



UNIVERSIDADE ESTADUAL DA PARAÍBA
CAMPUS I – CAMPINA GRANDE
PRÓ-REITORIA DE PÓS-GRADUAÇÃO E PESQUISA
PROGRAMA DE PÓS-GRADUAÇÃO EM ODONTOLOGIA
MESTRADO EM ODONTOLOGIA

PÂMELA DE MEDEIROS DANTAS

**UTILIZAÇÃO DO APRENDIZADO DE MÁQUINA NO DIAGNÓSTICO DE LESÕES
PERIAPICAIS CRÔNICAS POR MEIO DE IMAGENS TOMOGRÁFICAS**

CAMPINA GRANDE/PB

2022

PÂMELA DE MEDEIROS DANTAS

**UTILIZAÇÃO DO APRENDIZADO DE MÁQUINA NO DIAGNÓSTICO DE LESÕES
PERIAPICAIS CRÔNICAS POR MEIO DE IMAGENS TOMOGRÁFICA**

Dissertação apresentada ao Programa de Pós-graduação em Odontologia -PPGO, da Universidade Estadual da Paraíba- UEPB campus I, como parte dos requisitos para obtenção do título de Mestre em Odontologia.

Área de concentração: Clínica odontológica

Linha de Pesquisa: Estudo das Alterações do Sistema Estomatognático

Orientadora: Profa. Dra. Pollianna Muniz Alves

CAMPINA GRANDE/PB

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.

D192u Dantas, Pâmela de Medeiros.
Utilização do aprendizado de máquina no diagnóstico de lesões periapicais crônicas por meio de imagens tomográficas [manuscrito] / Pâmela de Medeiros Dantas. - 2022.
66 p. : il. colorido.

Digitado.
Dissertação (Mestrado em Odontologia) - Universidade Estadual da Paraíba, Centro de Ciências Biológicas e da Saúde, 2023.
"Orientação : Profa. Dra. Pollianna Muniz Alves, Coordenação do Curso de Odontologia - CCBS. "

1. Lesão periapical. 2. Tomografia computadorizada. 3. Inteligência artificial. I. Título

21. ed. CDD 617.6

PÂMELA DE MEDEIROS DANTAS

**UTILIZAÇÃO DO APRENDIZADO DE MÁQUINA NO DIAGNÓSTICO DE LESÕES
PERIAPICAIS CRÔNICAS POR MEIO DE IMAGENS TOMOGRÁFICA**

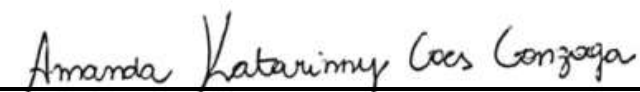
Dissertação apresentada ao Programa de Pós-graduação em Odontologia -PPGO, da Universidade Estadual da Paraíba- UEPB campus I, como parte dos requisitos para obtenção do título de Mestre em Odontologia.

Área de concentração: Clínica odontológica

Linha de Pesquisa: Estudo das Alterações do Sistema Estomatognático

Apresentada em 05/11/2022

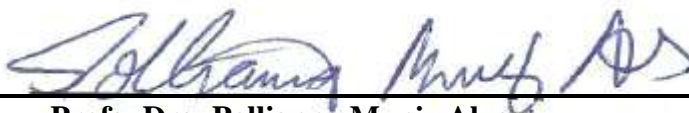
BANCA EXAMINADORA



Profa. Dra. Amanda Katarinny Goes Gonzaga
Membro Titular (1º Examinadora externa - UFRN)



Prof. Dr. Cassiano Francisco Weege Nonaka
Membro Titular (2º Examinador interno - UEPB)



Profa. Dra. Pollianna Muniz Alves
Membro Titular (Orientadora - UEPB)

*Dedico este trabalho a Sebastião Hugo Dantas e
Vânia Lúcia de Medeiros Dantas, meus pais!*

AGRADECIMENTOS

A **Deus**, pela proteção divina que zela e conduz meu caminho.

A minha orientadora, Prof^ª **Pollianna Muniz Alves**, que sem dúvida é a minha grande inspiração na docência. Parte do que eu sou como profissional, tem muito dela, é um privilégio tê-la como mentora e referência desde os meus 21 anos, quando iniciava minha jornada acadêmica como aluna de IC. Nunca foi “só” uma orientação acadêmica, é referência como mulher, cidadã, sempre engajada socialmente, sensível e atenciosa às causas alheias. Agradeço pelo exemplo, mentoria e paciência. Foram muitas lições valiosas, a senhora é um ser humano nobre e sinto-me muito orgulhosa e grata em ter a oportunidade de ser sua orientanda e aprender sobre docência e sobre a vida. Hoje, ao olhar para trás, é impossível não reconhecer que a senhora sempre quis e lutou pelo meu melhor. **MUITO OBRIGADA!**

A minha família, em especial **meus pais** e minhas irmãs **Paloma e Tatiany**. Todas as realizações e dificuldades enfrentadas ao longo dessa trajetória foram partilhadas e saber que posso contar com vocês me faz sentir mais segura. Agradeço aos meus pais por desde cedo me ensinarem o valor que o conhecimento tem. Obrigada por serem sempre o meu maior porto seguro, por todas as renúncias e doações em terem colocado os próprios desejos em segundo plano em detrimentos dos nossos, que se tornaram os seus. Meu amor por vocês transcende qualquer explicação! Tudo isso é por vocês.

Ao meu namorado, **Diego Fernandes Guimarães**, meu maior incentivador, impossível dimensionar todo crescimento e amadurecimento que tenho ao seu lado. Obrigado por todo amor, apoio e suporte emocional que me foi dado ao longo desses anos, por sempre motivar e acreditar em mim. Você é meu exemplo diário de dedicação, sensatez e ser humano justo. Essa conquista é nossa!

Ao professor, **Cassiano Francisco Weege Nonaka**, sou privilegiada em tê-lo na minha jornada, obrigada pela disponibilidade, exemplo, apoio e zelo. Tenho profundo respeito e admiração pela sua incansável dedicação, compromisso com o fortalecimento da pesquisa, do PPGO e com o diagnóstico oral. Meus sinceros agradecimentos por contribuir de uma maneira muito construtiva na minha formação acadêmica, o levarei sempre como referência.

A professora **Daniela de Pita Melo**, por todas as contribuições valiosas que me deu durante o desenvolvimento desta pesquisa. Pesquisadora inspiradora a qual tenho imenso respeito e admiração.

Á **Alberto e Elisa**, por serem essenciais nessa pesquisa. Eu nunca conseguirei retribuir tanta disponibilidade, paciência e disposição em ajudar. Quando o tema parecia impossível e muito desafiador, vocês seguraram minha mão e me fizeram acreditar que seria possível. Quero ser para alguém um dia, o que vocês foram pra mim. Serei eternamente grata.

A todos os meus colegas e grandes amigos de turma, **Elizabeth, Douglas, Márcia, Ariane, Laís, Wanúbia, Érika, Nathalie e Marianna**. Mesmo em meio a uma pandemia, assistindo aulas de forma remota, eu nunca presenciei tanto companheirismo e solicitude como em nossa turma. A caminhada tornou-se mais leve e bem humorada por ter vocês ao lado. O nosso encontro tem um significado muito especial pra mim.

A **Universidade estadual da Paraíba** e todos **os professores do PPGO-UEPB**, por fazerem a diferença na vida de tantas pessoas. Tenho muito orgulho em fazer parte desta instituição e com muita honra, levarei o nome onde eu estiver. Agradeço pelo empenho e por todo esforço despendido para manter e fazer com que o programa cresça. Sou grata pelo acolhimento que sempre tive e a oportunidade de conviver e aprender com mestres tão inspiradores. Muito obrigado!

Ao meu amigo, **John Lennon**, presente especial nesse ano de 2022. Obrigada por me inspirar, por todo companheirismo, apoio, cafés compartilhados e por acreditar em mim. Quero levá-lo sempre comigo. Agradeço a Deus por sua vida.

Ao meu grande amigo, **Robeci Macedo**, você sempre foi e sempre será minha inspiração de perseverança e humildade. Como é bom saber que posso contar com você, que além de dividirmos sonhos, anseios, medos, você contribuiu significativamente com as amostras, permitindo que minha pesquisa fosse viável. Te ver realizar sonhos é uma conquista minha também. Agradeço todos os dias a Deus por você na minha vida.

A **Luan Éverton**, que foi um grande incentivador para que eu estivesse aqui hoje. Você me inspira desde a primeira aula de estágio docência que assisti, me emociono de tanto orgulho pela sua trajetória. Muito obrigada por estar sempre presente.

Aos meus amigos **Illan Hadson, Janduhy Filho e Polion Neto** por toda a disponibilidade e boa vontade em contribuir com amostras para a pesquisa, sou muito grata por tudo.

À **Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES)** pela disponibilidade de bolsas.

A sabedoria é proveniente do conjunto de nossas vivências. Todos que passaram na nossa vida, marca e influencia no que nos tornamos. Sou grata a Deus e ao universo por tantas influências positivas, trocas e encontros edificantes.

a certeza em que nesta vida não se chega a lugar nenhum sozinho.

“A ciência é o grande antídoto do veneno do entusiasmo e da superstição”.

Adam Smith

RESUMO

Granuloma periapical (GP) e Cisto Radicular (CR) são lesões periapicais crônicas inflamatórias que se desenvolvem no ápice da raiz de um dente, com altas taxas de prevalência e similaridade entre suas características clínicas e imaginológicas. Estabelecer um diagnóstico diferencial do GP e do CR na Tomografia computadorizada de Feixe Cônico (TCFC) ainda permanece um desafio. Nesse contexto, a utilização do aprendizado de máquina, através de algoritmos, vem sendo utilizado com o intuito de melhorar a precisão do diagnóstico por imagens. **Objetivo:** Comparar a acurácia de diferentes classificadores, a partir do aprendizado de máquina em imagens tomográficas, na predição de GPs e CRs, diagnosticados, histopatologicamente. **Materiais e Métodos:** O estudo foi do tipo observacional, transversal e analítico através da análise de imagens de TCFC de GPs e CRs. A amostra foi constituída por 14 casos de GPs e 9 casos de CRs. As imagens de TCFC foram obtidas através do sistema CS 9000 3D (Carestream Dental) As reconstruções sagitais das tomografias foram avaliadas em 05 diferentes cortes no CS3D Imaging Software. No software GIMP, versão 2.10, a região de interesse (RoI) foi segmentada e exportada em imagem formato TIFF com 32 bits. Após a segmentação, 6 atributos de textura (contraste, dissimilaridade, correlação, energia, homogeneidade e segundo momento angular) foram extraídos das ROI com o auxílio de matrizes de co-ocorrência. Após a extração dos atributos, foi utilizada a análise por componentes principais para realizar a redução de dimensionalidade e selecionar os atributos mais significativos. Por fim, utilizou-se algoritmo classificador de aprendizado de máquina (K- Means) para calcular a acurácia, sensibilidade e especificidade do método. Os dados foram analisados através da estatística Hopkins a fim de identificar a presença de clusters. **Resultados:** Em relação às características clínicas da amostra, 78,2% (n= 8) dos casos de GPs eram do sexo feminino, enquanto 100% dos casos de CRs eram do sexo masculino. A média de idade foi de 47,33 anos para CRs e 35,50 anos para GPs. Para o aprendizado de máquina foram avaliadas 105 imagens e observou-se 77,14% de acurácia, 47,06% de sensibilidade e 91,55% de especificidade no agrupamento das lesões. **Conclusão:** O uso da Inteligência Artificial pode apresentar resultados promissores para a diferenciação de lesões periapicais crônicas através de imagens tomográficas.

Palavras-Chaves: lesão periapical; tomografia computadorizada; inteligência artificial; diagnóstico.

ABSTRACT

Periapical granuloma (PG) and radicular cyst (RC) are chronic inflammatory periapical lesions that arise at periapical region, with high prevalence rates and similarity between their clinical and imaginological features. To performed a differential diagnosis of PG and RC on Cone-Beam Computed Tomography (CBCT) still remains difficult. In this context, machine learning have been used to improve the accuracy of image diagnosis. **Objective:** To compare the accuracy of different classifiers, based on machine learning on tomographic images, of cases of PG and RC histopathologically diagnosed. **Materials and Methods:** This study was observational, transversal and analytical images of histopathologically diagnosed GPs and CRs. Sample consisted of 14 cases of PGs and 9 cases of RCs. CBCT images were obtained using the CS 9000 3D system (Carestream Dental). Coronal reconstructions of the CT scans were evaluated in 05 different slices in CS3D Imaging Software. In GIMP software, version 2.10, the Region of Interest (RoI) was segmented and exported in TIFF format image with 32 bits. After segmentation, 6 texture attributes (contrast, dissimilarity, correlation, energy, homogeneity, and second angular momentum) were extracted from the RoI through of co-occurrence matrices. After extraction of these attributes, principal component analysis was used to perform dimensionality reduction and select the most significant attributes. A machine learning classifier algorithm (K-means) was used to calculate the accuracy, sensitivity, and specificity of method. Data were analyzed using Hopkins statistics to identify the presence of clusters. **Results:** Regarding the clinical findings, 72.0% (n=8) of the PG were woman, and 100% of RC were man. The mean age was 47.33 years for RCs and 35,50 years for PGs. For machine learning, 105 images were reviewed and 77.14% accuracy, 47.06% sensitivity and 91.55% specificity were observed in the grouping of lesions. **Conclusion:** It is possible suggest that use of Artificial Intelligence shows promising results for the differentiation of chronic periapical lesions through tomographic images.

Keywords: periapical lesion; computed tomography; artificial intelligence; diagnosis.

LISTA DE QUADROS

| | | |
|-------------------|-------------------------------------|----|
| Quadro 1 - | Quadro de variáveis do estudo | 27 |
| Quadro 2 - | Definições de atributos | 31 |

LISTA DE FIGURAS

| | | |
|-------------------|--|----|
| Figura 1 - | Imagem de CBCT de lesões periapicais. A , Cisto Radicular; B , Granuloma Periapical..... | 29 |
| Figura 2 - | Validação do número de clusters (K=2)..... | 40 |
| Figura 3 - | Potencial descritivo das variáveis em GP..... | 41 |
| Figura 4 - | Potencial descritivo das variáveis em CR..... | 41 |
| Figura 5 - | Clusters obtidos do modelo..... | 42 |

LISTA DE GRÁFICOS

| | |
|---|----|
| Gráfico 1 - Validação do número de clusters | 53 |
| Gráfico 2 - Potencial descritivo das variáveis em GP | 53 |
| Gráfico 3 - Potencial descritivo das variáveis em CR | 54 |
| Gráfico 4 - Clusters obtidos do modelo | 55 |

LISTA DE TABELAS

| | |
|---|----|
| Tabela 1 -Distribuição dos dados clínicos e imaginológicos dos casos de GP e CR | 39 |
| Tabela 2 -Matriz de confusão | 42 |
| Tabela 3 -Valores de acurácia, sensibilidade e especificidade do conjunto de dados a partir dos métodos de extração de características radiômicas para o classificador avaliado..... | 43 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|-------------|---|
| CNNs | Redes Neurais Convolucionais (Convolutional Neural Networks) |
| CR | Cisto Radicular |
| DL | Do inglês “Deep Learning”, traduzido como Aprendizado profundo |
| IA | Inteligência Artificial. |
| GP | Granuloma Periapical |
| KNN | Tipo de classificador utilizado em aprendizagem de máquina, que em inglês significa “ <i>k-Nearest Neighbors</i> ”, traduzido como kernel-Vizinhos Mais Próximos. |
| LP | Lesão Periapical |
| ML | Do inglês “ <i>Machine Learning</i> ”, traduzido como Aprendizagem de Máquina |
| RP | Radiografia Periapical |
| RNA | Rede Neural Artificial |
| RND | Redes Neurais Densas |
| RoI | “ <i>Region of Interest</i> ” traduzido do inglês como Região de Interesse |
| SPSS | Statistical Package for the Social Science |
| SMA | Segundo momento angular |
| SVM | Support Vector Machine |
| TCFC | Tomografia Computadorizada de Feixe Cônico |
| TCLE | Termo de Consentimento Livre e Esclarecido |
| UEPB | Universidade Estadual da Paraíba |
| 3D | Tridimensional |

SUMÁRIO

| | | |
|---------------|--|----|
| 1 | INTRODUÇÃO | 17 |
| 1.1 | Lesões periapicais: epidemiologia, diagnóstico e tratamento | 17 |
| <i>1.1.1</i> | <i>Epidemiologia e etiopatologia</i> | 17 |
| <i>1.1.2</i> | <i>Diagnóstico e Tratamento</i> | 18 |
| 1.2 | Radiografia periapical x tcfc: aplicabilidade e limitações | 18 |
| 1.3 | Inteligência artificial (IA) | 20 |
| <i>1.3.1</i> | <i>Considerações Iniciais</i> | 20 |
| <i>1.3.2</i> | <i>Semântica e Radiômica</i> | 22 |
| <i>1.3.3</i> | <i>Aplicação de IA em saúde</i> | 22 |
| <i>1.3.4</i> | <i>Aplicação de IA em Odontologia</i> | 22 |
| 2 | OBJETIVOS | 25 |
| 2.1 | Objetivo geral | 25 |
| 2.2 | Objetivos específicos | 25 |
| 3 | MATERIAIS E MÉTODOS | 26 |
| 3.1 | Aspectos éticos | 26 |
| 3.2 | Tipo do estudo | 26 |
| 3.3 | População | 26 |
| 3.4 | Amostra | 26 |
| 3.5 | Variáveis do estudo | 26 |
| 3.6 | Critérios de inclusão | 26 |
| 3.7 | Critérios de exclusão | 27 |
| 3.8 | Coleta de dados | 27 |
| 3.9 | Análise morfológica | 27 |
| 3.10 | Aquisição de imagens | 28 |
| 3.11 | Treinamento e calibração | 28 |
| 3.12 | Análise de imagens | 28 |
| <i>3.12.1</i> | <i>Análise Qualitativa</i> | 28 |
| <i>3.12.2</i> | <i>Análise por técnicas de inteligência artificial</i> | 30 |
| 3.13 | Análise estatística | 32 |
| 4 | ARTIGO | 33 |
| 5 | CONCLUSÃO | 49 |

| | |
|--|-----------|
| REFERÊNCIAS..... | 50 |
| ANEXO A- Parecer de aprovação do estudo pelo Comitê de Ética em Pesquisa com Seres Humanos da Universidade Estadual da Paraíba..... | 57 |
| ANEXO B - Normas da Revista..... | 59 |

1 INTRODUÇÃO

1.1 Lesões periapicais: epidemiologia, diagnóstico e tratamento

1.1.1 *Epidemiologia e etiopatogenia*

Nos últimos anos, com implementação de políticas públicas voltadas para o uso generalizado de flúor e a acessibilidade ao serviço odontológico, a prevalência, a severidade e a taxa de progressão de cárie regrediram em todo o mundo (KASSEBAUM *et al.*, 2015, WATT *et al.*, 2019). Apesar disso, a cárie dentária continua sendo a doença bucal mais comum que afeta a população mundial (VOZ *et al.*, 2016). A principal consequência da cárie não tratada é a necrose pulpar, embora trauma e fatores iatrogênicos também possam levar a esse resultado (ZERO *et al.*, 2011).

A infecção de um canal radicular após necrose pulpar pode disseminar-se para o periápice e induzir respostas teciduais e imunológicas frente a enzimas e toxinas de microrganismos que persistem cronicamente, provocando a reabsorção dos tecidos e o desenvolvimento de lesões periapicais, que podem ser classificadas histologicamente como granuloma periapical (GP), cisto radicular (CR) e abscesso periapical (AP) (KOIVISTO *et al.*, 2012). Os GPs consistem em tecido de granulação com células inflamatórias e fibroblastos, que eventualmente, podem evoluir quando restos epiteliais de Malassez, localizados no tecido periodontal, são estimulados por citocinas e fatores de crescimento a proliferar, desencadeando o surgimento de um CR. O AP reflete a formação de pus como consequência de uma mudança dinâmica celular em resposta a uma infecção aguda (ANDRADE *et al.*, 2013; VALDERHAUG, 1972).

Estudos epidemiológicos em diferentes populações mostram a doença periapical como uma condição generalizada, representando até 13,8% das lesões orais diagnosticadas nos centros de referência. Mulheres (56,1%), jovens (22,9%) e pessoas de cor de pele branca (59,2%) foram os pacientes mais acometidos. Os CRs representaram 8,29%, os GPs representaram 5,48%, e os ABs representaram 0,07%. As lesões eram predominantemente assintomáticas (28,1%) e tamanho ≤ 10 mm. O tamanho médio da lesão foi de 12,58 mm ($\pm 13,68$) e variou entre 0,1 mm e 150,0 mm. Em relação à localização anatômica, a região posterior de maxila (60,1%) teve a maior frequência de casos (COUTO *et al.*, 2021). Apesar da existência de uma variabilidade expressiva, dentre as periapicopatias, a literatura reporta

uma maior prevalência dos CRs e GPs (BERLINCK *et al.*, 2015; SULLIVAN *et al.*, 2016; TAVARES, 2017; VILLASIS-SARMIENTO *et al.*, 2017 E KAMMER *et al.*, 2019).

1.1.2 Diagnóstico e Tratamento

O diagnóstico e o planejamento do tratamento de LPs podem ser desafiadores para os cirurgiões-dentistas, em virtude da alta similaridade de suas características clínicas e radiográficas. Clinicamente as LPs são assintomáticas, descobertas muitas vezes, acidentalmente, em exames radiográficos de rotina. Testes de vitalidade pulpar auxiliam a direcionar o tratamento adequado para estas lesões, em que não será observado vitalidade pulpar (SULLIVAN *et al.*, 2016).

Ainda que vários estudos estabeleçam métodos de diagnóstico para a diferenciação de CR e GP antes da intervenção cirúrgica, sabe-se que o exame histológico ainda é o com maior sensibilidade e especificidade de diagnóstico destas lesões (ÇALIŞKAN *et al.*, 2016; NAIR., 1998), que se configura num recurso importante na previsibilidade do tratamento. Entretanto, torna-se cada vez mais escasso o acesso a cortes histológicos desta natureza, devido ao baixo encaminhamento dessas lesões pelos profissionais aos serviços de referência (SILVA *et al.*, 2017; KARAMIFAR, TONDARI E SAGHIRI, 2020).

O tratamento de LPs já é bem fundamentado na literatura e consiste na terapia endodôntica e, dependendo do grau de comprometimento dentário, a exodontia ou enucleação da lesão por apicectomia (BILODEAU; COLLINS, 2017). A detecção precisa de uma LP pode permitir um diagnóstico diferencial com potencial para um planejamento de métodos terapêuticos efetivos para desinfecção de canais com lesões de caráter persistente (ZHANG *et al.*, 2015), tal como os cistos periapicais, que estão relacionados com maiores causas de insucesso, quando comparado às outras entidades supracitadas (COUTO *et al.*, 2021). Além disso, dentes associados com AP mostram maiores quantidades de endotoxinas bacterianas. Assim, um correto diagnóstico auxilia no planejamento adequado do tratamento, favorecendo a desinfecção microbiana antes que progrida para estágios avançados, evitando a disseminação da doença para outros tecidos, a fim de minimizar complicações à saúde geral do paciente. (GOMES; ENDO; MARTINHO, 2012; SETZER *et al.*, 2017).

1.2 Radiografia periapical x tcfc: aplicabilidade e limitações

O exame radiográfico é essencial no diagnóstico das LPs, os recursos bidimensionais

mais comumente utilizados para identificar a periodontite apical (PA) na prática clínica são as radiografias periapicais (RPs) e as radiografias panorâmicas (RPs), que as representam como radioluscências associadas à região periapical de um dente. Tais exames oferecem evidências importantes sobre a progressão, regressão e persistência das PAs, além exibir informações como: número de raízes e sua conformação, assim como a presença ou ausência de lesões periapicais e sua localização, que norteiam e embasam o planejamento do tratamento endodôntico. (NAIR *et al.*, 1999; BECCONSALL-RYAN, TONG, LOVE, 2010; DUTRA *et al.*, 2016; HAAS *et al.*, 2016; KRUSE *et al.*, 2017)

No entanto, esses exames imagiológicos possuem limitações inerentes, uma vez que as informações obtidas desses exames correspondem a um aspecto bidimensional (2D) de uma estrutura tridimensional (3D), principalmente quando se trata de um dente multirradicular, assim, ocorrências como sobreposição e distorção de estruturas importantes não são incomuns e normalmente mascaram a PA (ESTRELA *et al.*, 2008; DUTRA *et al.*, 2016). A última declaração da *American Academy of Oral and Maxillofacial / American Association of Endodontists* relatou que a imagem de TCFC deve ser considerada a modalidade de escolha para o diagnóstico em pacientes que apresentam sinais e sintomas clínicos contraditórios ou inespecíficos (SCARFE WC. 2011).

Para ser visível radiograficamente, uma radioluscência periapical deve atingir cerca de 30-50% da perda óssea (NAKATA. 2006). Além disso, as lesões no osso esponjoso podem não ser consistentemente detectadas com estas técnicas radiográficas, e, em alguns casos, pesquisas indicaram que reabsorção óssea pode estar presente mesmo quando não há evidência radiográfica dela e sugerirem que a realização de uma TCFC para esses diagnósticos seria melhor empregado. (BENDER, 1982; BENDER; SELTZER, 2003; HEDESIU *et al.*, 2012).

A incorporação da TCFC tem sido utilizada em medicina desde os anos 70 e foi empregada na odontologia nos anos 80 (PAULA-SILVA, 2009) e a sua incorporação proporcionou uma revolução na informação de procedimentos clínicos que contribuem para planejamento, diagnóstico, tratamento e prognóstico (ESTRELA *et al.*, 2008, PATEL *et al.*, 2012), pois excede a capacidade de outras técnicas não invasivas para descrever características do osso periapical (TSAI *et al.*, 2012), oferecendo uma ferramenta alternativa que evitará possíveis intervenções desnecessárias (OKADA *et al.*, 2015). A tecnologia de imagem tridimensional tornou-se um recurso auxiliar comum na prática clínica com aproximadamente 80% de utilização entre endodontistas para diagnóstico e planejamento de tratamento (SETZER *et al.*, 2017).

Em comparação com a radiografia periapical convencional, a imagem da TCFC aumentou a precisão da detecção das lesões periapicais (DAVIES *et al.*, 2015). Uma meta-análise relatou os valores de acurácia de 0,96 para imagens TCFC, 0,73 para radiografia periapical convencional e 0,72 para radiografia periapical digital (DUTRA *et al.*, 2015). Através da TCFC, pesquisas também sugerem a possibilidade de determinar e diferenciar a PA em granuloma ou CR, sem o envolvimento de cirurgia e conseqüentemente, análise histopatológica. Características imaginológicas como localização, volume, extensão, definição de bordas, afastamento de raízes e radiolucidez foram associadas às estas lesões na tentativa de diferenciá-las (SHROUT *et al.*, 1993; WHITE *et al.*, 1994; SARAF *et al.*, 2014, MAO *et al.*, 2021).

Entretanto, uma revisão sistemática publicada recentemente indica que há dados insuficientes e ausência de evidências de qualidade para comparar o desempenho diagnóstico da imagem digital de radiografia periapical digital (RPD) e CBCT (YAPP, BRENNAN, EKPO, 2021) Fatores como tamanho da lesão (TSAI, TORABINEJAD, AZEVEDO, 2012), obturação radicular (KRUSE *et al.*, 2019) presença de artefatos de movimento (BOAS e FLEISCHMANN, 2012; SPIN-NETO *et al.*, 2020), experiência do observador (CAMPELO *et al.*, 2017) influenciam a interpretação da imagem e conseqüentemente, a exatidão diagnóstica. Isto enfatiza a necessidade de estudos bem concebidos para informar os clínicos sobre o desempenho relativo de diagnóstico destas modalidades de imagem (GUO *et al.*, 2013).

Nesse contexto, a TCFC se insere como uma ferramenta de grande auxílio no diagnóstico e planejamento das PAs. Devido à semelhança de características clínicas e imaginológicas entre as lesões supracitadas, ferramentas auxiliares, como manipulação de imagem através de software específicos e uso de IA, podem ser de grande aplicabilidade para os radiologistas durante o diagnóstico diferencial. Além disso, a IA surge como uma real possibilidade de aliar a tecnologia aos exames de imagem no sentido de aumentar a precisão, superar a variabilidade no exame subjetivo individual, reduzir o tempo necessário para avaliação e enfim aproximar-se do diagnóstico que determina a abordagem terapêutica mais adequada (LIANG *et al.*, 2014; PAUWELS, *et al.*, 2021).

1.3 Inteligência artificial

1.3.1 Considerações Iniciais

A IA é um ramo da ciência da computação aplicada que foi descrito pela primeira vez

por John McCarthy em 1956 (BINDUSHREE *et al.*, 2020). A IA foi descrita como a "quarta revolução industrial", que usa tecnologia de computador para simular comportamento inteligente, pensamento crítico e tomada de decisões semelhantes aos humanos, que possui capacidade de aprender com os dados que lhe são fornecidos e fazer previsões, podendo ser dividida em *machine learning* (ML) ou “aprendizado de máquina” e *deep learning* ou “aprendizado profundo”. Essas redes são caracterizadas por algoritmos que visam simular a arquitetura do cérebro humano, processando dados usando uma série de “neurônios” interconectados (HEO *et al.*, 2020).

O “*Deep Learning*” (DL) ou aprendizado profundo é uma subdivisão da IA e do aprendizado de máquina (ML), em que utiliza Redes Neurais Multicamadas (RNM) que superam os algoritmos de ML, em particular as estruturas de dados complexas, como imagens ou linguagem, cujo processo é baseado no funcionamento cognitivo visual biológico humano. O termo "profundo" refere-se a múltiplas camadas neurais entre as camadas de entrada e saída. Através de exposição dos dados de treinamento a camadas sucessivas de aprendizado, cada uma delas mais representativa que a anterior, o sistema aprende a reconhecer padrões de maneira automática. Dessa forma, quanto mais camadas um modelo tiver, maior sua profundidade de aprendizado (GOODFELLOW, 2016; SHIJIE *et al.*, 2017).

Uma RNM compreende a nós que podem ser da ordem de centenas a milhões configurados em várias camadas, e é geralmente considerada como uma implementação mais sofisticada de ML, capaz de realizar análises mais detalhadas, combinando mais dados e / ou capaz de representar níveis mais elevados de abstração. Cada nó recebe informações de outros nós e as saídas desses nós são ponderadas. A RNM visa maximizar as respostas corretas em comparação com uma referência ou verdade fundamentada, ajustando as ponderações em cada nó com base no erro calculado em cada propagação direta. A cada iteração, a solução matemática converge para uma solução mais precisa (MCBEE *et al.*, 2018, TANG *et al.*, 2018, CURRIE *et al.*, 2019).

O ML envolve a representação (aprendizado) de estruturas e padrões estatísticos intrínsecos nos dados, o que permite previsões para dados invisíveis. “Aprendizado profundo” é uma forma de aprendizado de máquina em que redes neurais (NNs) de várias camadas (profundas) são treinadas para aprender recursos de estruturas de dados complexas (por exemplo, dados de imagem ou linguagem). Estas técnicas oferecem a promessa de mais poder tenta melhorar a capacidade humana no tratamento de dados massivos e complexos (SCHWENDICKE, SAMEK, KROIS, 2020).

1.3.2 Semântica e Radiômica

Ao avaliar diferentes modalidades de imagem, os radiologistas identificaram características e estruturas de acordo com sua avaliação visual, ou seja, o que é perceptível aos seus olhos, são os chamados atributos semânticos. Dessa forma, as características semânticas podem ser definidas como características qualitativas que são coletadas de acordo com a avaliação individual e subjetiva dos radiologistas, mesmo que esses dados sejam adquiridos com a ajuda de softwares (YIP, 2017). São exemplos de características semânticas: localização, volume, extensão, definição de bordas e afastamento de raízes. (PAN, 2020).

Apesar da objetividade dos recursos semânticos, eles estão sujeitos a variabilidade interobservador e a natureza quantitativa da TC permite que vários recursos de imagem sejam definidos usando algoritmos matemáticos avançados que excedem a capacidade visual humana. Um campo passível de aplicação de IA é a Radiômica, que se objetiva na extração das características quantitativas de uma imagem por meio de fórmulas matemáticas para posterior análise de dados e tomada de decisões clínicas (WU, 2019; SHI, 2020). Esses atributos descritores de imagem podem ser: contraste, correlação, energia, homogeneidade, entropia, médias aparadas, curtose, assimetria, desvio padrão e variância (GONZALEZ, WOODS, 2002). Tecnicamente, as imagens são tabuladas em dados dimensionais mais elevados para pesquisar correlações que possam fazer previsões diagnósticas (HAWKINS, 2016; WU, 2019).

1.3.4 Aplicação de IA em Odontologia

Aplicações de IA em odontologia não têm sido rotineiras em consultórios odontológico, no entanto, o advento dessas tecnologias influenciou a imagiologia e o diagnóstico. Com a capacidade de realizar a segmentação automática das lesões, o DL com redes neurais convolucionais (CNNs) tornou-se o componente de IA predominante utilizado em cariologia (PRADOS-PRIVADO *et al.*, 2020), endodontia (HIRAIWA *et al.*, 2018) e diagnóstico. A pesquisa de IA em endodontia cresceu paralelamente a outras especialidades da odontologia.

A literatura vem mostrando resultados promissores em sua aplicabilidade, os modelos de IA podem ser projetados para fornecer orientação e suporte ao dentista em sua prática clínica, podendo auxiliar na detecção de LP (ENDRES *et al.*, 2020), fraturas radiculares (FUKUDA *et al.*, 2020), previsibilidade do retratamento (CAMPO *et al.*, 2016), determinação

de comprimento de trabalho (SAGHIRI *et al.*, 2012), morfologia do sistema de canais radiculares (HIRAIWA *et al.*, 2018; LAHOUD *et al.*, 2021), que contribuem efetivamente na tomada de decisão clínica e consequentemente na previsão do sucesso do tratamento endodôntico. (BINDUSHREE *et al.*, 2020; AMINOSHARIAE; KULILD; NAGENDRABABU, 2021; PAUWELS *et al.*, 2021).

O diagnóstico e o planejamento do tratamento de dentes com lesões periapicais podem ser desafiadores para os cirurgiões-dentistas. A detecção precoce pode aumentar o sucesso do tratamento e evitar a propagação da doença para os tecidos circunjacentes, minimizando repercussões na saúde geral do paciente (SETZER *et al.*, 2020).

Endres *et al.* (2020) relataram que um modelo de algoritmo de AP pode corresponder ao desempenho diagnóstico de 24 cirurgiões orais na detecção de radiolucências periapicais em radiografias panorâmicas. Um estudo comparou a capacidade de modelos CNN com 3 radiologistas orais em detectar LPs simuladas em radiografias intraorais. Eles concluíram que os valores médios de sensibilidade especificidade foram maiores no grupo CNN em comparação com as interpretações dos radiologistas (PAUWELS *et al.*, 2021). Ekert *et al.*, 2019 relataram que o potencial de CNNs profundo foi preciso na capacidade de detectar lesões apicais em radiografias panorâmicas em comparação com dentistas com mais de 10 anos de experiência clínica. No entanto, ambos os estudos foram conduzidos com um tamanho de amostra limitado e usaram radiografia panorâmica, uma ferramenta usada muito raramente por endodontistas para diagnóstico (PAUWELS *et al.*, 2021).

O processo de segmentação divide as imagens em múltiplas regiões não sobrepostas utilizando conjuntos de regras, tais como pixéis semelhantes ou características intrínsecas, para converter de uma forma significativa que possa ser convenientemente analisada. Essas imagens, podem ser segmentadas, por exemplo, em "lesão", "dente", "osso", "materiais restauradores" e "fundo". A medição volumétrica em TCFC, seguindo uma segmentação baseada em DL, foi reportada como sendo comparável aos resultados obtidos com a segmentação manual de LPs (BINDUSHREE *et al.*, 2020; ORHAN *et al.*, 2020; SETZER *et al.*, 2020; CHAN; TAY; GU; 2021). A segmentação de aprendizagem profunda provou ter excelente precisão na detecção de uma LP em imagens de TCFC (SETZER *et al.*, 2020). A confiabilidade da detecção correta de uma LP a partir de imagens de TCFC por um sistema CNN foi de 92,8% (ORHAN *et al.*, 2020).

A IA está progredindo rapidamente, com potenciais aplicações no diagnóstico, tratamento e previsões de prognóstico. Embora complexidades que surgem da aquisição de dados, interpretação, poder informático, a IA é vista como um excelente coadjuvante para os

cirurgiões-dentistas. Com um design cuidadoso e validação clínica a longo prazo, a IA pode ser de fácil utilização, transparente, reprodutível e imparcial. O desenvolvimento futuro da IA deve continuar a considerar o desenvolvimento humano como sua missão principal, com capacidade crescente em tratamento de grandes dados (BINDUSHREE *et al.*, 2020).

2 OBJETIVOS

2.1 Objetivo geral

Estabelecer um método auxiliar ao diagnóstico diferencial de GP e CR a partir de imagens tomográficas, utilizando o aprendizado de máquina, através de diferentes classificadores.

2.2 Objetivos específicos

- Caracterizar a amostra de acordo com as informações dos aspectos clínicos das lesões e informações sociodemográficas dos pacientes;
- Utilizar algoritmo de aprendizagem de máquina para agrupar as amostras (N = 23) da base de dados.

3 MATERIAIS E MÉTODOS

3.1 Aspectos éticos

O projeto foi cadastrado na Plataforma Brasil e submetido ao comitê de Ética Pesquisa envolvendo Seres Humanos da Universidade Estadual da Paraíba, recebendo parecer favorável (CAAE: 62593822.8.0000.5187), seguindo a Resolução nº 466/12 do Conselho Nacional de Saúde/ Ministério da Saúde.

3.2 Tipo do estudo

O estudo do tipo observacional, transversal e analítico através da análise de imagens de TCFC, utilizando o aprendizado de máquina.

3.3 População

Pacientes que apresentaram LPs, exame tomográfico e diagnóstico histopatológico de GP e/ou CR.

3.4 Amostra

A amostra foi do tipo não-probabilística, obtida por conveniência, composta por 14 casos de GP e 9 casos de CR.

3.5 Critérios de inclusão

- Casos de GP e CR, confirmados através de exames histopatológicos que possuíam exames de TCFC.

3.6 Critérios de exclusão

- Amostras que não apresentaram material biológico suficiente em bloco parafinado para a avaliação morfológica.

- Casos de GP que apresentaram ilhas de epitélio odontogênico.
- Exames que apresentem indícios ou artefatos de movimentação do participante.

3.7 Variáveis do estudo

Quadro 01 - Classificação das variáveis dependentes e independentes do estudo.

| | Descrição | Tipo | Categoria |
|--------------------------------|---|-----------------------|---|
| Variável dependente | | | |
| Desempenho diagnóstico | Desempenho dos algoritmos de classificação para diagnóstico de lesões periapicais | Quantitativa discreta | |
| Variáveis independentes | | | |
| Idade | Idade em anos do indivíduo | Quantitativa discreta | Número de anos |
| Sexo | Sexo | Categórica nominal | 1- Masculino 2- Feminino |
| Diagnóstico histológico | Aspectos morfológicos da lesão | Categórica nominal | 1- Cisto Radicular 2- Granuloma Periapical |

Fonte: Elaborada pelo autor, 2021.

3.8 Coleta de dados

A coleta de dados consistiu em preenchimento de ficha elaborada exclusivamente para esta pesquisa com informações clínicas dos pacientes (sexo e idade) e da lesão (localização anatômica e aspectos tomográficos).

3.9 Análise morfológica

As amostras foram fixadas em formol a 10% e incluídas em parafina, sendo submetidas a cortes com 5µm de espessura, os quais foram estendidos em lâminas de vidro e submetidos à coloração de rotina com hematoxilina e eosina. Sob microscopia de luz (Panthera L, Motic North America, Richmond, BC - Canada), um patologista oral experiente realizou a análise morfológica. Após emissão do laudo histopatológico, as lesões foram classificadas em CR ou GP.

Para os GPs os espécimes foram avaliados quanto a presença de tecido de granulação inflamado, circundado por uma parede de tecido conjuntivo fibroso com um infiltrado constituído predominantemente por linfócitos, plasmócitos, histiócitos. Para os casos de CRs, foi definido como uma cavidade revestida pela presença de epitélio escamoso estratificado. A parede do cisto consiste em tecido conjuntivo fibroso denso contendo um infiltrado inflamatório linfocitário permeado por plasmócitos, histiócitos e lúmen preenchido por fluido e resíduos celulares. (NEVILLE *et al.*, 2016).

3.10 Aquisição de Imagens

As imagens tomográficas foram adquiridas de pacientes com diagnóstico de GPs e CRs. Para este fim, utilizou-se o aparelho CS 9000 3D (Kodak, Dental Systems, a Carestream Health, Rochester, NY, EUA). As imagens foram salvas em pastas individualizadas para cada paciente em formato DICOM (*Digital Imaging and Communications in Medicine*) e avaliadas no CS 3D Imaging Software (Kodak Dental Systems, a Carestream Health, NY, EUA).

3.11 Treinamento e Calibração

As imagens foram avaliadas por um único radiologista experiente em análise de imagens tomográficas.


3.12 Análise das Imagens

3.12.1 Análise Qualitativa

De forma qualitativa, foram avaliados todos os volumes tomográficos com o auxílio do CS 3D Imaging Software (Kodak Dental Systems, Carestream Health, NY, EUA). A região da maxila e mandíbula e os dentes associados à lesão foram registrados.

A figura 1 mostra imagens de TCFC de um CR (A) e um GP (B). Foram selecionadas as incidências sagitais mais representativas das lesões periapicais (contendo a maior dimensão das lesões).

Figura 1 - Imagem de CBCT de lesões periapicais. **A**, Cisto Radicular; **B**, Granuloma Periapical



Fonte: Elaborada pelo autor, 2021.

3.12.2 Análise por técnicas de inteligência artificial

Segmentação

Para definir a região de interesse (ROI) realizou-se a segmentação manual, isolando apenas a área periapical dos dentes, acometida pelas lesões, com o intuito de preservar apenas a região relevante e descartar áreas com potencial de interferência na classificação.

Para realização da segmentação, os volumes tomográficos foram analisados no CS 3D Imaging Software (*Kodak Dental Systems, Carestream Health, NY, EUA*). Utilizando o modo de visualização oblíquo, onde é possível girar as reconstruções multiplanares e centralizá-las. Sendo assim, a reconstrução multiplanar coronal que melhor representou a lesão foi maximizada e uma captura de tela foi realizada com a ferramenta “câmera” do software.

A captura de tela foi importada para o GNU Image Manipulation Program (GIMP) onde realizou-se a segmentação manual da lesão. A ferramenta “Zoom” foi aplicada em 100% e com a ferramenta de “seleção livre” e “CTRL + X” a região correspondente a lesão foi isolada.

Para salvar a área isolada, se fez necessário criar uma imagem com plano de fundo transparente, utilizando as ferramentas “criar imagem”, “A4-300ppi”, “tamanho: 2x2 cm”, “tons de cinza” e “cor de fundo”. Logo criou-se uma imagem de 32 bits onde foi colada a região segmentada anteriormente. Essa imagem foi exportada em formato TIFF para ser analisada posteriormente.

Atributos de textura (Características Radiômicas)

As imagens tomográficas foram processadas por técnicas de visão computacional para extração de feições radiômicas, que são as características extraídas de uma imagem por meio de descritores estatísticos que descrevem quantitativamente características relacionadas à textura da imagem dentro da ROI.

Para treinamento dos modelos, atributos de textura foram extraídos por meio de método estatística de matriz de coocorrência em uma angulação padronizada de 0° , que consiste em uma contagem de quantas combinações de diferentes níveis de cinza ocorrem em uma imagem, ou seja, é uma tabulação de quantas combinações diferentes de valores de intensidade dos pixels (níveis de cinza) ocorrem em uma imagem, sendo empregada para caracterizar texturas em uma imagem através de um conjunto de estatísticas para as ocorrências de cada nível de cinza em pixels diferentes ao longo de diferentes direções. Os atributos extraídos foram contraste, correlação, energia, homogeneidade, dissimilaridade e segundo momento angular (SMA) (GONZALEZ; WOODS, 2002; SIQUEIRA; SCHWARTZ; PEDRINI, 2013). As definições desses atributos são apresentadas no quadro a seguir (quadro 1).

Quadro 2 - Definições de atributos

| NOME DO ATRIBUTO | DEFINIÇÃO |
|--------------------------------------|--|
| Contraste | Caracteriza-se pela diferença entre os tons de cinza entre um pixel e sua vizinhança. |
| Correlação | Mede a dependência linear entre os tons de cinza presentes em uma imagem. |
| Energia ou uniformidade | Retorna a soma dos elementos elevados ao quadrado dentro da matriz de co-ocorrência de tons de cinza. |
| Homogeneidade | Mede a proximidade da distribuição dos pixels dentro da matriz de coocorrência. |
| Dissimilaridade | Mostra o quão diferente são os pixels entre si dentro da matriz (na matriz de coocorrência mede a distância entre pares de pixels na região de interesse). |
| SMA (Segundo Momento Angular) | Também conhecido como energia, expressa a uniformidade de uma textura. |

Fonte: Elaborada pelo autor, 2021.

Atributos semânticos

De forma qualitativa, um radiologista experiente avaliou as características semânticas das lesões (localização, dimensões, limites, definição de bordas, presença de halo esclerótico, afastamento de raízes e reabsorção radicular) (PAN, 2020).

Classificadores utilizados

Foi utilizado o classificador K-MEANS para treinamento em diferentes cenários e métricas. Para avaliar e comparar os resultados foram utilizados sensibilidade, especificidade e acurácia. O modelo foi implementado conforme descrito a seguir:

Classificador K-MEANS

O K-MEANS é um algoritmo de aprendizagem de máquina do tipo não supervisionado, ou seja, os padrões não há classificação ou rótulo para os dados. Nesse tipo

de algoritmo, que também são chamados de algoritmos de clusterização, busca-se agrupar as amostras do conjunto de dados de acordo com a similaridade entre elas.

Basicamente o algoritmo K-MEANS define um número K de centroides que corresponde ao número de clusters. O valor de K é definido manualmente. Os centroides são iniciados em posições aleatórias no espaço amostral, assim cada amostra do conjunto de dados é associada a um cluster de acordo com a sua proximidade de um dos centroides. Em seguida, é realizado o cálculo das médias das distâncias das amostras de cada cluster em relação aos seus centroides, após obter as médias, os centroides são reposicionados repetidamente até que a convergência da média das distâncias. Em outras palavras, o objetivo do K-means é minimizar a distância entre cada amostra e o seu respectivo centroide.

3.13 Análise estatística

Para a análise do classificador (K- MEANS) entre os grupos, foi desenvolvida uma matriz de confusão, levando em consideração: especificidade, sensibilidade e acurácia, foram classificados de acordo com a classificação para testes diagnósticos, de Leonardi Dutra *et al.* (2016) com escores de >80% considerados resultados excelentes, entre 70% e 80% bons, entre 60% e 69% regular e <60% como ruim.

4 ARTIGO

Apresentação

O projeto de pesquisa foi desenvolvido e aprovado por qualificação do Programa de Pós-Graduação em Odontologia da UEPB. Mediante execução desse projeto, um artigo é apresentado nesta dissertação: *“Avaliação do aprendizado de máquina no diagnóstico diferencial de granulomas periapicais e cistos radiculares”*.

O artigo será submetido ao periódico Dento-Maxillo-Facial Radiology (ISSN: 0250-832X; Fator de impacto: 1.796; Qualis /Referência A2) e será colocado nas normas após avaliação da banca. As normas para submissão de trabalhos ao referido periódico são apresentadas no Anexo B.

Artigo a ser submetido**Avaliação do aprendizado de máquina no diagnóstico diferencial de granulomas periapicais e cistos radiculares**

Running title: Machine Learning in the diagnosis of periapical lesions

Pâmela de Medeiros Dantas¹, Elisa Diniz de Lima², Robeci Alves Macêdo-Filho³, Jose Alberto Souza Paulino⁴, John Lennon Silva Cunha⁶, Daniela Pita de Melo⁵, Cassiano Francisco Weege Nonaka⁵, Pollianna Muniz Alves⁵

¹Mestranda do Programa de Pós-graduação em Odontologia, Universidade Estadual da Paraíba

²Doutora em Clínicas Odontológicas, Universidade Estadual da Paraíba

³Doutorando do Programa de Pós-graduação em Odontologia, Universidade Estadual da Paraíba

⁴Doutorando do Programa de Ciências da Computação, Universidade Federal de Campina Grande

⁵Professores do Programa de Pós-graduação em Odontologia, Universidade Estadual da Paraíba

⁵Professor do departamento de Odontologia da Universidade Estadual da Paraíba

Autor correspondente:

Pollianna Muniz Alves

Endereço: Universidade Estadual da Paraíba. Departamento de Odontologia. Programa de Pós-graduação em Odontologia. Rua das Baraúnas, 351 - Bairro Universitário – 58429-500 - Campina Grande, PB – Brasil. Telefone: (83) 3315-3327.

Email: pmunizalves@gmail.com

RESUMO

Objetivo: Avaliar a utilização do aprendizado de máquina, através de TCFC, na diferenciação de Granulomas Periapicais (GPs) e Cistos Radiculares (CRs).

Metodologia: A amostra foi constituída por 14 casos de GPs e 9 casos de CRs, diagnosticados histopatologicamente. As reconstruções sagitais das tomografias foram avaliadas em 05 diferentes cortes, com o auxílio do CS3D Imaging Software. No software GIMP, versão 2.10, a região de interesse (RoI) foi segmentada e exportada em imagem formato TIFF com 32 bits. A partir da RoI, foram geradas matrizes de co-ocorrência e obtidos seis atributos de textura (contraste, dissimilaridade, correlação, energia, homogeneidade e segundo momento angular). O algoritmo de clusterização KMeans foi utilizado, com valor de K=2 para agrupar pacientes com atributos semelhantes.

Resultados: Em relação às características clínicas da amostra, 78,2% (n= 8) de GPs eram do sexo feminino, enquanto 100% dos casos de CRs eram do sexo masculino. A média de idade foi de 47,33 anos para CRs e 35,50 anos para GPs. Para o aprendizado de máquina foram avaliadas 105 imagens e observou-se 77,14% de acurácia, 47,06% de sensibilidade e 91,55% de especificidade no agrupamento das lesões.

Conclusão: Sugere-se que o uso da Inteligência Artificial apresenta resultados promissores para a diferenciação de GPs e CRs crônicas através de TCFC.

Palavras-Chaves: Lesão Periapical; Cisto Radicular; Tomografia Computadorizada; Inteligência Artificial; Diagnóstico.

INTRODUÇÃO

Estudos clínicos epidemiológicos em diferentes populações mostram a doença periapical como uma condição generalizada, representando até 13,8% das lesões diagnosticadas nos centros de referência (COUTO *et al.*, 2021). O diagnóstico de uma lesão periapical é definido a partir de seu exame histopatológico, entretanto, é necessária biópsia incisional ou excisional para tal finalidade (NAIR; 2000, PETERS; LAU, 2003)

A Tomografia Computadorizada de Feixe Cônico (TCFC) destaca-se como meio imaginológico complementar padrão-ouro na localização e determinação da extensão das lesões (SETZER *et al.*, 2017). É um método radiográfico que tem sido utilizado em diversas áreas da Odontologia que, diferentemente da radiografia Periapical (RP), permite a análise tridimensional (3D) de estruturas dentárias com alta resolução, sem distorção e sobreposição de estruturas, apresentando vantagens para detecção precoce das lesões periapicais (LPs), assim como seu tratamento e preservação (TSAI *et al.*, 2012; YILMAZ *et al.*, 2017). No entanto, em situações clínicas como lesões menores (TSAI, TORABINEJAD, AZEVEDO, 2012), presença de artefatos de movimento (SPIN-NETO *et al.*, 2020) e obturação radicular (KRUSE *et al.*, 2019), a precisão da TCFC é bastante reduzida, além disso, a interpretação da imagem pode ter baixa concordância entre os observadores (TSAI *et al.*, 2012; PARKER *et al.*, 2017; CAMPELO *et al.*, 2017).

O uso da inteligência artificial (IA) como ferramenta diagnóstica tem ganhado atenção na radiologia. A aplicação de sistemas de IA sugere forte potencial na precisão do reconhecimento de uma LP em imaginologia (SETZER *et al.*, 2020). Recentes publicações concluíram que a IA pode superar, no que diz respeito à sensibilidade e especificidade na detecção de LPs, a interpretação de radiologistas orais (ENDRES *et al.*, 2020). Portanto, o uso de IA pode aumentar a acurácia e produtividade, melhorando assim, a eficiência diagnóstica (PUTRA *et al.*, 2020; LIMA *et al.*, 2021).

O “*Machine Learning*” (ML), é um método de IA que se utiliza de técnicas de categorização de algoritmos construídas através do desenvolvimento de redes neurais artificiais (RNAs). Esse método permite que um conjunto de dados seja categorizado automaticamente e promove recursos de aprendizagem por meio de redes neurais convulsionais multicamadas (CNNs). As CNNs simulam a arquitetura do cérebro humano, processando dados utilizando uma série de neurônios interconectados capazes de aprender e aplicar os conhecimentos para realizar tarefas complexas, tais como prever resultados de tratamento, reconhecimento, diagnóstico e prognóstico de doenças, reduzindo,

consequentemente, as limitações humanas (CASTRO; OBLITAS; SANTO-CRUZ; AVILA-GEORGE, 2017; HUNG *et al.*, 2019).

No campo da radiologia odontológica, modelos de IA utilizados para fim diagnóstico e planejamento de tratamento abrangem uma vasta gama de situações clínicas, incluindo diagnóstico de cáries, lesões periodontais (LEE *et al.*, 2018), avaliação periapical/endodôntica (STEZER *et al.*, 2020), fraturas (JOHARI *et al.*, 2017; TALWAR *et al.*, 2016), morfologia radicular (HIRAIWA *et al.*, 2018) localização automática de estruturas anatômicas craniofaciais e alterações patológicas e no diagnóstico diferencial de LPs (OKADA *et al.*, 2015). No entanto, a maioria destes modelos foram desenvolvidos utilizando imagens de diagnóstico bidimensional (2D), tais como radiografias periapicais, panorâmicas, e cefalométricas, que possuem limitações que reduzem a precisão diagnóstica (PATEL *et al.*, 2009; DUTRA *et al.*, 2016).

Trabalhos recentes têm sugerido resultados revolucionários na utilização das CNNs como recurso auxiliar para a radiologia odontológica (ARIJI *et al.*, 2019; FUKUDA *et al.*, 2019; BINDUSHREE *et al.*, 2020; HEO *et al.*, 2020). A TCFC é considerada como uma fonte de dados ideal no desenvolvimento de modelos de IA para superar as limitações dos algoritmos baseados em imagens 2D, todavia, há poucos estudos na literatura que investigam o uso de IA através de imagens 3D no diagnóstico oral, sobretudo, de LPs (ORHAN *et al.*, 2019; SETZER *et al.*, 2020; PAUWELS *et al.*, 2021). Desta forma, objetivo deste trabalho é estabelecer um método auxiliar ao diagnóstico diferencial de GP e CR a partir de TCFC, utilizando o aprendizado de máquina, através de diferentes classificadores.

MATERIAIS E MÉTODOS

O estudo foi do tipo observacional, transversal e analítico através da análise de imagens de TCFC de GPs e CRs, diagnosticados histopatologicamente. A amostra por conveniência foi constituída por 14 casos de GPs e 9 casos de CRs. Foram excluídos da pesquisa os casos cujos blocos parafinados não apresentaram material suficiente para análise e os casos de granulomas que apresentaram ilhas de epitélio odontogênico. O estudo foi aprovado pelo Comitê de Ética da Universidade Estadual da Paraíba (Nº do protocolo 62593822.8.0000.5187).

A análise clínica foi realizada por meio dos dados presentes nas fichas clínicas (sexo, idade e localização anatômica). No estudo morfológico, os blocos parafinados foram submetidos a cortes histológicos de 5- μ m de espessura e levados à coloração de rotina com

hematoxilina-eosina. Para os GPs os espécimes foram avaliados quanto a presença de tecido de granulação inflamado, circundado por uma parede de tecido conjuntivo fibroso com um infiltrado constituído predominantemente por linfócitos, plasmócitos, histiócitos. Já para os casos de CRs, foi definido como uma cavidade revestida pela presença de epitélio escamoso estratificado. A parede do cisto consiste em tecido conjuntivo fibroso denso contendo um infiltrado inflamatório linfocitário permeado por plasmócitos, histiócitos e lúmen preenchido por fluido e resíduos celulares. (NEVILLE *et al.*, 2016).

As imagens de TCFC foram obtidas através do sistema CS 9000 3D (*Carestream Dental*) e salvas em pastas individualizadas para cada paciente. De forma qualitativa, um radiologista experiente avaliou todos os volumes tomográficos com o auxílio do CS 3D Imaging Software (*Kodak Dental Systems, Carestream Health, NY, EUA*). A região e os dentes associados à lesão foram registrados. Selecionou-se as incidências sagitais mais representativas das lesões periapicais (contendo a maior dimensão das lesões) e uma captura de tela foi realizada. A captura de tela foi importada para o GNU image manipulation program (GIMP – versão 2.10). Utilizando a ferramenta de seleção livre, a região de interesse (ROI) correspondente a lesão foi segmentada e exportada em imagem formato TIFF (Joint Photographic Experts Group) e de 32 bits.

Após a segmentação, 6 atributos de textura (contraste, dissimilaridade, correlação, energia, homogeneidade e segundo momento angular) foram extraídos das ROI com o auxílio de matrizes de co-ocorrência. Após a extração dos atributos, foi utilizada a análise por componentes principais para realizar a redução de dimensionalidade e selecionar os atributos mais significativos. Por fim, utilizou-se algoritmo classificador de aprendizado de máquina não-supervisionado (K- Means), com valor de $K=2$ para agrupar pacientes com atributos semelhantes a fim de calcular a acurácia, sensibilidade e especificidade do método. Os dados foram analisados através da estatística Hopkins a fim de identificar a presença de clusters.

Para a análise do classificador (K- Means) entre os grupos, foi desenvolvida uma matriz de confusão, levando em consideração: especificidade, sensibilidade e acurácia, foram classificados de acordo com a classificação para testes diagnósticos, de Leonardi Dutra *et al.* (2016) com escores de $>80\%$ considerados resultados excelentes, entre 70% e 80% bons, entre 60% e 69% regular e $<60\%$ como ruim.

De forma qualitativa, um radiologista experiente avaliou as características semânticas das lesões (localização, dimensões, limites, definição de bordas, presença de halo esclerótico, afastamento de raízes e reabsorção radicular).

RESULTADOS

Análise clínica e semântica

Foram avaliados 23 indivíduos, distribuídos em 14 (60,9%) casos de GPs e 9 (39,1%) casos de CRs. Em relação às características clínicas, 78,2% (n= 11) dos casos de GPs eram do sexo feminino, com média de idade de 35,50 anos, enquanto o grupo de CRs foi composto por 100% dos casos do sexo masculino com média de idade de 47,33 anos, exibindo diferença significativa ($p=0,017$) e se encontravam em região de maxila (GP= 57,1% e CR= 55,6%). Não houve diferenças estatisticamente significativas em relação às características imaginológicas das lesões (bordas, afastamento de raízes, reabsorção), porém, pode-se observar uma maior presença de halo esclerótico nos casos de GPs (85,7%) e uma média de dimensão discretamente maior em CRs ($M= 7,71\text{mm}$) que variou de 1,1mm à 26,25 mm.

Tabela 1 -Distribuição dos dados clínicos e imaginológicos dos casos de Granuloma Periapical e Cisto Radicular.

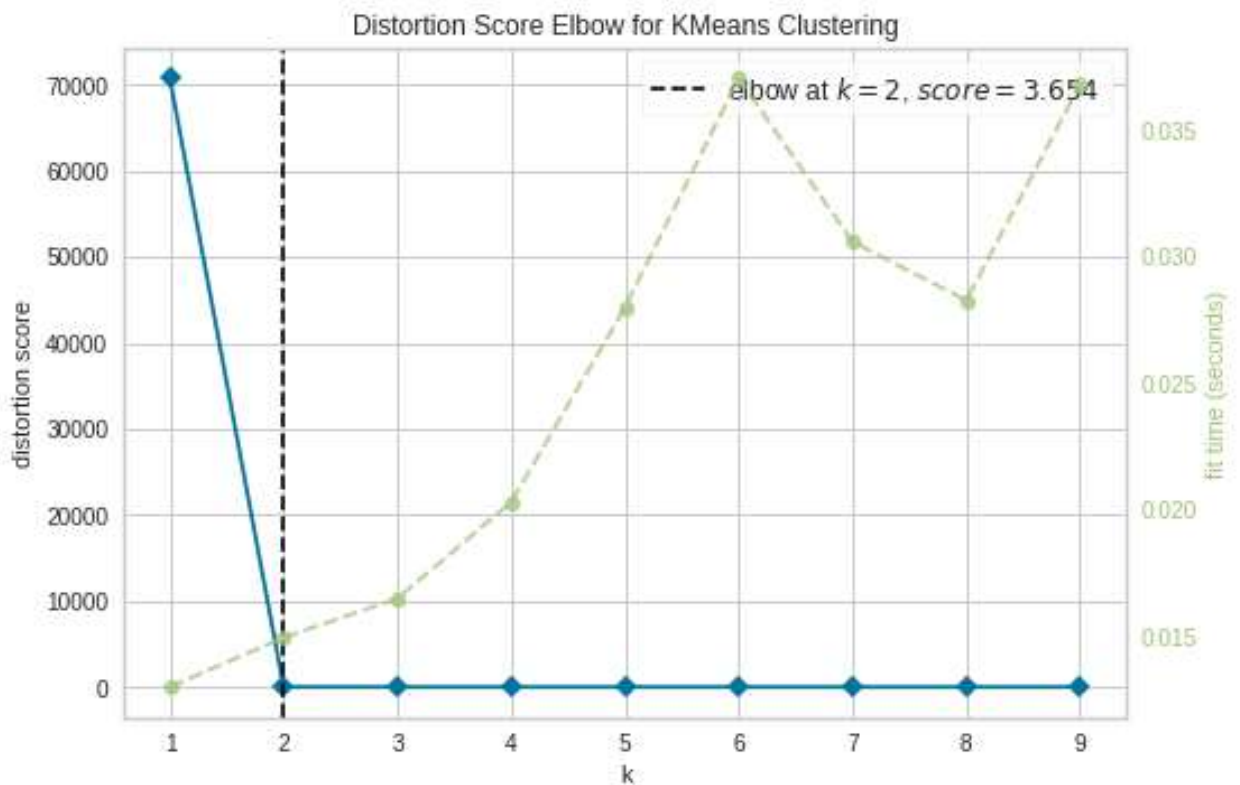
| <i>Variáveis</i> | <i>GP</i> | <i>CR</i> | <i>P</i> |
|--|------------------------|-----------------------|------------|
| Idade | 35,50±11,61 (19-58) | 47,33±9,91 (36-64) | 0,017 |
| Sexo | | | |
| Feminino | 11 (78,6%) | 0 (0%) | $p<0,0001$ |
| Masculino | 3 (21,4%) | 9 (100%) | |
| Localização | | | |
| Maxila | 8 (57,1%) | 5 (55,6%) | $p=1,000$ |
| Mandíbula | 6 (42,9%) | 4 (44,4%) | |
| Presença de halo | | | |
| Sim | 12 (85,7%) | 5 (55,6%) | $p=0,162$ |
| Não | 2 (14,3%) | 4 (44,4%) | |
| Dimensão da lesão (em mm ²) | 6,47±4,16 (1,75-16,60) | 7,71±7,48 (1,1–26,25) | $p=0,925$ |

Fonte: Elaborada pelo autor, 2021.

Análise das imagens de TCFC para aprendizado de máquina

Dada a característica da base de dados, o modelo desenvolvido separou a amostra em dois clusters, GP e CR, ou seja, $k = 2$. Se tratando de um modelo de aprendizado não supervisionado, o número de cluster é realizada manualmente e para verificar o valor ideal para k , pode ser adotado o método do cotovelo. A linha azul na figura 1 mostra, (de acordo com o método do cotovelo), que o valor ideal para k é 2, pois é possível perceber que não há variação à medida que o valor de k aumenta após esse valor. Além disso, o tempo de processamento aumenta proporcionalmente com o k . Assim, o número de cluster gerado pelo modelo corresponde às características do conjunto de dados.

Figura 2 - Validação do número de clusters ($K=2$).

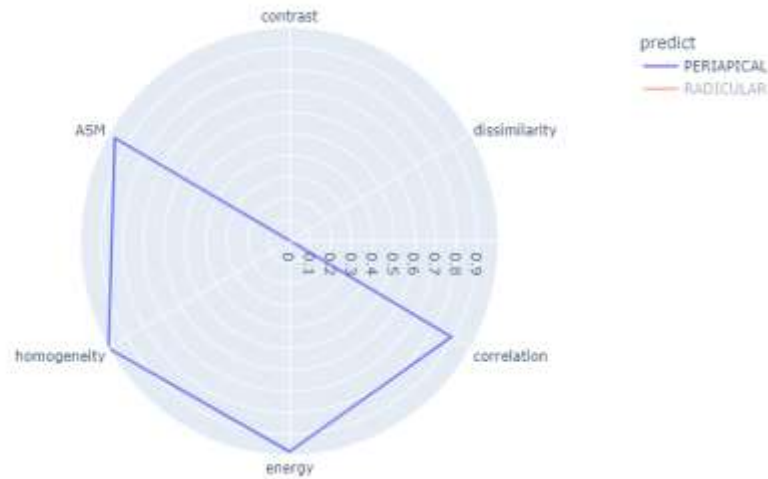


Fonte: Elaborada pelo autor, 2021.

Neste estudo, 6 atributos de textura (contraste, dissimilaridade, correlação, energia, homogeneidade e segundo momento angular) foram avaliados com o objetivo de caracterizar padrões por meio de atributos qualitativos de textura e possibilitar distinguir as amostras em GP e CR. Os gráficos 2 e 3 mostram o potencial descritivo das variáveis para as classes (GP e CR), respectivamente. A figura 2 mostra a relevância das variáveis: correlação, energia,

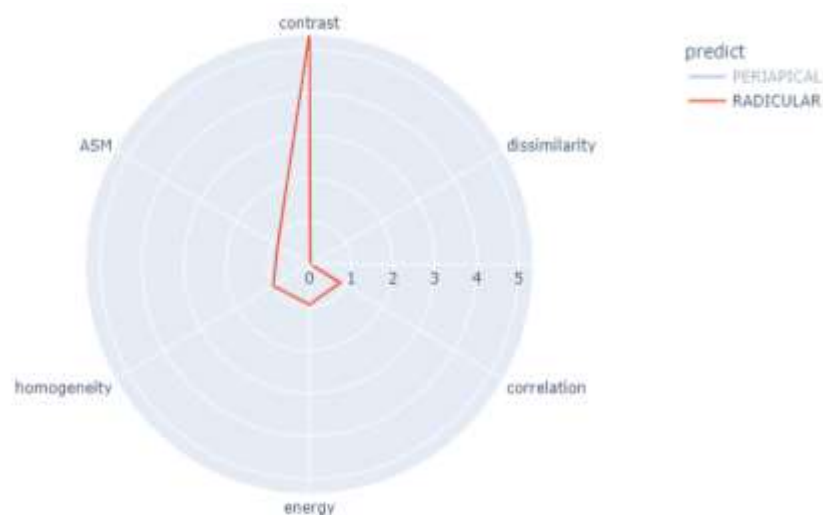
homogeneidade e SMA, para descrever os casos de GPs. Já a figura 3 mostra que o atributo contraste foi mais fortemente representativo para CRs.

Figura 3 - Potencial descritivo das variáveis em GP.



Fonte: Elaborada pelo autor, 2021.

Figura 4 - Potencial descritivo das variáveis em CR.




Fonte: Elaborada pelo autor, 2021.

A figura 4 mostra um comparativo do agrupamento das amostras relacionando as variáveis contraste e correlação. A figura 4(a) mostra o agrupamento das amostras de acordo

com o padrão ouro, ou seja, o agrupamento real. A figura 4(b) mostra o agrupamento obtido pelo modelo K-means. Foi possível perceber que o modelo separou os clusters de forma linear, as amostras marcadas de azul acima da linha vermelha tracejada, foram classificadas no primeiro cluster, ou classe GP. As amostras marcadas de verde abaixo da linha, foram classificadas no segundo cluster, ou classe CR.

Figura 5 - Clusters obtidos do modelo.



Fonte: Elaborada pelo autor, 2021.

Após a extração de recursos radiômicos, através da matriz de co-ocorrência, o classificador K-means exibiu resultados de 77,14% de acurácia, 47,6% de sensibilidade e 91,55% de especificidade para distinguir imagens entre os grupos (Tabela 3).

Tabela 2 - Matriz de confusão

| | GP | CR | |
|----|----|----|-------|
| | VP | FP | TOTAL |
| GP | 65 | 6 | 71 |
| CR | 16 | 18 | 34 |

Fonte: Elaborada pelo autor, 2021.

Tabela 3 - Valores de acurácia, sensibilidade e especificidade do conjunto de dados a partir dos métodos de extração de características radiômicas para o classificador avaliado.

| | K-MEANS |
|-----------------------|---------|
| ACURÁCIA | 77,14% |
| SENSIBILIDADE | 47,6% |
| ESPECIFICIDADE | 91,55% |

Fonte: Elaborada pelo autor, 2021.

Discussão

A TCFC tem sido amplamente utilizada para diagnóstico e planejamento do tratamento de lesões periapicais crônicas. Em comparação com a radiografia periapical convencional, a imagem da TCFC aumentou a precisão da detecção das LPs (DAVIES *et al.*, 2015). Uma meta-análise relatou os valores de acurácia de 0,96 para imagens TCFC, 0,73 para radiografia periapical convencional e 0,72 para radiografia periapical digital (DUTRA *et al.*, 2015). Características imaginológicas como localização, presença de cortical bem definida, volume, extensão, afastamento de raízes e radiolucidez foram associadas à estas lesões na tentativa de diferenciá-las (SHROUT *et al.*, 1993; WHITE *et al.*, 1994; SARAF *et al.*, 2014, ETOZ *et al.*, 2021, MAO *et al.*, 2021). No entanto, em nossa pesquisa, as análises semânticas não foram capazes de distinguir GPs dos CRs.

A IA como ferramenta diagnóstica tem ganhado atenção na área da radiologia, com diversos modelos apresentando resultados satisfatórios em diagnóstico de cáries, lesões periodontais (LEE *et al.*, 2018), avaliação periapical/ endodôntica (STEZER *et al.*, 2020), fraturas (JOHARI *et al.*, 2017; TALWAR *et al.*, 2016), morfologia radicular (HIRAIWA *et al.*, 2018) e diagnóstico de dtm (LIMA *et al.*, 2021). Estudos comparativos em imaginologia (SETZER *et al.*, 2020) para o diagnóstico de LPs revelam o potencial do uso de TCFC como uma fonte de dados ideal para o desenvolvimento de modelos de IA com vistas a superar limitações dos algoritmos baseados em imagens 2D, uma vez que demonstrou valores de sensibilidade de 93% e especificidade de 88%, superior ao alcançado por uma abordagem utilizando radiografias panorâmicas, a qual obteve sensibilidade de 65% e especificidade de 87% (EKTER *et al.*, 2019). Todavia, há poucos relatos na literatura da investigação do uso de IA através de imagens 3D no diagnóstico de lesões periapicais (ORHAN *et al.*, 2019;

SETZER et al., 2020; PAUWELS et al., 2021). Vale salientar que os pesquisadores se propuseram a detectar lesões periapicais crônicas sem, no entanto, diferenciá-las. Além disto, não houve exame histopatológico para confirmar o diagnóstico dessas lesões e diversos trabalhos sugerem que ainda há uma baixa concordância entre os observadores em análises radiográficas (ROSENBERG et al., 2010; PARKER et al., 2020).

A extração de recursos radiômicos têm valores em uma escala contínua que pode fornecer detalhes que distinguem diferentes lesões orais (YIP et al., 2017; Wu et al., 2021). Tecnicamente, as imagens são transformadas em dados numéricos para buscar correlações que possam definir um fenótipo radiográfico útil para o diagnóstico (LIMA et al., 2021). Pôde-se constatar que, nas lesões avaliadas, as imagens apresentaram um padrão de heterogeneidade maior do que com a inspeção visual. A partir dos atributos de textura extraídos da matriz de co-ocorrência, pudemos observar um potencial das variáveis correlação, energia, homogeneidade e ASM para descrever os casos de GPs, enquanto, o atributo contraste foi fortemente representativo para CRs, que corrobora as conclusões de DE ROSA et al., (2020). Além disso, o classificador K-means, algoritmo ideal para amostras menores, foi utilizado para avaliar a precisão da extração de recursos de ML e exibiu resultados de 77,14% de acurácia, 47,6% de sensibilidade e 91,55% de especificidade para distinguir imagens tomográficas entre os grupos. NURTANIO *et al.*, 2013 também utilizaram matriz de co-ocorrência para extração de características radiômicas para detecção de cistos com acurácia de 87,18%.

Este estudo é pioneiro em investigar o ML para diferenciação de LPs através de TCFC com confirmação histopatológica, apresentando metodologia inovadora e resultados promissores com potencial para ser utilizada em pesquisas futuras. Contudo, trabalhos com amostras mais representativas são necessários para desenvolvimento de software para ser utilizado em clínicas odontológicas e centros de radiologia.

Deste modo, a diferenciação de LPs através de imagens de TCFC, apresenta-se como um recurso importante na tomada de decisões clínicas, pois permite o planejamento de métodos terapêuticos efetivos direcionados ao perfil biológico dessas lesões.

Em conclusão, nossos resultados sugerem que, o uso da IA apresenta resultados promissores para a diferenciação de LPs através de imagens tomográficas. Contudo, trabalhos com amostras mais representativas são necessários para desenvolvimento de software para ser utilizado em clínicas odontológicas e centros de radiologia.

Conflito de Interesse

Os autores declaram não haver nenhum tipo de conflito de interesse para realização do presente estudo.

Referências

ANDRADE A. L. *et al.* Immunoexpression of interleukin 17, transforming growth factor β 1, and forkhead box P3 in periapical granulomas, radicular cysts, and residual radicular cysts. **J Endod.** v. 39, n. 8, p. 990-4. 2013

ARIJI, Y. *et al.* Automatic detection and classification of radiolucent lesions in the mandible on panoramic radiographs using a deep learning object detection technique. **Oral Surgery Oral Medicine Oral Pathology Oral Radiology**, v. 128, n.4, p.424-430, 2019.

BINDUSHREE, V. *et al.* Artificial intelligence: In modern dentistry. **Journal of Dental Research and Review**, v. 7, p. 27-31, 2020.

BRACKS, I. V. *et al.* Distribution of mast cells and macrophages and expression of interleukin-6 in periapical cysts. **J Endod.** v. 40, n. 1, p. 63-8. 2014

BRAZ-SILVA, P. H. *et al.* Inflammatory profile of chronic apical periodontitis: a literature review. **Acta Odontol Scand.** v. 77, p. 173-180, 2019.

CAMPELLO, F. A.; GONÇALVES, S. L.; GUEDES, R. F.; MARQUES, V. F. Cone-beam computed tomography versus digital periapical radiography in the detection of artificially created periapical lesions: A pilot study of the diagnostic accuracy of endodontists using both techniques. **Imaging Sci Dent.** v. 47, n.1, p. 25 – 31, 2017.

COUTO, M. A. *et al.* Chronic inflammatory periapical diseases: a Brazilian multicenter study of 10,381 cases and literature review. **Brazilian Oral Research.** v. 35, 2021.

DAVIES, A. *et al.* The detection of periapical pathoses in root filled teeth using single and parallax periapical radiographs versus cone beam computed tomography – a clinical study. **Journal of Endodontics.** v.48, p. 505-626, 2015.

DUTRA, L. K. *et al.* Diagnostic accuracy of cone-beam computed tomography and conventional radiography on apical periodontitis: A systematic review and meta-analysis. **Journal of Endodontics.** V. 42, p. 356-364, 2016.

ENDRES, G. M. *et al.* Development of a deep learning algorithm for periapical disease detection in dental radiographs. **Diagnostic.** v. 10, n. 6, p. 1-21, 2020.

ETÖZ, M. *et al.* Investigation of the effectiveness of CBCT and gray scale values in the differential diagnosis of apical cysts and granulomas. **Oral Radiol.** v. 1, p. 109 – 117, 2021.

FUKUDA, M *et al.* Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic radiography. **Oral Radiology** [in press], 2019.

HEO, S. M. *et al.* Artificial intelligence in oral and maxillofacial radiology: what is currently possible? **Dentomaxillofacial Radiology**, v. 50, n.3, 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, 2018.

HUNG, K. *et al.* The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review. **Dentomaxillofacial Radiology**. v.49, n.1, 2020.

JOHARI, M. *et al.* Detection of vertical root fractures in intact and endodontically treated premolar teeth by designing a probabilistic neural network: an ex vivo study. **Dentomaxillofacial Radiology**. v. 46, n. 2, 2017.

KOIVISTO, T.; BOWLES, R.; ROHRER, M.; Frequency and distribution of radiolucent jaw lesions: a retrospective analysis of 9,723 cases. **J Endod.** V. 38, p. 729-732, 2012.

KRUSE, C. *et al.* Diagnostic validity of periapical radiography and CBCT for assessing periapical lesions that persist after endodontic surgery. **Dentomaxillofac Radiol.** v. 46, n. 7, 2017.

LEE, H. J. *et al.* Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. **J dent.** v. 77, p. 106 – 111, 2018.

LEE, H. J. *et al.* Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm. **J Periodontal Implant Sci.** v. 48, n. 2, p. 114-123, 2018.

LIMA, D. E. *et al.* Artificial intelligence and infrared thermography as auxiliary tools in the diagnosis of temporomandibular disorder. **Dentomaxillofacial Radiology**. v. 50, p. 1 – 11, 2021.

MAO, W. Y. *et al.* Comparison of radiographical characteristics and diagnostic accuracy of intraosseous jaw lesions on panoramic radiographs and CBCT. **Dentomaxillofac Radiol.** v. 50, n. 2, 2021.

NAIR, P. N. Apical periodontitis: a dynamic encounter between root canal infection and host response. **Periodontol 2000**. v. 13, n. 1, p. 121-48, 1997.

NAIR, P. N. New perspectives on radicular cysts: Do they heal? **International Endodontic Journal**. v. 13, n. 3, p. 155-160, 1998.

NURTANIO, I. *et al.* Classifying cyst and tumor lesion using support vector machine based on dental panoramic images texture features. **International journal of computer Science**. V. 40, n. 1, p. 29 – 37, 2013.

OKADA, K. *et al.* Noninvasive differential diagnosis of dental periapical lesions in cone-beam CT scans. **Medical Physics**, v. 42, n. 4, p. 1653-1665, 2015.

ORHAN, K. *et al.* Evaluation of artificial intelligence for detecting periapical pathosis on cone-beam computed tomography scans. **J Endod.** v. 53, p. 680 – 689, 2020.

PATEL, S. *et al.* The detection of periapical pathosis using digital periapical radiography and cone beam computed tomography – Part 2: a 1-year post-treatment follow-up. **J endod.** v. 45, p. 711-713, 2012.

PARKER, J. *et al.* CBCT uses in clinical endodontics: the effect of CBCT on the ability to locate MB2 canals in maxillary molars. **International Endodontic Journal.** v. 20, n. 12, p. 1109 – 1115, 2017.

PAUWELS, R. *et al.* A brief introduction to concepts and applications of artificial intelligence in dental imaging. **Oral Radiology.** v. 37, p. 153 – 160, 2021.

PETERS, E.; LAU, M.; Histopathologic examination to confirm diagnosis of periapical lesions: a review. **J Can Dent Assoc.** v. 69, p. 598-600, 2003.

PUTRA, H. R. *et al.* Current applications and development of artificial intelligence for digital dental radiography. **Dentomaxillofac Radiol.** 2021.

SARAF, P. A. *et al.* Comparative evaluation of immunohistochemistry, histopathology and conventional radiography in differentiating periapical lesions. **J Conserv Dent,** v. 17, n. 2, p. 164-8, 2014.

SETZER, C. F. *et al.* A survey of cone-beam computed tomographic use among endodontic practitioners in the United States. **J endod.** v. 43, n. 5, p. 699-704, 2017.

SETZER, C. F. *et al.* Artificial intelligence for the computer-aided detection of periapical lesions in cone-beam computed tomographic images. **Journal of Endodontics,** v. 56, n. 7, p. 987- 993, 2020.

SPIN-NETO, R. *et al.* Impact of motion artefacts and motion-artefact correction on diagnostic accuracy of apical periodontitis in CBCT images: an ex vivo study in human cadavers. **International Endodontic Journal,** v.53, n.9, p. 1275-1288, 2020.

TALWAR, S. *et al.* Role of cone-beam computed tomography in diagnosis of vertical root fractures: a systematic review and meta-analysis. **Journal of endodontics.** v. 42, n.1, p. 12 – 24, 2016.

TSAI, P.; TORABINEJAD, M.; AZEVEDO, B. Accuracy of cone-beam computed tomography and periapical radiography in detecting small periapical lesions. **Journal of Endodontic.** v. 38, n.7, p. 965-970, 2012.

WHITE S. C.; SAPP, J. P.; SETO, B.G.; MANKOVICH, N. J. Absence of radiometric differentiation between periapical cysts and granulomas. **Oral Surg Oral Med Oral Pathol,** v. 78, n. 5, p. 650-4, 1994.

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

WU, W. *et al.* Comparison of prediction models with radiological semantic features and radiomics in lung cancer diagnosis of the pulmonary nodules: a case-control study. **Eur Radiol.** v. 29, n. 11, p. 6100-6108, 2021.

5 CONCLUSÃO

A partir dos nossos resultados pode se sugerir que, o uso da IA apresenta resultados promissores para a diferenciação de lesões periapicais crônicas através de imagens tomográficas.

Contudo, trabalhos com amostras mais representativas são necessários para o desenvolvimento de um software para ser utilizado em clínicas odontológicas e centros de radiologia.

REFERÊNCIAS

- AMINOSHARIAE, A.; KULILD, J.; NAGENDRABABU, V. Artificial Intelligence in Endodontics: Current Applications and Future Directions Evaluation of the accuracy values of cone-beam CT regarding apical. **J Endod.** V. 47, N. 9, P. 1352-1357, 2021.
- ANDRADE A. L. *et al.* Immunoexpression of interleukin 17, transforming growth factor β 1, and forkhead box P3 in periapical granulomas, radicular cysts, and residual radicular cysts. **J Endod.** v. 39, n. 8, p. 990-4. 2013
- ARIJI, Y. *et al.* Automatic detection and classification of radiolucent lesions in the b mandible on panoramic radiographs using a deep learning object detection technique. *Oral Surgery Oral Medicine Oral Pathology Oral Radiology*, v. 128, n.4, p.424-430, 2019.
- BATES, D.W. *et al.* The potential of artificial intelligence to improve patient safety: a scoping review. **npj Digit Med.** v. 4, n. 54, 2021.
- BECCONSALL-RYAN, K, TONG, D, LOVE, R. M. Radiolucent inflammatory jaw lesions: a twenty-year analysis. **Int Endod J**, v. 43, p.859-65, 2010.
- BENDER, I. B.; Factors influencing the radiographic appearance of bony lesions. **J endod.** V. 4, p. 161-170, 1982.
- BENDER, I. B.; SELTZER, S.; Roentgenographic and direct observation of experimental lesions in bone: I. **J Endod.** V.29, p. 702-706, 2003.
- BERLINCK, T. *et al.* Epidemiological evaluation of apical periodontitis prevalence in na urban Brazilian population. **Braz Oral Res**, v. 29, n.1, p. 1-7, 2015.
- BILODEAU, E. A.; COLLINS, B.M. Odontogenic Cysts and Neoplasms. **Surg Pathol Clin**, v. 10, n. 1, p. 177-222, 2017.
- BINDUSHREE, V. *et al.* Artificial intelligence: In modern dentistry. **Journal of Dental Research and Review**, v. 7, p. 27-31, 2020.
- BOAS, E. F.; FLEISCHMANN, D. CT artifacts: Causes and reduction techniques. **Imaging Med**, v. 4, n. 2, p. 229-240, 2012.
- BRACKS, I. V. *et al.* Distribution of mast cells and macrophages and expression of interleukin-6 in periapical cysts. **J Endod.** v. 40, n. 1, p. 63-8. 2014
- BRAZ-SILVA, P. H. *et al.* Inflammatory profile of chronic apical periodontitis: a literature review. **Acta Odontol Scand.** v. 77, p. 173-180, 2019.
- BRINKER, J. T. *et al.* Comparing artificial intelligence algorithms to 157 German dermatologists: the melanoma classification benchmark. **European Journal of Cancer.** v, 111, p. 30- 37, 2019.

CAMPELLO, F. A.; GONÇALVES, S. L.; GUEDES, R. F.; MARQUES, V. F. Cone-beam computed tomography versus digital periapical radiography in the detection of artificially created periapical lesions: A pilot study of the diagnostic accuracy of endodontists using both techniques. **Imaging Sci Dent.** v. 47, n.1, p. 25 – 31, 2017.

CAMPO, L. *et al.* Retreatment Predictions in Odontology by means of CBR Systems. **Comput Intell Neurosci.** V. 2016, p. 1-11, 2016.

ÇALIŞKAN, M. K.; KAVAL, M. E.; TEKİN U.; ÜNAL T. Radiographic and histological evaluation of persistent periapical lesions associated with endodontic failures after apical microsurgery. **Int Endod J,** v. 49, n. 11, p. 1011-1019, 2016.

CHENG, Y.; YU, Y. K-Means Clustering Algorithm-Based Functional Magnetic Resonance for Evaluation of Regular Hemodialysis on Brain Function of Patients with End-Stage Renal Disease. **Comput Math Methods Med.** V. 2022, p. 1-9, 2022.

CHOLLET, François. Deep Learning with Python. MANNING SHELTER ISLAND. New York, USA.

COUTO, M. A. *et al.* Chronic inflammatory periapical diseases: a Brazilian multicenter study of 10,381 cases and literature review. **Brazilian Oral Research.** v. 35, 2021.

CURRIE, G. *et al.* Machine Learning and Deep Learning in Medical Imaging: Intelligent Imaging. **Journal of medical imaging and radiation sciences.** V. 50, n. 4, p.477–487, 2019.

DAVIES, A. *et al.* The detection of periapical pathoses in root filled teeth using single and parallax periapical radiographs versus cone beam computed tomography – a clinical study. **Journal of Endodontics.** v.48, p. 505-626, 2015.

DUTRA, L. K. *et al.* Diagnostic Accuracy of Cone-beam Computed Tomography and Conventional Radiography on Apical Periodontitis: A Systematic Review and Meta-analysis. **Journal of Endodontics.** V. 42, p. 356-364, 2016.

ENDRES, G. M. *et al.* Development of a Deep Learning Algorithm for Periapical Disease Detection in Dental Radiographs. **Diagnostic.** v. 10, n. 6, p. 1-21, 2020.

ESTRELA, C. *et al.* Accuracy of Cone Beam Computed Tomography and Panoramic and Periapical Radiography for Detection of Apical Periodontitis. **Journal of Endodontics.** v. 35, p. 273-279, 2008.

ETÖZ, M. *et al.* Investigation of the effectiveness of CBCT and gray scale values in the differential diagnosis of apical cysts and granulomas. **Oral Radiol.** v. 1, p. 109 – 117, 2021.

FAZAL, M. I. *et al.* The past, present and future role of artificial intelligence in imaging. **Eur J Radiol.** v. 105, p. 246–50, 2018.

FUKUDA, M *et al.* Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic radiography. **Oral Radiology** [in press], 2019.

- GOMES, B. P.; ENDO, M. S.; MARTINHO, F. C. Comparison of endotoxin levels found in primary and secondary endodontic infections. **J Endod**, v. 38, n. 8, p. 1082-6, 2012.
- GONG, B. *et al.* Influence of Artificial Intelligence on Canadian Medical Students' Preference for Radiology Specialty: A National Survey Study. **Academic Radiology**. v.26, n.4, p. 566 – 577, 2019.
- GOODFELLOW, I. *et al.* Deep learning, volume 1. MIT press Cambridge, 2016.
- GUO, J. *et al.* Evaluation of the reliability and accuracy of using cone-beam computed tomography for diagnosing periapical cysts from granulomas. **Journal of Endodontics**. v. 39, n. 12, p. 1485 – 1490, 2013.
- HAAS, L. F. *et al.* Anatomical variations of mandibular canal detected by panoramic radiography and CT: a systematic review and meta-analysis. **Dentomaxillofac Radiol**. v. 45, n. 2, p. 03 – 10, 2016.
- HEO, S. M. *et al.* Artificial intelligence in oral and maxillofacial radiology: what is currently possible? **Dentomaxillofacial Radiology**, v. 50, n.3, 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, 2018.
- HUNG, K. *et al.* The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review. **Dentomaxillofacial Radiology**. v.49, n.1, 2020.
- JOHARI, M. *et al.* Detection of vertical root fractures in intact and endodontically treated premolar teeth by designing a probabilistic neural network: an ex vivo study. **Dentomaxillofacial Radiology**. v. 46, n. 2, 2017.
- KAMMER, V, P.; MELLO, W. F.; RIVERO, C. R. E. Comparative analysis between developmental and inflammatory odontogenic cysts: retrospective study and literature review. **Oral and Maxillofacial Surgery**, v. 24, p. 73 – 84, 2019.
- KASSEBAUM, N. J. *et al.* Global burden of untreated caries: a systematic review and metaregression. **J Dent Res**. v. 94, n.5, p. 650 – 658, 2015.
- KOIVISTO, T.; BOWLES, R.; ROHRER, M.; Frequency and distribution of radiolucent jaw lesions: a retrospective analysis of 9,723 cases. **J Endod**. V. 38, p. 729-732, 2012.
- KRUSE, C. *et al.* Diagnostic validity of periapical radiography and CBCT for assessing periapical lesions that persist after endodontic surgery. **Dentomaxillofac Radiol**. v. 46, n. 7, 2017.
- LAHOUD, P. *et al.* Artificial Intelligence for Fast and Accurate 3-Dimensional Tooth Segmentation on Cone-beam Computed Tomography. **Journal of Endodontics**. v. 47, n. 5, p. 827-835, 2021.

LEE, H. J. *et al.* Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. **J dent.** v. 77, p. 106 – 111, 2018.

LEE, H. J. *et al.* Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm. **J Periodontal Implant Sci.** v. 48, n. 2, p. 114-123, 2018.

LIANG, H. *et al.* Detection and measurement of artificial periapical lesions by cone-beam computed tomography. **Int Endod J.** v. 47, n.4, p. 332 – 338, 2014.

LIMA, D. E. *et al.* Artificial intelligence and infrared thermography as auxiliary tools in the diagnosis of temporomandibular disorder. **Dentomaxillofacial Radiology.** v. 50, p. 1 – 11, 2021.

MAO, W. Y. *et al.* Comparison of radiographical characteristics and diagnostic accuracy of intraosseous jaw lesions on panoramic radiographs and CBCT. **Dentomaxillofac Radiol.** v. 50, n. 2, 2021.

MCBEE, M. P. *et al.* Deep learning in radiology. **Acad Radiol,** V. 25, n. 11, p. 1472–1480, 2018.

NAIR, P. N. Apical periodontitis: a dynamic encounter between root canal infection and host response. **Periodontol 2000.** v. 13, n. 1, p. 121-48, 1997.

NAIR, P. N. New perspectives on radicular cysts: Do they heal? **International Endodontic Journal.** v. 13, n. 3, p. 155-160, 1998.

NAKATA, K. *et al.* Effectiveness of dental computed tomography in diagnostic imaging of periradicular lesion of each root of a multirooted tooth: a case report. **J Endod,** v. 32, n. 6, p. 583-7, 2006.

NURTANIO, I. *et al.* Classifying Cyst and Tumor Lesion Using Support Vector Machine Based on Dental Panoramic Images Texture Features. **International journal of computer Science.** V. 40, n. 1, p. 29 – 37, 2013.

OKADA, K. *et al.* Noninvasive differential diagnosis of dental periapical lesions in cone-beam CT scans. **Medical Physics,** v. 42, n. 4, p. 1653-1665, 2015.

ORHAN, K. *et al.* Evaluation of artificial intelligence for detecting periapical pathosis on cone-beam computed tomography scans. **J Endod.** v. 53, p. 680 – 689, 2020.

PRADOS-PRIVADO, M. *et al.* Dental Caries Diagnosis and Detection Using Neural Networks: A Systematic Review. **J. Clin. Med.** V. 9, n. 11, 2020.

PATEL, S. *et al.* The detection of periapical pathosis using digital periapical radiography and cone beam computed tomography – Part 2: a 1-year post-treatment follow-up. **J endod.** v. 45, p. 711-713, 2012.

PARKER, J. *et al.* CBCT uses in clinical endodontics: the effect of CBCT on the ability to locate MB2 canals in maxillary molars. **International Endodontic Journal**. v. 20, n. 12, p. 1109 – 1115, 2017.

PAULA-SILVA, F. W. *et al.* Accuracy of periapical radiography and cone-beam computed tomography scans in diagnosing apical periodontitis using histopathological findings as a gold standard. **J Endod**, v. 35, n. 7, p.1009-12. 2009.

PAUWELS, R. *et al.* A brief introduction to concepts and applications of artificial intelligence in dental imaging. **Oral Radiology**. v. 37, p. 153 – 160, 2020.

PETERS, E.; LAU, M.; Histopathologic examination to confirm diagnosis of periapical lesions: a review. **J Can Dent Assoc**. v. 69, p. 598-600, 2003.

PUTRA, H. R. *et al.* Current applications and development of artificial intelligence for digital dental radiography. **Dentomaxillofac Radiol**. 2021.

RAMIS-ALARIO, A. *et al.* Comparison of the diagnostic efficacy of 2D radiography and cone beam computed tomography in persistent apical periodontal disease: A PRISMA-DTA systematic review and meta-analysis. **Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology**. v. 132, n. 4, p. e153-e168. 2021.

SAGHIRI, M. A. *et al.* A new approach for locating the minor apical foramen using an artificial neural network. **Journal of Endodontics**, v. 45, n. 3, p. 257- 265, 2012.

-SARAF, P. A. *et al.* Comparative evaluation of immunohistochemistry, histopathology and conventional radiography in differentiating periapical lesions. **J Conserv Dent**, v. 17, n. 2, p. 164-8, 2014.

SCARFE, W.C.; Use of cone-beam computed tomography in endodontics Joint Position Statement of the American Association of Endodontists and the American Academy of Oral and Maxillofacial Radiology. **Oral Surg Oral Med Oral Pathol Oral Radiol Endod**. V. 111 (2), p. 234-237, 2011.

SETZER, C. F. *et al.* A Survey of Cone-beam Computed Tomographic Use among Endodontic Practitioners in the United States. **J endod**. v. 43, n. 5, p. 699-704, 2017.

SETZER, C. F. *et al.* Artificial Intelligence for the Computer-aided Detection of Periapical Lesions in Cone-beam Computed Tomographic Images. **Journal of Endodontics**, v. 56, n. 7, p. 987- 993, 2020.

SILVA, B. S. F. *et al.* Differential diagnosis and clinical management of periapical radiopaque/hyperdense jaw lesions. **Braz Oral Res**. v. 131, n. 3. 2017;

SPIN-NETO, R. *et al.* Impact of motion artefacts and motion-artefact correction on diagnostic accuracy of apical periodontitis in CBCT images: an ex vivo study in human cadavers. **International Endodontic Journal**, v.53, n.9, p. 1275-1288, 2020.

SULLIVAN, M.; GALLAGHER, G.; NOONAN, V.; The root of the problem: Occurrence of typical and atypical periapical pathoses. **J Am Dent Assoc**. V. 147, 646-649, 2016.

SCHILLING, J. *et al.* Regional 3D superimposition to assess temporomandibular joint condylar morphology. **Dentomaxillofac Radiol.** V. 43, 2014.

SCHWENDICKE, F.; SAMEK, W.; KROIS, J. Artificial Intelligence in Dentistry: Chances and Challenges. **Journal of Dental Research.** v. 99, n. 7, p.769-774, 2020.

SHIJIE, J. *et al.* Research on Data Augmentation for Image Classification Based on Convolution Neural Networks. In Chinese Automation Congress (CAC) IEEE, p. 4165-4170, 2017.

SHROUT, M.K.; HALL, J.M.; HILDEBOLT, C.E. Differentiation of periapical granulomas and radicular cysts by digital radiometric analysis. **Oral Surg Oral Med Oral Pathol,** v. 29, n. 3, p. 356-61, 1993.

TAVARES, D. P. *et al.* Clinical and radiological analysis of a series of periapical cysts and periapical granulomas diagnosed in a Brazilian population. **J Clin Exp Dent.** v. 9, n. 1, p. e129-135, 2017.

TALWAR, S. *et al.* Role of Cone-beam Computed Tomography in Diagnosis of Vertical Root Fractures: A Systematic Review and Meta-analysis. **Journal of endodontics.** v. 42, n.1, p. 12 – 24, 2016.

TANG, A. *et al.* Canadian association of radiologists white paper on artificial intelligence in radiology. **Can Assoc Radiol J,** V.69, N. 2, P. 120–135, 2018.

TSAI, P.; TORABINEJAD, M.; AZEVEDO, B. Accuracy of Cone-Beam Computed Tomography and Periapical Radiography in Detecting Small Periapical Lesions. **Journal of Endodontic.** v. 38, n.7, p. 965-970, 2012.

WHITE S. C.; SAPP, J. P.; SETO, B.G.; MANKOVICH, N. J. Absence of radiometric differentiation between periapical cysts and granulomas. **Oral Surg Oral Med Oral Pathol,** v. 78, n. 5, p. 650-4, 1994.

VAN DER BORDEN, G. W. *et al.* Area and 3-dimensional Volumetric Changes of Periapical Lesions after Root Canal Treatments. **Journal of Endodontics.** n. 39, n.10, p. 1245-1249, 2013.

VILLASIS-SARMIENTO, L. *et al.* Prevalence and distribution of odontogenic cysts in a Mexican sample: a 753 cases study. **J Clin Exp Dent,** v. 9, n. 4, p. e531- 538, 2017.

VOZ, T. *et al.* Global, regional, and national incidence, prevalence, and years lived with disability for 310 diseases and injuries, 1990-2015: a systematic analysis for the Global Burden of Disease Study 2015. **Lancet.** v. 388, n. 10053, p. 1545-602, 2016.

YAMASHITA, R. *et al.* Convolutional neural networks: an overview and application in radiology. **Insights Imaging,** v. 9, n. 4, p. 611-629, 2018.

YAPP, E.; BRENNAN, P.; EKPO, E.; Endodontic disease detection: digital periapical radiography versus cone-beam computed tomography-a systematic review. **J Med Imaging.** V. 8, n.4, 2021.

YIMAZ, F.; KAMBUROĞLU, K.; SENEL, G. Endodontic Working Length Measurement Using Cone-beam Computed Tomographic Images Obtained at Different Voxel Sizes and Field of Views, Periapical Radiography, and Apex Locator: A Comparative Ex Vivo Study. **Journal of Endodontics**. v. 43, n.1, p. 152 – 156, 2017.

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

Wu, W. *et al.* Comparison of prediction models with radiological semantic features and radiomics in lung cancer diagnosis of the pulmonary nodules: a case-control study. **Eur Radiol**. v. 29, n. 11, p. 6100-6108, 2021.

ZHANG, M. *et al.* Management of Apical Periodontitis: Healing of Post-treatment Periapical Lesions Present 1 Year after Endodontic Treatment. **Journal of Endodontics**, V. 41, n. 7, p. 1020-1025, 2015.

ZERO, D. T. *et al.* Dental caries and pulpal disease. **Dent Clin North Am**. v. 55, n. 1, p. 29-46, 2011.

ANEXO A – Parecer de aprovação do estudo pelo Comitê de Ética em Pesquisa com Seres Humanos da Universidade Estadual da Paraíba.

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: UTILIZAÇÃO DO APRENDIZADO DE MÁQUINA NO DIAGNÓSTICO DE LESÕES PERIAPICAIS CRÔNICAS ATRAVÉS DE IMAGENS TOMOGRÁFICAS

Pesquisador: POLLIANNA MUNIZ ALVES

Área Temática:

Versão: 2

CAAE: 62593822.8.0000.5187

Instituição Proponente: Universidade Estadual da Paraíba - UEPB

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 5.670.545

Apresentação do Projeto:

O estudo é do tipo observacional, transversal e analítico através da análise de imagens de TCFC, utilizando o aprendizado de máquina. A amostra será do tipo não-probabilística, obtida por conveniência, composta por 20 casos de GP e 20 casos de CR.

Objetivo da Pesquisa:

Objetivo geral

Estabelecer um método auxiliar ao diagnóstico diferencial de GP e CR a partir de imagens tomográficas, utilizando o aprendizado de máquina, através de diferentes classificadores.

Objetivos específicos

Caracterizar a amostra de acordo com as informações dos aspectos clínicos das lesões e informações sociodemográficas dos pacientes;

Avaliar diferentes classificadores para aprendizado de máquina (SVM, KNN e RNM);

Avaliar qual método de aprendizado de máquina para extração de atributos: radiômicos, semânticos e radiômicos-semânticos associados, é o mais efetivo para estabelecer o diagnóstico diferencial das LPs.

Avaliação dos Riscos e Benefícios:

Os riscos da pesquisa são medianos, uma vez que serão feitas análise provenientes de tomografias (exame invasivo). Salienta-se que as tomografias que farão parte do estudo, são aquelas pedidas para diagnóstico na clínica escola e não apenas para finalidade de pesquisa. Além disso, há a possibilidade de vazamento de dados pessoais, que serão devidamente resguardados pelo pesquisador. O participante poderá, ou não, autorizar a sua participação por meio do TCLE. Os benefícios desta pesquisa poderão superar os possíveis riscos, como a melhoria na acuidade diagnóstica das lesões periapicais e consequentemente tomadas clínicas de decisões mais efetivas para o paciente.

Comentários e Considerações sobre a Pesquisa:

A proposta do projeto é relevante, uma vez que proporciona um avanço no conhecimento, com a possibilidade do uso da Inteligência Artificial como adjuvante no diagnóstico de lesões.

Considerações sobre os Termos de apresentação obrigatória:

Folha de rosto: anexada;

Autorização Institucional: Anexada

Termo de Compromisso do Pesquisador Responsável: anexado

Termo de uso de banco de dados anexado.

Termo de Consentimento Livre e esclarecido: anexado

Recomendações:

O projeto é relevante, apresenta importância acadêmica e social. A metodologia está clara e adequada ao que se propõe. Todos os documentos foram anexados sem necessidade de alterações.

Conclusões ou Pendências e Lista de Inadequações:

O projeto apresenta todos os documentos necessários, desta forma está aprovado salvo melhor entendimento.

Considerações Finais a critério do CEP:**Este parecer foi elaborado baseado nos documentos abaixo relacionados:**

| Tipo Documento | Arquivo | Postagem | Autor | Situação |
|---|---|------------------------|---------------------------|----------|
| Informações Básicas do Projeto | PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO_2004952.pdf | 23/09/2022 23:41:35 | | Aceito |
| TCLE / Termos de Assentimento / Justificativa de Ausência | TCLE_.pdf | 23/09/2022 23:41:08 | PAMELA DE MEDEIROS DANTAS | Aceito |
| TCLE / Termos de Assentimento / Justificativa de Ausência | TERMO_DE_CONSENTIMENTO_LIVRE_E_ESCLARECIDO.pdf | 26/08/2022 15:22:31 | PAMELA DE MEDEIROS DANTAS | Aceito |
| Cronograma | CRONOGRAMA.pdf | 26/08/2022 14:33:01 | PAMELA DE MEDEIROS DANTAS | Aceito |
| Orçamento | ORCAMENTO.pdf | 26/08/2022 13:33:25 | PAMELA DE MEDEIROS DANTAS | Aceito |
| Projeto Detalhado / Brochura Investigador | Projeto_PamelaMedeiros.pdf | 26/08/2022 13:24:06 | PAMELA DE MEDEIROS DANTAS | Aceito |
| Declaração de Pesquisadores | TERMO_DE_COMPROMISSO_PARA_UTILIZACAO_DE_DADOS_DE_ARQUIVO_PRONTUARIOS.pdf | 26/08/2022 12:41:10 | PAMELA DE MEDEIROS DANTAS | Aceito |
| Declaração de Pesquisadores | TERMO_DE_COMPROMISSO_DO_PESQUISADOR_RESPONSAVEL_EM_CUMPRIR_OS_TERMOS_DA_RESOLUCAO_466.pdf | 26/08/2022 12:40:22 | PAMELA DE MEDEIROS DANTAS | Aceito |
| Declaração de Manuseio Material Biológico / Biorepositório / Biobanco | TERMO_DE_AUTORIZACAO_INSTITUCIONAL_PARA_USO_E_COLETA_DE_DADOS.pdf | 26/08/2022 12:39:46 | PAMELA DE MEDEIROS DANTAS | Aceito |
| Declaração de Instituição e Infraestrutura | TERMO_DE_AUTORIZACAO_INSTITUCIONAL_PARA_USO_E_COLETA_DE_DADOS.pdf | 26/08/2022 12:38:28 | PAMELA DE MEDEIROS DANTAS | Aceito |
| Declaração de Instituição e Infraestrutura | TERMO_DE_AUTORIZACAO_INSTITUCIONAL.pdf | 26/08/2022 12:36:42 | PAMELA DE MEDEIROS DANTAS | Aceito |
| Declaração de Pesquisadores | DECLARACAO_DE_CONCORDANCIA_COM_PROJETO.pdf | 26/08/2022 12:33:06 | PAMELA DE MEDEIROS DANTAS | Aceito |
| Folha de Rosto | Folha_de_rosto.pdf | 26/08/2022 10:38:19 | PAMELA DE MEDEIROS DANTAS | Aceito |

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:

Não

ANEXO B - Normas da Revista

For guidelines regarding word count, figure/table count and references for all DMFR article types see here.

Authors' names and affiliations should not appear anywhere on the manuscript pages or the images (to ensure blind peer-review).

Teeth should be designated in the text using the full English terminology. In tables and figures individual teeth can be identified using the FDI two-digit system, i.e. tooth 13 is the first permanent canine in the right maxilla region.

Author contribution statement

- DMFR requires that an author contribution statement accompany each submission, outlining the contributions of each author towards the work. A template statement can be downloaded here.
- DMFR requires that for all submitted papers:
- All the authors have made substantive contributions to the article and assume full responsibility for its content; and
- All those who have made substantive contributions to the article have been named as authors.
- The International Committee of Medical Journal Editors recommends the following definition for an author of a work, which we ask our authors to adhere to:
- Authorship be based on the following 4 criteria [1]:
- Substantial contributions to the conception or design of the work; or the acquisition, analysis, or interpretation of data for the work; AND
- Drafting the work or revising it critically for important intellectual content; AND
- Final approval of the version to be published; AND
- Agreement to be accountable for all aspects of the work in ensuring that questions related to the accuracy or integrity of any part of the work are appropriately investigated and resolved.
- 1 The International Committee of Medical Journal Editors, Roles and Responsibilities of Authors, Contributors, Reviewers, Editors, Publishers, and Owners: Defining the Role of Authors and Contributors, http://www.icmje.org/roles_a.html

Title page

- The title page is a separate submission item to the main manuscript and should provide the following information:
- Title of the paper. Abbreviations other than CT or MRI should not be used in the title.
- A shortened version of the title (no more than 70 characters in length, including spaces) should be provided for use as the running head. Abbreviations are permissible.
- Type of Manuscript (see all types of manuscript)
- Author names should appear in full (in the format: "first name, initial(s), last name), qualifications and affiliations.
- Statement indicating any source of funding or financial interest where relevant should be included.
- A cover letter or statement can be included into the title page, but please note this is not a compulsory item.

Blind title page

- A blind title page should be included with the full manuscript, giving only the title (i.e. without the authors' names and affiliations), for use in the peer-review process.

Abstract

- The abstract should be an accurate and succinct summary of the paper, not exceeding 250 words. For papers containing research: the abstract should be constructed under the following subheadings:
 - Objectives;
 - Methods;
 - Results;
 - Conclusions.
- These subheadings should appear in the text of the abstract and the abstract should not contain references. The abstract should: indicate the specific objective or purpose of the article; describe the methods used to achieve the objective, stating what was done and how it was done; present the findings of the methods described – key statistics should be included; present the conclusion of the study based solely on the data provided, and highlight the novelty of the work.
- Beneath the abstract please select up to 5 keywords from the current Medical Subject Headings (MeSH).

Main text

- Please organise your paper in a logical structure with clear subheadings to indicate relevant sections. It is up to the authors to decide the specific nature of any subheadings as they see fit. Research papers typically follow the structure:
 - Introductory section;
 - Methods and materials/patients;
 - Results;
 - Discussion;
 - Conclusion;
 - Acknowledgments (if relevant).
- Present results in a clear logical sequence. The conclusions drawn should be supported by the results obtained and the discussion section should comment critically on the findings and conclusions as well as any limitations of the work.
- Acknowledgments should be brief and should indicate any potential conflicts of interest and sources of financial support.
- An appendix may be used for mathematical formulae or method details of interest to readers with specialist knowledge of the area.

In addition:

- Avoid repetition between sections.
- Avoid repetition of text featured in tables and the main body of the article.
- Abbreviations and acronyms may be used where appropriate, but must always be defined where first used.
- The names and locations (town, country) of manufacturers of all equipment and non-generic drugs must be given.
- Avoid the use of footnotes.

- Use SI units throughout the text (Grays, Sieverts not RADs and REMs).

References

- Authors are responsible for the accuracy of the references. Only papers closely related to the work should be cited; exhaustive lists should be avoided. All references must appear both in the text and the reference list.
- References should follow the Vancouver format.
- In the text, references are cited in numerical order as superscript numbers starting at 1. The superscript numbers are placed AFTER the full point.
- At the end of the paper they should be listed (double-spaced) in numerical order corresponding to the order of citation in the text.
- A reference cited in a table or figure caption counts as being cited where the table or figure is first mentioned in the text.
- Papers in press may be included in the list of references.
- Do not include references to uncompleted work or work that has not yet been accepted for publication. Abstracts and/or papers presented at meetings not in the public domain should not be included as references.
- References to private communications should be given only in the text (i.e. no number allocated). The author and year should be provided.
- If there are 6 or fewer authors, list them all. If there are 7 or more, list the first 6 followed by et al.
- Abbreviations for titles of medical periodicals should conform to those used in the latest edition of Index Medicus.
- The first and last page numbers for each reference should be provided.
- Abstracts and letters must be identified as such.

Examples of references:

Journal article:

Gardner DG, Kessler HP, Morency R, Schaffner DL. The glandular odontogenic cyst: an apparent entity. *J Oral Pathol* 1988; 17:359–366.

Journal article, in press:

Dufoo S, Maupome G, Diez-de-Bonilla J. Caries experience in a selected patient population in Mexico City. *Community Dent Oral Epidemiol* (in press).

Complete book:

Kramer IRH, Pindborg JJ, Shear M. *Histological typing of odontogenic tumours* (2nd edn). Berlin: Springer Verlag, 1992.

Chapter in book:

DelBalso AM, Ellis GE, Hartman KS, Langlais RP. Diagnostic imaging of the salivary glands and periglandular regions. In: DelBalso AM (ed). *Maxillofacial imaging*. Philadelphia, PA: WB Saunders, 1990, pp 409–510.

Abstract:

Mileman PA, Espelid I. Radiographic treatment decisions - a comparison between Dutch and

Norwegian practitioners. *J Dent Res* 1986; 65: 609 (Abstr 32).

Letter to the Editor:

Gomez RS, de Oliveira JR, Castro WH. Spontaneous regression of a paradental cyst. *Dentomaxillofac Radiol* 2001; 30: 296 (letter).

Journal article on the internet:

Aboud S. Quality improvement initiative in nursing homes: the ANA acts in an advisory role. *Am J Nurs* [serial on the Internet]. 2002 Jun [cited 2002 Aug 12];102(6):[about 3 p.]. Available from: <http://www.nursingworld.org/AJN/2002/june/Wawatch.htm>.

Homepage/Web site:

Cancer-Pain.org [homepage on the Internet]. New York: Association of Cancer Online Resources, Inc.; c2000-01 [updated 2002 May 16; cited 2002 Jul 9]. Available from: <http://www.cancer-pain.org/>.

Tables

Tables should be referred to specifically in the text of the paper but provided as separate files.

- Number tables consecutively with Arabic numerals (1, 2, 3, etc.), in the order in which they appear in the text.
- Give each table a short descriptive title.
- Make tables self-explanatory and do not duplicate data given in the text or figures.
- Aim for maximum clarity when arranging data in tables. Where practicable, confine entries in tables to one line (row) in the table, e.g. “value (\pm sd) (range)” on a single line is preferred to stacking each entry on three separate lines.
- Ensure that all columns and rows are properly aligned.
- Include horizontal rules at the top and bottom of a table and one below the column headings. If a column heading encompasses two or more subheadings, then the main headings and subheadings should be separated by a single short rule. No other rules should be included, neither horizontal nor vertical.
- Appropriate space should be used to separate columns. Rows should be double-spaced.
- A table may have footnotes if necessary. These should be referred to within the table by superscript letters, which will then also be given at the beginning of the relevant footnote. Begin each footnote on a new line. A general footnote referring to the whole table does not require a superscript letter.
- Define abbreviations in tables in the footnotes even if defined in the text or a previous table.
- Submit tables as editable text.

Figures

Figures should be referred to specifically in the text of the paper.

- Number figures consecutively using Arabic numerals (1, 2, 3, etc.) and any figure that has multiple parts should be labelled alphabetically (e.g. 2a, 2b).
- Concise, numbered legend(s) should be listed on a separate sheet. Avoid repeating

material from the text.

- Abbreviations used in figures should be defined in the caption.
- Labelling of artwork should be Arial 8 point font.
- Ideally, figure sizes should be 84 mm wide, 175 mm wide or the intermediate width of 130 mm.

Files

- Supply image files in EPS, TIFF, PDF or JPEG format.
- TIFF is preferred for halftones, i.e. medical images such as radiographs, MR scans etc.
- EPS is preferred for drawn artwork (line drawings and graphs).
- For JPEG files, it is essential to save at maximum quality, i.e. “10”, to ensure that quality is satisfactory when the files are eventually decompressed.
- Files supplied in Word, PowerPoint or Excel may prove acceptable, but please supply in EPS, TIFF or JPEG if practicable. Other formats will not be usable.
- Do not supply GIF files – GIF is a compressed format that can cause quality problems when printed.
- Upload each figure separately and numbered.

Colour

- Unless essential to the content of the article, all illustrations should be supplied in black and white with no colour (RGB, CMYK or Pantone references) contained within them.
- The cost of reproduction of colour images will be charged to the author at the following rates: £300 for one colour image, £500 for two colour images and £100 for each subsequent additional colour image. All prices are exclusive of UK VAT.
- Images that do need to be reproduced in colour should be saved in CMYK, with no RGB or Pantone references contained within them.

Resolution

- Files should be saved at the appropriate dpi (dots per inch) for the type of graphic (the typical screen value of 72 dpi will not yield satisfactory printed results). Lower resolutions will not be usable.
- Line drawings – save at 800 dpi (or 1200 dpi for fine line work).
- Halftone and colour work – save at 300 dpi.

Composition

- The image should be cropped to show just the relevant area (i.e. no more than is necessary to illustrate the points made by the author whilst retaining sufficient anatomical landmarks). The amount of white space around the illustration should be kept to a minimum.
- Supply illustrations at the size they are to be printed, usually 76 mm wide (single column of text) or for especially large figures 161 mm (two columns of text).
- Annotations, e.g. arrows, should be used to indicate subtle but salient points. All annotations should be included within the images supplied.
- Patient identification must be obscured.

Additional points to note:

- Do not put a box around graphs, diagrams or other artwork.
- Avoid background gridlines unless these are essential (e.g. confidence limits).
- Fonts should be Adobe Type 1 standard – Helvetica or Times are preferred.
- Ensure that lettering is appropriately sized – should correspond to 8 or 9 pt when printed.
- Include all units of measurement on axes.
- All lines (e.g. graph axes) should have a minimum width of ¼ pt (0.1 mm) otherwise they will not print; 1 pt weight is preferable.
- Avoid using tints (solid black and white or variations of crosshatching are preferred), but any tints that are used must be at a minimum 5% level to print (but do not use too high a tint as it may print too dark).
- Do not use three-dimensional histograms when the addition of a third dimension gives no further information.

Appendices

- Appendices should be used to include detailed background material that is essential for the understanding of the manuscript e.g. statistical analyses, very detailed preliminary studies, but which is too comprehensive to include as part of the main text.
- Where possible, authors are encouraged to include all relevant material in the main body of the text, however, if an appendix is necessary it should be supplied as a separate file. If more than one appendix is included, these should be identified using different letters.
- An appendix may contain references, but these should be listed separately and numbered A1, A2, etc.
- Appendices must be referred to in the main text in the relevant section.

Supplementary material

- Supplemental material is intended for material that would add value to your manuscript but is not essential to the understanding of the work. Supplementary material is typically used for including material that can not be accommodated in print form, for example multimedia files such as dynamic images, video/audio files etc.
- There are no restrictions on supplementary file formats, though it is recommended that authors choose file types that the majority of readers will be able to open e.g.
- Text/Data: PDF, Word, Excel, Powerpoint, .txt
- Graphics: TIF, PNG, JPEG, GIF
- Video: AVI, MOV, MP4, MPEG, WMV
- Audio: mp3, m4a

Units, symbols and statistics

- Authors should use the International System of Units (SI) [1]. Units of radiation should be given in SI, e.g. 1 Sv, 1 Gy, 1 MBq. Exceptions are mmHg for blood pressure and g dl⁻¹ for haemoglobin. For guidance, authors can refer to the publication Units, Symbols and Abbreviations. A guide for medical and scientific authors [2].
- All radiation factors (dose/time/fractionation) must be listed.
- Equations should be numbered (1), (2) etc. to the right of the equation. Do not use punctuation after equations.
- Do not include dots to signify multiplication – parameters should simply be typed

closed up, or with a multiplication sign if necessary to avoid ambiguity.

Statistical Guidelines

The aim of the study should be clearly described and a suitable design, incorporating an appropriate number of subjects, should be used to accomplish the aim. It is frequently beneficial to consult a professional statistician before undertaking a study to confirm it has adequate power, and presentation of a power calculation within the paper demonstrates the ability of the study to detect clinically or biologically meaningful effects.

Details should be provided on selection criteria, whether data were collected prospectively or retrospectively, and any exclusions or losses to follow-up that might affect the study population. Information on subject characteristics in groups being compared should be given for any factors that could potentially bias the comparison of the groups; such information is often best presented in a tabular format in which the groups are in adjacent columns. If the study was randomized, details of the randomization procedure should be included.

Measures of variation should be included for all important results. When means are presented, the standard deviation or the standard error of the mean should also be given, and it should be clear which of these two measures is being quoted. When medians are given, measures of variation such as the interquartile range or overall range should also be included. Estimates of differences, e.g. between two means being compared, should be provided with 95% confidence limits to aid the reader and author to interpret the results correctly. Note that estimation of the size of effects, e.g. treatment or prognostic factor effects, is as important as hypothesis testing.

Statistical procedures should be described and referenced for all p-values given, and the values from which they were derived should be included. The validity of statistical procedures should also be confirmed, e.g. the t-test requires normal distribution(s) in the basic data and the chi-squared test is not valid when the expected numbers in cells are less than 5. Data may sometimes be transformed, e.g. using a log or square root transformation, to achieve normality. Non-parametric tests should be used when the conditions for normality are not met. It should be noted, however, that the Wilcoxon signed rank test (the non-parametric equivalent of the paired t-test) is semi-quantitative. If more than two groups are being compared then an analysis of variance should be performed before undertaking comparisons of pairs of groups. You are advised to seek the help of a professional statistician if you are uncertain of the appropriateness or interpretation of statistical methods.

Analysis of repeated measurements on the same subject can give rise to spurious results if comparisons are made at a large number of different time points. It is frequently preferable to represent each subject's outcome by a single summary measure chosen for its appropriateness. Examples of such measures are the area under the curve, the overall mean, the maximum or minimum, and the time to reach a given value. Simple statistics can then be applied to these summary measures.

The results of the evaluation of a test procedure should state clearly the criteria used to define positivity, and the sensitivity, specificity, positive predictive value and negative predictive value should all be quoted together with their 95% confidence limits.

1. Goldman DT, Bell RJ, eds. The International System of Units (SI). 5th edn. London, UK: HMSO; 1987.

2. Baron DN, ed. Units, symbols and abbreviations. A guide for medical and scientific authors. 5th edn. London, UK: Royal Society of Medicine Press; 1994.