Journal of Health Informatics

J Health Inform. 2026;18:e1826
DOI: https://doi.org/10.59681/2175-4411.v18.iEspecial.2026.1826

ARTIGO COMPLETO
CBIS 2026

Inferência de idade a partir de radiografias panorâmicas dentárias por redes de difusão

Age estimation from dental panoramic radiographs with diffusion networks

Jadson Faustino Mororó[1] ✉, Adriano Trajano Rodrigues[1], Antonio Leoncio de Carvalho Resende[1], Ialis Cavalcante de Paula Junior[1]

ORCID: 0009-0004-9846-6315 · 0009-0004-9025-0843 · 0009-0001-9732-4962 · 0000-0002-2374-4817

[1] Universidade Federal do Ceará, Sobral (CE), Brasil.

FICHA DO ARTIGO

TIPO
Artigo completo · CBIS 2026

IDENTIFICADOR
e1826

DOI
10.59681/2175-4411.v18.iEspecial.2026.1826

RECEBIDO
17/05/2026

APROVADO
20/07/2026

PROCESSO DE AVALIAÇÃO
Double Blind Review

EDITOR RESPONSÁVEL
Juliano de Souza Gaspar

ACESSO
Aberto, CC BY 4.0

AUTOR CORRESPONDENTE
Jadson Faustino Mororó
jadsonfaustino7@gmail.com

LICENÇA

Este é um artigo publicado em acesso aberto sob a licença Creative Commons CC BY 4.0, que permite uso, distribuição e reprodução em qualquer meio, desde que o trabalho original seja corretamente citado.

CC BY 4.0

RESUMO

Objetivo: Investigar a aplicabilidade de modelos de difusão para estimação de idade cronológica a partir de radiografias panorâmicas dentárias. **Método:** Foram utilizadas 737 radiografias de pacientes brasileiros (4–91 anos), submetidas a pré-processamento com filtro TV-CLAHE. Redes de difusão baseadas em ResNet18 foram treinadas com validação cruzada k-fold (k=20), variando número de épocas (10, 50, 100) e resolução de entrada (64×64, 224×224 e 512×512 pixels). O desempenho foi avaliado por MAE, MSE e R^2. **Resultados:** A configuração de 100 épocas com entrada 512×512 produziu os melhores resultados: MAE médio de 5,2 anos, MSE de 57,6 e R^2 de 0,77. **Conclusão:** Modelos de difusão representam alternativa viável às arquiteturas convolucionais para estimação automática de idade, com desempenho crescente mediante aumento conjunto de épocas e resolução.

Descritores: Determinação da Idade pelos Dentes; Radiografia Panorâmica; Redes de Difusão.

ABSTRACT

Objective: To investigate the applicability of diffusion models for chronological age estimation from panoramic dental radiographs. **Method:** 737 panoramic radiographs from Brazilian patients (aged 4–91) were preprocessed using TV-CLAHE. ResNet18-based diffusion networks were trained with k-fold cross-validation (k=20), varying epoch count (10, 50, 100) and input resolution (64×64, 224×224, 512×512 pixels). Performance was assessed using MAE, MSE, and R^2. **Results:** The 100-epoch, 512×512 configuration achieved the best results: mean MAE of 5.2 years, MSE of 57.6, and R^2 of 0.77. **Conclusion:** Diffusion models represent a viable alternative to convolutional architectures for automatic age estimation, with performance improving as epoch count and resolution increase jointly.

Keywords: Age Determination by Teeth; Panoramic Radiograph; Diffusion Models.

CBIS 2026 XXI CONGRESSO BRASILEIRO DE INFORMÁTICA EM SAÚDE

Artigo apresentado no XXI Congresso Brasileiro de Informática em Saúde (CBIS 2026), realizado de 23 a 25 de setembro de 2026, em Brasília (DF), e publicado na seção CBIS 2026 do Journal of Health Informatics.

COMO CITAR ESTE ARTIGO: Mororó JF, Rodrigues AT, Resende ALC, de Paula Junior IC. Inferência de idade a partir de radiografias panorâmicas dentárias por redes de difusão. J Health Inform 2026;18:e1826. doi: https://doi.org/10.59681/2175-4411.v18.iEspecial.2026.1826

1 INTRODUÇÃO

A estimação da idade cronológica de um indivíduo a partir de imagens médicas é tema de grande relevância em contextos forenses, clínicos e antropológicos, pois permite uma avaliação não invasiva do desenvolvimento biológico quando outros métodos de inferência de idade não estão disponíveis [1]. A odontologia forense possui forte relevância nesse contexto, especialmente na estimação de idade, devido à robustez e aos padrões previsíveis de desenvolvimento dentário ao longo da vida de um indivíduo [1,2]. As técnicas tradicionais baseiam-se na observação de características morfológicas dos dentes e estruturas adjacentes. Contudo, a subjetividade inerente a essas avaliações manuais e a sua limitação para indivíduos mais velhos motivam a busca por abordagens mais objetivas e automatizadas [2,3].

As radiografias panorâmicas são amplamente empregadas na prática odontológica por sua capacidade de capturar, em uma única imagem e com baixo custo, uma visão abrangente da dentição e das estruturas orofaciais, tornando-as um recurso valioso tanto para o diagnóstico e planejamento de tratamentos quanto para a estimação de idade em contextos forenses [2-5]. Sua eficiência e a vasta quantidade de informações anatômicas que fornecem as tornam ideais para a aplicação de métodos computacionais [3, 4].

Com o avanço do aprendizado de máquina, as redes neurais convolucionais (CNNs) tornaram-se a abordagem dominante na automação da inferência de idade em radiografias panorâmicas, alcançando desempenho competitivo em termos de erro médio absoluto (MAE) e coeficiente de determinação R^2 [3-6]. As CNNs são compostas por camadas de convolução que aplicam filtros para detectar padrões locais, permitindo a extração automática de características complexas a partir de dados brutos. No contexto médico, essas redes têm sido extensivamente aplicadas em tarefas como detecção de doenças, segmentação de estruturas anatômicas e estimação de idade [3-8]. Apesar dos avanços, desafios persistem: a dependência de grandes volumes de dados rotulados, a dificuldade de generalização para diferentes populações e artefatos odontológicos, e a interpretabilidade limitada, que dificulta a aceitação regulatória e a confiança dos especialistas [9].

Nesse cenário, as redes de difusão emergem como uma arquitetura inovadora, originalmente desenvolvida para tarefas generativas e com potencial para regressão contínua de atributos complexos [10,11]. Essencialmente, esses modelos operam em dois estágios: um processo de difusão que adiciona ruído gaussiano à imagem até que se torne ruído puro, e um processo reverso que aprende a remover o ruído para reconstruir a imagem original, permitindo a geração de novas amostras e uma modelagem probabilística precisa de distribuições complexas [10]. Essa capacidade de modelagem explícita da incerteza, decorrente de sua natureza probabilística, é uma vantagem diferenciada sobre as CNNs clássicas, especialmente relevante em contextos forenses e clínicos nos quais a confiabilidade das estimativas é tão importante quanto a acurácia pontual [10-12]. Apesar de demonstrarem capacidades promissoras em classificação, regressão supervisionada e aplicações médicas como reconstituição e segmentação de imagens [11-13], as redes de difusão têm sido pouco exploradas na literatura de inferência de idade em imagens médicas [10,12].

Diante dessa lacuna, o presente estudo propõe-se a investigar a aplicabilidade e o desempenho de modelos de difusão para a estimação de idade a partir de radiografias panorâmicas dentárias, comparando seu desempenho sob diferentes configurações de hiperparâmetros. A metodologia geral consiste em três etapas principais: (i) pré-processamento das imagens para normalização e padronização; (ii) treinamento de modelos de difusão com diferentes resoluções de entrada e números de épocas, variando as combinações de hiperparâmetros para avaliar seu impacto no desempenho preditivo; e (iii) avaliação quantitativa dos modelos utilizando métricas de regressão bem estabelecidas, como o erro médio absoluto (MAE), erro quadrático médio (MSE) e coeficiente de determinação (R^2). Os experimentos foram conduzidos em um conjunto de dados composto por 737 amostras de radiografias panorâmicas dentárias de 737 pacientes brasileiros.

2 MÉTODOS

2.1 Conjunto de Dados

Um conjunto de imagens de radiografias panorâmicas odontológicas, rotuladas com sexo e idade dos respectivos pacientes, foi desenvolvido na Universidade Federal do Ceará (UFC) com a colaboração de docentes dos cursos de Engenharia de Computação e Odontologia. A base é composta por 737 amostras de 737 pacientes brasileiros com idades entre 4 e 91 anos. Embora ainda não esteja disponível publicamente, o conjunto de dados pode ser acessado mediante solicitação aos autores.

2.2 Pré-processamento das Imagens

No pré-processamento, realizou-se o redimensionamento das imagens, com tamanho variado de acordo com o experimento, e a conversão para escala de cinza. Além disso, foi efetuada a remoção das bordas pretas características de imagens de radiografia e a aplicação do filtro TV-CLAHE (*Total Variation–Contrast-Limited Adaptive Histogram Equalization*). Essa técnica combina o método de Equalização de Histograma Adaptativa por blocos (CLAHE) com a regularização por Variação Total

(TV), visando melhorar o contraste local das imagens enquanto reduz o ruído e preserva detalhes anatômicos importantes, como os canais radiculares, essencial para uma visualização precisa das estruturas dentárias [14].

A Figura 1 exemplifica o efeito do processamento TV-CLAHE em uma amostra de radiografia panorâmica dentária, onde os lados esquerdo e direito da figura apresentam a imagem antes e depois do processamento, respectivamente.

Figura 1. Exemplo de efeito do processamento TV-CLAHE em radiografia panorâmica dentária

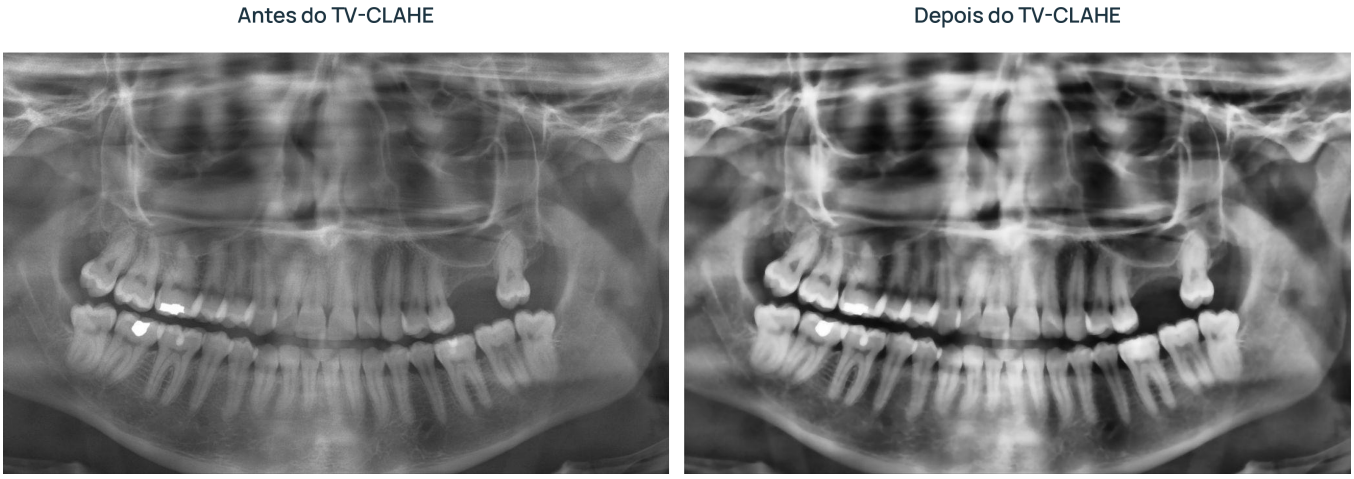

Fonte: Elaborado pelos autores (2026).

2.3 Arquitetura e Treinamento da Rede de Difusão

As redes neurais são compostas por camadas interconectadas de neurônios artificiais que processam informações de forma hierárquica, aprendendo representações complexas dos dados. O aprendizado profundo refere-se às redes com múltiplas camadas ocultas, capazes de extrair características de alto nível a partir de dados brutos. A arquitetura e a implementação da rede de difusão foram adaptadas a partir do trabalho de Han *et al.* (2022) [12], cujo código-fonte está disponível publicamente em Python e propõe a adaptação de modelos de difusão para tarefas de classificação e regressão supervisionadas.

Os experimentos foram realizados em Python. Os parâmetros fixos foram: taxa de aprendizado de 10^{-4}, otimizador AdamW, função de perda MSE e *backbone* ResNet18. Os hiperparâmetros variados foram o número de épocas (10, 50 e 100) e o tamanho do redimensionamento das imagens de entrada (64×64, 224×224 e 512×512 pixels), totalizando nove combinações experimentais.

2.4 Validação Cruzada

Para aferir a robustez e a capacidade de generalização dos modelos, especialmente em cenários com conjuntos de dados limitados, foi adotada a validação cruzada *k-fold*, com k=20. Essa técnica consiste em dividir integralmente e aleatoriamente o conjunto de dados original em k subconjuntos mutuamente exclusivos (*folds*) de tamanho aproximadamente igual. Em cada iteração, um dos *folds* é utilizado como conjunto de validação e os k−1 *folds* restantes são usados para treinamento. Esse procedimento é repetido k vezes, de forma que cada *fold* seja utilizado exatamente uma vez para validação.

A validação cruzada *k-fold* maximiza a utilização dos dados disponíveis, o que é valioso quando há poucas amostras, e reduz viés e variância nas estimativas de desempenho do modelo, produzindo uma avaliação mais confiável de sua capacidade de generalização para dados não vistos. Ao avaliar o modelo em diferentes subconjuntos em múltiplas rodadas, essa técnica também auxilia na identificação e mitigação de sobreajuste (*overfitting*), sendo frequentemente utilizada como base para a otimização de hiperparâmetros e seleção de modelos. Cada experimento gerou 20 conjuntos de métricas, permitindo uma análise estatística robusta do desempenho médio e da variabilidade entre os diferentes subconjuntos de validação.

2.5 Métricas de Avaliação

Em tarefas de regressão, é essencial avaliar a qualidade das predições por meio de métricas que quantifiquem quão próximas as estimativas estão dos valores observados. O erro médio absoluto (MAE) mede a média das diferenças absolutas entre os valores previstos $\hat{y}_i$ e os valores observados y_i, conforme a Equação (a), onde n é o número total de observações. Essa métrica fornece uma interpretação intuitiva do erro médio na mesma unidade da variável de interesse, neste estudo, em anos.

$$MAE = (1/n)\ \Sigma_i\ |y_i - \hat{y}_i|\ (a)$$

O erro quadrático médio (MSE) é definido como a média dos quadrados das diferenças entre os valores reais e os valores previstos, conforme a Equação (b). Ao

elevar as diferenças ao quadrado, o MSE penaliza erros maiores de forma mais acentuada, sendo útil quando grandes desvios são indesejáveis; porém, essa mesma propriedade o torna mais sensível a *outliers*.

$$MSE = (1/n)\ \Sigma_i\ (y_i - \hat{y}_i)^2 \quad (b)$$

Por fim, o coeficiente de determinação R^2 quantifica a proporção da variabilidade total dos dados que é explicada pelo modelo, conforme a Equação (c), onde $\bar{y}$ é a média dos valores observados. Valores de R^2 próximos de 1 indicam que o modelo explica bem a variabilidade dos dados, enquanto valores próximos ou inferiores a zero sugerem que o modelo não captura a tendência dos dados melhor do que uma predição baseada na média dos valores observados. Em conjunto, essas métricas fornecem uma avaliação abrangente do desempenho de um modelo de regressão.

$$R^2 = 1 - \Sigma_i(y_i - \hat{y}_i)^2 / \Sigma_i(y_i - \bar{y})^2 \quad (c)$$

2.6 Aspectos Éticos

O estudo utilizou uma base de dados radiográficos retrospectivos e anonimizados, desenvolvida com a colaboração de docentes dos cursos de Odontologia e Engenharia de Computação, a partir de exames de pacientes reais obtidos em atendimentos odontológicos de rotina. O projeto foi submetido e aprovado pelo Comitê de Ética em Pesquisa (CEP) da instituição responsável, sob o Certificado de Apresentação de Apreciação Ética (CAAE) nº 50339221.3.0000.5053 e Parecer Consubstanciado nº 4.882.840. Todos os dados foram desidentificados, e sua utilização seguiu os princípios da Declaração de Helsinque e da Lei Geral de Proteção de Dados Pessoais (Lei nº 13.709/2018).

3 RESULTADOS

Os resultados quantitativos obtidos nos nove experimentos são apresentados nas Tabelas 1, 2 e 3, correspondentes às métricas MAE, MSE e R^2, respectivamente. Para cada configuração, são reportados a média, o desvio padrão, o mínimo, o máximo e a mediana calculados sobre os 20 *folds* de validação cruzada.

Os resultados evidenciam uma tendência clara de melhora das métricas à medida que tanto o número de épocas quanto a resolução de entrada aumentam. É importante notar, contudo, que a simples elevação da resolução de entrada sem um aumento proporcional no número de épocas de treinamento pode ser desfavorável, pois o modelo não dispõe de iterações suficientes para capturar as informações adicionais contidas em imagens de maior dimensão. Esse efeito é observado no experimento com 10 épocas e entrada 512×512, no qual o desempenho apresentou piora expressiva em comparação às resoluções menores

Tabela 1. Erro médio absoluto (MAE) por configuração de hiperparâmetros (em anos).

Épocas	Entrada	Média	Desvio Padrão	Mínimo	Máximo	Mediana
10	64×64	6,0	1,0	4,3	7,7	6,1
10	224×224	6,5	1,5	4,3	10,9	6,1
10	512×512	9,4	5,0	4,7	22,7	7,4
50	64×64	5,6	0,9	3,8	7,4	5,7
50	224×224	5,4	0,9	3,7	7,3	5,5
50	512×512	5,7	1,4	3,5	10,3	5,6
100	64×64	5,5	0,8	3,8	6,9	5,6
100	224×224	5,5	1,0	3,4	6,9	5,5
100	512×512	5,2	0,9	3,5	6,4	5,4

Fonte: Elaborado pelos autores (2026).

Tabela 2. Erro quadrático médio (MSE) por configuração de hiperparâmetros.

Épocas	Entrada	Média	Desvio Padrão	Mínimo	Máximo	Mediana
10	64×64	73,0	27,1	32,4	113,3	65,8
10	224×224	84,3	43,5	32,5	184,7	65,8
10	512×512	167,2	148,2	46,4	597,3	100,5
50	64×64	63,5	24,7	24,2	109,4	61,3
50	224×224	58,5	22,9	26,1	112,4	59,3
50	512×512	65,8	29,1	24,5	146,0	58,6
100	64×64	63,3	21,7	24,6	104,1	63,5
100	224×224	60,8	23,6	25,8	112,6	59,0
100	512×512	57,6	24,6	24,1	112,6	58,3

Fonte: Elaborado pelos autores (2026).

Tabela 3. Coeficiente de determinação (R^2) por configuração de hiperparâmetros.

Épocas	Entrada	Média	Desvio Padrão	Mínimo	Máximo	Mediana
10	64×64	0,70	0,08	0,55	0,82	0,71
10	224×224	0,71	0,10	0,48	0,82	0,73
10	512×512	0,61	0,18	−0,07	0,80	0,67
50	64×64	0,74	0,08	0,60	0,86	0,75
50	224×224	0,76	0,07	0,64	0,87	0,78
50	512×512	0,76	0,07	0,64	0,88	0,76
100	64×64	0,73	0,08	0,60	0,89	0,74
100	224×224	0,75	0,07	0,63	0,87	0,75
100	512×512	0,77	0,08	0,64	0,90	0,78

Fonte: Elaborado pelos autores (2026).

(MAE=9,4; MSE=167,2; R^2=0,61).

Nas execuções com 10 épocas, o MAE médio variou entre 6,0 e 6,5 anos para as entradas menores, enquanto o aumento para 50 e 100 épocas levou a reduções para a faixa de 5,2 a 5,7 anos. Analisando o MSE, observou-se também uma redução geral com a melhora da resolução e com mais épocas: para a entrada 224×224, o MSE médio reduziu de 84,3 (10 épocas) para 60,8 (100 épocas). Em relação ao R^2, os valores médios aumentaram consistentemente com mais épocas e maior resolução, variando de 0,61 a 0,77, indicando capacidade moderada do modelo em explicar a variabilidade dos dados. O desvio padrão das métricas também diminuiu progressivamente com o aumento das épocas. Para a entrada 512×512, o desvio padrão do MAE reduziu de 5,0 (10 épocas) para 0,9 (100 épocas), indicando modelos mais estáveis. Destacam-se ainda os melhores resultados individuais obtidos por *folds* isolados na configuração de 100 épocas: MAE mínimo de 3,4 anos (entrada 224×224), MSE mínimo de 24,1 e R^2 máximo de 0,90 (ambos com entrada 512×512), valores que ilustram o teto de desempenho alcançável pelo modelo nas condições experimentais avaliadas.

4 DISCUSSÃO

Os valores observados de MAE na faixa de aproximadamente 5 a 6 anos e de R^2 entre 0,70 e 0,77 podem ser considerados resultados promissores no contexto da estimação de idade a partir de radiografias panorâmicas, especialmente quando comparados a outros trabalhos da literatura que também utilizam métricas de regressão visual neste domínio [3-8]. O MSE e o R^2 devem ser interpretados em conjunto, pois o MSE pode ser fortemente influenciado por erros maiores, enquanto o R^2 reflete a proporção da variância explicada em relação à média dos dados observados.

O desempenho da rede está diretamente associado ao tamanho do conjunto de dados. Em aprendizado profundo, volumes maiores de dados tendem a permitir que o modelo aprenda representações mais robustas e generalizáveis, devido à maior diversidade e amplitude de exemplos disponíveis para o ajuste dos pesos das redes neurais. Esse aumento na variabilidade amostral contribui para a redução do risco de sobreajuste e para a melhoria da capacidade de generalização em dados não vistos, aspecto amplamente discutido na literatura como fundamental para a performance de modelos complexos como CNNs, que possuem grande quantidade de parâmetros [9]. Em

contrapartida, conjuntos menores limitam a riqueza de padrões aprendidos, resultando em desempenho mais modesto e maior variabilidade nas métricas de validação.

As tendências observadas reforçam que o benefício não decorre do aumento isolado da resolução ou das épocas, mas da combinação equilibrada entre ambos. Imagens com maior tamanho de entrada disponibilizam informações mais detalhadas, como características anatômicas mais finas presentes nas radiografias, mas tais informações só são efetivamente exploradas quando o modelo dispõe de épocas suficientes para ajustar adequadamente seus parâmetros. Quando o tamanho da entrada é ampliado sem o correspondente aumento no número de épocas, pode ocorrer degradação de desempenho, possivelmente porque o modelo passa a lidar com um espaço de maior dimensionalidade sem tempo adequado para convergir.

O estudo também contribui para a literatura ao demonstrar que modelos baseados em difusão podem ser usados como alternativa às abordagens tradicionais e às arquiteturas clássicas de redes neurais convolucionais, expandindo o repertório de técnicas disponíveis para análises de imagens médicas. Além disso, sua arquitetura probabilística permite uma compreensão mais profunda da incerteza e da variabilidade dos dados [10-12], o que pode fortalecer aplicações forenses e odontológicas ao fornecer estimativas de idade mais objetivas, replicáveis e acompanhadas de intervalos de confiança, um requisito essencial em contextos legais e clínicos em que a precisão e a confiabilidade das predições são determinantes.

A dependência de uma quantidade substancial de dados rotulados para assegurar boa capacidade de generalização, especialmente para arquiteturas de alta capacidade como as redes de difusão, é um dos principais obstáculos em aplicações práticas. Isso é especialmente relevante em domínios como a odontologia forense, onde dados rotulados podem ser escassos ou custosos de coletar e anotar. Estratégias como aumento de dados (*data augmentation*) ou aprendizado por transferência (*transfer learning*) podem ser consideradas para mitigar esses desafios em cenários de dados menos abundantes.

5 CONCLUSÕES

Nesta pesquisa, investigou-se a aplicabilidade de modelos de difusão para a inferência de idade a partir de 737 radiografias panorâmicas dentárias de pacientes brasileiros, avaliando seu desempenho sob diferentes combinações de hiperparâmetros. Os resultados obtidos por meio das métricas MAE, MSE e R^2 mostraram que os modelos foram capazes de aprender relações relevantes entre as características presentes nas imagens e a idade cronológica dos indivíduos, mesmo quando treinados com resoluções menores de entrada.

Verificou-se que o aumento conjunto do número de épocas de treinamento e do tamanho da entrada está associado a melhorias consistentes nas métricas de desempenho, com reduções em MAE e MSE e elevações em R^2. Observou-se, contudo, que a ampliação isolada do tamanho da entrada sem o correspondente aumento no número de épocas pode não produzir o mesmo efeito e, em alguns casos, comprometer o desempenho, possivelmente em razão da maior complexidade do espaço de entrada e do tempo insuficiente para a adequada convergência do modelo.

De maneira geral, os erros absolutos médios encontrados, na faixa de aproximadamente 5 a 6 anos para as melhores configurações avaliadas, e a capacidade explicativa retratada pelos valores de R^2 reforçam o potencial dessa abordagem para a estimação automática de idade a partir de radiografias panorâmicas. O estudo demonstrou que modelos de difusão representam uma alternativa viável às abordagens tradicionais de aprendizado profundo, fornecendo estimativas objetivas e replicáveis, e expandindo o repertório de técnicas disponíveis para análises de imagens médicas.

Trabalhos futuros podem explorar a combinação dessas técnicas com mecanismos de interpretabilidade e explicabilidade, além de investigar o impacto de diferentes estratégias de pré-processamento e arquiteturas híbridas para potencializar a acurácia dos modelos. Integrar informações demográficas, metadados de saúde ou outras modalidades de imagem também se apresenta como uma diretriz promissora para ampliar a generalização dos modelos para populações diversas.

Contribuição dos autores. Os autores contribuíram igualmente em todas as etapas de construção do artigo: concepção e delineamento do estudo; coleta, análise e interpretação dos dados; redação e revisão crítica do manuscrito; e aprovação da versão final.

Agradecimentos. Os autores agradecem ao corpo docente dos cursos de Engenharia de Computação e Odontologia da Universidade Federal do Ceará (UFC) pela colaboração na construção da base de dados utilizada na pesquisa.

Financiamento. Os autores não declararam fonte de financiamento.

Disponibilidade de dados e materiais. Os autores declararam que os dados e materiais da pesquisa podem ser disponibilizados mediante requisição aos autores.

Conflitos de interesse. Os autores não declararam conflitos de interesse.

Declaração de uso de IA. Os autores declaram que ferramentas de inteligência artificial não foram utilizadas para a geração de dados, código experimental, resultados, tabelas, análises ou conclusões deste trabalho. Ferramentas de apoio à revisão gramatical e ortográfica foram empregadas de forma auxiliar na redação do texto, sem substituição da autoria intelectual humana e sem alteração do conteúdo científico.

REFERÊNCIAS

1. Kuhnen B, Fernandes CMS, Barros F, Andrade JM, Scarso Filho J, Gonçalves M, et al. Age estimation by analysis of dental mineralization and its forensic contribution. RSD. 2021;10(11):e598101119481. doi: https://doi.org/10.33448/rsd-v10i11.19481
2. Oliveira W, Albuquerque Santos M, Burgardt CAP, Anjos Pontual ML, Zanchettin C. Estimation of human age using machine learning on panoramic radiographs for Brazilian patients. Sci Rep. 2024;14(1):19689. doi: https://doi.org/10.1038/s41598-024-70621-1
3. Bussaban L, Boonchieng E, Panyarak W, Charuakkra A, Chulamanee P. Age Group Classification From Dental Panoramic Radiographs Using Deep Learning Techniques. IEEE Access. 2024;12:139962-73. doi: https://doi.org/10.1109/access.2024.3466953
4. Oh S, Park J, Roh BY, Kumagai A, Lee SS. Development and validation of an age estimation model based on dental characteristics using panoramic radiographs. Sci Rep. 2025;15(1):35124. doi: https://doi.org/10.1038/s41598-025-19164-7
5. Ong SH, Kim H, Song JS, Shin TJ, Hyun HK, Jang KT, et al. Fully automated deep learning approach to dental development assessment in panoramic radiographs. BMC Oral Health. 2024;24(1):426. doi: https://doi.org/10.1186/s12903-024-04160-6
6. Li Z, Xiao N, Nan X, Chen K, Zhao Y, Wang S, et al. Automatic dental age estimation in adolescents via oral panoramic imaging. Front Dent Med. 2025;6:1618246. doi: https://doi.org/10.3389/fdmed.2025.1618246
7. Sributsayakarn N, Intharah T, Hirunchavarod N, Pornprasertsuk-Damrongsri S, Jirarattanasopha V. Automated Age and Sex Estimation From Dental Panoramic Radiographs. Int Dent J. 2025;75(6):103967. doi: https://doi.org/10.1016/j.identj.2025.103967
8. Salehizeinabadi M, Ameli N, Kouchehbaghi K, Arastoo S, Neghab S, Kornerup IM, et al. Dental age prediction from panoramic radiographs using machine learning techniques. PLOS Digit Health. 2025;4(10):e0001077. doi: https://doi.org/10.1371/journal.pdig.0001077
9. Mienye ID, Swart TG, Obaido G, Jordan M, Ilono P. Deep Convolutional Neural Networks in Medical Image Analysis: A Review. Information. 2025;16(3):195. doi: https://doi.org/10.3390/info16030195
10. Kazerouni A, Aghdam EK, Heidari M, Azad R, Fayyaz M, Hacihaliloglu I, et al. Diffusion models in medical imaging: A comprehensive survey. Med Image Anal. 2023;88:102846. doi: https://doi.org/10.1016/j.media.2023.102846
11. Mukhopadhyay S, Gwilliam M, Agarwal V, Padmanabhan N, Swaminathan A, Hegde S, et al. Diffusion models beat GANs on image classification. arXiv. 2023;2307.08702.
12. Han X, Zheng H, Zhou M. CARD: Classification and Regression Diffusion Models. In: Advances in Neural Information Processing Systems 35. San Diego, California, USA: Neural Information Processing Systems Foundation, Inc. (NeurIPS); 2022. p. 18100-15. doi: https://doi.org/10.52202/068431-1316
13. Atad M, Schinz D, Moeller H, Graf R, Wiestler B, Rueckert D, et al. Counterfactual Explanations for Medical Image Classification and Regression using Diffusion Autoencoder. Melba. 2024;2024(iMIMIC 2023):2103-25. doi: https://doi.org/10.59275/j.melba.2024-4862
14. Obuchowicz B, Zarzecka J, Strzelecki M, Jakubowska M, Obuchowicz R, Piórkowski A, et al. Improving Endodontic Radiograph Interpretation with TV-CLAHE for Enhanced Root Canal Detection. J Clin Med. 2025;14(15):5554. doi: https://doi.org/10.3390/jcm14155554

NOTAS EDITORIAIS

O Journal of Health Informatics é uma publicação científica mantida pela Sociedade Brasileira de Informática em Saúde, associação científica sem fins lucrativos dedicada ao desenvolvimento da Informática em Saúde e da Saúde Digital no Brasil. O processo editorial é conduzido com independência científica, sem interferência institucional, comercial ou de patrocinadores, e segue as boas práticas internacionais de ética em publicação científica.

Este artigo foi avaliado por pares, em sistema duplo-cego, por especialistas da área. A equipe editorial usou ferramentas de inteligência artificial, com supervisão humana, na triagem inicial, na conferência do texto, das referências e dos números e, quando necessário, no redesenho de figuras, quadros e tabelas, aprovado pelos autores na prova. As ferramentas e as salvaguardas estão na Política de uso de inteligência artificial da revista. As decisões editoriais foram tomadas por pessoas.

SBIS Sociedade Brasileira de Informática em Saúde