages and analyze the variability of data from the I estimated. The margin of error used in the decision of the statistical tests was of 5% and the intervals with 95% of confidence. Regarding age prediction through artificial intelligence, three approaches were used: semantics, radiomics and the concatenation of semantic and radiomic attributes. The sample partitioning was performed in the proportion 85/15 (85% of the sample for training and 15% for tests) in the three approaches. From the training, the regression algorithms with the best performances were selected and used in the test group: Logistic Regression, Linear Regression, Random Forest Reg, Gradient Boost Reg and XG Boosting Reg. The tabulated data of the Kvaal method were extracted, generating nineteen semantic attributes. The maxillary central incisors and maxillary canines were segmented from the panoramic radiographs manually using the GIMP® software and generated seven radiomic attributes (contrast, correlation, energy, homogeneity, entropy, mean and deviation) for each tooth, totaling fourteen attributes. Finally, the concatenation of the data resulted in thirty-three attributes (semantic and radiomic). To analyze the statistical results of machine learning, the Mean Absolute Error (EMA) was applied. The isolated Kvaal method is applicable in the studied population (EMA 5.68) with emphasis on the maxillary incisor (EPE 7.10) which obtained greater estimation precision than the canine (EPE 7.38). Regarding applied machine learning, the extraction of semantic and radiomic attributes presented similar performance in the complete base (EMA 5.23), while the concatenation of these attributes obtained superior precision in the estimation of ages (EMA 4.77). The XG Boosting Reg classifier showed promising performance. Machine learning showed higher accuracy (EMA 4.77) when estimating the ages of the population studied when compared to the Kvaal method (EMA 5.68). Therefore, artificial intelligence can be applied as an auxiliary approach in age estimation using panoramic radiographs.

**Keywords:** Age determination by teeth; Artificial intelligence; Legal dentistry.

## LISTA DE FIGURAS

<b>Figura 1</b> - Radiografia panorâmica realizada no equipamento CS 8100 3D. Campo focal menor em altura. FONTE: Autor.....	30
<b>Figura 2</b> - Radiografia panorâmica realizada no equipamento CS 9000 3D. Campo focal maior em altura. FONTE: Autor.....	31
<b>Figura 3</b> - Mensuração do comprimento total (CD) do dente 21 realizada no software ImageJ. ....	32
<b>Figura 4</b> - Mensuração do comprimento da polpa (CP) do dente 21 realizada no software ImageJ.....	33
<b>Figura 5</b> - Mensuração do comprimento da raiz (CR) do dente 21 realizada no software ImageJ.....	33
<b>Figura 6</b> - Mensuração da largura da raiz na junção cimento-esmalte (LRA) do dente 21 realizada no software ImageJ. ....	34
<b>Figura 7</b> - Mensuração da largura da raiz entre a junção cimento-esmalte e o ápice da raiz (LRC) do dente 21 realizada no software ImageJ. ....	34
<b>Figura 8</b> - Mensuração da largura da raiz entre os níveis A e C (LRB) do dente 21 realizada no software ImageJ.....	35
<b>Figura 9</b> - Mensuração da largura da polpa ao nível da junção cimento-esmalte (LPA) do dente 21 realizada no software ImageJ.....	35
<b>Figura 10</b> - Mensuração da largura da polpa entre a junção cimento-esmalte e o ápice (LPC) do dente 21 realizada no software ImageJ.....	36
<b>Figura 11</b> - Mensuração da largura da polpa entre os níveis A e C (LPB) do dente 21 realizada no software ImageJ. ....	36
<b>Figura 12</b> - Delimitação do dente 21 no software GIMP através da "ferramenta de seleção livre" .....	38
<b>Figura 13</b> - Delimitação da cavidade pulpar do dente 21 no software GIMP através da "ferramenta de seleção livre" .....	39
<b>Figura 14</b> - Segmentação do dente 21 através do atalho "Ctrl + X" no software GIMP .....	39
<b>Figura 15</b> - Segmentação da cavidade pulpar do dente 21 através do atalho "Ctrl + X" no software GIMP .....	40
<b>Figura 16</b> - Dente 21 segmentado e colado em outra imagem com fundo preto no software GIMP .....	41
<b>Figura 17</b> - Cavidade pulpar do dente 21 segmentada e colada em outra imagem com fundo preto no software GIMP .....	41
<b>Figura 18</b> - Descrição da abordagem metodológica utilizada .....	45

## ARTIGO

<b>Figure 1</b> - Cropped panoramic radiographic images to exemplify the measurements performed according to the Kvaal method on tooth 21 (A) and tooth 23 (B).....	53
<b>Figure 2</b> - Segmentation of tooth 21 and its segmented pulp chamber.....	55
<b>Figure 3</b> - Real and estimated age dispersion for tooth 21. ....	59
<b>Figure 4</b> - Real and estimated age dispersion for tooth 23 .....	59

<b>Figure 5</b> - Comparison of the Mean Absolute Error (MAE) obtained by the studied algorithms for the male, female and complete database using the semantic attribute extraction. ..	61
<b>Figure 6</b> - Comparison of the Mean Absolute Error (MAE) obtained by the studied algorithms for male, female and the complete database using the radiomic attribute extraction..	61
<b>Figure 7</b> - Comparison of the Mean Absolute Error (MAE) obtained by the studied algorithms for the male, female and the complete database using the radiomics-semantics associated approach.....	62
<b>Figure 8</b> - Comparison between real age (blue line) and estimated age (red line) for the test group using the semantic approach for the male database, female database and complete database .....	63
<b>Figure 9</b> - Comparison between real age (blue line) and estimated age (red line) in the radiomic approach for the male database, female database and complete database.....	64
<b>Figure 10</b> - Comparison between real age (blue line) and estimated age (red line) obtained using the semantic-radiomic approach for the male database, female database and complete database .....	65
<b>Figure 11</b> - Comparison of semantic, radiomic and semantic-radiomic ML attribute extraction methods performance on age estimation for both genders and the complete database .....	66
<b>Figure 12</b> - Comparison between Kvaal's method and ML for age estimation. ....	67

## LISTA DE TABELAS

<b>Tabela 1</b> - Valores do coeficiente de concordância de Kappa para as medidas lineares do método de Kvaal.....	29
--	----

### ARTIGO

<b>Table 1</b> - Spearman correlations between age and the studied variables for tooth 21 and tooth 23 .....	57
<b>Table 2</b> - Regression equations for the age variable with coefficients of determination and standard error estimate per tooth .....	58
<b>Table 3</b> - Regression equations for the age variable in the total group and by gender .....	60
<b>Table 4</b> - Regression algorithms selected according to its performance for each database during the training phas .....	62

## LISTA DE ABREVIATURAS, SÍMBOLOS E SIGLAS

<b>CAAE</b>	Certificado de Apresentação de Apreciação Ética
<b>CD</b>	Comprimento do dente
<b>CEP</b>	Comitê de Ética em Pesquisa
<b>CNNs</b>	Redes Neurais Convolucionais
<b>CNS</b>	Conselho Nacional de Saúde
<b>CP</b>	Comprimento da polpa
<b>CR</b>	Comprimento radicular
<b>CS 8100®</b>	Tomógrafo Carestream Dental 8100
<b>CS 9000®</b>	Tomógrafo Carestream Dental 9000
<b>DNA</b>	Ácido desoxirribonucleico
<b>DPI</b>	Dots Per Inch (Pontos Por Polegada)
<b>EMA</b>	Erro Médio Absoluto
<b>EPE</b>	Erro Padrão da Estimativa
<b>IA</b>	Inteligência artificial
<b>ID</b>	Código de identidade
<b>KNN</b>	K-Nearest Neighbors
<b>kV</b>	Kilovoltagem
<b>LPA</b>	Largura da polpa no nível A
<b>LPB</b>	Largura da polpa no nível B
<b>LPC</b>	Largura da polpa no nível C
<b>LRA</b>	Largura da raiz no nível A
<b>LRB</b>	Largura da raiz no nível B
<b>LRC</b>	Largura da raiz no nível C
<b>mA</b>	Miliamperagem
<b>R<sup>2</sup></b>	Coefficiente de determinação
<b>S</b>	Segundos
<b>SVR</b>	Support Vector Regression
<b>TCFC</b>	Tomografia Computadorizada por Feixe Cônico
<b>TCLE</b>	Termo de Consentimento Livre e Esclarecido
<b>UEPB</b>	Universidade Estadual da Paraíba

## SUMÁRIO

<b>1. CONSIDERAÇÕES INICIAIS</b> .....	<b>15</b>
<b>1.2 Estimativa de idade através de dentes</b> .....	<b>15</b>
<b>1.3 Estimativa de idade utilizando radiografias odontológicas</b> .....	<b>16</b>
<b>1.4 Inteligência artificial</b> .....	<b>18</b>
1.4.1 Extração de atributos radiômicos e semânticos .....	19
<b>1.5 Estimativa de idade através do aprendizado de máquina utilizando radiografias odontológicas</b> .....	<b>20</b>
<b>2 OBJETIVO</b> .....	<b>22</b>
<b>2.1 Objetivo Geral</b> .....	<b>22</b>
<b>2.2 Objetivos Específicos</b> .....	<b>22</b>
<b>3 METODOLOGIA</b> .....	<b>23</b>
<b>3.1. Tipo de estudo</b> .....	<b>23</b>
<b>3.2. Aspectos éticos</b> .....	<b>23</b>
<b>3.3. Amostra</b> .....	<b>23</b>
3.3.1 Critérios de inclusão .....	23
3.3.2 Critérios de exclusão .....	23
<b>3.4. Teste <i>Kappa</i></b> .....	<b>24</b>
<b>3.5. Análise radiográfica para a estimativa de idade através do método de Kvaal</b> .....	<b>24</b>
3.5.1 Exportação das imagens do banco de dados .....	24
3.5.2 Padronização das imagens .....	24
3.5.2 Mensurações lineares nas imagens .....	26
<b>3.6. Análise radiográfica e do método de Kvaal através da inteligência artificial para a estimativa de idade</b> .....	<b>32</b>
3.6.1. Extração de atributos semânticos .....	32
3.6.2 Extração de atributos radiômicos .....	33
3.6.3 Concatenação de atributos semânticos e radiômicos .....	37
3.6.4 Algoritmos de regressão utilizados pelo aprendizado de máquina para previsão da idade	
37	
3.6.4.1 Logistic Regression .....	38
3.6.4.2 Linear Regression .....	38
3.6.4.3 K-Nearest Neighbors .....	38
3.6.4.4 Support Vector Regression (SVR) .....	38
3.6.4.5 Decision Tree Reg .....	39
3.6.4.6 Random Forest Reg .....	39

3.6.4.7 Gradient Boost Reg .....	39
3.6.4.8 XG Boosting Reg.....	40
<b>3.7. Fluxograma .....</b>	<b>40</b>
<b>3.8. Análise estatística.....</b>	<b>40</b>
3.8.1 Análise estatística do método de Kvaal.....	41
3.8.2 Análise estatística do aprendizado de máquina .....	41
<b>4 RESULTADOS.....</b>	<b>42</b>
<b>5 ARTIGO.....</b>	<b>43</b>
<b>6 CONSIDERAÇÕES FINAIS.....</b>	<b>68</b>
<b>REFERÊNCIAS .....</b>	<b>69</b>
<b>APÊNDICE A - TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO.....</b>	<b>73</b>
<b>APÊNDICE B - TERMO DE ASSENTIMENTO DO MENOR.....</b>	<b>75</b>
<b>APÊNDICE C - Tabela para o cálculo do método de Kvaal .....</b>	<b>77</b>
<b>ANEXO – PARECER DO COMITÊ DE ÉTICA EM PESQUISA (CEP) .....</b>	<b>78</b>



## **1. CONSIDERAÇÕES INICIAIS**

A estimativa da idade de um indivíduo é importante para a Odontologia Forense e para vários fins médico-legais, sendo realizada em vivos nos casos de crimes, de acidentes ou de refugiados com identidade desconhecida (BARDAL; SOLTANI, 2021). Além disso, essa estimativa tem um papel crucial também na reconstrução do perfil biológico de cadáveres não identificados em desastres em massa (MUÑOZ et al., 2018).

Levando-se em consideração a determinação da idade, faz-se necessária a diferenciação entre os conceitos de idade cronológica e idade biológica. A primeira diz respeito ao tempo decorrido desde o nascimento do indivíduo, enquanto a segunda refere-se à idade estimada a partir da análise de tecidos ou órgãos, sendo essa última aplicada quando a data de nascimento é desconhecida (KHORATE; DINKAR; AHMED, 2014; MAKKAD et al., 2013).

Cada método empregado para a determinação da idade é caracterizado pela precisão, pela confiabilidade e pela invasividade. Por essas razões, às vezes, métodos diferentes são normalmente combinados, a fim de se obter uma estimativa de idade mais precisa. Entretanto, um método definitivo para esse fim ainda não foi alcançado (GOBBO et al., 2021; KIM et al., 2021).

Em crianças, os métodos mais comuns para essa estimativa são baseados na maturação esquelética utilizando radiografias carpais. Porém, o método esquelético é limitado, pois a variabilidade da maturação óssea é influenciada por fatores ambientais. A determinação da idade em adultos é mais difícil e desafiadora, tendo em vista que o desenvolvimento dentário e a maturação esquelética já foram concluídos. Os métodos utilizados, levando-se em consideração as mudanças degenerativas do esqueleto, não são tão precisos quanto aqueles aplicados em crianças com foco no desenvolvimento dentário (NEMSI et al., 2017). Outros indicadores para tal estimativa incluem o estágio de desenvolvimento das vértebras cervicais e do crânio ou o grau de calcificação da epífise clavicular medial (MARRENO-RAMOS et al., 2020).

### **1.2 Estimativa de idade através de dentes**

Nessa perspectiva surge o dente, órgão com estrutura rígida que garante resistência às alterações físico-químicas ao longo do tempo, tornando-se um melhor preditor de idade em

comparação aos ossos e ideal para a estimativa da idade em indivíduos vivos, assim como em cadáveres (BARDAL; SOLTANI, 2021).

Existem diferentes métodos de estimativa de idade na Odontologia. Indicadores odontológicos como a racemização de ácido aspártico, a contagem dos anéis de cimento, a translucidez da dentina e o material de DNA dos dentes têm sido extensivamente estudados com o propósito de desenvolver padrões de estimativa de idade em populações adultas. Dentre esses métodos, a translucidez dentinária parece ser um dos mais confiáveis para prever a idade real de um indivíduo, considerado como o melhor parâmetro morfo-histológico na estimativa da idade dentária. No entanto, esses métodos citados são invasivos, caros, exigem equipamentos ou conhecimentos específicos e alguns deles não são passíveis de reprodução (ALHARBI et al., 2022; HAGHANIFAR et al., 2019; KHANAGAR et al., 2021; VADLA et al., 2020).

### **1.3 Estimativa de idade utilizando radiografias odontológicas**

As imagens radiográficas odontológicas fornecem informações preciosas na identificação, sendo consideradas um material útil em populações vivas ou não vivas para estudo genético ou investigações odontológicas, antropológicas e forenses (SANTOSH et al., 2022). Dentre todos os métodos utilizados para estimar a idade dentária, o radiológico é menos variável e não destrutivo (DALESSANDRI et al., 2020; ZHAI et al., 2017)

A diminuição do tamanho da cavidade pulpar é um processo associado à idade. Essa deposição começa após a erupção do dente, resultando na diminuição gradual do tamanho da cavidade pulpar ao longo da vida do indivíduo e a avaliação dos dentes no exame por imagem pode quantificar o tamanho dessa cavidade pulpar e correlacioná-lo com a idade (GE et al., 2016).

O estudo de Kvaal, et al. (1995) foi uma das primeiras investigações que desenvolveu um método indireto de estimativa de idade baseado na quantidade de deposição de dentina secundária utilizando radiografias periapicais através de razões entre as medidas do dente e da cavidade pulpar de uma população norueguesa. O estudo mostrou uma relação significativa entre a quantidade de dentina depositada e a idade dos indivíduos. Posteriormente, esse método foi modificado e aplicado em radiografias panorâmicas também mostrando um resultado significativo entre a relação da largura polpa-raiz e a idade cronológica (BARDAL; SOLTANI, 2021; HAGHANIFAR et al., 2019)

Por se tratar de uma abordagem relativamente não invasiva, o método de Kvaal et al. é recomendado pela Sociedade Americana de Odontologia Forense para estimativa de idade em adultos vivos, tornando-o vantajoso, uma vez que nessa faixa etária é mais difícil estimar a idade com um intervalo de erro reduzido. Entretanto, a sobreposição e a ampliação de estruturas dos exames por imagem podem ser fatores limitantes e, para contornar essa situação as razões entre as medidas do dente e da cavidade pulpar são calculadas. Para estimar a idade, métodos radiográficos como este propõem que sejam desenvolvidas fórmulas matemáticas de regressão individualizadas para cada população estudada, pois estudos já mostraram que estimar a idade com fórmulas desenvolvidas para outras populações pode gerar resultados pouco significativos (KARKHANIS; MACK; FRANKLIN, 2014; KAZMI et al., 2019).

Uma pesquisa realizada em uma população brasileira utilizando o método proposto por Kvaal obteve resultados diferentes dependendo da idade dos pacientes, com as previsões mais precisas da idade nos sujeitos mais jovens pertencentes aos grupos de 20-29 e 30-39 anos quando em relação a outras faixas etárias mais velhas estudadas (MIRANDA et al., 2020).

Outros métodos radiográficos utilizando diferentes abordagens dentárias têm sido propostos para a estimativa de idade, dentre eles destacam-se o de Demirjian e o de Camerieri. Ambos visam estimar a idade cronológica medindo os ápices de dentes permanentes em desenvolvimento. Embora estes métodos utilizem também exames por imagem, seus sujeitos são geralmente limitados a crianças e adolescentes (LEE et al., 2022).

Embora os métodos radiográficos de estimativa de idade tenham um desempenho razoavelmente bom e sejam amplamente utilizados na comunidade científica, todos eles dependem de medições ou classificações manuais exigindo tempo e esforço do avaliador. A inconveniência de aplicar esses métodos manuais na atividade clínica de rotina também é um fator importante. Além disso, os conjuntos de dados usados para inicialmente desenvolver e posteriormente validar esses métodos possuem critérios de exclusão rigorosos, incluindo ausência de dentes, presença de material obturador endodôntico ou cárie, resultando em técnicas que não funcionam com sujeitos que têm qualquer uma dessas condições (VILA-BLANCO et al., 2020).

Ainda sobre as desvantagens dos métodos radiográficos, estimar a idade em adultos pode apresentar uma margem de erro alta de aproximadamente 8 a 12 anos (AZEVEDO et al., 2015; MIRANDA et al., 2020). As Ciências Forenses determinam que o desvio padrão de um

método para a estimativa de idade do adulto deve ser preferencialmente abaixo de  $\pm 10$  anos (MARROQUIN et al., 2017).

Muitos pesquisadores se concentraram no método manual de identificação utilizando dentes, mas poucas contribuições vêm sendo feitas com aprendizado de máquina e visão computacional para identificação automatizada da idade com base nos dentes em radiografias odontológicas (SANTOSH et al., 2022).

#### **1.4 Inteligência artificial**

O termo “Inteligência Artificial” foi criado na década de 1950 e refere-se à ideia de construir máquinas capazes de realizar tarefas normalmente atribuídas aos humanos. É um sistema que pode ser aprimorado interativamente com base nas informações que coleta. Atualmente, a IA é utilizada na Radiologia Odontológica para automatizar tarefas repetitivas e com isso otimizar e concentrar o tempo do radiologista somente no diagnóstico (OSSOWSKA; KUSIAK; ŚWIETLIK, 2022; SHAN; TAY; GU, 2021).

O significado de IA é amplo e abrange qualquer algoritmo de computador que execute uma tarefa em nível humano. Isso inclui o aprendizado de máquina ou “*machine learning*”, em que um computador é treinado por dados para executar uma tarefa; e o aprendizado profundo ou “*deep learning*” que utiliza redes neurais com várias camadas treinadas por dados (BORSTELMANN, 2020).

O aprendizado de máquina pode ser entendido como a base operacional da IA e refere-se ao treinamento de algoritmos de computador para fazer previsões com base na experiência, buscando aprender automaticamente padrões significativos a partir de exemplos e observações. Portanto, um algoritmo de aprendizado de máquina requer dados de amostra para construir um modelo e fazer previsões (HIRAIWA et al., 2019; JANIESCH; ZSCHECH; HEINRICH, 2021; LIU; LANG, 2019).

Esse aprendizado de máquina pode ser dividido em supervisionado e não supervisionado. No aprendizado supervisionado realizam-se cálculos e, em seguida, ajusta-se o erro para obter uma saída esperada com a função inferida a partir de dados de um conjunto de exemplos de treinamento, processo mediado por um supervisor (humano). Em outras palavras, esses sistemas aprendem a detectar características normais e anormais. Já o aprendizado não supervisionado é o aprendizado de máquina por conta própria com base no padrão de entrada.

Os dados especificados não são rotulados e divididos em diferentes grupos. Esses modelos também são conhecidos como algoritmos de agrupamento e a principal limitação é que não há avaliação explícita da precisão da saída, o que o diferencia do aprendizado supervisionado (NAGI et al., 2020).

Já o aprendizado profundo é um tipo de aprendizado de máquina que surgiu da pesquisa de redes neurais na década de 1980 compreendendo várias camadas de algoritmos interconectados e estratificados. Os sistemas de aprendizado profundo são distintos dos modelos convencionais de aprendizado de máquina devido à sua capacidade de derivar abstrações de alto nível e recursos complexos por meio de uma combinação de várias transformações não lineares usando redes neurais convolucionais (CNNs). São redes de aprendizado profundo que consistem em vários blocos de construção empilhados. Uma CNN aprende diretamente com os dados, reconhece padrões nas imagens e classifica a saída final com base em sua tarefa (HEO et al., 2020; NAGI et al., 2020).

As CNNs têm sido utilizadas como componentes principais para a estimativa de idade, na qual esses métodos mostraram melhor desempenho do que abordagens matemáticas. Diferente dos algoritmos clássicos de visão computacional, as CNNs realizam a classificação e a extração dos atributos automaticamente. No entanto, além de exigirem dados de entrada bidimensionais, independentemente do tipo de exame por imagem estudado, necessitam de uma quantidade de dados significativamente grande para o treinamento automatizado (MOHAMMAD et al., 2022).

#### 1.4.1 Extração de atributos radiômicos e semânticos

Com o aumento de ferramentas computacionais de reconhecimento de padrões e o aumento no tamanho dos bancos de dados, a área das análises de imagens cresceu exponencialmente facilitando o desenvolvimento de processos de extração de recursos que resultam em dados consistentes. A essa prática chamamos de radiômica (do inglês *radiomics*) que é descrita como uma ferramenta quantitativa, reproduzível e promissora para a caracterização de imagens. Basicamente, a radiômica estabelece a extração massiva e a análise computadorizada de variáveis quantitativas das imagens. O objetivo principal da radiômica é extrair o máximo possível de dados ocultos importantes para o diagnóstico (FERREIRA JUNIOR et al., 2021; KOÇAK et al., 2019).

Já os atributos semânticos são parâmetros adquiridos e/ou calculados pelo pesquisador advindos por tabulação de dados ou fórmulas. As características semânticas são consideradas qualitativas, pois são pontuadas de acordo com a avaliação visual dos radiologistas. Embora os recursos semânticos sejam altamente intuitivos, eles estão sujeitos à variabilidade entre observadores (COROLLER et al., 2017; YIP et al., 2017).

### **1.5 Estimativa de idade através do aprendizado de máquina utilizando radiografias odontológicas**

A literatura sugere que as regressões dos métodos radiográficos clássicos com modelos matemáticos para a estimativa de idade utilizando radiografias odontológicas só podem ser aplicadas em determinadas populações sendo necessárias modificações no método original para alcançar resultados desejáveis. Na tentativa de resolver essa situação, surge a possibilidade de aplicar técnicas de aprendizado de máquina utilizando as imagens radiográficas (TAO et al., 2020).

Atualmente, os estudos vêm fortalecendo o aprendizado de máquina para a estimativa da idade. Como uma abordagem fundamental da inteligência artificial, esse tipo de aprendizado permite prever a idade dental não somente com mais precisão, mas também com mais eficiência quando em relação aos métodos tradicionais que utilizam somente modelos matemáticos de regressão (SHEN et al., 2021).

As técnicas de aprendizado de máquina podem servir como ferramentas complementares para investigadores forenses. A ausência do uso de tabelas de conversão específicas para uma determinada população, a adaptabilidade dos métodos para cada população estudada, a possibilidade de fornecer diretamente uma estimativa da idade dentária e integrar mais preditores do que os utilizados nos métodos clássicos podendo ampliar a faixa de estimativa desde crianças até a população adulta jovem são as principais vantagens desses métodos automatizados (GALIBOURG et al., 2021).

Outro contraponto que existe nos métodos radiográficos clássicos é o fato de serem considerados procedimentos complexos envolvendo um número significativo de identificações forenses. Assim, a automação do método convencional pode servir como ponto de partida para melhorar a eficiência e a reprodutibilidade durante o processo de identificação. Questões como o tempo necessário para estimar a idade usando atlas manual, pontuação subjetiva do avaliador

e grande número de casos a serem concluídos dentro de curto prazo estão entre os motivos para agilizar esse procedimento através do aprendizado de máquina (MOHAMMAD et al., 2022).

Poucas contribuições foram feitas com abordagens de aprendizado de máquina para identificação automatizada de idade com base em radiografias de dentes. Os estudos disponíveis seja comparando a IA a métodos radiográficos convencionais, seja utilizando somente a IA para estimar a idade através da extração de atributos radiômicos, são unânimes em concluir que os resultados do aprendizado de máquina apresentam dados promissores, superando os resultados das abordagens radiográficas clássicas para estimativa de idade (BOEDI et al., 2020; GALIBOURG et al., 2021; SANTOS et al., 2019; SHEN et al., 2021). Embora vários métodos clássicos já tenham sido testados pela IA, ainda não há estudos que comparem especificamente o método de Kvaal e o aprendizado de máquina utilizando radiografias panorâmicas.

Diante da variabilidade dos resultados dos métodos radiográficos clássicos utilizados para a previsão da idade por meio de dentes, a IA surge como uma alternativa com potencial para aumentar a estimativa de idade. Dessa forma, esse estudo tem como objetivo estimar a idade através da aplicação do método radiográfico de Kvaal em radiografias panorâmicas utilizando a IA como abordagem auxiliar.

## **2 OBJETIVO**

### **2.1 Objetivo Geral**

- Estimar a idade através do método radiográfico de Kvaal em radiografias panorâmicas utilizando a IA como abordagem auxiliar.

### **2.2 Objetivos Específicos**

- Avaliar o desempenho do método de Kvaal na estimativa de idade;
- Determinar o desempenho dos atributos radiômicos e semânticos na estimativa de idade;
- Verificar o desempenho da concatenação dos atributos radiômicos e semânticos na estimativa da idade;
- Definir qual dos métodos avaliados é mais preciso para estimar a idade;



### **3 METODOLOGIA**

#### **3.1. Tipo de estudo**

Observacional do tipo transversal.

#### **3.2. Aspectos éticos**

Este projeto foi devidamente cadastrado na Plataforma Brasil e subsequentemente enviado ao Comitê de Ética em Pesquisa da Universidade Estadual da Paraíba para apreciação, obtendo seu parecer aprovado sob o CAAE: 56455322.6.0000.5187 (Anexo) e estando em conformidade com a resolução do Conselho Nacional de Saúde (CNS) nº 466/2012 e nº580/2018 que estabelecem diretrizes e normas regulamentadoras de pesquisas envolvendo seres humanos.

#### **3.3. Amostra**

Foram selecionadas 554 radiografias panorâmicas de pacientes entre 13 e 57 anos do banco de dados de uma clínica de imagem particular no município de Campina Grande na Paraíba entre os anos de 2017 e 2019 e que apresentaram indicação para a realização desses exames por razões distintas às desta pesquisa. A amostra foi selecionada a partir do método de amostragem não probabilística e por conveniência de acordo com os critérios de elegibilidade.

##### **3.3.1 Critérios de inclusão**

- Radiografias panorâmicas de participantes com idade cronológica entre 13 e 57 anos apresentando o incisivo central superior esquerdo, assim como o canino superior esquerdo irrompidos e hígidos.

##### **3.3.2 Critérios de exclusão**

- Radiografias panorâmicas em que o incisivo central superior esquerdo e/ou canino superior esquerdo estivessem ausentes ou que apresentassem: tratamento endodôntico, aparelho ortodôntico, restaurações extensas que envolvessem ou sobrepusessem a cavidade pulpar, giroversões, lesões cariosas extensas e destruição coronária, sobreposições inerentes à técnica, dilaceração radicular, atrição severa, hipercementose, fratura coronária ou radicular, raízes fora do campo focal, reabsorções radiculares externas ou internas, calcificação pulpar ou patologias.

### 3.4. Teste *Kappa*

Antes da aplicação do método de Kvaal, a concordância intraobservador foi estabelecida através do teste *Kappa de Cohen* utilizando 10% da amostra. Um único observador realizou as mensurações e, após um intervalo de quinze dias, mensurou novamente. O coeficiente demonstrou confiabilidade de moderada a perfeita.

<b>Medida linear do método de Kvaal</b>	<b>Valor do coeficiente de concordância de <i>Kappa</i></b>
Comprimento total (CD)	1.0
Comprimento da polpa (CP)	0.9
Comprimento da raiz (CR)	0.9
Largura da raiz (nível A)	0.9
Largura da raiz (nível B)	0.9
Largura da raiz (nível C)	0.9
Largura da polpa (nível A)	0.8
Largura da polpa (nível B)	0.7
Largura da polpa (nível C)	0.7

**Tabela 1** - Valores do coeficiente de concordância de *Kappa* para as medidas lineares do método de Kvaal

### 3.5. Análise radiográfica para a estimativa de idade através do método de Kvaal

#### 3.5.1 Exportação das imagens do banco de dados

As imagens utilizadas neste estudo foram exportadas a partir da base de dados da clínica de radiologia odontológica através da plataforma Studio 3 iDoc (RadioMemory®, Minas Gerais, Brasil). Na plataforma foram filtradas as imagens do período compreendido entre os anos de 2017 e 2019. Logo após, o cadastro do paciente era aberto em “nova guia” do navegador e o *download* da radiografia panorâmica em formato “jpg” era realizado. Em seguida, esse arquivo baixado era renomeado com um ID (código numérico identificador) que a clínica atribuiu ao cadastro do paciente no momento em que ele realizou o exame. Por fim, registrava-se o ID, a idade real e o sexo de cada participante na planilha do *Excel*.

#### 3.5.2 Padronização das imagens

Como as radiografias panorâmicas utilizadas nessa pesquisa foram realizadas em dois equipamentos da mesma marca, mas com campos focais de tamanhos diferentes (Carestream®

CS 8100 3D exigindo 80 kV a 8 mA e tempo de rotação de 10,5s; e o Carestream® CS 9000 3D com 68 kV a 9 mA com um tempo de rotação de 14s). As imagens obtidas pelo CS 8100 possuíam 2600 x 1400 pixels com resolução de 280dpi e intensidade de 8 bites. Já as imagens adquiridas pelo CS 9000 tinham 2706 x 1536 pixels com resolução de 280dpi e intensidade de 8 bites. Fez-se, portanto, necessária a padronização dessas imagens antes de proceder às mensurações. A imagem de cada equipamento foi importada no ImageJ® (ImageJ, 1.43 n; National Institutes of Health, Bethesda, MD, USA) e considerou-se como tamanho nativo o arquivo que era aberto através desse *software* sem utilizar ferramentas de zoom, maximização ou ampliação da janela de visualização. Utilizando uma régua milimetrada mediu-se apenas a altura de cada imagem, pois a largura era igual para ambas. A altura da imagem do equipamento CS 8100 foi de 117.0mm; já a altura da imagem do equipamento CS 9000 foi de 129.0mm. Um valor médio de 123.0mm foi estabelecido para todas as imagens da amostra.

A fim de manter esses parâmetros fixos para as demais imagens, os seguintes ajustes foram realizados nesse *software*: através da ferramenta “*strayght*” foi traçada uma linha vertical no centro da imagem; em seguida as opções “*analyze*” e “*set scale*” foram selecionadas, respectivamente; na opção “*known distance*” da nova janela aberta foi digitado o valor correlativo à média da altura entre as duas imagens; e a unidade de comprimento em “*unit of length*” também foi definida em mm. Em seguida, o item “*global*” foi escolhido e por fim, o botão “*ok*” foi selecionado para salvar as modificações. Com isso, o ImageJ® estava preparado para realizar as mensurações.



**Figura 1** - Radiografia panorâmica realizada no equipamento CS 8100 3D. Campo focal menor em altura. FONTE: Autor




**Figura 2** - Radiografia panorâmica realizada no equipamento CS 9000 3D. Campo focal maior em altura. FONTE: Autor

### 3.5.2 Mensurações lineares nas imagens


Para a estimativa da idade através do método de *Kvaal* foram realizadas medidas lineares nos dentes 21 e 23 obedecendo os seguintes parâmetros:

- Comprimento total do dente (CD);
- Comprimento da polpa (CP);
- Comprimento da raiz (CR) medida na face distal desde a junção cimento-esmalte ao ápice radicular;
- Largura da raiz na junção cimento-esmalte correspondente ao nível A (LRA);
- Largura da raiz entre a junção cimento-esmalte e o ápice da raiz, correspondente ao nível C (LRC);
- Largura da raiz entre os dois níveis anteriores (A e C), correspondente ao nível B (LRB);
- Largura da polpa na junção cimento-esmalte correspondente ao nível A (LPA);
- Largura da polpa entre a junção cimento-esmalte e o ápice da raiz correspondente ao nível C (LPC);
- Largura da polpa entre os dois níveis anteriores (A e C) correspondente ao nível B (LPB);


No momento das mensurações o examinador desconhecia o sexo e a idade real dos participantes. Após a importação da imagem no *software*, a ferramenta “*straight*” era então selecionada e um total de nove mensurações eram realizadas em cada dente (CD, CP, LRA, LRC, LRB, LPA, LPC e LPB, respectivamente). A cada medida realizada, o atalho no teclado “Ctrl+M” era ativado para que uma janela paralela fosse aberta com os valores das medidas na coluna “*Lenght*”.



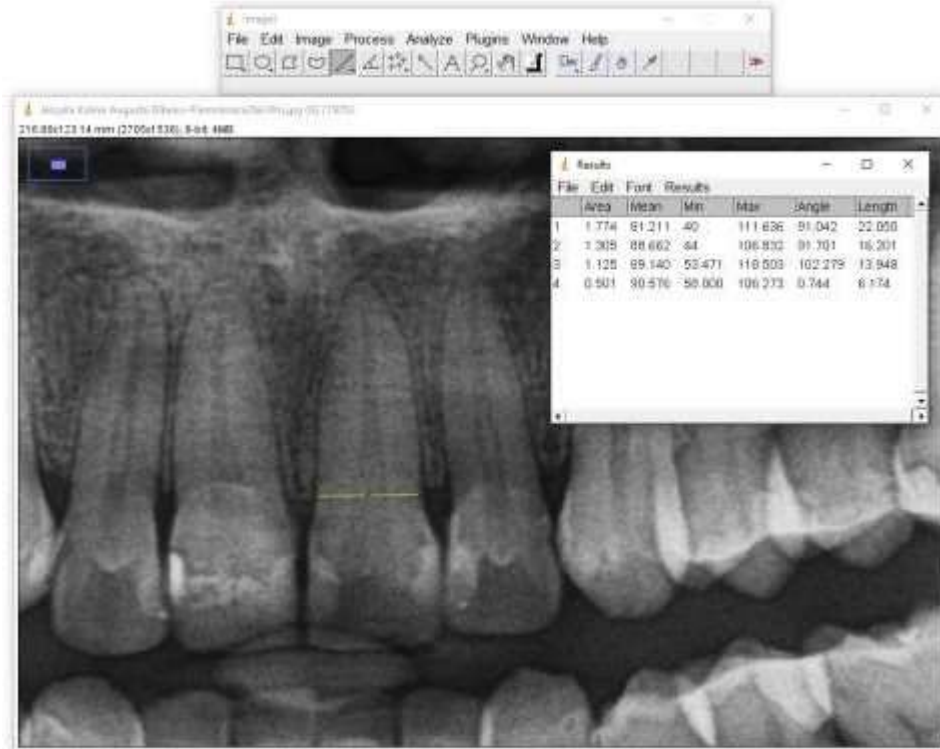
**Figura 3** - Mensuração do comprimento total (CD) do dente 21 realizada no software ImageJ.




**Figura 4** - Mensuração do comprimento da polpa (CP) do dente 21 realizada no software ImageJ.



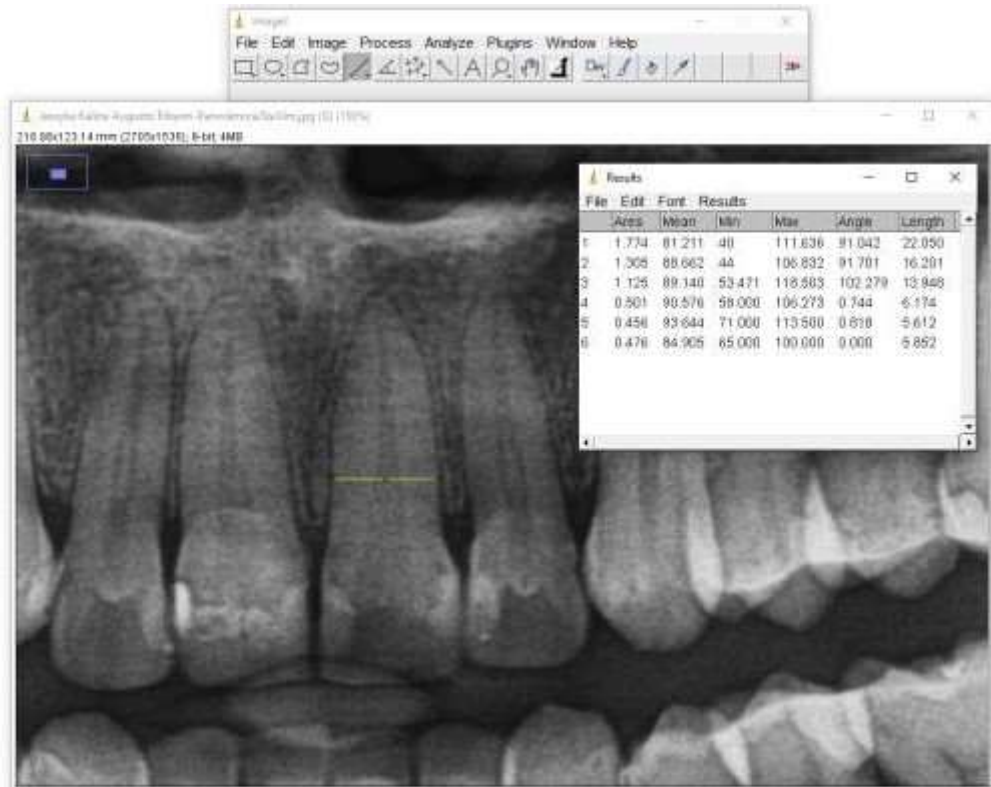
**Figura 5** - Mensuração do comprimento da raiz (CR) do dente 21 realizada no software ImageJ.



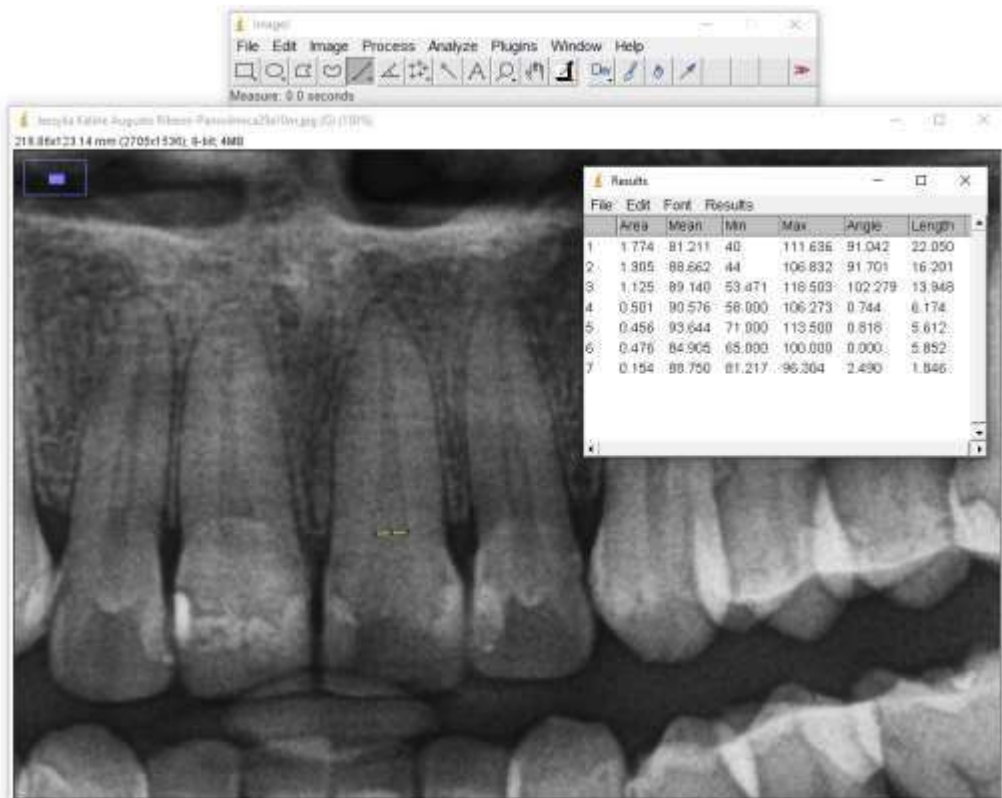
**Figura 6** - Mensuração da largura da raiz na junção cimento-esmalte (LRA) do dente 21 realizada no software ImageJ.



**Figura 7** - Mensuração da largura da raiz entre a junção cimento-esmalte e o ápice da raiz (LRC) do dente 21 realizada no software ImageJ.




**Figura 8** - Mensuração da largura da raiz entre os níveis A e C (LRB) do dente 21 realizada no software ImageJ.

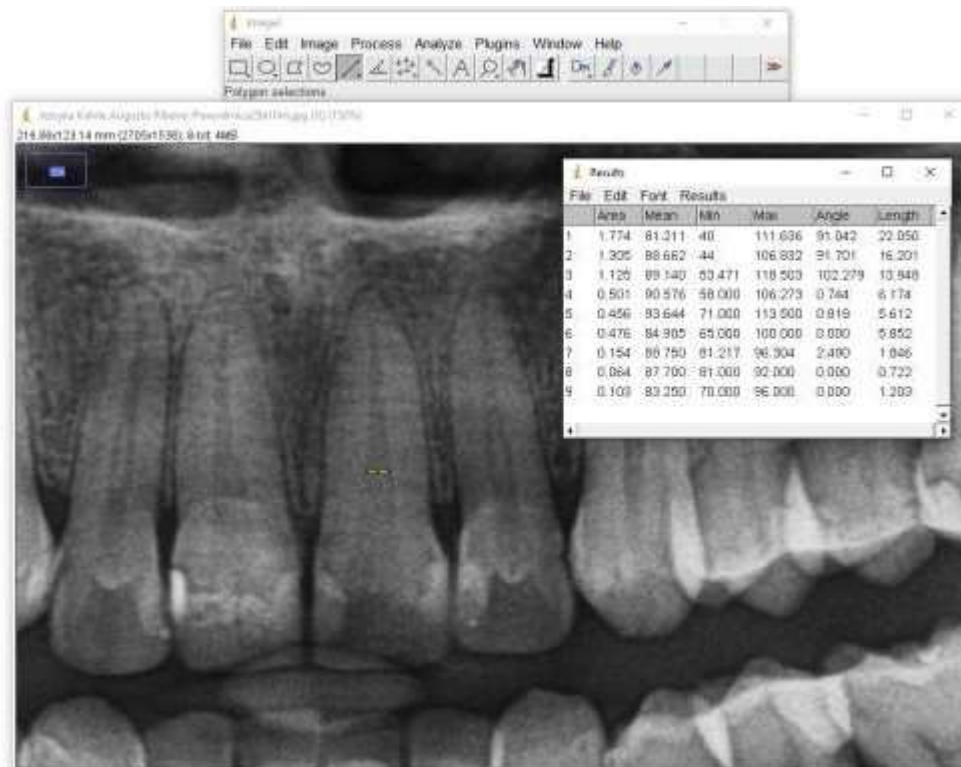


**Figura 9** - Mensuração da largura da polpa ao nível da junção cimento-esmalte (LPA) do dente 21 realizada no software ImageJ.





**Figura 10** - Mensuração da largura da polpa entre a junção cimento-esmalte e o ápice (LPC) do dente 21 realizada no software ImageJ.



**Figura 11** - Mensuração da largura da polpa entre os níveis A e C (LPB) do dente 21 realizada no software ImageJ.

Em seguida, esses valores da coluna “*Length*” eram repassados imediatamente para a planilha do *Excel* e as proporções entre as medidas do dente e da cavidade pulpar listadas abaixo eram automaticamente calculadas a fim de compensar qualquer diferença promovida pela ampliação inerente das radiografias panorâmicas:

$$A = LPA/LRA$$

$$B = LPB/LRB$$

$$C = LPC/LRC$$

$$P = CP/CR$$

$$T = CD/CR$$

$$R = CP/CD$$

$$M = (P+R+A+B+C)/5$$

$$W = (B+C)/2$$

$$L = (P+R)/2$$

$$W - L$$

### **3.6. Análise radiográfica e do método de Kvaal através da inteligência artificial para a estimativa de idade**

Os dentes 21 e 23 das radiografias panorâmicas foram analisados através de algoritmos de regressão de aprendizado de máquina que utilizaram três abordagens a partir dos atributos extraídos: radiômicos, semânticos e a concatenação (semânticos e radiômicos). Os atributos radiômicos foram extraídos das imagens com técnicas clássicas de visão computacional. Já os atributos semânticos foram as medidas lineares do dente e da cavidade pulpar feitas pelo avaliador e extraídos do método de Kvaal (dados da tabela). O particionamento foi realizado na proporção 85/15, sendo 85% da amostra para treinamento e 15% para testes. A opção de 85% no treinamento ocorreu em virtude do tamanho amostral reduzido. Esse particionamento foi utilizado nos três cenários: primeiro na base semântica, depois na radiômica e, por fim, com a base final concatenando as duas abordagens.

#### **3.6.1. Extração de atributos semânticos**

Os dados da tabela do método de Kvaal foram extraídos dando origem ao seguinte conjunto de atributos: “SEXO”, “CD\_21”, “CP\_21”, “CR\_21”, “LRA\_21”, ”LRB\_21”,

“LRC\_21”, “LPA\_2”, “LPB\_21”, “LPC\_21”, “CD\_23”, “CP\_23”, “CR\_23”, “LRA\_23”, “LRB\_23”, “LRC\_23”, “LPA\_23”, “LPB\_23” e “LPC\_23”. Sendo, por exemplo, “CD\_21” o CD do dente 21 e “CD\_23” do dente 23. Esse processo de extração gerou um conjunto de dados com 554 amostras em estrutura tabular, sendo que cada amostra continha 19 atributos.

### 3.6.2 Extração de atributos radiômicos

A segmentação dos arquivos deste estudo foi do tipo manual, na qual os dentes e as cavidades pulpares foram separados da radiografia panorâmica. Essa etapa foi realizada por dois examinadores que também desconheciam o sexo e a idade real dos participantes.

As radiografias panorâmicas, desta vez, eram importadas para outro *software*, o GNU Image Manipulation Program (GIMP® 2.10.32) clicando na opção “Arquivo” e depois em “Abrir”. Em seguida, a “ferramenta de seleção livre” era ativada com o objetivo de demarcar a área dos dentes e posteriormente a área das cavidades pulpares. O zoom de 300X na imagem era aplicado antes da seleção. Para realizar o contorno das estruturas era necessário clicar em um ponto de partida que delimitava o dente para iniciar a definição de todos os pontos que se interconectavam por meio de uma linha. Eram demarcados aproximadamente 20 pontos para a delimitação dos dentes e das cavidades pulpares.



**Figura 12** - Delimitação do dente 21 no software GIMP através da "ferramenta de seleção livre"



**Figura 13** - Delimitação da cavidade pulpar do dente 21 no software GIMP através da "ferramenta de seleção livre"

A etapa subsequente era segmentar, de fato, os dentes e as cavidades pulpares da radiografia panorâmica através do atalho no teclado "Ctrl + X".




**Figura 14** - Segmentação do dente 21 através do atalho "Ctrl + X" no software GIMP




**Figura 15** - Segmentação da cavidade pulpar do dente 21 através do atalho "Ctrl + X" no software GIMP

Em seguida, clicava-se na opção “criar uma nova imagem” e outra janela era aberta. Nessa nova janela, no item “modelo”, selecionava-se o tamanho “A4 (300ppi)” da nova imagem e ajustava-se a largura e a altura para 4.0cm. Em “opções avançadas” no item “espaço de cor” era selecionada a opção “níveis de cinza” e, no item “preencher com”, a opção “cor de frente” era escolhida. Os dentes e as cavidades pulpares segmentados eram colados na nova imagem com fundo preto que era criada. Por fim, essas imagens segmentadas foram exportadas em formato “jpg.” e nomeadas como 21.JPEG, 23.JPEG, p21.JPEG e p23. JPEG, respectivamente.



**Figura 16** - Dente 21 segmentado e colado em outra imagem com fundo preto no software GIMP



**Figura 17** - Cavidade pulpar do dente 21 segmentada e colada em outra imagem com fundo preto no software GIMP

Para cada paciente foram extraídos os seguintes atributos de textura de ambos os dentes: contraste, correlação, energia (segundo momento angular), homogeneidade, entropia e média. Assim, temos para cada paciente o seguinte conjunto de atributos: “CONTRASTE\_21”, “CORRELACAO\_21”, “ENERGIA\_21”, “HOMOGENEIDADE\_21”, “ENTROPIA\_21”, “MEDIA\_21”, “DESVIO\_21”, “CONTRASTE\_23”, “CORRELACAO\_23”, “ENERGIA\_23”, “HOMOGENEIDADE\_23”, “ENTROPIA\_23”, “MEDIA\_23” e

“DESVIO\_23”. Sendo, por exemplo, “CONTRASTE\_21”, o contraste do dente 21 e “CONTRASTE\_23” do dente 23.

É importante salientar que a utilização da base das cavidades pulpares segmentadas gerou resultados inferiores, provavelmente pelo pequeno número de amostras, nas quais os modelos não conseguiram extrair informações suficientes para caracterizar padrões de idade. Somente a base dos dentes segmentados foi considerada neste estudo e com isso, criou-se então um conjunto de dados contendo 554 amostras, nas quais cada uma apresentando 14 atributos.

### 3.6.3 Concatenação de atributos semânticos e radiômicos

Para verificar se a associação de atributos radiômicos e semânticos poderia melhorar a estimativa de idade, foi criado outro conjunto de dados associando ambos os métodos. Esse conjunto de dados continha 554 amostras e 33 atributos: “SEXO”, “CD\_21”, “CP\_21”, “CR\_21”, “LRA\_21”, “LRB\_21”, “LRC\_21”, “LPA\_21”, “LPB\_21”, “LPC\_21”, “CD\_23”, “CP\_23”, “CR\_23”, “LRA\_23”, “LRB\_23”, “LRC\_23”, “LPA\_23”, “LPB\_23”, “LPC\_23”; e “CONTRASTE\_21”, “CORRELACAO\_21”, “ENERGIA\_21”, “HOMOGENEIDADE\_21”, “ENTROPIA\_21”, “MEDIA\_21”, “DESVIO\_21”, “CONTRASTE\_23”, “CORRELACAO\_23”, “ENERGIA\_23”, “HOMOGENEIDADE\_23”, “ENTROPIA\_23”, “MEDIA\_23”, “DESVIO\_23”.

### 3.6.4 Algoritmos de regressão utilizados pelo aprendizado de máquina para previsão da idade

No presente estudo não foram utilizadas CNNs em virtude do tamanho da amostra. Optou-se então pela utilização de algoritmos de regressão que fazem parte do aprendizado de máquina supervisionado. Nesse caso, não se trata especificamente de complexidade, pois alguns dos modelos usados são tão ou mais complexos que as CNNs.

No aprendizado de máquina não há um algoritmo único que funcione melhor para todos os problemas, assim como também não é possível dizer, por exemplo, que as redes neurais são sempre melhores que as árvores de decisão ou vice-versa. Existem muitos fatores dependentes como o tamanho e a estrutura do conjunto de dados. Por isso é necessário testar muitos algoritmos diferentes de aprendizado para prever a idade, enquanto se utiliza um conjunto de dados de espera para avaliar o desempenho e selecionar aquele que se destaca.

Os classificadores abaixo foram aplicados no grupo de treinamento e aqueles que apresentaram desempenho superior foram utilizados na previsão das idades com o grupo de testes.

#### *3.6.4.1 Logistic Regression*

O algoritmo “Logistic Regression” é amplamente utilizado para lidar com problemas multifatoriais semelhantes. Aplicado à medicina, à estatística e ao aprendizado de máquina, esse algoritmo ajusta vários parâmetros em um modelo de previsão, verificando se os preditores estão relacionados linear e aditivamente a um resultado (SUFRIYANA et al., 2020).

#### *3.6.4.2 Linear Regression*

O “Linear Regression” é talvez um dos algoritmos mais conhecidos e bem compreendidos em estatística e aprendizado de máquina. É denominado dessa forma por ser uma reta traçada a partir de uma relação em um diagrama de dispersão. Essa reta resume uma relação entre os dados de duas variáveis e também pode ser utilizada para realizar previsões. Sua origem provém da correlação linear que é a verificação da existência de um relacionamento entre duas variáveis e, para isso, utiliza os pontos de dados para encontrar a melhor linha de ajuste a fim de modelar essa relação.

#### *3.6.4.3 K-Nearest Neighbors*

Os modelos “K-Nearest Neighbors” (KNN) usam a localização geográfica de informações no espaço preditor para prever o resultado de uma nova amostra. Por exemplo, um modelo KNN utilizando cinco “neighbors” se relaciona com as cinco observações mais próximas em espaço multidimensional, baseado em uma medida de distância para prever o resultado de uma nova observação (CHURPEK et al., 2016).

#### *3.6.4.4 Support Vector Regression (SVR)*

“Support Vector Regression”, como o nome sugere, é um algoritmo de regressão que suporta regressões lineares e não lineares. Este método funciona com base no princípio da



“Support Vector Machine”. O SVR difere do SVM. Este último é um classificador usado para prever rótulos categóricos discretos, enquanto o primeiro é um regressor usado para prever variáveis ordenadas contínuas (KHEMCHANDANI; GOYAL; CHANDRA, 2016).

#### *3.6.4.5 Decision Tree Reg*

Os algoritmos “Decision Tree Reg” são fáceis de entender e interpretar. Árvores de decisão simples são muitas vezes feitas em papel na forma de fluxogramas ou mesmo como modelos mentais em diagnósticos radiológicos. Uma árvore de aprendizado de máquina se parece mais com uma rede ramificada de raízes ou dendritos. Em cada ponto de divisão ou nó, é feita uma separação em uma única variável minimizando a função de perda associada ao algoritmo (BORSTELMANN, 2020).

#### *3.6.4.6 Random Forest Reg*

Os “Random Forest Reg” são métodos baseados em árvores de decisão comumente usados e muitas vezes considerado como algoritmo obrigatório para muitos cientistas de dados, principalmente quando eles precisam obter algo que simplesmente funcione. No entanto, esse algoritmo é computacionalmente caro e pode exigir um tempo substancial para ser executado em conjuntos de dados muito grandes. Portanto, às vezes são combinados com técnicas de redução de dimensionalidade (BORSTELMANN, 2020).

#### *3.6.4.7 Gradient Boost Reg*

Os algoritmos “Gradient Boost Reg” calculam a média de árvores para subconjuntos ponderados dos dados, onde os erros cometidos na primeira árvore contribuem para o aprendizado de outra árvore na próxima interação (chamada de estratégia de reforço). Essa abordagem muitas vezes exige que os pesquisadores experimentem, em média, quão profundas as árvores devem ser e com que rapidez as árvores devem se adaptar ao erro inicial (taxa de aprendizado) (DOUPE; FAGHMOUS; BASU, 2019).

### 3.6.4.8 XG Boosting Reg

O “XG Boosting Reg” é altamente eficiente, sendo um dos algoritmos de aprendizado de máquina mais rápidos de aumento de gradiente. Esse algoritmo detém mais poder computacional para obter previsões mais precisas. Como uma biblioteca extensível, o XGBoost permite que os usuários definam objetivos de otimização personalizados e métricas de avaliação incorporando recursos para realizar validação cruzada (RAMÍREZ-MEJÍA; LEVERS; MAS, 2022). Alguns cientistas de dados consideram o algoritmo XG Boosting Reg superior ao Random Forest Reg (BORSTELMANN, 2020).

### 3.7. Fluxograma

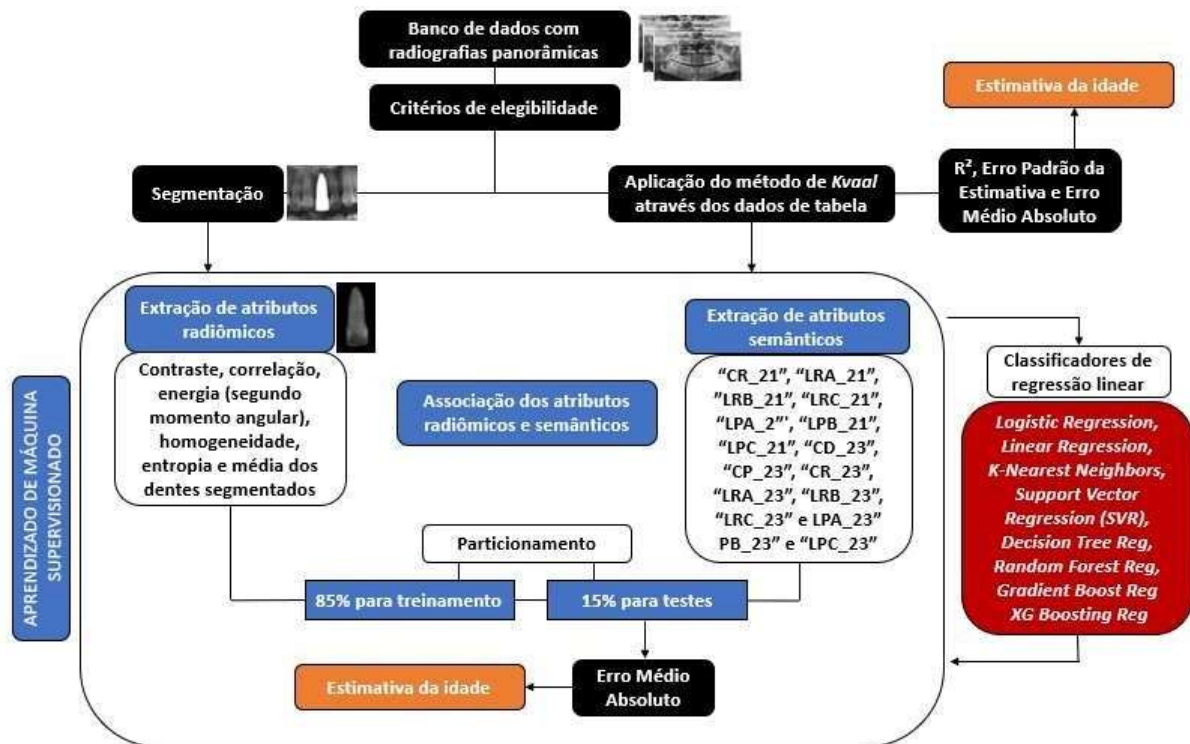


Figura 18 - Descrição da abordagem metodológica utilizada

### 3.8. Análise estatística

### 3.8.1 Análise estatística do método de Kvaal

Para a comparação entre sexos em relação às variáveis analisadas foi utilizado o teste de Mann-Whitney. Para avaliar o grau da relação entre duas variáveis numéricas foi obtido o coeficiente de correlação de Spearman e o teste t-Student específico para a hipótese de correlação nula. A fim de analisar a variabilidade dos dados na estimativa da idade foram aplicadas regressões lineares, no qual o coeficiente de determinação ( $R^2$ ) representa o percentual da variância dos dados que é explicado pelo modelo. Quanto maior o valor de  $R^2$ , mais explicativo é o modelo em relação aos dados previstos. Nas regressões iniciais foram incluídas todas as variáveis que apresentavam correlações significativas a 5% ( $p < 0,05$ ) e foram mantidas as que apresentavam significância a 10% ( $p < 0,10$ ) pelo processo *stepwise*.

Para verificar o nível de concordância entre os valores reais e os estimados pelas regressões, para cada dente, foi obtido o coeficiente de correlação de concordância e o respectivo intervalo de confiança. A escolha do teste de Mann-Whitney e da correlação de Spearman foi a ausência de normalidade. A verificação da normalidade foi realizada pelo teste de Shapiro-Wilk. A margem de erro utilizada na decisão dos testes estatísticos foi de 5% e os intervalos com 95% de confiança. Os dados foram digitados na planilha EXCEL e o programa utilizado para obtenção dos cálculos estatísticos foi o IMB SPSS na versão 23.

### 3.8.2 Análise estatística do aprendizado de máquina

Para analisar quantitativamente a precisão dos algoritmos foi aplicada uma métrica difundida na avaliação de sistemas para estimativa de idade, o Erro Médio Absoluto (EMA). Definido como um valor médio das diferenças absolutas entre as idades previstas e as idades reais. É a medida padrão para erros de previsão de idade. Um EMA baixo significa que a idade estimada está próxima da idade real e, portanto, uma estimativa razoável. Por outro lado, um valor EMA alto indica resultados imprecisos (GRÜBL; LALLIE, 2022).

#### **4 RESULTADOS**

Os resultados do presente estudo serão apresentados em formato de artigo, o qual será submetido à revista *Dentomaxillofacial Radiology* que detém fator de impacto de 3.525.

## 5 ARTIGO

### *Age determination on panoramic radiographs with the aid of artificial intelligence*

Douglas Pereira de Sousa, DDS, MSD - Department of Dentistry, State University of Paraiba, Rua Baraúnas, 351, Bairro Universitário, 58429-500, Campina Grande, Paraíba, Brasil. Email: [drsousa.douglas@gmail.com](mailto:drsousa.douglas@gmail.com)

Elisa Diniz Lima, DDS, MSD, Phd - Department of Dentistry, State University of Paraiba, Rua Baraúnas, 351, Bairro Universitário, 58429-500, Campina Grande, Paraíba, Brasil. Email: [elisadinizdelima@gmail.com](mailto:elisadinizdelima@gmail.com)

José Alberto Souza Paulino, BSC, MS (health technology)- Computer Science Phd Student, Federal University of Campina Grande, Rua Aprígio Veloso, 882, Bairro Universitário, 58429-900, Campina Grande, Paraíba, Brazil. Email: [souzapaulino@gmail.com](mailto:souzapaulino@gmail.com)

Maria Luiza dos Anjos Pontual, DDS, MSD, PhD – Department of Oral Diagnosis, Division of Oral Radiology, Federal University of Pernambuco, Av. Prof. Artur de Sá, 329-481 - Cidade Universitária, Recife - PE, Brazil. Email: [mlpontual@gmail.com](mailto:mlpontual@gmail.com)

Patrícia Meira Bento, DDS, MSD, Phd - Department of Dentistry, State University of Paraiba, Rua Baraúnas, 351, Bairro Universitário, 58429-500, Campina Grande, Paraíba, Brasil. Email: [patmeira@uol.com.br](mailto:patmeira@uol.com.br)

Daniela Pita de Melo, DDS, MSD, Phd - Department of Dentistry, State University of Paraiba, Rua Baraúnas, 351, Bairro Universitário, 58429-500, Campina Grande, Paraíba, Brasil. Email: [danipita@gmail.com](mailto:danipita@gmail.com)

#### **Corresponding Author:**

**Daniela Pita de Melo**

**Rua Baraúnas, 351, Bairro Universitário**

**Campina Grande, PB, Brasil. 58429-500**

**E-mail: [danipita@gmail.com](mailto:danipita@gmail.com)**

This research has not received any specific grants from funding agencies in the public, commercial, or not-for-profit sectors.

## ABSTRACT

This study aimed to assess and compare age estimation on panoramic radiography using the Kvaal method and machine learning (ML). 554 panoramic radiographs were selected from a Brazilian practice. To estimate age using the Kvaal method, the following measurements were performed on the upper left central incisors and canines: tooth, pulp and root length; root and pulp width at three different levels: at the enamel-cementum junction (ECJ); midpoint between the ECJ and; at the mid root level. For ML age estimation, radiomic, semantic and the radiomic-semantic attribute extractions were assessed. Nineteen semantic and fourteen radiomic attributes and a single set of thirty-three semantic-radiomic attributes were extracted. Logistic Regression, Linear Regression, KNN, SVR, Decision Tree Reg, Random Forest Reg, Gradient Boost Reg e XG Boosting Reg were used for ML classification. For the Kvaal method, Mann-Whitney test, Spearman correlation coefficient, Student's t test and linear regression with its respective coefficient of determination were used to estimate age and to assess data variability. Mean absolute error (MAE) and standard error estimate (SEE) were assessed. For the Kvaal method, upper incisors presented higher precision than canines ( $R^2:0.335$ ,  $SSE:7.108$ ). Males presented better MAE and SEE values (5.29,6.96) than females (5.69,7.37). The radiomic-semantic attributes presented superior precision (MAE:4.77) than the radiomic and semantic (MAE:5.23) attributes. The XG Boosting Reg classifier performed better than the other 6 assessed classifiers (MAE: 4.65). ML presented higher age estimation precision than the Kvaal method (MAE: 4.77,5.68). The use of ML on panoramic radiographs can improve age estimation.

**Keywords:** Panoramic Radiography; Artificial Intelligence; Forensic Dentistry.

## INTRODUCTION

The knowledge of the age of individuals is relevant with regard to criminal liability, illegal immigration and for the adoption process when a birth certificate is not available. In addition, age estimation plays a critical role in determining the civil rights of refugees.<sup>1</sup> For living individuals, particularly children and adolescents, age estimation is necessary to determine whether the subject is a minor or not,<sup>2,3</sup> with judicial implications.

The most common methods used for child age estimation are based on skeletal maturity using carpal radiographs and the assessment of dental development on dental radiographic images.<sup>4,5</sup> For adult age estimation, secondary dentin deposition on the pulp chamber walls have been considered the main dental characteristic to be assessed.<sup>6,7</sup> This deposition begins after the tooth erupts, resulting in a gradual decrease in the size of the pulp cavity throughout the individual's life and the assessment of dental radiographic images enables pulp cavity size quantification and its correlation with age.<sup>7</sup>

Kvaal, et al. (1995)<sup>8</sup> developed an indirect method to estimate age based on the amount of secondary dentin deposition using periapical radiographs to assess tooth/pulp cavity ratios of a Norwegian population. The study showed a significant relationship between the amount of dentin deposited and the age of the subjects. Subsequently, this method was modified and applied to panoramic radiographs, also presenting promising results.<sup>9,10</sup>

A previous study carried out in a Brazilian population using the Kvaal's method showed a variability of results depending on the patient's age, with the most accurate age predictions in the subjects under forty years-old.<sup>11</sup> Based on the fact that Kvaal's method is a relatively non-invasive age estimate approach and estimating age in adults with a reduced error has proven to be challenging, this method is recommended by the American Society of Forensic Dentistry for age estimation in living adults.<sup>12,13</sup>

Although radiographic age estimation methods perform reasonably well and are widely used by the scientific community, they all rely on manual measurements or classifications, which require trained specialists and are time consuming. In addition, the datasets used to develop and later validate these methods have strict exclusion criteria including missing teeth, endodontic treatments, caries,<sup>14</sup> and are centered in one or two image characteristics, not taking in consideration other important information that may improve age prediction.<sup>15</sup>

Previous studies have focused on radiographic age estimation, but few contributions have been made on machine learning (ML) and computer vision approaches to improve

automated age identification, especially as automated segmentation is still an issue that needs improvement and validation.<sup>16</sup> Recently, deep learning techniques have made advances in computer vision,<sup>17</sup> and have been used to estimate dental age by using learning algorithms with promising results.<sup>18</sup> Therefore, AI can be used to increase the accuracy of age estimation methods, performing tasks that can be improved interactively based on the collected data. As a fundamental approach to AI, ML allows us to predict age accurately and also more efficiently, especially if we can determine the best algorithm and attribute extraction method for this end.<sup>19</sup>

The studies available in the literature, whether comparing AI to conventional radiographic methods or using AI alone to estimate age through the extraction of radiomic attributes, are unanimous in concluding that ML presents promising results, surpassing the results of classical radiographic approaches for age estimation<sup>17,19-21</sup>. However, studies comparing existing age estimation methods are needed to assess and improve machine learning algorithms performance. Therefore, this study aims to assess and compare the Kvaal's radiographic method for panoramic radiographs and ML algorithms performances on a northeastern Brazilian population.

## **MATERIAL E METHODS**

This cross-sectional observational study was approved by the University's Ethics and Research Committee (protocol nº 56455322.6.0000.5187) and follows the Helsinki Declaration.

### *Sample Selection*

A total of 554 panoramic radiographs of patients aged between 13 and 57 years-old were selected from the database of a private imaging clinic in Campina Grande, Paraíba, northeastern Brazil, from 2017 to 2019. The sample was selected by non-probability sampling method and by convenience according to the eligibility criteria of the study.

Panoramic radiographs in which the left maxillary central incisor and/or left maxillary canine were absent or which showed: endodontic treatment, orthodontic appliance, extensive restorations involving or overlapping the pulp cavity, gyroversions, extensive carious lesions and coronary destruction, overlaps inherent to the technique, root dilaceration, severe attrition, hypercementosis, coronary or root fracture, roots outside the focal field, external or internal root resorption, pulp calcification or pathologies were excluded from the sample.

### *Age estimation using the Kvaal method*



### *Kappa test*

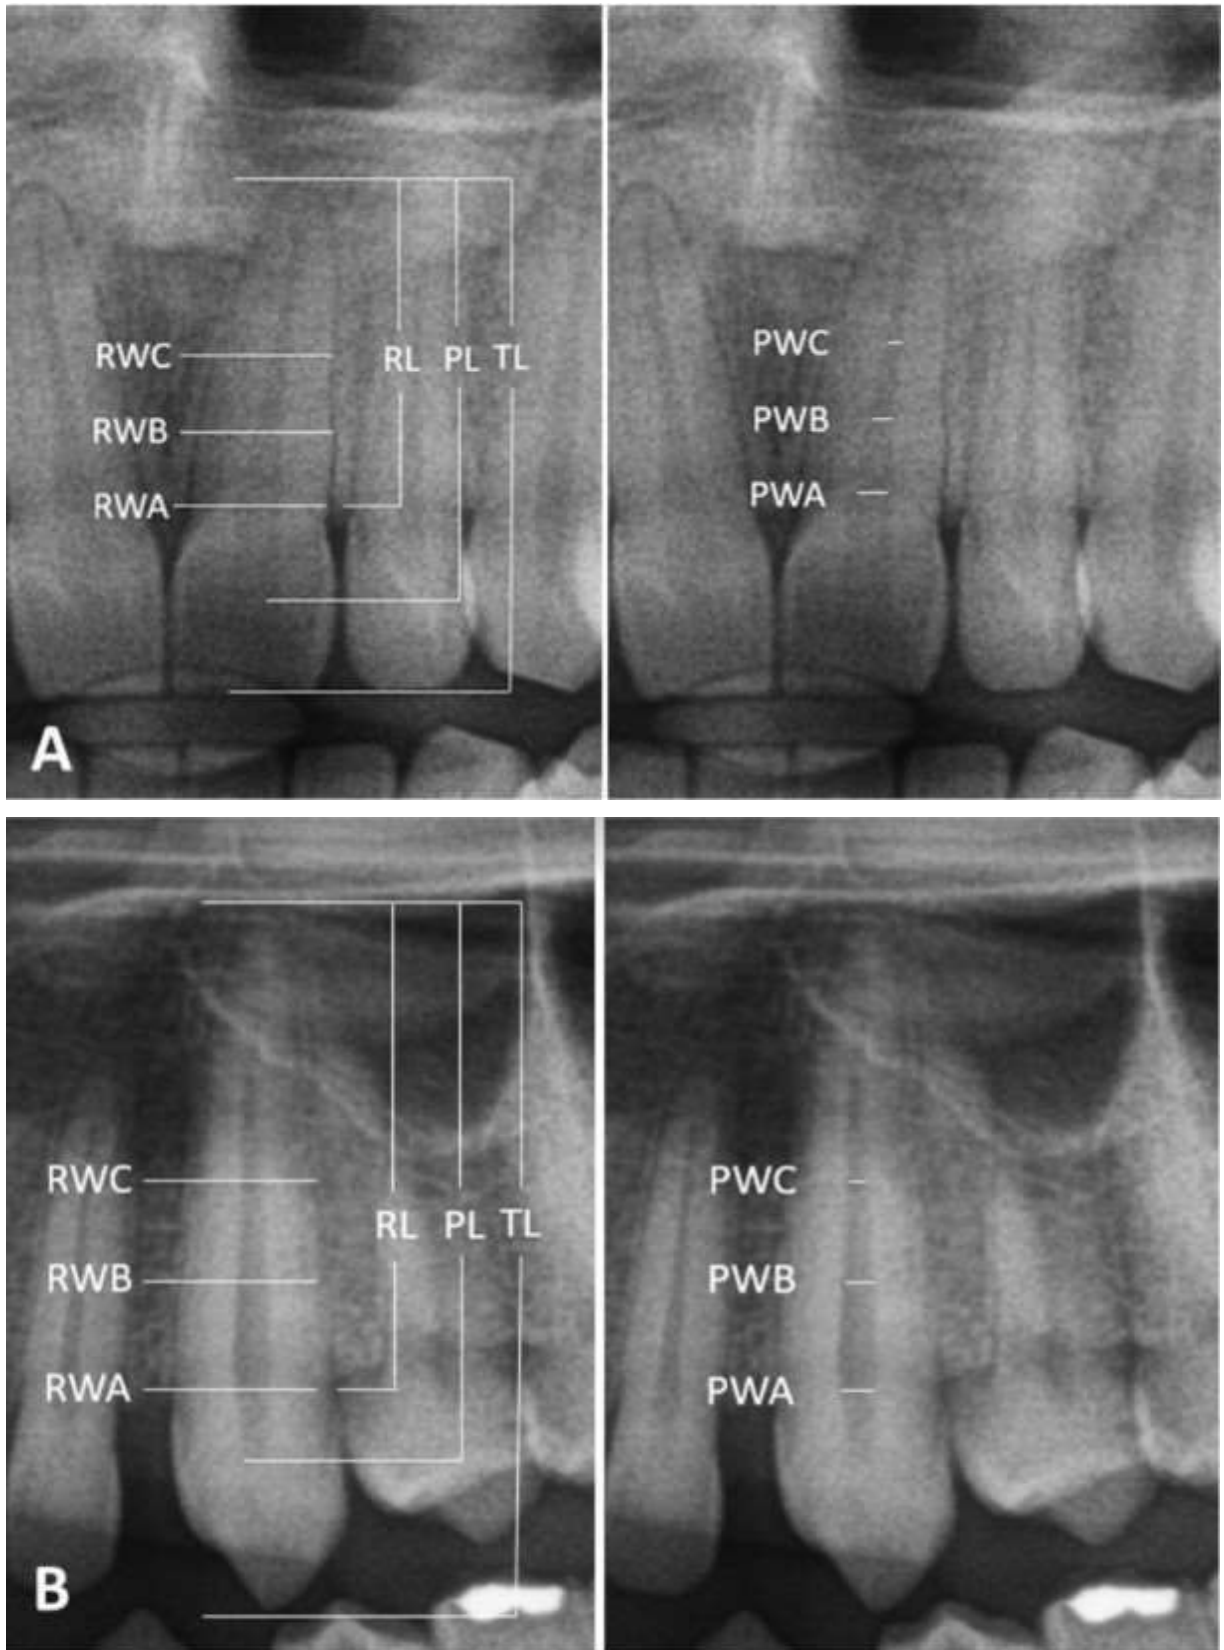
Before applying Kvaal's method, intra-observer agreement was established using Cohen's Kappa test on 10% of the sample for the linear measurements. A single observer performed the measurements twice with a fifteen days interval and presented moderate to perfect (0.7 - 1.0) reliability.

### *Standardization of the selected images*

The panoramic radiographs used in this research were performed on two different Carestream® panoramic units with different focal sizes: CS 8100 3D and CS 9000 3D (Carestream Dental LLC, Atlanta, GA). The images obtained using CS 8100 had 2600 x 1400 pixels with a resolution of 280dpi and an intensity of 8 bits, acquired at 80 kV, 8 mA and a rotation time of 10.5s. The images acquired using CS 9000 had 2706 x 1536 pixels with a resolution of 280dpi and an intensity of 8 bits at 68 kV, 9 mA and a rotation time of 14s. Therefore, it was necessary to standardize these images before proceeding with the measurements. The height of each image was measured, as the width was the same for both panoramic images. The image height of the CS 8100 panoramic images was 117.0mm and of the CS 9000 was 129.0mm. The images were calibrated to an average value of 123.0mm in order to perform image measurements using ImageJ software (64-bit Java 1.8.0\_172, National Institutes of Health, Bethesda, MD).

### *Linear measurements*

The following linear measurements were performed on the incisors and canines (Figure 1): Tooth length (TL); Pulp length (PL); Root length (RL); Pulp and root width at three different levels: A- at the enamel cementum junction (ECJ) – Root width A (RWA) and Pulp width A (PWA); B- at the midpoint between the ECJ – Root width B (RWB) and Pulp width B (PWB) and mid root level and C- at the mid root level– Root width C (RWC) and Pulp width C (PWC).



**Figure 1** - Cropped panoramic radiographic images to exemplify the measurements performed according to the Kvaal method on tooth 21 (A) and tooth 23 (B).

The measurement values were then immediately transferred to a spreadsheet and the proportions between the tooth and pulp cavity measurements were calculated in order to compensate for any difference in magnification:  $A = PWA/RWA$ ;  $B = PWB/RWB$ ;  $C = PWC/RWC$ ;  $P = PL/RL$ ;  $T = TL/RL$ ;  $R = PL/TL$ ;  $M = (P+R+A+B+C)/5$ ;  $W = (B+C)/2$ ;  $L = (P+R)/2$ ; e  $W - L$ .

### *Age estimation using ML*

Left central incisors and canines were analyzed using ML regression algorithms with three attribute extraction approaches: radiomic, semantic and the association of radiomic and semantic features. The radiomic attributes were extracted from the images with classical computer vision techniques. The tooth and pulp cavity linear measurements were used for semantic attribute extraction.

The partitioning of the training set and validation set (testing set) was performed in the proportion 85/15, with 85% of the sample for training and 15% for testing, due to the small sample size. During the training set, the assessment of the algorithms of choice was done to determine which of them performed better on age estimation. The best algorithms for each attribute extraction approach were used to assess the teste set.


#### *Extraction of semantic attributes*

The Kvaal method measurements and proportions per assessed tooth (21 and 23) and gender data were extracted and the following set of attributes were used: “SEX”, “TL\_21”, “PL\_21”, “RL\_21”, “RWA\_21”, ”RWB\_21”, “RWC\_21”, “PWA\_21”, “PWB\_21”, “PWC\_21”, “TL\_23”, “PL\_23”, “RL\_23”, “RWA\_23”, “RWB\_23”, “RWC\_23”, “PWA\_23”, “PWB\_23” and “PWC\_23”. This extraction process generated a dataset with 554 samples in a tabular structure, with each sample containing 19 attributes.

#### *Extraction of radiomic attributes*

The vector of attributes construction of each image was done initially with the segmentation of the ROI. For the definition of the ROI, manual segmentation of the teeth and pulp chamber was performed manually by two calibrated observers who were also unaware of the participants' gender and age.

The panoramic radiographs were imported into another software, the GNU Image Manipulation Program (GIMP® 2.10.32). Approximately 20 points were marked for the delimitation of the teeth and pulp cavities for segmentation (Figure 2).



**Figure 2** - Segmentation of tooth 21 and its segmented pulp chamber.

For each patient, the following seven texture attributes were extracted from both assessed teeth: contrast, correlation, energy (second angular momentum), homogeneity, entropy, mean and deviation. Thus, the following set of attributes were extracted for each patient: “CONTRAST\_21”, “CORRELATION\_21”, “ENERGY\_21”, “HOMOGENEITY\_21”, “ENTROPY\_21”, “MEAN\_21”, “DEVIATION\_21”, “CONTRAST\_23”, “CORRELATION\_23”, “ENERGY\_23”, “HOMOGENEITY\_23”, “ENTROPY\_23”, “MEAN\_23” and “DEVIATION\_23”.

It is important to point out that the database of segmented pulp cavities generated inferior results, therefore; models were not able to extract enough information to characterize age patterns from the segmented pulp chambers. Only the database of segmented teeth was considered in this study, hence; a dataset containing 554 samples was created, in which each sample presented 14 attributes.

#### *Semantic-radiomic attribute extraction*

To verify if the association of radiomic and semantic attributes could improve age estimation, another dataset was created associating both attribute extraction methods. This

dataset contained 554 samples and 33 attributes: “SEX”, “TL\_21”, “PL\_21”, “RL\_21”, “RWA\_21”, “RWB\_21”, “RWC\_21”, “PWA\_21”, “PWB\_21”, “PWC\_21”, “TL\_23”, “PL\_23”, “RL\_23”, “RWA\_23”, “RWB\_23”, “RWC\_23”, “PWA\_23”, “PWB\_23”, “PWC\_23”, “CONTRAST\_21”, “CORRELATION\_21”, “ENERGY\_21”, “HOMOGENEITY\_21”, “ENTROPY\_21”, “MEAN\_21”, “DEVIATION\_21”, “CONTRAST\_23”, “CORRELATION\_23”, “ENERGY\_23”, “HOMOGENEITY\_23”, “ENTROPY\_23”, “MEAN\_23” and “DEVIATION\_23”.

#### *Regression algorithms used by machine learning for age estimation*

The following supervised machine learning regression algorithms were tested: *Logistic Regression, Linear Regression, K-Nearest Neighbors (KNN), Support Vector Regression (SVR), Decision Tree Reg, Random Forest Reg, Gradient Boost Reg e XG Boosting Reg.*

#### ***Statistical analysis***

IBM SPSS 20.0 software (IBM® SPSS® Statistics, Armonk, NY, EUA) was used to perform the statistical analysis of the Kvaal method. The Mann-Whitney test was applied to compare genders, while Spearman correlation coefficient and the specific t-Student test were used to assess the degree of relationship between two numerical variables.

In order to analyze data variability in age estimation, multiple linear regressions were applied. The coefficient of determination ( $R^2$ ) represents the percentage of data variance that is explained by the model. The higher the value of  $R^2$ , the more explanatory the model is in relation to the predicted data. To verify the level of agreement between the real values and those estimated by the regressions, for each tooth, the correlation coefficient of agreement and the respective confidence interval were obtained. The level of significance established in the statistical tests was 5%. The vast majority of studies that applied the Kvaal method used the Standard Error of Estimation (SEE) to assess the precision obtained by the age estimate;<sup>22</sup> therefore, this metric was also used in the present study.

To analyze the statistical results of the machine learning algorithms, the Mean Absolute Error (MAE) was applied, defined as an average value of the absolute differences between predicted age and real age. It is the standard measure for age prediction errors. A low MAE means that the estimated age is close to the real age, therefore; a reasonable age estimation. On the other hand, a high MAE value indicates inaccurate results.<sup>23</sup> The Mean Absolute Error (MAE) of the Kvaal method was also calculated for posterior comparison with ML findings.

## RESULTS

### *Age estimation using the Kvaal method*

The age of the participants ranged from 13 to 57 years (mean: 24.96). Mean measurements for teeth 21 and 23 were higher in male participants than in female participants ( $p < 0,05$ ).

Table 1 shows the values of the correlations between the variables used in the Kvaal method and age. The variable W presented the highest correlation with age for both assessed teeth in the studied sample.

**Table 1** - Spearman correlations between age and the studied variables for tooth 21 and tooth 23.

<b>Variable</b>	<b>Tooth 21</b>	<b>Tooth 23</b>
Tooth Length (TL)	- 0.163 (<0.001) *	- 0.132 (0.002) *
Pulp Length (PL)	- 0.172 (<0.001) *	- 0.026 (0.540)
Root Length (RL)	- 0.090 (0.035) *	- 0.050 (0.237)
Root Width A (RWA)	- 0.062 (0.142)	- 0.087 (0.041) *
Root Width B (RWB)	- 0.070 (0.099)	- 0.060 (0.155)
Root Width C (RWC)	- 0.075 (0.078)	- 0.061 (0.153)
Pulp Width A (PWA)	- 0.313 (<0.001) *	- 0.339 (<0.001) *
Pulp Width B (PWB)	- 0.436 (<0.001) *	- 0.416 (<0.001) *
Pulp Width C (PWC)	- 0.461 (<0.001) *	- 0.455 (<0.001) *
TL/ RL (T)	- 0.043 (0.315)	- 0.152 (<0.001) *
PL/RL (P)	- 0.150 (<0.001) *	0.065 (0.125)
PL/TL (R)	- 0.101 (0.017) *	0,223 (<0.001) *
PWA/RWA (A)	- 0.374 (<0.001) *	- 0.370 (<0.001) *
PWB/RWB (B)	- 0.499 (<0.001) *	- 0.471 (<0.001) *
PWC/RWC (C)	- 0.516 (<0.001) *	- 0.495 (<0.001) *

M	- 0.449 (<0.001) *	- 0.366 (<0.001) *
W	- 0.548 (<0.001) *	- 0.522 (<0.001) *
L	0.132 (0.002) *	0.137 (0.001) *
W - L	- 0.250 (<0.001) *	- 0.484 (<0.001) *

---

(\*) Statistically different from zero at the level of 5%.


Table 2 shows the SEE and the regression equation results for age, confirming that the central incisor performs better on age estimation than the canine ( $> R^2$  and  $< SEE$ ). In the initial regression, all variables that presented significant correlations up to 5% were included and the ones that presented 10% significance were maintained ( $p < 0.10$ ) by the stepwise process. For tooth 21 the variables TL, RL, TL/RL, RWA, PWA and W were assessed, which presented a 5% significance, except for the constant. For tooth 23, TL, TL/PL, M and W were assessed, which were all 5% significant, except for the constant.

**Table 2** - Regression equations for the age variable with coefficients of determination and standard error estimate per tooth


Tooth	Equation	R <sup>2</sup>	Significant predictor (5%)	Standard Error of Estimate
21	Age <sub>est</sub> = - 50.764 - 5.205.TL + 7.251.RL + 59.546.(TL/RL) + 2.203.RWA - 2.160.PWA - 101.512.W	0.335	All, except the constant	7.108
23	Age <sub>est</sub> = 25.947 - 0.467.CD + 71.105.(CP/CD) - 75.433.M - 54.609.W	0.279	All, except the constant	7.388

Figures 3 and 4 show the dispersion of real and estimated age. 56% and 57.4% of the participants presented overestimated age (estimated age greater than the real age) for the incisors

and canines, respectively. The rest of the sample corresponded to underestimated values (estimated age lower than the real age).



**Figure 3** - Real and estimated age dispersion for tooth 21.



**Figure 4** - Real and estimated age dispersion for tooth 23.



Table 3 shows the regression results for the age variable between genders and the total sample including the MAE and the SEE. Male patients achieved the best results in terms of age estimation ( $< \text{MAE}$  and  $< \text{SEE}$ ), but the regression model for this gender was not able to explain the variability of the data ( $< R^2$ ).

**Table 3** - Regression equations for the age variable in the total group and by gender.

Gender	Equation	R <sup>2</sup>	Significant Predictors	MAE	SEE
Male	Age <sub>est</sub> = 45.931 - 0.936.TL + 0.902.RL + 13.031.PWA - 5.873.PWB - 9.44.LPC - 91.329.LPA/LRA	0.276	All	5.29	6.96
Female	Age <sub>est</sub> = 110.559 - 4.937.TL + 5.572.PL + 1.397.RWA + 26.689.(TL/RL) + 38,136.(PWA/RWA) - 259,321.M	0.317	All	5.69	7.37
Total	Age <sub>est</sub> = 102.371 - 4.241.TL + 4.218.PL + 1.197.RWA + 23.18.(TL/RL) + 33.19.(PWA/RWA) - 233.262.M	0.301	All	5.68	7.27

The correlation coefficient of agreement and the respective 95% confidence interval between the real and estimated ages were: 0.502 (0.450 to 0.552) for tooth 21 and 0.447 (0.383 to 0.488) for tooth 23.

### *Age estimation results using ML*

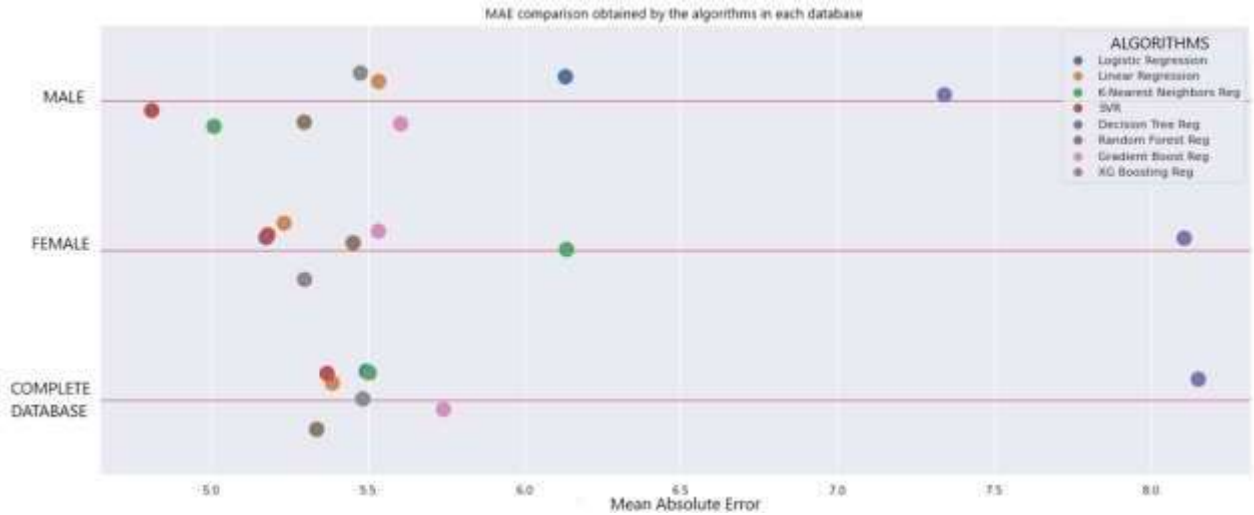
Regression classifier algorithms were applied to the training group and those that showed superior performance were used to predict the ages with the test group.

### *Training group*

#### *Semantic attribute extraction*

Figure 5 shows the performance of the regression classifier algorithms used in the semantic attribute extraction of the training group. For the male patient's database, SVR showed the best result (MAE: 4.81); while Logistic Regression presented the best results for the female

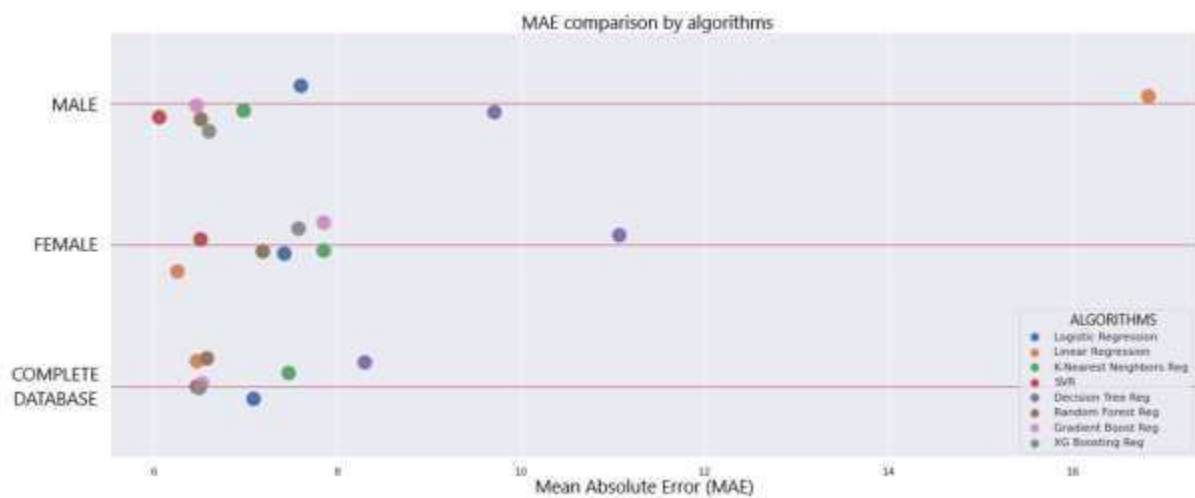
database (MAE of 5.17 years). When assessing the whole database, the Random Forest Reg indicator performed better than the other studied algorithms (MAE: 5.33 years).



**Figure 5** - Comparison of the Mean Absolute Error (MAE) obtained by the studied algorithms for the male, female and complete database using the semantic attribute extraction.

#### *Radiomics attribute extraction*

Figure 6 shows the performance of the regression algorithms used in the radiomics attribute extraction. For the male database, SVR showed the best result (MAE: 6.06 years), while for the female database, the Linear Regression classifier showed a lower degree of error (MAE= 6.26 years). When assessing the complete database, five algorithms had similar performance, but the Linear Regression presented the best result (MAE= 6.47 years).

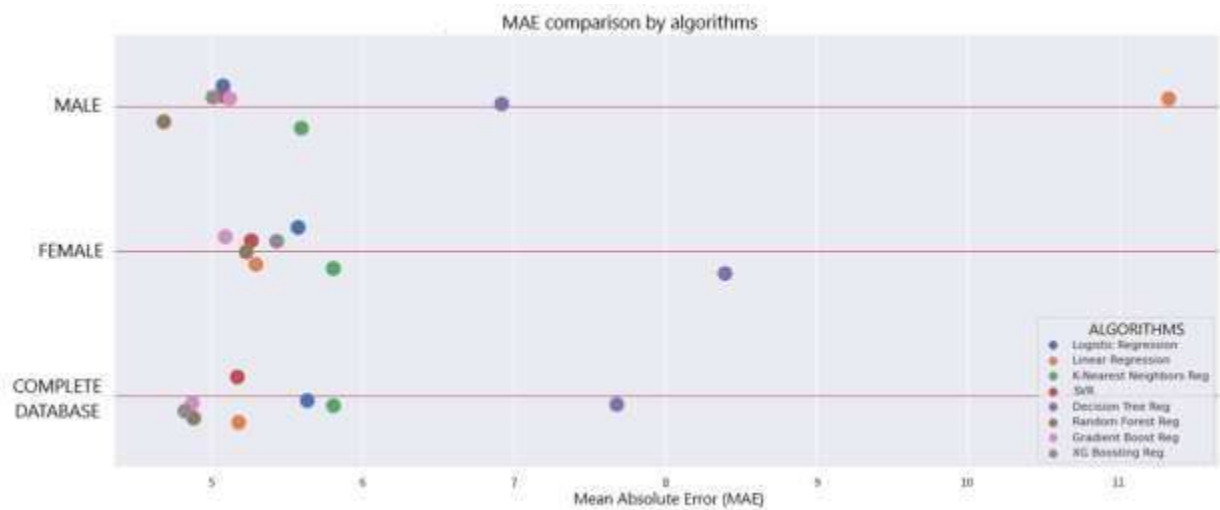


**Figure 6** - Comparison of the Mean Absolute Error (MAE) obtained by the studied algorithms for male, female and the complete database using the radiomic attribute extraction.

### Semantic-radiomic attribute extraction

In an attempt to increase the ability to estimate age during algorithm training, the semantic and radiomic approaches were associated.

Figure 7 shows the behavior of the regression classifiers when estimating age with the semantic-radiomic attribute extraction approach. For the male database, Random Forest Reg showed the best result (MAE: 4.90 years), while Gradient Boost Reg performed better for the female database (MAE: 5.79 years). When considering the complete database, the XG Boosting Reg algorithm presented the best performance (MAE= 4.64 years).



**Figure 7** - Comparison of the Mean Absolute Error (MAE) obtained by the studied algorithms for the male, female and the complete database using the radiomics-semantic associated approach.

The algorithms that presented the best performances during training according to their databases were selected for the testing phase (Table 4).

**Table 4** - Regression algorithms selected according to its performance for each database during the training phase.

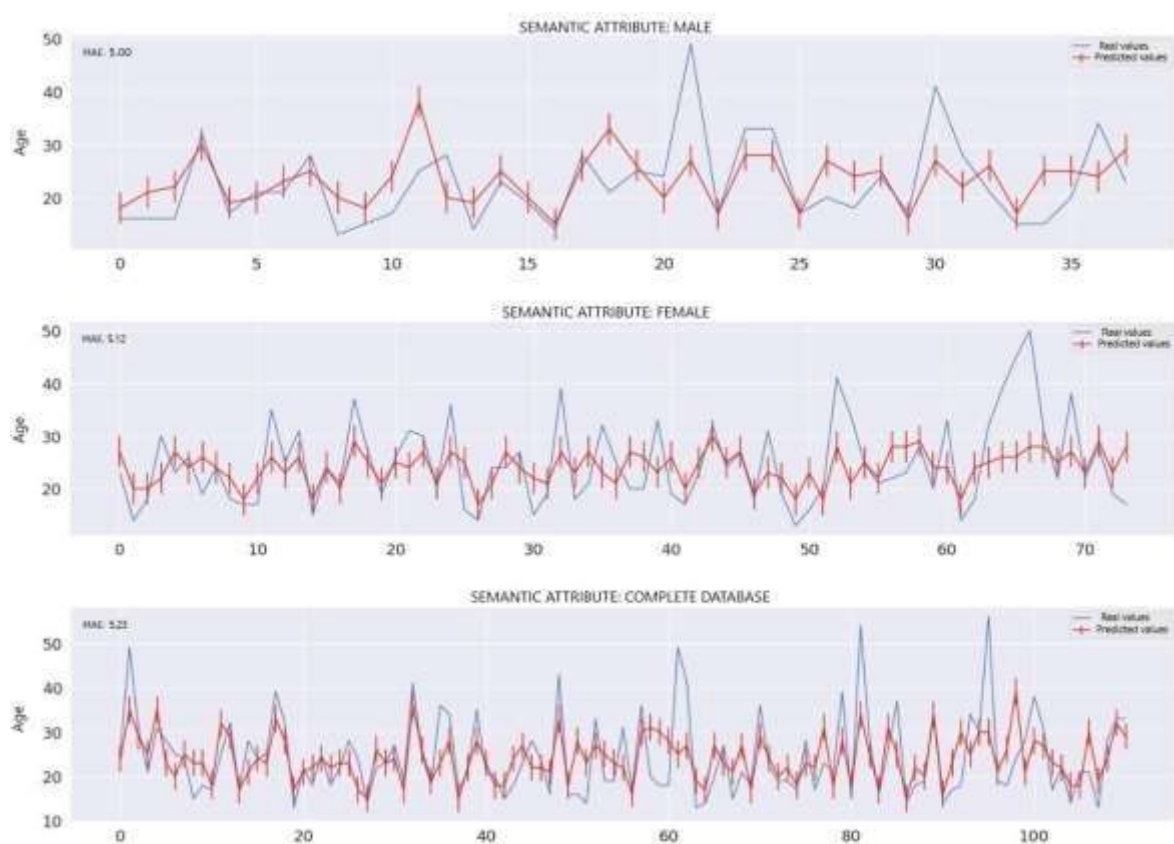
	Semantic	Radiomic	Semantic-radiomic
<b>Female</b>	<i>Logistic Regression</i>	<i>Linear Regression</i>	<i>Gradient Boost Reg</i>
<b>Male</b>	<i>SVR</i>	<i>SVR</i>	<i>Random Forest Reg</i>
<b>Total database</b>	<i>Random Forest Reg</i>	<i>Linear Regression</i>	<i>XG Boosting Reg</i>

## *Test group*

### *Semantic attribute extraction*

The test group consisted of 110 participants, 73 female and 37 male patients. In general, all databases estimated ages with a MAE of 5 years, the highlight was the male test group that obtained a slightly higher accuracy than the other groups.

Figure 8 shows the comparison between the real age and the age predicted by the algorithms in the semantic attribute extraction approach.

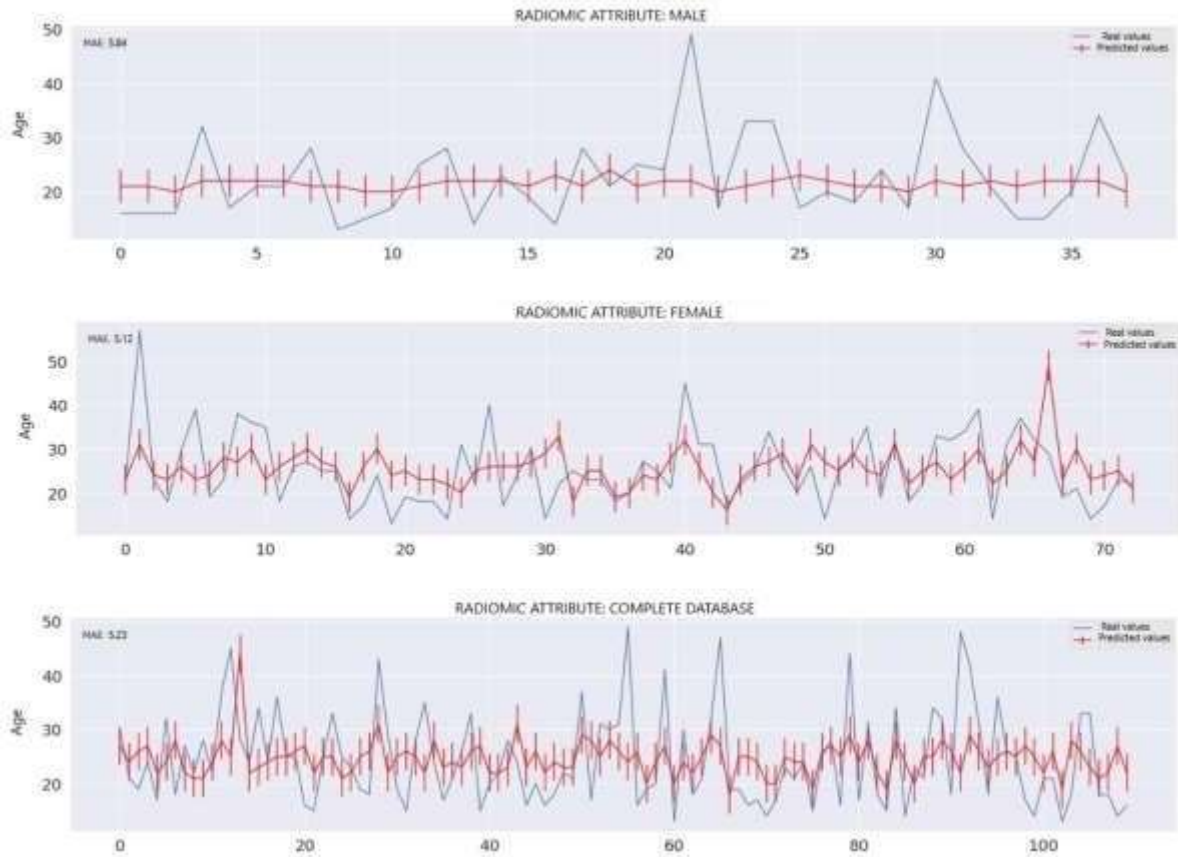


**Figure 8** - Comparison between real age (blue line) and estimated age (red line) for the test group using the semantic approach for the male database, female database and complete database.

### *Radiomic attribute extraction*

Figure 9 shows the comparison between the real age and the age predicted by the classifiers with the radiomic attribute extraction approach. In general, all databases estimated ages with a MAE of 5 years, with the female database achieving a subtly better prediction than


the other databases, but a lower overall performance when compared to the performance of the semantic approach.



**Figure 9** - Comparison between real age (blue line) and estimated age (red line) in the radiomic approach for the male database, female database and complete database.

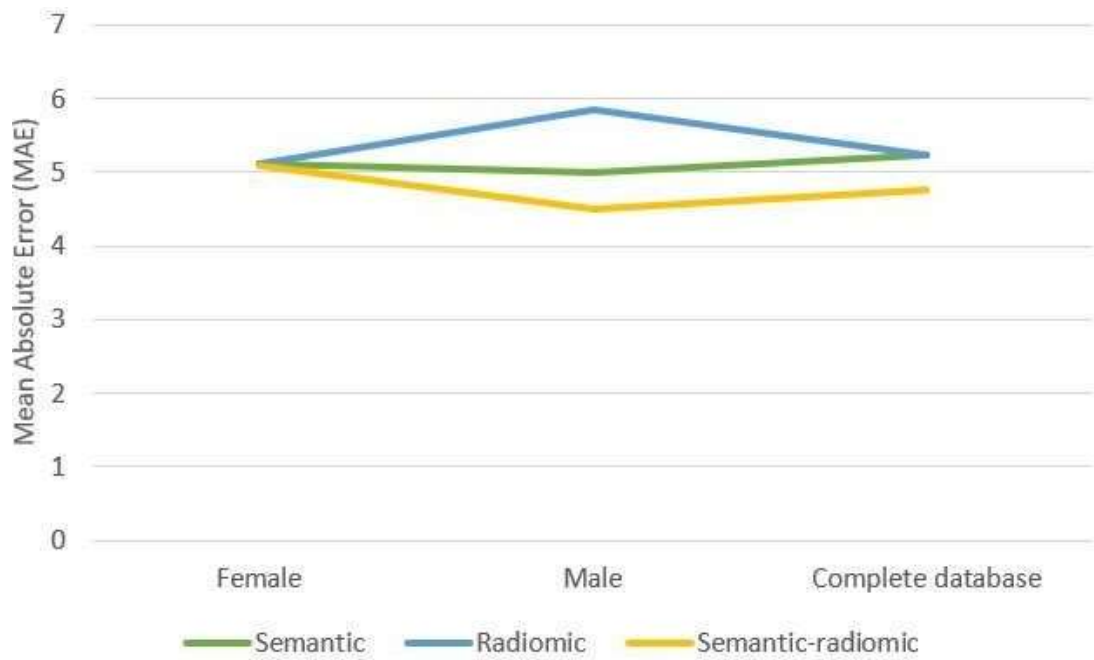
#### *Semantic-radiomic attribute extraction*

Figures 10 shows the comparison between the real age and the estimated age predicted by the classifiers using the semantic-radiomic attribute extraction approach. The male database achieved a slightly better age prediction than the total database.



**Figure 10** - Comparison between real age (blue line) and estimated age (red line) obtained using the semantic-radiomic approach for the male database, female database and complete database.

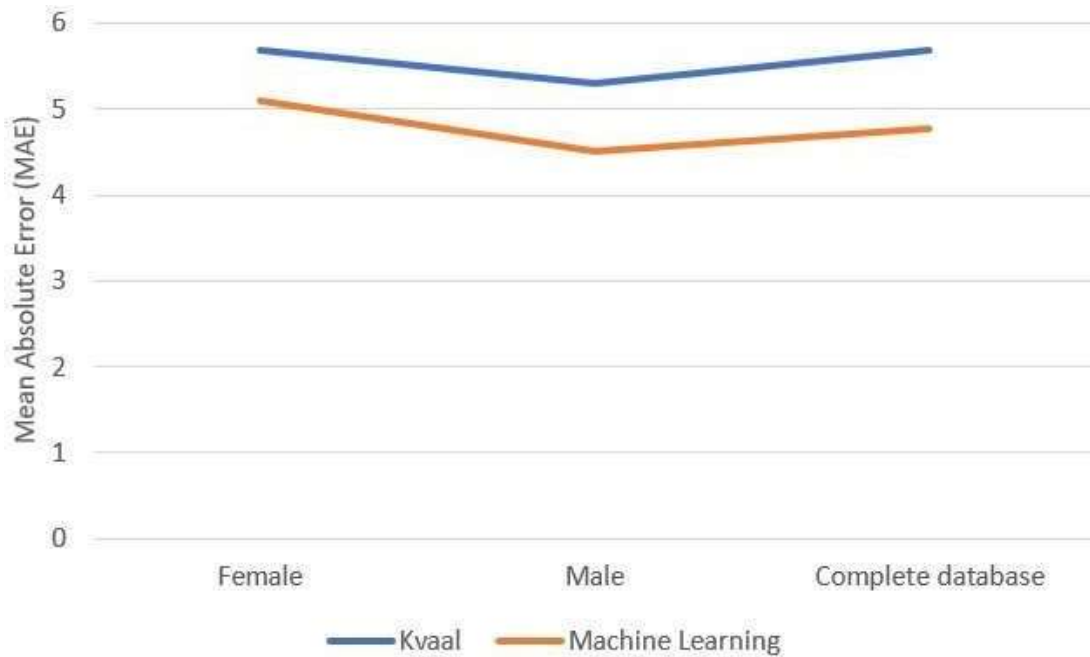
Figure 11 shows the comparison between the performance of the semantic, radiomic and the association of semantic and radiomic attribute extraction approaches. The three approaches showed similar age estimation performance for the female database. The semantic and radiomic methods presented equal performances when estimating age on the complete database; while, the association of the semantic and radiomic attributes showed the best overall age estimation performance.



**Figure 11** - Comparison of semantic, radiomic and semantic-radiomic ML attribute extraction methods performance on age estimation for both genders and the complete database.

#### *Comparison of age estimation between the Kvaal method and ML*

Figure 12 shows the age estimation comparison between the Kvaal method and the assessed ML approaches. For this comparison, the MAE value of the semantic-radiomic association was used to represent the ML performance. Kvaal's method and ML performed better for the male database and ML performed better than the Kvaal method with a difference of approximately 1 year for all studied scenarios.



**Figure 12** - Comparison between Kvaal's method and ML for age estimation.

## DISCUSSION

This study assessed Kvaal's age estimation method with different machine learning attribute extraction approaches and algorithms on a Brazilian northeastern population using digital panoramic radiographs and found promising results for the semantic-radiomic association attribute extraction approach and the XG Boosting Reg classifier.

In Kvaal's original proposal<sup>8</sup>, six teeth were measured using the same methodology described in this study; however, only the maxillary central incisor and the maxillary canine were used for age assessment in the present study. The incisors and canines were assessed based on their prevalence on the arch of patients of different ages, larger pulp cavities, simpler root morphology and less susceptibility to the effects of diet when compared to posterior teeth (Andrade et al. 2021).<sup>24</sup> The assessment of only one central incisor and one maxillary canine can be justified by Kvaal et al. (1995)<sup>8</sup> study which found that when comparing measurements from teeth positioned on opposite sides of the arch, no significant differences were found.

In previous studies,<sup>12,25</sup> the W variable of the Kvaal method presented a stronger correlation with the chronological age for anterior teeth, as well as for the upper canine, in agreement with this study which also showed a high correlation between W and chronological age for the maxillary left central incisor (-0.548) and the maxillary left canine (-0.522). The



investigation of the estimation of dental age from the third decade of life is based on the regressive period. At this stage, the teeth reach the completion of their formation and age-related regressive changes are evaluated. These methods are considered less accurate when compared to the stages of tooth development and use parameters partially influenced by function (physiological) and also pathological, such as loss of fixation in the alveolus, presence of dental attrition and other types of wear, as well as deposition of secondary dentin in root canals.<sup>8,26-28</sup>

There is a methodological variability in the literature when assessing the precision of different methods of age estimation on radiographic images, but the majority of the studies use the SEE to assess data. The smaller the SEE of a method of age estimation, more accurate is the method.<sup>22</sup> In this study, the SEE of the maxillary incisor was 7.10 years, similar to the SEE found by Alharbi et al. (2022)<sup>29</sup> which was 7.26 years for the central incisors. However, these authors used the six teeth proposed by the original Kvaal method to estimate the age of a Saudi population and when the SEE was calculated for all teeth, there was an increase of 1.10 years to its value. Although the difference in results can be associated to the choice of teeth used to assess age, this difference can be also associated to the different populations assessed on both studies.

Different populations may present different estimated age ranges. When applying the Kvaal method on panoramic radiographs on a chinese population, Li et al. (2020)<sup>25</sup> found that the upper left canine had the highest SEE (11 years), while Roh et al. 2018 obtained similar SEE value (11.9 years) for a korean population for the central incisors.<sup>30</sup> This study presented lower SEE values than the previously cited studies, 7.38 years for the left canine and 7.27 years for both teeth, thus this method showed higher precision for the studied population.

The coefficient of determination ( $R^2$ ) measures how well the statistical model predicts the outcome. The  $R^2$  of the central incisor in this study was higher than previous studies, which presented lower sample sizes (Manzoor et al., 2021, Zdravkoic et al., 2022), which may indicate that a higher sample size may improve  $R^2$  values.<sup>31,32</sup> However, a previous study<sup>29</sup> obtained a highly significant  $R^2$  (0.648) in an arabian population, which strengthens the hypothesis that different demographic groups may have individual dental characteristics that can improve or impair the accuracy of the age estimation method. Although the central incisors presented higher  $R^2$  than previous studies, the canine presented lower  $R^2$  values than the central incisor, in accordance with Li et al. (2020)<sup>25</sup>

In the present study, more than half of the sample overestimated the predicted age, differing from Pires, Santos and Pereira (2021) study.<sup>33</sup> The referred authors found that the

estimates obtained by linear regression tend to underestimate age for young age groups and overestimate age for older age groups. The population of the present study was considered to be composed of a young patients and a possible explanation for this divergent result may be related to the small sample size or ethnic factors.<sup>34</sup>

Regarding ML, to quantify its predictive performance, studies<sup>20,34</sup> usually calculate the MAE of the different classifier algorithms assessed. The lower the MAE, the more accurate is the ML approach to age estimation. In this study the XG Boosting Reg algorithm showed the best performance with a MAE value of 4.77 years. Mu & Li (2022)<sup>34</sup> assessed the accuracy of transfer learning models for age estimation from 3,000 panoramic radiographs of young patients and, using the ResNet, EfficientNet, VggNet and DenseNet classifiers, found that EfficientNet achieved the best age estimative presenting a MAE of 2.83 years. Therefore, ML classifiers should be tested using larger sample sizes and different attribute extraction methods to improve age estimation assessments for adult patients.

This study may be one of the first to assess and compare the Kvaal method using ML on panoramic radiographs. Farhadian et al. (2019)<sup>35</sup> explored convolutional neuro networks (CNN) to assess pulp-tooth relationship of canines to assess age on 300 CBCTs of individuals aged between 14 and 60 years, and found MAE values of 4.12 years, similar to the ones found in this study using rather simpler ML classifiers. CNNs usually need a large sample size for learning and to achieve a better performance and even then, it may not guarantee more accurate results. Farhadian et al. (2019)<sup>35</sup> suggested additional investigations assessing different teeth and other CBCT acquisition parameters, reinforcing the need to reassess the methodology on a larger sample size, considering different ethnicities and age groups.

Although a previous study<sup>36</sup> has stated that gender does not influence age estimation when using classical radiographic methods, when using ML classifiers to assess age according to gender, the Kvaal method and ML presented higher precision for male patients and ML classifiers performed differently for each gender group. In this study, ML classifiers performed better than the classical Kvaal method even using a simple learning model without the application of neural networks, in agreement with recent studies that state AI presents superior performance in age prediction when compared to the radiographic reference method.

The major limitation of the present study was the small sample size which also made the use of CNNs impossible. The small sample size and the fact that the population was not perfectly divided between the different age groups may have compromised the variability of the data. However, instead on only focusing on the radiomic attribute extraction, this study used

the semantic attribute extraction approach which added information to the Kvaal method and improved the overall ML age estimation.

## CONCLUSION

ML classifiers can improve age estimation when assessing panoramic radiography using the Kvaal method. The semantic-radiomic attribute extraction approach should be chosen when estimating age. The XG Boosting Reg classifier showed promising performance; therefore, should be tested with larger samples and diverse populations for age estimation.

## REFERENCES

1. Ekizoglu O, Inci E, Ors S, et al. Applicability of T1-weighted MRI in the assessment of forensic age based on the epiphyseal closure of the humeral head. *Int J Legal Med* 2019; 133: 241–248.
2. Fernandes PO, Reis LG, Devito KL, et al. Aplicação e ajuste da fórmula proposta por Cameriere para uma amostra brasileira: estudo piloto. *Rev Bras Odontol Leg RBOL* 2018; 5: 20–27.
3. Gannepalli A, Balla S, Pacha V, et al. Applicability of Cameriere European formula for age estimation of 10–15 years legal threshold in South Indian population. *J Forensic Dent Sci* 2019; 11: 78.
4. Azevedo A de CS, Alves NZ, Michel-Crosato E, et al. Dental age estimation in a Brazilian adult population using Cameriere's method. *Braz Oral Res* 2015; 29: 1–9.
5. Nair VV, Thomas S, Thomas J, et al. Comparison of Cameriere's and Demirjian's Methods of Age Estimation among Children in Kerala: A Pilot Study. *Clin Pract* 2018; 8: 991.
6. Gadelha MNV, Lima JCA de, Ribeiro ILA, et al. Aplicabilidade do volume da câmara pulpar para a estimativa de idade em adultos a partir de tomografias computadorizadas de feixe cônico: um estudo piloto. *Revista Brasileira de Odontologia Legal* 2019; 6: 30–39.
7. Ge Z pu, Yang P, Li G, et al. Age estimation based on pulp cavity/chamber volume of 13 types of tooth from cone beam computed tomography images. *Int J Legal Med* 2016; 130: 1159–1167.
8. Kvaal SI, Kolltveit KM, Thomsen IO, et al. Age estimation of adults from dental radiographs. *Forensic Sci Int* 1995; 74: 175–185.
9. Haghanifar S, Ghobadi F, Vahdani N, et al. Age estimation by pulp/tooth area ratio in anterior teeth using cone-beam computed tomography: Comparison of four teeth. *Journal of Applied Oral Science*; 27. Epub ahead of print 2019. DOI: 10.1590/1678-7757-2018-0722.

10. Bardal R, Soltani M. Age estimation by pulp/tooth area and width ratios in panoramic images of upper and lower canines among the Iranian population. *Braz Dent Sci*; 24. Epub ahead of print 2021. DOI: 10.14295/bds.2021.v24i4.2466.
11. Miranda JC de, Azevedo A de CS, Rocha M, et al. Age estimation in Brazilian adults by Kvaal's and Cameriere's methods. *Braz Oral Res*; 34. Epub ahead of print 2020. DOI: 10.1590/1807-3107BOR-2020.VOL34.0051.
12. Karkhanis S, Mack P, Franklin D. Age estimation standards for a Western Australian population using the dental age estimation technique developed by Kvaal et al. *Forensic Sci Int* 2014; 235: 104.e1-104.e6.
13. Kazmi S, Mânica S, Revie G, et al. Age estimation using canine pulp volumes in adults: a CBCT image analysis. *Int J Legal Med* 2019; 133: 1967–1976.
14. Vila-Blanco N, Carreira MJ, Varas-Quintana P, et al. Deep Neural Networks for Chronological Age Estimation from OPG Images. *IEEE Trans Med Imaging* 2020; 39: 2374–2384.
15. Kim S, Lee YH, Noh YK, et al. Age-group determination of living individuals using first molar images based on artificial intelligence. *Sci Rep*; 11. Epub ahead of print 1 December 2021. DOI: 10.1038/s41598-020-80182-8.
16. Santosh KC, Pradeep N, Goel V, et al. Machine Learning Techniques for Human Age and Gender Identification Based on Teeth X-Ray Images. *J Healthc Eng*; 2022. Epub ahead of print 2022. DOI: 10.1155/2022/8302674.
17. Guo Y cheng, 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: 1589–1597.
18. Saric R, Kevric J, Hadziabdic N, et al. Dental age assessment based on CBCT images using machine learning algorithms. *Forensic Sci Int*; 334. Epub ahead of print 1 May 2022. DOI: 10.1016/j.forsciint.2022.111245.
19. Shen S, Liu Z, Wang J, et al. Machine learning assisted Cameriere method for dental age estimation. *BMC Oral Health*; 21. Epub ahead of print 1 December 2021. DOI: 10.1186/s12903-021-01996-0.
20. Galibourg A, Cussat-Blanc S, Dumoncel J, et al. Comparison of different machine learning approaches to predict dental age using Demirjian's staging approach. *Int J Legal Med* 2021; 135: 665–675.
21. Boedi RM, Banar N, de Tobel J, et al. Effect of lower third molar segmentations on automated tooth development staging using a convolutional neural network. *J Forensic Sci* 2020; 65: 481–486.
22. Marroquin TY, Karkhanis S, Kvaal SI, et al. Age estimation in adults by dental imaging assessment systematic review. *Forensic Sci Int* 2017; 275: 203–211.
23. Gröbl T, Lallie S. Applying Artificial Intelligence for Age Estimation in Digital Forensic Investigations. *International journal of environmental research and public health*.

24. Moreira Andrade V, Uenoyama Dezem T, Breda de Souza AC, et al. Three-Dimensional Radiological Methods for Age Estimation in Adults by Using the Pulp/Tooth Relation: an Integrative Review. *Brazilian Journal of Forensic Sciences, Medical Law and Bioethics* 2021; 10: 97–110.
25. Li M, Zhao J, Chen W, et al. Can canines alone be used for age estimation in Chinese individuals when applying the Kvaal method? *Forensic Sci Res*. Epub ahead of print 2020. DOI: 10.1080/20961790.2020.1717029.
26. GUSTAFSON G. Age determination on teeth. *J Am Dent Assoc* 1950; 41: 45–54.
27. Lavez GP, Terada ASSD, Dezem TU, et al. Age estimation using Olze's method in an adult Brazilian population. *J Forensic Leg Med* 2017; 52: 241–244.
28. Timme M, Timme WH, Olze A, et al. Dental age estimation in the living after completion of third molar mineralization: new data for Gustafson's criteria. *Int J Legal Med* 2017; 131: 569–577.
29. Alharbi HS, Alharbi AM, Alenazi AO, et al. Age Estimation by Kvaal's Method Using Digital Panoramic Radiographs in the Saudi Population. *Cureus*. Epub ahead of print 2 April 2022. DOI: 10.7759/cureus.23768.
30. Roh B yoon, Lee WJ, Ryu JW, et al. The application of the Kvaal method to estimate the age of live Korean subjects using digital panoramic radiographs. *Int J Legal Med* 2018; 132: 1161–1166.
31. Manzoor A, Maini V, Manzoor W. Forensic age assessment using Kvaal's method with digital orthopantomographs (OPG) and comparison with the actual age of the subjects. *Asian J Med Sci* 2021; 12: 142–146.
32. Zdravkovic D, Jovanovic M, Papic M, et al. Application of the Kvaal Method in Age Estimation of the Serbian Population Based on Dental Radiographs. *Diagnostics*; 12. Epub ahead of print 1 April 2022. DOI: 10.3390/diagnostics12040911.
33. Pires AC, Santos RFV de S, Pereira CP. Dental age assessment by the pulp/tooth area proportion in cone beam computed tomography: is medico-legal application for age estimation reliable? *Journal of Forensic Odonto-Stomatology* 2021; 39: 2–14.
34. Mu CC, Li G. Age Estimation using Panoramic Radiographs by Transfer Learning. *Chin J Dent Res* 2022; 25: 119–124.
35. Farhadian M, Salemi F, Saati S, et al. Dental age estimation using the pulp-to-tooth ratio in canines by neural networks. *Imaging Sci Dent* 2019; 49: 19–26.
36. Vadla P, Surekha R, Rao GV, et al. Assessing the accuracy of Cameriere's Indian-specific formula for age estimation on right and left sides of orthopantomogram. *Egypt J Forensic Sci*; 10. Epub ahead of print 1 December 2020. DOI: 10.1186/s41935-020-00183-6.

## 6 CONSIDERAÇÕES FINAIS

- O método de Kvaal isolado é aplicável na população estudada com destaque para o incisivo superior que obteve maior precisão na estimativa das idades.
- As extrações de atributos radiômicos e semânticos obtiveram desempenhos semelhantes, mas ainda sim inferiores ao da concatenação.
- A concatenação dos atributos radiômicos e semânticos do aprendizado de máquina alcançou precisão mais elevada na estimativa das idades.
- O aprendizado de máquina apresentou maior precisão ao estimar as idades quando comparado ao método de Kvaal.

## REFERÊNCIAS

- ALHARBI, H. S. et al. Age Estimation by Kvaal's Method Using Digital Panoramic Radiographs in the Saudi Population. **Cureus**, 2 abr. 2022.
- AZEVEDO, A. DE C. S. et al. Dental age estimation in a Brazilian adult population using Cameriere's method. **Brazilian Oral Research**, v. 29, n. 1, p. 1–9, 2015.
- BARDAL, R.; SOLTANI, M. Age estimation by pulp/tooth area and width ratios in panoramic images of upper and lower canines among the Iranian population. **Brazilian Dental Science**, v. 24, n. 4, 2021.
- BOEDI, R. M. et al. Effect of lower third molar segmentations on automated tooth development staging using a convolutional neural network. **Journal of Forensic Sciences**, v. 65, n. 2, p. 481–486, 1 mar. 2020.
- BORSTELMANN, S. M. **Machine Learning Principles for Radiology Investigators**. Academic Radiology Elsevier USA, , 1 jan. 2020.
- CHURPEK, M. M. et al. Multicenter Comparison of Machine Learning Methods and Conventional Regression for Predicting Clinical Deterioration on the Wards. **Critical Care Medicine**. *Anais*. Lippincott Williams and Wilkins, 1 fev. 2016.
- COROLLER, T. P. et al. Radiographic prediction of meningioma grade by semantic and radiomic features. **PLoS ONE**, v. 12, n. 11, 1 nov. 2017.
- DALESSANDRI, D. et al. 2D vs. 3D radiological methods for dental age determination around 18 years: A systematic review. **Applied Sciences (Switzerland)** MDPI AG, , 1 maio 2020.
- DOUPE, P.; FAGHMOUS, J.; BASU, S. Machine Learning for Health Services Researchers. **Value in Health**, v. 22, n. 7, p. 808–815, 1 jul. 2019.
- FERNANDES, P. O. et al. Aplicação e ajuste da fórmula proposta por Cameriere para uma amostra brasileira: estudo piloto. **Rev Bras Odontol Leg RBOL**, v. 5, n. 2, p. 20–27, 2018.
- FERREIRA JUNIOR, J. R. et al. Radiomic analysis of lung cancer for the assessment of patient prognosis and intratumor heterogeneity. **Radiologia Brasileira**, v. 54, n. 2, p. 87–93, 2021.
- GALIBOURG, A. et al. Comparison of different machine learning approaches to predict dental age using Demirjian's staging approach. **International Journal of Legal Medicine**, v. 135, n. 2, p. 665–675, 1 mar. 2021.
- GANNEPALLI, A. et al. Applicability of Cameriere European formula for age estimation of 10–15 years legal threshold in South Indian population. **Journal of Forensic Dental Sciences**, v. 11, n. 2, p. 78, 2019.
- GE, Z. PU et al. Age estimation based on pulp cavity/chamber volume of 13 types of tooth from cone beam computed tomography images. **International Journal of Legal Medicine**, v. 130, n. 4, p. 1159–1167, 1 jul. 2016.

- GOBBO, S. et al. Estimativa da idade dental pelo método de nicodemo em uma população da região sudeste do Brasil. **Revista Criminalística e Medicina Legal**, v. 06, n. 01, p. 10–18, 2021.
- GRÜBL, T.; LALLIE, S. Applying Artificial Intelligence for Age Estimation in Digital Forensic Investigations. **International journal of environmental research and public health**, 2022.
- HAGHANIFAR, S. et al. Age estimation by pulp/tooth area ratio in anterior teeth using cone-beam computed tomography: Comparison of four teeth. **Journal of Applied Oral Science**, v. 27, 2019.
- HEO, M. S. et al. Dmfr 50th anniversary: Review article artificial intelligence in oral and maxillofacial radiology: What is currently possible? **Dentomaxillofacial Radiology**, 2020.
- HIRAIWA, T. et al. A deep-learning artificial intelligence system for assessment of root morphology of the mandibular first molar on panoramic radiography. **Dentomaxillofacial Radiology**, v. 48, n. 3, 2019.
- JANIESCH, C.; ZSCHECH, P.; HEINRICH, K. Machine learning and deep learning. **Electronic Markets**, v. 31, p. 685–695, 2021.
- KARKHANIS, S.; MACK, P.; FRANKLIN, D. Age estimation standards for a Western Australian population using the dental age estimation technique developed by Kvaal et al. **Forensic Science International**, v. 235, p. 104.e1-104.e6, 2014.
- KAZMI, S. et al. Age estimation using canine pulp volumes in adults: a CBCT image analysis. **International Journal of Legal Medicine**, v. 133, n. 6, p. 1967–1976, 1 nov. 2019.
- KHANAGAR, S. B. et al. Application and performance of artificial intelligence technology in forensic odontology – A systematic review. **Legal Medicine** Elsevier B.V., , 1 fev. 2021.
- KHEMCHANDANI, R.; GOYAL, K.; CHANDRA, S. TWSVR: Regression via Twin Support Vector Machine. **Neural Networks**, v. 74, p. 14–21, 1 fev. 2016.
- KHORATE, M. M.; DINKAR, A. D.; AHMED, J. Accuracy of age estimation methods from orthopantomograph in forensic odontology: A comparative study. **Forensic Science International**, v. 234, p. 184.e1-184.e8, 2014.
- KIM, S. et al. Age-group determination of living individuals using first molar images based on artificial intelligence. **Scientific Reports**, v. 11, n. 1, 1 dez. 2021.
- KOÇAK, B. et al. Radiomics with artificial intelligence: A practical guide for beginners. **Diagnostic and Interventional Radiology** AVES, , 1 nov. 2019.
- LEE, Y.-H. et al. Age group prediction with panoramic radiomorphometric parameters using machine learning algorithms. **Scientific Reports**, v. 12, n. 1, p. 11703, 9 dez. 2022.
- LIU, H.; LANG, B. **Machine learning and deep learning methods for intrusion detection systems: A survey**. **Applied Sciences (Switzerland)** MDPI AG, , 1 out. 2019.
- MAKKAD, R. et al. Reliability of panoramic radiography in chronological age estimation. **Journal of Forensic Dental Sciences**, v. 5, n. 2, p. 129, 2013.



- MARRENO-RAMOS, M. DEL C. et al. Estimation of the age majority through radiographic evaluation of the third molar maturation degree. **Oral Medicine and Pathology**, v. 25, n. 3, p. e359–e363, 1 maio 2020.
- MARROQUIN, T. Y. et al. Age estimation in adults by dental imaging assessment systematic review. **Forensic Science International**, v. 275, p. 203–211, 1 jun. 2017.
- MIRANDA, J. C. DE et al. Age estimation in Brazilian adults by Kvaal's and Cameriere's methods. **Brazilian Oral Research**, v. 34, 2020.
- MOHAMMAD, N. et al. Accuracy of advanced deep learning with tensorflow and keras for classifying teeth developmental stages in digital panoramic imaging. **BMC Medical Imaging**, v. 22, n. 1, 1 dez. 2022.
- MUÑOZ, A. et al. Sex and age at death estimation from the sternal end of the fourth rib. Does Íscan's method really work? **Legal Medicine**, v. 31, p. 24–29, 1 mar. 2018.
- NAGI, R. et al. Clinical applications and performance of intelligent systems in dental and maxillofacial radiology: A review. **Imaging Science in Dentistry**, v. 50, n. 2, p. 81–92, 1 jun. 2020.
- NEMSI, H. et al. Age assessment in canine and premolar by cervical axial sections of cone-beam computed tomography. **Legal Medicine**, v. 28, p. 31–36, 1 set. 2017.
- OSSOWSKA, A.; KUSIAK, A.; ŚWIETLIK, D. Artificial Intelligence in Dentistry—Narrative Review. **International Journal of Environmental Research and Public Health** MDPI, , 1 mar. 2022.
- RAMÍREZ-MEJÍA, D.; LEVERS, C.; MAS, J. F. Spatial patterns and determinants of avocado frontier dynamics in Mexico. **Regional Environmental Change**, v. 22, n. 1, 1 mar. 2022.
- SANTOS, M. K. et al. Artificial intelligence, machine learning, computer-aided diagnosis, and radiomics: Advances in imaging towards to precision medicine. **Radiologia Brasileira**, v. 52, n. 6, p. 387–396, 1 nov. 2019.
- SANTOSH, K. C. et al. Machine Learning Techniques for Human Age and Gender Identification Based on Teeth X-Ray Images. **Journal of Healthcare Engineering**, v. 2022, 2022.
- SHAN, T.; TAY, F. R.; GU, L. Application of Artificial Intelligence in Dentistry. **Journal of Dental Research** SAGE Publications Inc., , 1 mar. 2021.
- SHEN, S. et al. Machine learning assisted Cameriere method for dental age estimation. **BMC Oral Health**, v. 21, n. 1, 1 dez. 2021a.
- SHEN, S. et al. Machine learning assisted Cameriere method for dental age estimation. **BMC Oral Health**, v. 21, n. 1, 1 dez. 2021b.
- SUFRIYANA, H. et al. Comparison of multivariable logistic regression and other machine learning algorithms for prognostic prediction studies in pregnancy care: Systematic review and meta-analysis. **JMIR Medical Informatics** JMIR Publications Inc., , 1 nov. 2020.
- TAO, J. et al. Dental Age Estimation: A Machine Learning Perspective. **Advances in Intelligent Systems and Computing**. Springer Verlag, 2020.

VADLA, P. et al. Assessing the accuracy of Cameriere's Indian-specific formula for age estimation on right and left sides of orthopantomogram. **Egyptian Journal of Forensic Sciences**, v. 10, n. 1, 1 dez. 2020.

VILA-BLANCO, N. et al. Deep Neural Networks for Chronological Age Estimation from OPG Images. **IEEE Transactions on Medical Imaging**, v. 39, n. 7, p. 2374–2384, 1 jul. 2020.

YIP, S. S. F. et al. Associations between radiologist-defined semantic and automatically computed radiomic features in non-small cell lung cancer. **Scientific Reports**, v. 7, n. 1, 1 dez. 2017.

ZHAI, Q. et al. Effect of bimodal soil-water characteristic curve on the estimation of permeability function. **Engineering Geology**, v. 230, p. 142–151, 29 nov. 2017.

## APÊNDICE A - TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO

**(OBS: para o caso de pessoas maiores de 18 anos e que não estejam inseridas nas hipóteses de vulnerabilidade que impossibilitam o livre discernimento com autonomia para o exercício dos atos da vida civil).**

Pelo presente Termo de Consentimento Livre e Esclarecido eu, \_\_\_\_\_, em pleno exercício dos meus direitos me disponho a participar da Pesquisa “INTELIGÊNCIA ARTIFICIAL COMO MÉTODO AUXILIAR NA ESTIMATIVA DE IDADE EM RADIOGRAFIA PANORÂMICA”.

Declaro ser esclarecido e estar de acordo com os seguintes pontos:

O estudo “INTELIGÊNCIA ARTIFICIAL COMO MÉTODO AUXILIAR NA ESTIMATIVA DE IDADE EM RADIOGRAFIA PANORÂMICA” terá como objetivo geral mensurar a acurácia de dois métodos de estimativa de idade em radiografias panorâmicas associados à inteligência artificial (IA).

Ao voluntário só caberá a autorização para preencher o formulário e não haverá grandes riscos aos participantes, visto que os mesmos estarão realizando os exames de imagem para diferentes fins de tratamento não relacionados a este estudo. Vale salientar que os exames de radiografia panorâmica são realizados respeitando os parâmetros de exposição à radiação recomendados pelos princípios de radioproteção, onde a vantagem do diagnóstico é maior em comparação com o detrimento que possa ser causado pela radiação ao indivíduo.

- Ao pesquisador caberá o desenvolvimento da pesquisa de forma confidencial; entretanto, quando necessário for, poderá revelar os resultados ao médico, indivíduo e/ou familiares, cumprindo as exigências da Resolução N°. 466/12 do Conselho Nacional de Saúde/Ministério da Saúde.
- O voluntário poderá se recusar a participar, ou retirar seu consentimento a qualquer momento da realização do trabalho ora proposto, não havendo qualquer penalização ou prejuízo para o mesmo.
- Será garantido o sigilo dos resultados obtidos neste trabalho, assegurando assim a privacidade dos participantes em manter tais resultados em caráter confidencial.
- Não haverá qualquer despesa ou ônus financeiro aos participantes voluntários deste projeto científico e não haverá qualquer procedimento que possa incorrer em danos físicos ou

financeiros ao voluntário e, portanto, não haveria necessidade de indenização por parte da equipe científica e/ou da Instituição responsável.

- Qualquer dúvida ou solicitação de esclarecimentos, o participante poderá contatar a equipe científica no número (83) 99601 - 7564 com DOUGLAS PEREIRA DE SOUSA, JUNTO A CONEP PLATAFORMA BRASIL.
- Ao final da pesquisa, se for do meu interesse, terei livre acesso ao conteúdo da mesma, podendo discutir os dados, com o pesquisador, vale salientar que este documento será impresso em duas vias e uma delas ficará em minha posse.
- Desta forma, uma vez tendo lido e entendido tais esclarecimentos e, por estar de pleno acordo com o teor do mesmo, dato e assino este termo de consentimento livre e esclarecido.



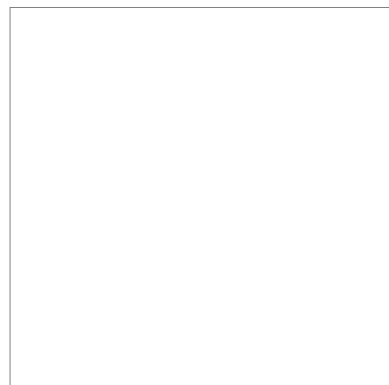
---

Assinatura do pesquisador responsável

---

Assinatura do participante

Assinatura Dactiloscópica do participante da pesquisa  
(OBS: utilizado apenas nos casos em que não seja possível a coleta da assinatura do participante da pesquisa).



## **APÊNDICE B - TERMO DE ASSENTIMENTO DO MENOR**

Você está sendo convidado para participar da pesquisa “INTELIGÊNCIA ARTIFICIAL COMO MÉTODO AUXILIAR NA ESTIMATIVA DE IDADE EM RADIOGRAFIA PANORÂMICA”. Seus pais permitiram que você participasse.

Queremos saber o desempenho de dois métodos de estimativa de idade em radiografias panorâmicas associados à inteligência artificial (IA).

Os menores que irão participar dessa pesquisa têm de 13 a 17 anos de idade. Você não precisa participar da pesquisa se não quiser, é um direito seu e não terá nenhum problema se desistir.

A pesquisa será feita utilizando a imagem do exame que você fez em clínica particular com outros fins. Caso aconteça algo errado, você pode entrar em contato pelo telefone (83) 9 9601 7564 do pesquisador DOUGLAS PEREIRA DE SOUSA.

Mas há coisas boas que podem acontecer. Você poderá contribuir com a ciência através de maneiras capazes de determinar a idade de alguém utilizando apenas a imagem dos dentes e facilitando o reconhecimento de pessoas que não tinham documentos e já morreram, por exemplo.

Ninguém saberá que você está participando da pesquisa, não falaremos a outras pessoas, nem daremos a estranhos as informações que você nos der. Os resultados da pesquisa vão ser publicados, mas sem identificar o seu nome quando terminarmos a pesquisa.

Se você tiver alguma dúvida, você pode perguntar ao pesquisador. O telefone está na parte de cima desse texto.

Eu \_\_\_\_\_ aceito participar da pesquisa “INTELIGÊNCIA ARTIFICIAL COMO MÉTODO AUXILIAR NA ESTIMATIVA DE IDADE EM RADIOGRAFIA PANORÂMICA”, que objetiva mensurar a acurácia de dois métodos de estimativa de idade em radiografias panorâmicas associados à inteligência artificial (IA). Entendi que posso dizer “sim” e participar. Mas que, a qualquer momento, posso dizer “não” e desistir que ninguém vai ficar furioso. Os pesquisadores tiraram dúvidas e conversaram com os meus responsáveis.

Recebi uma via deste termo de assentimento e li e concordo em participar da pesquisa.

Campina Grande, \_\_\_\_ de \_\_\_\_\_ de 2022.

A handwritten signature in black ink, appearing to be "D. P. R. - A. P. R.", positioned above a horizontal line.

---

Assinatura do menor

---

Assinatura do (a) pesquisador (a)



## ANEXO – PARECER DO COMITÊ DE ÉTICA EM PESQUISA (CEP)

UNIVERSIDADE ESTADUAL DA  
PARAÍBA - PRÓ-REITORIA DE  
PÓS-GRADUAÇÃO E  
PESQUISA / UEPB - PRPGP



### PARECER CONSUBSTANCIADO DO CEP

#### DADOS DO PROJETO DE PESQUISA

**Título da Pesquisa:** INTELIGÊNCIA ARTIFICIAL COMO MÉTODO AUXILIAR NA ESTIMATIVA DE IDADE EM RADIOGRAFIA PANORÂMICA

**Pesquisador:** DOUGLAS PEREIRA DE SOUSA

**Área Temática:**

**Versão:** 1

**CAAE:** 56455322.6.0000.5187

**Instituição Proponente:** UNIVERSIDADE ESTADUAL DA PARAÍBA

**Patrocinador Principal:** Financiamento Próprio

#### DADOS DO PARECER

**Número do Parecer:** 5.277.153

#### Apresentação do Projeto:

Trata-se de um estudo observacional quantitativo, descritivo e analítico com pacientes entre 13 e 40 anos que apresentarão indicação para exame de radiografia panorâmica por razões distintas às desta pesquisa.

#### Objetivo da Pesquisa:

##### Objetivo geral

O objetivo geral deste estudo é comparar o desempenho de dois métodos diferentes de estimativa de idade associados à IA utilizando incisivos, caninos e terceiros molares permanentes em radiografias panorâmicas.

##### Objetivos específicos

Avaliar e comparar a acurácia da estimativa de idade por meio do método de segmentação da área do dente e da polpa; método de Cameriere; e método de Kvaal;

Avaliar e comparar os métodos de extração de características radiômicas e semânticas na estimativa da idade do paciente utilizando radiografia panorâmica e os métodos de estimativa de idade supracitados;

Determinar qual dos métodos (métodos radiográficos e método de extração de atributos) é mais preciso para estimativa da idade em radiografias panorâmicas.

**Endereço:** Av. das Baraúnas, 351- Campus Universitário

**Bairro:** Bodocongó **CEP:** 58.109-753

**UF:** PB **Município:** CAMPINA GRANDE

**Telefone:** (83)3315-3373 **Fax:** (83)3315-3373 **E-mail:** cep@setor.uepb.edu.br



UNIVERSIDADE ESTADUAL DA  
PARAÍBA - PRÓ-REITORIA DE  
PÓS-GRADUAÇÃO E  
PESQUISA / UEPB - PRPGP



Continuação do Parecer: 5.277.153

**Avaliação dos Riscos e Benefícios:**

O projeto apresenta risco mediano, uma vez que serão submetidos a exame radiográfico panorâmico. Salienta-se que este exame será para outra finalidade e não é específico para a pesquisa. Os exames serão realizados em clínica particular e os pacientes serão esclarecidos sobre a possibilidade de uso das imagens para a finalidade acadêmica. Em caso de permissão do uso da imagem do exame, os participantes menores de idade assinarão o termo de assentimento e os responsáveis o TCLE. Em caso de pacientes maiores de idade a autorização do uso de imagem se dará por meio do TCLE. Os benefícios esperados podem superar possíveis riscos, uma vez que a utilização da inteligência artificial (algoritmos) para estimar a idade em exames radiográficos, pode reduzir possíveis vieses com a utilização de métodos convencionais (subjetivos).

**Comentários e Considerações sobre a Pesquisa:**

A proposta do projeto é relevante, uma vez que proporciona é um tema inovador que vai contribuir academicamente e socialmente ao reduzir possíveis erros de diagnóstico de imagem.

**Considerações sobre os Termos de apresentação obrigatória:**

Folha de rosto: anexada;  
Autorização Institucional: Anexada  
Declaração de concordância com projeto de pesquisa: anexado  
Termo de Compromisso do Pesquisador Responsável: anexado  
TCLE: anexado  
Termo de assentimento: anexado  
Autorização para acesso de banco de dados: anexado.

**Recomendações:**

O projeto é relevante, apresenta importância acadêmica e social. A metodologia está clara e adequada ao que se propõe. Todos os termos foram anexados. Não há recomendações.

**Conclusões ou Pendências e Lista de Inadequações:**

O projeto apresenta todos os documentos necessários e está aprovado.

**Considerações Finais a critério do CEP:**

Endereço: Av. das Baraúnas, 351- Campus Universitário  
Bairro: Bodocongó CEP: 58.109-753  
UF: PB Município: CAMPINA GRANDE  
Telefone: (83)3315-3373 Fax: (83)3315-3373 E-mail: cep@setor.uepb.edu.br

UNIVERSIDADE ESTADUAL DA  
PARAÍBA - PRÓ-REITORIA DE  
PÓS-GRADUAÇÃO E  
PESQUISA / UEPB - PRPG



Continuação do Parecer: 5.277.153

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BASICAS_DO_PROJETO_1877448.pdf	02/03/2022 12:45:07		Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	termo_de_assentimento_do_menor.docx	02/03/2022 12:44:10	DOUGLAS PEREIRA DE SOUSA	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLE_DO_RESPONSAVEL_DO_MENOR.docx	02/03/2022 12:43:50	DOUGLAS PEREIRA DE SOUSA	Aceito
Projeto Detalhado / Brochura Investigador	Projeto_Douglas_Mestrado_01_03_2022.docx	01/03/2022 11:37:29	DOUGLAS PEREIRA DE SOUSA	Aceito
Declaração de Instituição e Infraestrutura	termo_de_autorizacao_institucional_para_uso_e_coleta.pdf	01/03/2022 11:36:11	DOUGLAS PEREIRA DE SOUSA	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	termo_de_consentimento_livre_e_esclarecido.pdf	01/03/2022 11:35:08	DOUGLAS PEREIRA DE SOUSA	Aceito
Declaração de concordância	declaracao_de_concordancia_com_projeto_de_pesquisa.pdf	01/03/2022 11:34:44	DOUGLAS PEREIRA DE SOUSA	Aceito
Declaração de Pesquisadores	termo_de_compromisso_pesquisador_responsavel.pdf	01/03/2022 11:33:35	DOUGLAS PEREIRA DE SOUSA	Aceito
Declaração de Instituição e Infraestrutura	Termo_de_autorizacao_institucional.pdf	01/03/2022 11:32:12	DOUGLAS PEREIRA DE SOUSA	Aceito
Declaração de Pesquisadores	Termo_de_compromisso_utilizacao_de_dados.pdf	01/03/2022 11:31:32	DOUGLAS PEREIRA DE SOUSA	Aceito
Cronograma	Cronograma.docx	01/03/2022 11:05:29	DOUGLAS PEREIRA DE SOUSA	Aceito
Folha de Rosto	folha_De_Rosto_Projeto_de_Pesquisa_Douglas.pdf	01/03/2022 11:01:09	DOUGLAS PEREIRA DE SOUSA	Aceito

Situação do Parecer:

Aprovado

Necessita apreciação da CONEP:

Não

Endereço: Av. das Baraúnas, 351- Campus Universitário  
 Bairro: Bodocongó CEP: 58.109-753  
 UF: PB Município: CAMPINA GRANDE  
 Telefone: (83)3315-3373 Fax: (83)3315-3373 E-mail: cep@setor.uepb.edu.br