



**UNIVERSIDADE FEDERAL DA BAHIA**  
**FACULDADE DE ODONTOLOGIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ODONTOLOGIA E SAÚDE**

**MAYARA SIMÕES BISPO**

**ANÁLISE DO DESEMPENHO DE REDE NEURAL  
CONVOLUCIONAL NA CLASSIFICAÇÃO AUTOMÁTICA DE  
IMAGENS TOMOGRÁFICAS DE QUERATOCISTOS  
ODONTOGÊNICOS E AMELOBLASTOMAS**

Salvador  
2020

**MAYARA SIMÕES BISPO**

**ANÁLISE DO DESEMPENHO DE REDE NEURAL  
CONVOLUCIONAL NA CLASSIFICAÇÃO AUTOMÁTICA DE  
IMAGENS TOMOGRÁFICAS DE QUERATOCISTOS  
ODONTOGÊNICOS E AMELOBLASTOMAS**

Dissertação apresentada ao Programa de Pós-graduação em Odontologia e Saúde da UFBA como parte dos requisitos essenciais à obtenção do Título de Mestre.

Orientadora: Prof<sup>a</sup> Dr<sup>a</sup> Iêda Margarida Crusoé Rocha Rebello

Salvador  
2020

A

Edna, minha amada mãe, por toda dedicação e amor a mim direcionados.

Renilton, meu amado pai, por nunca medir esforços pelas minhas realizações.

Leonardo, minha outra metade, pelo apoio incondicional.

## AGRADECIMENTOS

A Deus, por me conceder força e saúde para a finalização desse ciclo com a sensação de dever cumprido.

Aos meus pais e irmão, a quem devo simplesmente TUDO. Meus exemplos de resiliência, alegria, amor incondicional e superação. Minha luta diária é para orgulhar vocês.

A Jefferson por ser nada menos do que fundamental nesse processo. Sem você, com toda certeza, eu teria desistido. Obrigada por existir.

Aos amigos que compreenderam meus constantes momentos de ausência, mas permaneceram presentes de alguma forma.

Ao Prof. Ms. Mário Lúcio Pierre Jr. e Prof. Dr. Antônio Apolinário Jr. pelo tempo despendido tanto na concepção quanto na execução deste trabalho.

Aos membros das bancas de qualificação e defesa pelas importantes considerações ao nosso trabalho.

Às queridas Isabela Fernandes e Clara Maria por todo auxílio nos momentos em que mais precisei. Tenham certeza de que nunca esquecerei dessa demonstração de afeto. Aprendi muito com vocês. Voem alto!

À profissional e mulher em quem me espelho: Profa. Dra. Iêda Crusoé. Agradeço imensamente pela oportunidade de ser sua orientada. Por onde estiver sempre carregarei comigo os ensinamentos e o espelho de como grandes mestres se comportam.

À equipe da Radiologia Odontológica FO-UFBA pelo aprendizado nessa trajetória. Em especial, ao Prof. Dr. Frederico Sampaio, por toda confiança e oportunidade a mim ofertados e a querida Edjane pelo cuidado e carinho nunca ausentes.

Aos laços que fiz e aos que consolidei durante os 2 anos de Mestrado: Bruno, Edval, William e Yann Victor.

À minha casa FO-UFBA e a todos os professores que me motivaram a seguir pelas veias acadêmicas. Meu “muito obrigada” àqueles que fazem jus ao sentido da palavra “mestre”.

Por fim, agradeço a mim por ter resistido bravamente.

*"Acredito que o desenvolvimento pleno da Inteligência Artificial poderia significar o fim da raça humana."*

Stephen Hawking

## RESUMO

**Introdução:** Dentre as várias entidades patológicas do grupo lesões intraósseas odontogênicas benignas, confere-se destaque ao queratocisto odontogênico e ao ameloblastoma em razão de suas altas taxas de prevalência e similaridade nas características radiográficas, que tornam desafiador o diagnóstico diferencial entre elas. Nesse contexto, as Redes Neurais Convolucionais (*Convolutional Neural Networks* - CNNs), uma das vertentes da Inteligência Artificial, podem sugerir diagnóstico de lesões com alta precisão e rapidez ao aprender com padrões reconhecidos nas imagens de maneira supervisionada. **Objetivo:** analisar o desempenho da classificação automática de queratocistos odontogênicos e ameloblastomas, a partir de imagens de Tomografia Computadorizada de Multidetectors (TCMD) através do uso de um modelo de CNN. **Metodologia:** Para a construção do *dataset* foram selecionados exames por TCMD de pacientes portadores de ameloblastomas convencionais (n=22) e queratocistos odontogênicos (n=18) com laudo anatomopatológico conclusivo. As imagens tomográficas axiais foram segmentadas manualmente por um examinador experiente e submetidas a algoritmos de incremento de base, totalizando 2000 imagens. Para estimativa de acurácia do modelo CNN *GoogLe Inception v.3* como classificador binário foi utilizado o método de validação cruzada *k-fold*, com  $k = 5$ . **Resultados:** Os valores de acurácia e desvio padrão (%) da validação cruzada para as cinco iterações realizadas foram de  $90,16 \pm 0,95$ ,  $91,37 \pm 0,57$ ,  $91,62 \pm 0,19$ ,  $92,48 \pm 0,16$  e  $91,21 \pm 0,87$ , respectivamente. **Conclusão:** O modelo de CNN *GoogLe Inception v.3* demonstrou resultados positivos para classificação de imagens tomográficas de queratocistos odontogênicos e ameloblastomas.

**Palavras-chave:** Ameloblastoma, Cistos Odontogênicos, Inteligência Artificial, Tomografia Computadorizada por Raios-X

## ABSTRACT

**Introduction:** Among the various pathological entities in the group benign odontogenic intraosseous lesions, odontogenic keratocyst and ameloblastoma are highlighted due to their high prevalence rates and similarity in radiographic characteristics, which make the differential diagnosis between them challenging. In this context, the Convolutional Neural Networks (CNNs), one of the strands of Artificial Intelligence, can suggest diagnosis of injuries with high precision and speed when learning from patterns recognized in the images in a supervised manner. **Objective:** to analyze the performance of the automatic classification of odontogenic keratocysts and ameloblastomas, using Multidetector Computed Tomography (MDCT) images using a CNN model. **Methodology:** For the construction of the dataset, MDCT examinations of patients with conventional ameloblastomas (n = 22) and odontogenic keratocysts (n = 18) with conclusive anatomopathological report were selected. The axial tomographic images were manually segmented by an experienced examiner and subjected to basic incremental algorithms, totaling 2000 images. To estimate the accuracy of the CNN *GoogLe Inception v.3* model as a binary classifier, the k-fold cross-validation method was used, with k = 5. **Results:** The values of accuracy and standard deviation (%) of the cross-validation for the five iterations performed were  $90.16 \pm 0.95$ ,  $91.37 \pm 0.57$ ,  $91.62 \pm 0.19$ ,  $92.48 \pm 0.16$  and  $91.21 \pm 0.87$ , respectively. **Conclusion:** The CNN *GoogLe Inception v.3* model showed positive results for the classification of odontogenic keratocysts and ameloblastomas tomographic images.

**Keywords:** Ameloblastoma, Odontogenic Cysts, Artificial Intelligence, Tomography, X-Ray Computed

## LISTA DE ILUSTRAÇÕES

- Figura 1 Diagrama de subdivisão da Inteligência Artificial.
- Figura 2 Representação da validação cruzada *k-fold*, com  $k = 5$ . A, B, C, D e E representam os subconjuntos (folds). TE = Teste, TR = Treinamento (adaptado de Hackeling, 2017).
- Figura 3 Arquitetura de CNN (SUZUKI, 2017).
- Figura 4 TCMD. Corte axial. Representação do método de seleção da ROI com a ferramenta “*rectangle*” do software ImageJ.
- Figura 5 Representação esquemática da matriz de confusão 2x2. P e N representam as classes, sendo P = positiva e N = negativa. Nas linhas e colunas estão distribuídos os parâmetros *TP*, *FP*, *TN* e *FN*.



## LISTA DE TABELAS

- Tabela 1 Resultado dos parâmetros da primeira rodada de treinamentos (n = 350). Acurácia da validação cruzada =  $90,16 \pm 0,95\%$ . Tempo de execução: 2.570,25 minutos (aproximadamente 42,83hrs).
- Tabela 2 Matriz de confusão da primeira execução de validação cruzada (n = 350).
- Tabela 3 Resultado dos parâmetros da segunda rodada de treinamentos (n = 350). Acurácia da validação cruzada =  $91,37 \pm 0,57\%$ . Tempo de execução: 2.695,58 minutos (aproximadamente 44,93hrs).
- Tabela 4 Matriz de confusão da segunda execução de validação cruzada (n = 350).
- Tabela 5 Resultado dos parâmetros da terceira rodada de treinamentos (n = 350). Acurácia da validação cruzada =  $91,26 \pm 0,29\%$ . Tempo de execução: 2498,61 minutos (aproximadamente 41,6hrs).
- Tabela 6 Matriz de confusão da terceira execução de validação cruzada (n = 350).
- Tabela 7 Resultado dos parâmetros da quarta rodada de treinamentos (n = 350). Acurácia da validação cruzada =  $92,48 \pm 0,16\%$ . Tempo de execução: 2.498,01min (aproximadamente 41,6hrs).
- Tabela 8 Matriz de confusão da quarta execução de validação cruzada (n = 350).
- Tabela 9 Resultado dos parâmetros da quinta rodada de treinamentos (n = 350). Acurácia da validação cruzada =  $91,21 \pm 0,16\%$ . Tempo de execução: 2.547,33min (aproximadamente 42,4hrs).
- Tabela 10 Matriz de confusão da quinta execução de validação cruzada (n = 350).
- Tabela 11 Resultados de taxas de acurácia da validação cruzada nas 5 repetições.

## LISTA DE ABREVIATURAS E SIGLAS

Am	Ameloblastoma
CNN	<i>Convolutional Neural Network</i>
DICOM	<i>Digital Imaging and Communications in Medicine</i>
FN	<i>False negative</i>
FO-UFBA	Faculdade de Odontologia da Universidade Federal da Bahia
FP	<i>False positive</i>
IA	Inteligência Artificial
IFBaiano	Instituto Federal de Educação, Ciência e Tecnologia Baiano
IME-UFBA	Instituto de Matemática e Estatística da UFBA
OMS	Organização Mundial da Saúde
PNG	<i>Portable Network Graphics</i>
QO	Queratocisto Odontogênico
ROI	<i>Region of Interest</i>
SJ	Síndrome de Sjögren
TC	Tomografia Computadorizada
TCFC	Tomografia Computadorizada de Feixe Cônico
TCMD	Tomografia Computadorizada de Multidetectors
TE	Teste
TIFF	<i>Tagged Image File Format</i>
TN	<i>True negative</i>
TP	<i>True positive</i>
TR	Treinamento
UH	Unidades <i>Hounsfield</i>

# SUMÁRIO

	<b>RESUMO</b>	
	<b>ABSTRACT</b>	
<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>11</b>
<b>2</b>	<b>REVISÃO DA LITERATURA</b> .....	<b>14</b>
2.1	QUERATOCISTO ODONTOGÊNICO (QO) .....	14
2.2	AMELOBLASTOMA (Am) .....	15
2.3	TOMOGRÁFIA COMPUTADORIZADA (TC) .....	18
2.4	INTELIGÊNCIA ARTIFICIAL (IA) .....	19
2.4.1	<b>Aprendizado de máquina (<i>machine learning</i>)</b> .....	<b>20</b>
2.4.2	<b>Validação cruzada (<i>cross-validation</i>)</b> .....	<b>20</b>
2.4.3	<b>Problema de sobreajuste (<i>overfitting</i>)</b> .....	<b>22</b>
2.4.4	<b>Aprendizado profundo (<i>deep learning</i>)</b> .....	<b>22</b>
2.5	USO DAS CNNs NA RADIOLOGIA ODONTOLÓGICA .....	23
<b>3</b>	<b>OBJETIVO</b> .....	<b>26</b>
<b>4</b>	<b>METODOLOGIA</b> .....	<b>27</b>
<b>5</b>	<b>RESULTADOS</b> .....	<b>32</b>
<b>6</b>	<b>DISCUSSÃO</b> .....	<b>35</b>
<b>7</b>	<b>CONCLUSÃO</b> .....	<b>39</b>
	<b>REFERÊNCIAS</b> .....	<b>40</b>
	<b>ANEXO – PARECER CONSUBSTANCIADO DO CEP</b> .....	<b>46</b>



## 1 INTRODUÇÃO

As lesões intraósseas odontogênicas benignas englobam um grupo de lesões de natureza, sintomatologia, apresentação clínica, radiográfica e histopatológica variadas. Essas lesões podem ser encontradas incidentalmente em exames radiográficos de rotina, visto que não é comum a ocorrência de sintomas em seu curso de desenvolvimento, especialmente nos estágios iniciais. Embora benignas, são lesões destrutivas que podem atingir importante extensão até que se tornem sintomáticas, (RINGER E KOLOKYTHAS, 2017) levando à redução na qualidade de vida. Excluindo-se as lesões inflamatórias e odontoma, queratocisto odontogênico (QO) e ameloblastoma (Am) são as mais prevalentes em diversos estudos de base populacional (LEDESMA-MONTES *et al.*, 2007; MACDONALD, 2016), maior destaque é dado a essas lesões em comparação às outras entidades do grupo. Ambas apresentam características imaginológicas similares, embora origem, comportamento e abordagem terapêutica sejam relativamente distintos.

O QO é a terceira lesão mais comum dentro do grupo dos cistos odontogênicos, com frequência de 10 a 20%. Essa entidade patológica se desenvolve dos remanescentes da lâmina dentária e costuma acometer principalmente indivíduos mais jovens, com pico de incidência entre segunda e terceira décadas de vida. Radiograficamente, se apresenta como uma radiotransparência uni ou multilocular, bem circunscrita, que demonstra crescimento com mínima expansão de corticais e acomete mais comumente a região posterior de mandíbula (RINGER E KOLOKYTHAS, 2017; TAKATA E SLOOTWEG, 2017) e tendência de crescimento em direção ao ramo mandibular (GOHEL *et al.*, 2018; SANTOSH, 2019). O tratamento comumente envolve enucleação associada a exodontia da(s) unidade(s) dentária(s) envolvida(s) (se houver) ou marsupialização para lesões de grandes extensões (SANTOSH, 2019).

O Ameloblastoma, também denominado ameloblastoma convencional, ameloblastoma intraósseo clássico ou ameloblastoma sólido/multicístico (TAKATA E SLOOTWEG, 2017) é uma neoplasia benigna de origem epitelial (SANTOSH e OGLE, 2019). Em torno de 80% dos casos ocorrem em mandíbula, com exceção para o tipo histológico desmoplásico, que apresenta predileção pela região anterior de maxila. O pico de incidência se mantém entre quarta e sexta décadas de vida (TAKATA E SLOOTWEG, 2017). Radiograficamente, visualiza-se lesão radiolúcida uni ou

multilocular associada a dentes impactados, deslocamento dentário, reabsorção radicular, expansão e/ou perfuração de corticais e presença de septos resultando em padrões semelhantes a bolhas de sabão ou favos de mel (SCARFE *et al.*, 2018). Tratamento cirúrgico radical costuma ser a terapia de escolha em razão das altas taxas de recorrência alcançadas pelo Am (HENDRA *et al.*, 2018), mas inibidores específicos para mutações no oncogene BRAF V600E (frequente em ameloblastomas) a exemplo do vemurafenib, dabrafenib e trametinib apontam resultados promissores (CHA *et al.*, 2017; FADEN E ALGAZI, 2017; KAYE *et al.*, 2015).

Nesse contexto, a Tomografia Computadorizada de Multidetectors (TCMD) se insere como uma ferramenta de grande auxílio no diagnóstico e planejamento das lesões intraósseas benignas dos maxilares. A TCMD, introduzida no início dos anos 70, atualmente fornece cortes de diminuta espessura com alta resolução, que permitem obtenção de reconstruções multiplanares e caracterização de tecidos moles com qualidade superior à Tomografia Computadorizada de Feixe Cônico (TCFC) (GOHEL *et al.*, 2018). Embora a TCFC forneça resultados similares à TCMD na identificação de lesões ósseas com custo e dose de radiação relativamente inferiores (GAIA *et al.*, 2011), sugere-se a utilização da TCMD para avaliação de lesões intraósseas pela alta resolução das estruturas anatômicas e possibilidade de aplicação de técnicas de análise textural (GOHEL *et al.*, 2018), a exemplo da avaliação do padrão de densidade intralesional e heterogeneidade através do estudo das Unidades *Hounsfield* (UH) (CRUSOÉ-REBELLO *et al.*, 2009). Essas ferramentas contribuem com dados objetivos que guiam a análise subjetiva do radiologista.

Devido à similaridade de características imaginológicas entre as lesões supracitadas, como padrão lítico, local de prevalência em região posterior de mandíbula e presença de septos as ferramentas auxiliares podem ser de grande utilidade para os radiologistas no momento do diagnóstico diferencial. Dessa maneira, a Inteligência Artificial (IA) surge como uma real possibilidade de aliar a tecnologia disponível nos computadores de última geração aos exames de imagem no sentido de aumentar a precisão, reduzir o tempo necessário para avaliação e enfim aproximar-se do diagnóstico que determina a abordagem terapêutica mais adequada.

A Inteligência Artificial é uma ciência que possui capacidade de aprender com os dados que lhe são fornecidos e fazer previsões e ser subdividida entre *machine learning* ou “aprendizado de máquina” e *deep learning* ou “aprendizado profundo”, as

quais se diferem, basicamente, pelo uso das Redes Neurais Convolucionais. Essas redes são caracterizadas por algoritmos inspirados na estrutura do cérebro humano, com função análoga às células neuronais (MUPPARAPU; WU; CHEN, 2018). É importante destacar que a IA não é uma tecnologia nova, porém, com o avanço na capacidade de processamento das máquinas a partir dos anos 90, seu uso se tornou possível, logo o interesse e o conhecimento na área avançaram consideravelmente nos últimos anos.

Nas ciências médicas, a aplicação da IA iniciou mais precocemente do que nas ciências odontológicas e muitos estudos já demonstraram sua aplicabilidade nas mais variadas áreas. Detecção e classificação de lesões malignas de pele (BRINKER *et al.*, 2018), mama (GONG *et al.*, 2019), pulmão (SIM *et al.*, 2020) e tumores gástricos (CHO *et al.*, 2019) são algumas das possíveis aplicações das CNNs como recurso diagnóstico auxiliar para a medicina.

As publicações recentes têm sugerido ótimos resultados da utilização das CNNs como recurso auxiliar para a radiologia odontológica. Os estudos realizados até então já relatam alto desempenho das redes para avaliação de sinusite maxilar em radiografias panorâmicas (MURATA *et al.*, 2018), detecção e diagnóstico de lesões de cárie (LEE *et al.*, 2018a) ou fraturas verticais (FUKUDA *et al.*, 2019), predição de doença periodontal (LEE *et al.*, 2018b), contagem automática de dentes através de radiografias periapicais (CHEN *et al.*, 2019), predição de xerostomia pós radioterapia de cabeça e pescoço (MEN *et al.*, 2019), diagnóstico da Síndrome de Sjögren por Tomografia Computadorizada (KISE *et al.*, 2019) ou lesões malignas da cavidade oral (AUBREVILLE *et al.*, 2017) e detecção automática de lesões ósseas dos maxilares por radiografia panorâmica (ARIJI *et al.*, 2019; POEDJIASTOETI E SUEBNUKARN, 2018).

Justifica-se a execução deste trabalho pela similaridade nas características imaginológicas do QO e Am, o que torna desafiadora a distinção entre elas. Isto posto, a elaboração de uma ferramenta apta a classificá-las pode colaborar sobremodo.

## 2 REVISÃO DA LITERATURA

### 2.1 QUERATOCISTO ODONTOGÊNICO (QO)

O queratocisto odontogênico é uma lesão de natureza cística que se desenvolve dos remanescentes da lâmina dentária presentes nos ossos maxilares. Em função de seu comportamento agressivo e altas taxas de recorrência (RINGER E KOLOKYTHAS, 2017) há uma constante discussão na literatura acerca de sua natureza, se neoplásica ou cística. Todavia, a última publicação da Organização Mundial da Saúde (TAKATA E SLOOTWEG, 2017) o reclassificou como cisto odontogênico por julgar não haver evidências científicas suficientes para ratificar sua origem neoplásica.

A maioria dos QOs se desenvolve esporadicamente e de maneira solitária nos maxilares, porém, o desenvolvimento de múltiplos QOs em idade jovem sugere presença da Síndrome de Gorlin (CHA *et al.*, 2017). Além disso, anomalias esqueléticas como calcificações em foice do cérebro e sela túrcica, hipertelorismo, diâmetro craniano aumentado; depressões palmo-plantares; e desenvolvimento de neoplasias como fibromas ovarianos e cardíacos e múltiplos carcinomas nevóides de células basais são sinais de manifestação dessa Síndrome (SANTOS *et al.*, 2018).

Radiograficamente, o QO se apresenta como uma radiolucência uni ou multilocular circundada por margens corticalizadas situada em região posterior de mandíbula (GOHEL *et al.*, 2018; RINGER E KOLOKHYTAS, 2017). Adicionalmente, quando ocorre em mandíbula, o QO parece capaz de atingir grandes dimensões no sentido médio-distal sem expansão de corticais vestibular ou lingual significativa (BORGHESI *et al.*, 2018; GOHEL *et al.*, 2018). Por outro lado, quando da ocorrência dessa lesão em maxila, expansão significativa do osso alveolar é visualizada atingindo estruturas adjacentes, como o seio maxilar (BORGHESI *et al.*, 2018).

Constantemente, são encontradas extensões intramedulares de tecidos moles periféricos, que em conjunto com friabilidade da cápsula da lesão, resulta em aumento da recorrência. Em torno de 50% dos casos dos QOs são uniloculares. Quando multiloculares, usualmente possuem septos curvos e podem exibir padrões de bolha-de-sabão ou favos de mel. Uma vez acometido por QO, recomenda-se o acompanhamento pelos primeiros cinco anos, a despeito das taxas de recorrência aumentadas (SCARFE *et al.*, 2018).



Para tratamento do queratocisto odontogênico, técnicas conservadoras são sugeridas com resultados satisfatórios. Entre as técnicas disponíveis destacam-se descompressão e marsupialização seguidas ou não de enucleação, embora resultados sugiram que a descompressão isolada alcançam menores taxas de recidiva que a marsupialização (TABRIZI *et al.*, 2019). Alguns estudos também sugerem a utilização da Solução de Carnoy, todavia, pela classificação do clorofórmio presente na formulação da solução como carcinógeno, a obtenção não é possível em qualquer localidade. Por outro lado, uma nova formulação livre de clorofórmio ainda não apresenta estudos que comprovem a efetividade (POGREL, 2015). Bons resultados foram obtidos por Pogrel (2015) em pacientes tratados com associação de descompressão, enucleação e osteotomia periférica, que se mantiveram livres de lesão por cinco anos após o tratamento.

## 2.2 AMELOBLASTOMA (Am)

O ameloblastoma é o tumor odontogênico benigno de maior relevância para a área odontológica e o segundo mais comum de todo o grupo (SCARFE *et al.*, 2018). Esse tumor se origina de células epiteliais, a exemplo das células remanescentes da lâmina dentária ou do epitélio do órgão do esmalte, células da camada basal da mucosa oral ou revestimento epitelial de cistos odontogênicos (SANTOSH E OGLE, 2019). Em razão das características radiográficas, clínicas e prognóstico, essa lesão apresenta quatro variantes: (1) convencional; (2) unicístico; (3) periférico; e (4) metastatizante.

As características epidemiológicas do Am vêm sendo estudadas ao longo dos anos em várias localidades do mundo. Algumas dessas características estão consolidadas na literatura e apontam homogeneidade entre os estudos, a exemplo da localização da lesão em mandíbula. Outras são mais heterogêneas, como idade no momento do diagnóstico.

Em estudo multicêntrico realizado na América Latina, o Am representou 22% de todos os tumores odontogênicos incluídos, com média de idade de 41,4 anos. A mandíbula foi o sítio mais afetado (86,4%), demonstrando dimensão méso-distal média de 6,2cm. Dentre os achados clínicos detectados para o ameloblastoma convencional inclui-se tumefação da área afetada (97%), dor (34,4%), ulceração (12,5%), e deslocamento dentário (12,5%). Nesse estudo, nenhum caso de Am foi

diagnosticado em pacientes menor que 20 anos de idade (LEDESMA-MONTES *et al.*, 2007).

Segundo revisão sistemática com metanálise realizada recentemente (HENDRA *et al.*, 2019), a incidência global do ameloblastoma foi estimada em 0,92 casos por milhão de pessoas/ano. Porém, os estudos de base populacional analisados demonstram heterogeneidade entre os países, variando entre 2,41 por milhão/ano na Austrália e 0,76 na Nigéria por milhão/ano. Quanto à distribuição dos casos por sexo o mesmo estudo apontou ligeira predileção dessa lesão por homens, com relação homem/mulher de 1,14:1. Sobre a localização da lesão verificou-se 87,2% dos casos reportados em mandíbula e apenas 8,5% em maxila. Embora a média de idade ao diagnóstico tenha sido de 34,3 anos, a distribuição etária na América do Sul apresentou divergência em relação a América do Norte, Ásia e Europa e se assemelhou ao continente africano, com predominância dos casos em faixa etária mais jovem que a média global (21-30 anos). A variante clínico-radiográfica mais representativa foi a sólido/multicístico (67,7%) – reclassificado como variante convencional (TAKATA E SLOOTWEG, 2017) e os padrões histopatológicos folicular (24,8%) e plexiforme (24,7%) se mostraram igualmente predominantes.

Embora raramente, o Am pode ocorrer em associação com síndromes genéticas, a despeito das Síndromes de Gardner, Williams, do nevo epidérmico, Simpson-Golabi-Bemel e, principalmente, a Síndrome de Gorlin (ou Síndrome dos Carcinomas Nevoides de Células Basais). Na ocorrência dessa síndrome, as manifestações foram mais prevalentes fora da região comum de ocorrência, sendo 80% delas em maxila (ATARBASHI-MOGHADAM *et al.*, 2019).

Radiograficamente, o Am se apresenta como uma lesão osteolítica uni ou multilocular que normalmente exhibe expansão de corticais e associação com dentes impactados (FREGNANI *et al.*, 2010). Tais achados não são específicos deste e podem sugerir outras lesões de apresentação imaginológica similar, como o QO. Analisar características fornecidas pelos exames tridimensionais facilitam a distinção entre QO e Am, por exemplo. De acordo com Ariji *et al.* (2011), o ameloblastoma produz expansão de corticais significativamente superior em comparação ao QO, sendo, portanto, esse o critério de distinção radiográfica entre as duas lesões (MACDONALD, 2016). Adicionalmente, número de loculações, presença de áreas de alta-densidade e a inclusão de dentes impactados contribuem sobremaneira para o correto diagnóstico (ARIJI *et al.*, 2011).

O Am usualmente expressa septos desordenados, que irradiam de um centro comum. Alguns padrões conhecidos como bolha de sabão ou favo de mel ocasionalmente estão presentes quando das lesões multiloculares. Em estágios iniciais, o Am pode manifestar padrão unilocular e ser facilmente confundido com o cisto dentífero ou QO. Outrossim, reabsorção em lâmina de faca nas raízes dos dentes adjacentes à lesão e deslocamento de unidades impactadas são comuns. O canal mandibular pode sofrer modificação e estar deslocado, erodido ou ausente. (SCARFE *et al.*, 2018)

Ainda não existem protocolos terapêuticos determinados para a abordagem do ameloblastoma convencional. Sabe-se que, devido às características de agressividade local e altas taxas de recidiva, sugere-se que o tratamento aplicado seja mais radical (FREGNANI *et al.*, 2010). As técnicas cirúrgicas variam desde tratamentos mais conservadores: enucleação associada ou não a marsupialização, curetagem ou cauterização; curetagem associada a crioterapia ou cauterização; enucleação associada a aplicação de Solução de Carnoy; ou combinação de duas ou mais técnicas (HENDRA *et al.*, 2018; SILVA *et al.*, 2018). As terapias mais radicais utilizam ressecção óssea nos variados graus de invasividade, produzindo defeitos ósseos menores ou maiores na dependência do tamanho do segmento ósseo removido.

De acordo com revisão da literatura realizada por Neagu e colaboradores (2019), o tratamento cirúrgico radical demonstra ser a opção terapêutica mais indicada não somente para a variante convencional, mas também para a variante unicística em estágio avançado. Segundo os autores, apesar da morbidade, tal abordagem favorece redução da recorrência e minimiza as chances de novas intervenções cirúrgicas. Além disso, novas estratégias de planejamento podem ser utilizadas para reduzir a morbidade e as dificuldades da reabilitação, como o uso de modelos digitais. Lesões de pequena extensão podem ser tratadas com técnicas mais conservadoras associadas a longo tempo de acompanhamento, todavia maiores taxas de recorrência são esperadas. Em revisão sistemática publicada recentemente, os autores avaliam os resultados obtidos para as opções terapêuticas do ameloblastoma convencional e reportam as taxas de recorrência de 8% para terapias cirúrgicas radicais e 41% para terapias conservadoras (HENDRA *et al.*, 2018). É fundamental considerar que o planejamento deve ser individualizado, pautado no tamanho e localização do tumor,

técnicas cirúrgicas disponíveis, experiência do cirurgião e comorbidades do paciente (NEAGU *et al.*, 2019).

Para pacientes portadores de ameloblastomas recorrentes ou em estágio avançado e irressecáveis, positivas para mutações no gene BRAF V600E, alternativas ao tratamento cirúrgico têm sido testadas, sugerindo resultados promissores. Tanto a administração de dabrafenib (75mg) duas vezes ao dia quanto a combinação de dabrafenib (150mg) ao trametinib (2mg) uma vez ao dia demonstraram efeito benéfico na redução da extensão e nas comorbidades produzidas pela lesão (FADEN E ALGAZI, 2017; KAYE *et al.*, 2015).

### 2.3 TOMOGRAFIA COMPUTADORIZADA (TC)

Para avaliação maxilofacial por imagens tridimensionais geradas por feixes de raios-X há duas principais modalidades de TCs: TC de Feixe Cônico e TC de Multidetectors. Ambas são consideradas adequadas para planejamento preoperativo pela capacidade em gerar reconstruções multiplanares de alta qualidade nos diferentes planos. Todavia, enquanto a TCFC fornece maior resolução espacial comparada à TCMD, sendo efetiva na avaliação de corticais ósseas, sua pobre resolução de contraste reduz substancialmente a qualidade de avaliação dos tecidos moles. Diante disso, sugere-se a utilização da TCMD principalmente por possibilitar análise do padrão de densidade e extensão de lesões para tecidos moles (BORGHESI *et al.*, 2018; GOHEL *et al.*, 2018).

A possibilidade de avaliar o volume de lesões por meio da TC também fornece informações de grande valia para o diagnóstico. Estudo tomográfico executado por Kauke *et al.* (2018) avaliou o volume do QO em comparação a cistos não-odontogênicos e concluiu que lesões de volume superior a 3000mm<sup>3</sup> demonstram alta associação com diagnóstico histopatológico de queratocisto odontogênico. Adicionalmente, quanto maior o volume de um cisto, maior a probabilidade de se tratar de um queratocisto odontogênico (KAUKE *et al.*, 2017).

O diagnóstico diferencial de cistos odontogênicos e tumores tem como base o reconhecimento de padrões radiográficos, como grau de atenuação, localização em relação a dente e osso e forma da lesão. É mais provável que os tumores odontogênicos manifestem padrão multilocular, material calcificado no interior da lesão, que se apresenta como área de hiperatenuação, além de septos internos. Já

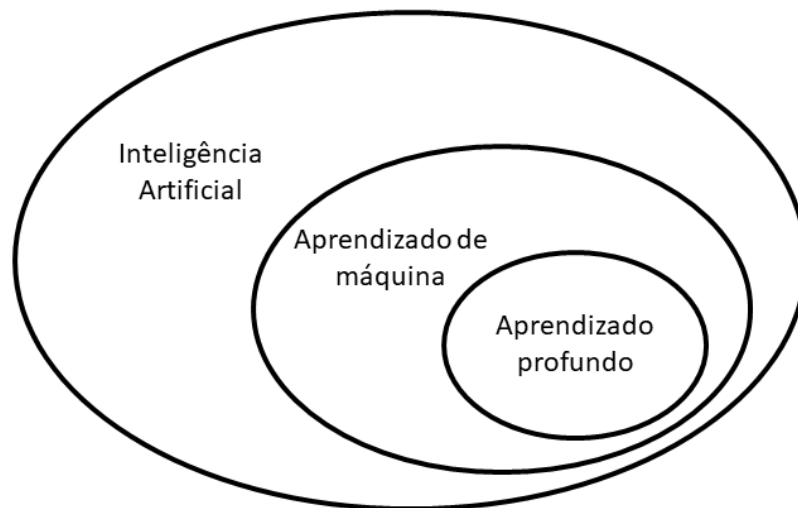
os cistos geralmente não contam com septos internos e são hipoatenuantes (SCARFE *et al.*, 2018).

A possibilidade de avaliação objetiva através das Unidades *Hounsfield* com fidelidade é uma vantagem inerente à TCMD e permite caracterização de tecidos e patologias. Trata-se da quantificação de radiação absorvida por uma estrutura em relação a seu número atômico por meio de uma escala de valores. Em pesquisa que analisou padrões de densidade e heterogeneidade de QOs e Ams através de UH, resultados indicam que o QOs possuem menores valores de densidade que o Am e conteúdo mais heterogêneo. Ademais, diferenças de densidade entre regiões centrais e periféricas nos ameloblastomas foram encontradas, e os autores atribuem a densidade mais alta em cortes periféricos à menor vascularização nas regiões centrais do tumor (CRUSOÉ-REBELLO *et al.*, 2009). Todos os achados supracitados reportam informações demasiadamente valiosas ofertadas pela TCMD que auxiliam na compreensão do comportamento biológico e composição das lesões intraósseas benignas dos maxilares.

Apesar da natureza benigna das lesões avaliadas no presente trabalho, estas costumam apontar características de agressividade (RINGER E KOLOKHYTAS, 2017). Expansão, erosão e perfuração de corticais, reabsorção radicular, deslocamento do canal mandibular e margens irregulares sugerem natureza agressiva de uma lesão (BORGHESI *et al.*, 2018; GÜMÜSOK *et al.*, 2015). Tais características apontam para a chances altas de recorrência, especialmente se o tratamento de escolha estiver inapropriado (RINGER E KOLOKHYTAS, 2017). Nesse sentido, a TC atua como importante instrumento a nortear o processo de escolha da terapia mais adequada ao caso.

#### 2.4 INTELIGÊNCIA ARTIFICIAL (IA)

A IA tem por definição “o esforço para automatizar tarefas tradicionalmente realizadas por seres humanos”, que se configura como um campo amplo da tecnologia e não como uma ferramenta específica. Além de outras tecnologias, a AI engloba o aprendizado de máquina (*machine learning*) e o aprendizado profundo (*deep learning*) (CHOLLET, 2018).



**Figura 1.** Diagrama de subdivisão da Inteligência Artificial.

#### **2.4.1 Aprendizado de máquina (*machine learning*)**

Os sistemas baseados em aprendizado de máquina podem ser subdivididos em duas categorias de aprendizado: supervisionado ou não-supervisionado por humanos. Nos problemas baseados em aprendizado supervisionado, um programa aprende através de pares de entrada e saída previamente rotulados como corretos. Desta forma, uma vez que uma coleção de respostas para diferentes perguntas é fornecida para o conjunto de treinamento, os programas aprendem a responder a perguntas não explícitas similares. O aprendizado não-supervisionado baseia-se na busca pelo programa em aprender com padrões identificados nos dados fornecidos (HACKELING, 2017).

O conjunto total de dados ou imagens (*dataset*) pode ser segmentados basicamente em três conjuntos principais: conjunto de treinamento (*training set*), conjunto de teste (*test set*) e conjunto de validação (*validation set*). Não há regras pré-estabelecidas para a divisão dos grupos, mas normalmente opta-se por distribuir pelo menos 50% para o conjunto de treinamento, 25% para o conjunto de teste e 25% para o conjunto de validação. Destaca-se que não há relação direta entre a quantidade de dados disponíveis no conjunto de treinamento e uma melhor performance alcançada pelo sistema, visto que uma grande porção de dados não implica, necessariamente, em dados corretos e fiéis (HACKELING, 2017).

#### **2.4.2 Validação cruzada (*cross-validation*)**

Existem algumas formas de estimar a acurácia de um classificador: *k-fold* e *holdout*. O método *holdout* ou método de estimativa da amostra consiste na divisão de um *dataset* em dois grupos, *training set* e *test set* de mesmo tamanho, em que 2/3 são distribuídos para o *training set* e os dados remanescentes, para o *test set*. Entretanto, tal método demonstra sempre estimativas pessimistas, visto que somente um conjunto de dados é submetido a treinamento (KOHAVI, 1995).

O processo nomeado de validação cruzada *k-fold* ou estimativa de rotação costuma ser aplicado quando há reduzida ou escassa quantidade de dados no conjunto de treinamento. Esse procedimento possibilita a subdivisão do conjunto de treinamento  $t$  em  $k$  subconjuntos (*folds*) aleatórios de, aproximadamente, mesmo tamanho. O classificador é treinado e testado  $k$  vezes, fornecendo uma estimativa de acurácia correspondente à razão entre o número geral de classificações corretas pelo total de objetos do *dataset* (KOHAVI, 1995). Observem a representação abaixo:

	A	B	C	D	E
Validação cruzada repetição 1	TE	TR	TR	TR	TR
Validação cruzada repetição 2	TR	TE	TR	TR	TR
Validação cruzada repetição 3	TR	TR	TE	TR	TR
Validação cruzada repetição 4	TR	TR	TR	TE	TR
Validação cruzada repetição 5	TR	TR	TR	TR	TE

**Figura 2.** Representação da validação cruzada *k-fold*, com  $k=5$ . A, B, C, D e E representam os subconjuntos (*folds*). TE = Teste, TR = Treinamento (adaptado de Hackeling, 2017).

Na repetição 1 (*1-fold*), o subconjunto A é submetido a teste de validação enquanto os demais (B, C, D e E) são submetidos a treinamento. Na repetição seguinte (*2-fold*), o teste de validação é realizado com os dados do subconjunto B e os demais (A, C, D e E) são submetidos a treinamento. Assim, as  $k$  repetições são feitas sucessivamente até que todos os  $k$  subconjuntos tenham sido submetidos a

treinamento e teste de validação. Esse processo fornece uma estimativa mais acurada de desempenho dos algoritmos de classificação ao assegurar que todos os objetos sejam submetidos tanto a treinamento quanto a teste de validação (HACKELING, 2017).

#### **2.4.3 Problema de sobreajuste (*overfitting*)**

Embora os sistemas tenham autonomia de aprendizado, um sistema é capaz memorizar o conjunto de dados fornecido para treinamento (*training dataset*), processo esse conhecido como problema de sobreajuste ou *overfitting*. Dessa maneira, o programa poderia memorizar relações ou estruturas que não são necessariamente reais, como ruídos ou coincidências, o que afeta significativamente na sua capacidade em classificar um novo conjunto de dados que lhe seja fornecido (HACKELING, 2017). Como consequência, há uma grande diferença entre as taxas de acurácia alcançadas no treinamento e no teste final, sendo, geralmente, maior no treinamento e menor no teste (GOODFELLOW, 2016). Normalmente esse inconveniente deriva de um conjunto de amostras reduzido ou com pouca variabilidade de características. Uma estratégia útil na redução ou eliminação do sobreajuste é a técnica de incremento de base ou *augmentation*. Essa técnica consiste em gerar mais imagens a partir das imagens existentes ao aplicar rotações; zoom; giro horizontal; recorte; redimensionamento; modificações de saturação, brilho e contraste; adição de ruído; e *shifting* – alteração de localização do conteúdo da imagem (SHIJIE *et al.*, 2017). Com a aplicação da técnica a CNN nunca “verá” a mesma imagem mais de uma vez, todavia, é imprescindível notar que isso não elimina as chances de ocorrer sobreajuste (CHOLLET, 2018).

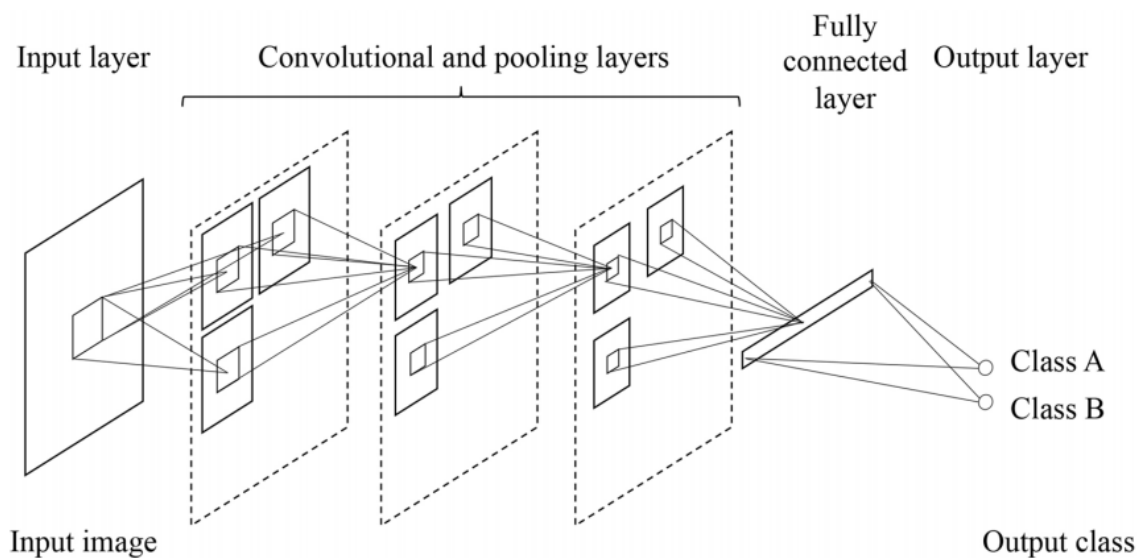
#### **2.4.4 Aprendizado profundo (*deep learning*)**

Trata-se de subdivisão da IA e do aprendizado de máquina, em que utiliza Redes Neurais Convolucionais, cujo processo é baseado no funcionamento cognitivo visual biológico humano (SHIJIE *et al.*, 2017). Por meio 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. Considera-se que quanto mais camadas um modelo tiver, maior sua profundidade de aprendizado (GOODFELLOW, 2016).



O primeiro modelo de CNN a alcançar resultados otimistas para classificação de imagens foi o *AlexNet*, desenvolvido por Krizhevsky *et al.* (2012), com a finalidade de participar da competição ILSVRC-2012. Dada a repercussão dos resultados alcançados por esse modelo, cerca de 40% melhores que os métodos tradicionais, outros modelos foram propostos em seguida, a exemplo de *ResNet*, *VGGNet*, *ZFNet* e *GoogLeNet* (SHIJIE *et al.*, 2017)

A estrutura básica de uma CNN é composta por: camada de entrada (*input layer*), camadas convolucionais (*convolutional layers*), camada de *pooling*, camadas completamente conectadas (*fully connected layers*) e camada de saída (*output layer*) (SHIJIE *et al.*, 2017) como representado pela imagem abaixo (figura 3):



**Figura 3.** Arquitetura de CNN (SUZUKI, 2017).

## 2.5. USO DAS CNNs NA RADIOLOGIA ODONTOLÓGICA

É possível perceber, nos últimos anos, o crescente interesse das ciências odontológicas pelos sistemas baseados em *deep learning*, representado pelo número de publicações na área nos últimos dois anos. Através dos estudos já realizados fica explícita a gama de aplicações da inteligência artificial com o uso de imagens, que permite desde avaliação da morfologia radicular de primeiros molares inferiores (HIRAIWA *et al.*, 2018) ao diagnóstico e predição de dentes com comprometimento periodontal (LEE *et al.*, 2018), ambos utilizando exames radiográficos bidimensionais.

Um estudo preliminar realizado por Kise *et al.* (2019) buscou investigar o desempenho diagnóstico de um sistema baseado em *deep learning* para detecção da Síndrome de Sjögren (SJ) em 40 TCs em comparação ao diagnóstico realizado por 03 radiologistas experientes e 03 radiologistas inexperientes. Para o diagnóstico, os profissionais receberam as imagens tomográficas com a finalidade de classificá-las por meio de escala numérica variando de 1 a 4 pontos, em que o escore 1 representava a maior probabilidade de presença da SJ e o escore 4, maior probabilidade de normalidade. Os autores utilizaram, no total, 500 imagens de tamanho 30 x 30 pixels de cortes tomográficos da região central da glândula parótida, das quais 400 foram aplicadas na fase de treinamento da rede e as outras 100 utilizadas para a fase de teste. Os processos de treinamento, validação e teste foram aplicados na rede *AlexNet*, cujos resultados apontaram níveis de acurácia, sensibilidade e especificidade do sistema de, respectivamente, 96%, 100% e 92%. Já os radiologistas inexperientes alcançaram níveis inferiores ao sistema (83,5%, 77,9% e 89,2%, respectivamente), sendo esta diferença estatisticamente significativa. Já os radiologistas experientes demonstraram valores diagnósticos similares à rede neural, não havendo, portanto, diferença estatística significativa entre estes. Dessa maneira, o sistema se mostrou como uma potencial ferramenta de suporte diagnóstico para os radiologistas inexperientes.

No que tange à aplicação das redes neurais convolucionais no diagnóstico de lesões ósseas dos maxilares, apenas dois estudos estão publicados até o presente momento (ARIJI *et al.*, 2019; POEDJIASTOETI E SUEBNUKARN, 2018), ambos para detecção das lesões através de radiografia panorâmica.

A fim de avaliar a capacidade de detecção de QOs e Am por CNNs em comparação Poedjiastoeti e Suebnukarn (2018) realizaram estudo incluindo 500 exames panorâmicos. Destes, 400 foram utilizados na fase de treinamento e 100 na fase de teste da rede neural. Os autores selecionaram a CNN *VGG-16* e aplicaram o método de incremento de base a fim de transpor a limitação da quantidade de imagens da amostra. Como resultados, os autores relatam que a CNN alcançou 81,3% de sensibilidade, 83,3% de especificidade e acurácia de 83%, com tempo necessário para analisar todas as imagens de 38 segundos.

Com o propósito de detecção e classificação automática de lesões radiolúcidas mandibulares ainda em radiografias panorâmicas, 210 exames foram submetidos à segmentação da região da imagem compreendida pela lesão. Para pré-treinamento

da CNN *DetectNet*, os autores utilizaram a biblioteca *DIGITS*. Neste estudo, diferentemente do anterior, foram incluídos, além de ameloblastoma e queratocisto odontogênico, os cistos dentígero, radicular e ósseo simples. O estudo buscou investigar a capacidade não somente de detecção das lesões no exame, mas a correta classificação de cada lesão através das taxas de sensibilidade de detecção e classificação, bem como falso positivo. O desempenho de detecção alcançou 88% de sensibilidade e falso positivo de 1 a cada 25 imagens submetidas a teste. Já a sensibilidade da classificação foi mais alta para os cistos dentígeros, seguida dos cistos radiculares, ameloblastomas e, por último, os queratocistos. Os autores sugerem que houve maior facilidade de classificação para os cistos dentígeros não somente pelas margens bem definidas, mas pela localização destes distintamente das outras lesões inseridas no estudo (ARIJI *et al.*, 2019).

Para detecção de fraturas verticais, Fukuda e colaboradores (2019) submeteram 300 radiografias panorâmicas ao modelo de CNN *DetectNet*. Os parâmetros de avaliação demonstraram: *recall* de 0,75, precisão de 0,93 e F-score de 0,83. Todas as taxas de precisão reportadas superaram 75%, atingindo 100% para detecção de fraturas verticais em molares e incisivos inferiores, respectivamente, o que aponta que o modelo testado apresenta potencial para essa função.

### **3 OBJETIVO**

Analisar o desempenho de classificação automática de queratocistos odontogênicos e ameloblastomas, a partir de imagens de TCMD através do uso de um modelo de Rede Neural Convolutacional (*Convolutional Neural Network* - CNN).

## 4 METODOLOGIA

Trata-se de um estudo executado no Serviço de Radiologia Odontológica da Faculdade de Odontologia da UFBA em cooperação com o Instituto de Matemática e Estatística da UFBA (IME-UFBA) e o Instituto Federal de Educação, Ciência e Tecnologia Baiano (IFBaiano), submetido e aprovado pelo Comitê de Ética em Pesquisa da Faculdade de Odontologia da UFBA, sob o parecer de nº 366.989, aprovado em 07/08/2013.

Foram incluídos exames por TCMD de indivíduos atendidos no Serviço especializado de Cirurgia e Traumatologia Bucomaxilofacial da Faculdade de Odontologia da UFBA (FO-UFBA) e no Hospital Santo Antônio (HSA/OSID) entre 2013 a 2019, após fornecido, por patologista bucal experiente, laudo anatomopatológico conclusivo para: ameloblastoma convencional, ameloblastoma intraósseo clássico (TAKATA E SLOOTWEG, 2017) ou ameloblastoma sólido/multicístico (BARNES *et al.*, 2005); e queratocisto odontogênico (TAKATA E SLOOTWEG, 2017) ou tumor odontogênico queratocístico (BARNES *et al.*, 2005). As imagens com alta produção de artefatos metálicos afetando a região compreendida pela lesão foram excluídas do *dataset*.

Para a construção do *dataset* foram incluídas imagens tomográficas axiais de 22 ameloblastomas e 18 queratocistos odontogênicos compreendendo um total de 350 imagens. As Tomografias Computadorizadas foram processadas na janela para tecidos moles no software Horos™ DICOM Viewer (Pixmeo, SARL, Bernex, Suíça), com o objetivo de evidenciar as diferenças de tons de cinza do tecido intralesional. Os cortes tomográficos que compreendiam imagem compatível com lesão foram exportados do formato padrão DICOM (*Digital Imaging and Communications in Medicine*) para formato TIFF (*Tagged Image File Format*) e seguidos de segmentação.

A segmentação das imagens foi realizada manual e individualmente por um único examinador calibrado e experiente, utilizado o software Image J (*National Institutes of Health, Bethesda, Maryland, USA*). Através da ferramenta “rectangle” foi selecionada toda a região compreendida pela lesão (figura 4), resultando em ROIs arbitrárias de diferentes dimensões. As imagens foram salvas em formato PNG para preservar as informações, evitar compressão e conseqüente perda de informações das imagens.



**Figura 4.** TCMD. Corte axial. Representação do método de seleção da ROI com a ferramenta “rectangle” do software ImageJ.

Com o objetivo de ampliar o número de imagens e minimizar o sobreajuste, foi aplicada a técnica de incremento de base ou *augmentation*, aplicando rotações de 90°, 180° e 270° às ROIs originais totalizando 2000 imagens. O método de validação aplicado foi o *k-fold cross validation*, com valor de  $k = 5$ , logo, as imagens foram aleatoriamente divididas em cinco *folds* e, enquanto um dos *folds* era usado para teste de validação, os outros 4 foram usados para treinamento da rede. Esse processo foi repetido 5x, alternando entre os *folds* para assegurar que todas as imagens fossem aplicadas a treinamento e teste.

Durante a elaboração da metodologia proposta, foram testadas CNNs com diferentes arquiteturas, como a *LeNet-5* (LECUN *et al.*, 1998) (7 camadas) e *GoogLe Inception v.3* (SZEGEDY *et al.*, 2016) (42 camadas) com uma parte do *dataset*. As CNNs apresentaram divergências significantes nos resultados. Embora a *LeNet-5* tenha sido capaz de executar os processos de treinamento e teste em aproximadamente 9 minutos, alcançou acurácia máxima de 69,55%, enquanto a *CNN Inception v.3* forneceu 82,48% após 6hrs de treinamento e teste. Apesar da *Inception*

v.3 requerer maior tempo de treinamento, esse modelo de rede foi selecionado em razão da superioridade de acurácia atingida.

Foram utilizadas as seguintes configurações de hardware e software: Processador Intel® Core™ i7-7500U CPU @2.70GHz x 4; memória de 8GB, DDR4, 2400MHz; Disco rígido de 1TB (5400 RPM); Placa de vídeo NVIDIA® GeForce RMX150 de 4GB, GDDR5; Sistema operacional *Ubuntu* 16.04 LTS; *PyCharm Community* 2016.3, como Ambiente de Desenvolvimento Integrado (IDE); *Python* 2.7.12; *Keras* 2.2.0; *TensorFlow* 1.9.0, *Jupyter Notebook*.

O sistema de classificação binária fornece os resultados por meio de uma tabela 2 x 2 (colunas e linhas) conhecida por matriz de confusão. Trata-se da descrição dos valores preditos e reais para cada classe (positiva ou negativa) nas linhas e colunas, permitindo 4 saídas distintas: *True positive (TP)*, *false positive (FP)*, *false negative (FN)* e *true negative (TN)*.

**Figura 5.** Representação esquemática da matriz de confusão 2x2. P e N representam as classes, sendo P = positiva e N = negativa. Nas linhas e colunas estão distribuídos os parâmetros *TP*, *FP*, *TN* e *TN*.

		Real	
		P	N
Previsto	P	TP	FP
	N	FN	TN

Verdadeiro positivo (*true positive - TP*):

Correta classificação de uma classe. Na representação acima consiste na proporção de imagens preditas pelo sistema como classe positiva (P) que pertencem verdadeiramente a esta classe.

Falso positivo (*false positive - FP*)

Incorreta classificação de uma classe. Na representação acima consiste na proporção de imagens preditas pelo sistema como classe positiva (P) que pertence na realidade, à classe negativa (N).

Falso negativo (*false negative - FN*)

Incorreta classificação de uma classe. Na representação acima consiste na proporção de imagens preditas pelo sistema como classe negativa (N) que pertence, na realidade, à classe positiva (P).

Verdadeiro negativo (*true negative* - *TN*)

Correta classificação de uma classe. Na representação acima consiste na proporção de imagens preditas pelo sistema como classe negativa (N) que pertencem verdadeiramente a esta classe.

Os valores de *true positive* (*TP*), *false positive* (*FP*), *false negative* (*FN*) e *true negative* (*TN*) foram usados para o cálculo das medidas de acurácia, precisão, *recall* e F1-Score (FAWCETT, 2006), os quais foram levados em consideração na análise do desempenho da rede neural de classificação das imagens de queratocistos odontogênicos e ameloblastomas.

Acurácia é a proporção de predições corretas dentro do total de predições realizadas pelo sistema. Em geral é uma medida pouco representativa do real desempenho de um classificador. A fórmula da acurácia é definida por:

$$Acurácia = \frac{TP + TN}{TP + TN + FP + FN}$$

Precisão ou valor preditivo positivo, calcula a quantidade de previsões feitas que corresponde à classe positiva. Quanto maior a precisão, maior a capacidade de identificação da classe positiva. Segue a fórmula para cálculo da precisão:

$$Precisão = \frac{TP}{TP + FP}$$

*Recall* ou Sensibilidade corresponde ao número de objetos reais da classe positiva previstos corretamente. A fórmula do *recall* é definida por:

$$Recall = \frac{TP}{TP + FN}$$



*F1-Score* (F1) é uma média harmônica entre a precisão e o *recall* representada pela fórmula:

$$F1Score = \frac{2x \text{ (precisão)}x \text{ (recall)}}{\text{precisão} + \text{recall}}$$

## 5 RESULTADOS

Nas tabelas abaixo estão descritos os resultados dos parâmetros de avaliação do desempenho da rede neural *GoogLe Inception v.3* para classificação automática de imagens tomográficas de queratocistos odontogênicos e ameloblastomas usando o método de validação cruzada *k-fold*, com  $k=5$ . Nas tabelas 1, 3, 5, 7 e 9 estão detalhados os valores de acurácia, *recall*, precisão e F1-Score alcançados pelo *training set* de cada repetição. As matrizes de confusão discriminadas nas tabelas 2, 4, 6, 8 e 10 apontam os parâmetros preditivos *TP*, *FP*, *FN* e *FP*. Nas linhas são representadas as proporções de imagens preditas pela rede para cada classe de saída (P ou N) e, nas colunas, a proporção real de objetos distribuídos em cada classe.

**Tabela 1.** Resultado dos parâmetros da primeira rodada de treinamentos (n = 350). Tempo de execução: 2.570,25 minutos (aproximadamente 42,83hrs).

Teste de parâmetros	%
Acurácia (A)	90,0
<i>Recall</i> (R)	84,57
Precisão (P)	94,8
F1-Score (F)	89,18

**Tabela 2.** Matriz de confusão da primeira execução de validação cruzada (n = 350).

	P	N
P	148	8
N	27	167

**Tabela 3.** Resultado dos parâmetros da segunda rodada de treinamentos (n = 350). Tempo de execução: 2.695,58 minutos (aproximadamente 44,93hrs).

Teste de parâmetros	%
Acurácia (A)	84,0
<i>Recall</i> (R)	85,14
Precisão (P)	83,24
F1-Score (F)	84,18

**Tabela 4.** Matriz de confusão da segunda execução de validação cruzada (n = 350).

	P	N
--	---	---

P	149	30
N	26	145

**Tabela 5.** Resultado dos parâmetros da terceira rodada de treinamentos (n = 350). Tempo de execução: 2498,61 minutos (aproximadamente 41,6hrs).

Teste de parâmetros	%
Acurácia (A)	88,28
<i>Recall</i> (R)	84,0
Precisão (P)	91,8
F1-Score (F)	87,76

**Tabela 6.** Matriz de confusão da terceira execução de validação cruzada (n = 350)

	P	N
P	147	13
N	28	162

**Tabela 7.** Resultado dos parâmetros da quarta rodada de treinamentos (n = 350). Tempo de execução: 2.498,01min (aproximadamente 41,6hrs).

Teste de parâmetros	%
Acurácia (A)	85,42
<i>Recall</i> (R)	77,14
Precisão (P)	92,46
F1-Score (F)	84,11

**Tabela 8.** Matriz de confusão da quarta execução de validação cruzada (n = 350).

	P	N
P	135	11
N	40	164

**Tabela 9.** Resultado dos parâmetros da quinta rodada de treinamentos (n = 350). Tempo de execução: 2.547,33min (aproximadamente 42,4hrs).

Teste de parâmetros	%
Acurácia (A)	87,89
<i>Recall</i> (R)	84,84
Precisão (P)	92,0
F1-Score (F)	87,83

**Tabela 10.** Matriz de confusão da quinta execução de validação cruzada (n = 350)

	P	N
P	147	15
N	28	160

A partir dos resultados acima é possível perceber que todas as taxas de precisão alcançadas pelo modelo foram maiores que 80%, evidenciando ótima capacidade da *GoogLe Inception v.3* em classificar a classe positiva.

**Tabela 11.** Resultados de taxas de acurácia da validação cruzada nas 5 repetições.

	<i>1-fold</i>	<i>2-fold</i>	<i>3-fold</i>	<i>4-fold</i>	<i>5-fold</i>
Acurácia da validação cruzada ± desvio-padrão (%)	90,16±0,95	91,37±0,57	91,26±0,19	92,48±0,16	91,21±0,87

A tabela acima aponta valores de acurácia alcançados pela CNN no teste de validação a cada repetição. Note que em todas as cinco iterações os valores se mantiveram acima de 90% com desvio-padrão inferior a 1%, o que sugere excelente capacidade de classificação quando novas imagens foram apresentadas ao modelo testado.

## 6 DISCUSSÃO

O presente trabalho foi capaz de demonstrar o uso da CNN *GoogLe Inception* v.3 para classificação de imagens de TCMD de queratocistos odontogênicos e ameloblastomas, com valores de acurácia superiores a 90% corroborando os resultados previamente reportados nas áreas odontológica (AUBREVILLE *et al.*, 2017; LEE *et al.*, 2018a) e médica (CHANG *et al.*, 2017; COUDRAY *et al.*, 2018; MEDNIKOV *et al.*, 2018).

Para a metodologia do presente estudo, optou-se pela seleção de imagens por TCMD para avaliação da acurácia do classificador visto que ofertou à rede neural tons de cinza mais fidedignos ao conteúdo intralesional e melhor resolução de contraste BORGHESI *et al.*, 2018; GOHEL *et al.*, 2018. Embora similares quanto à qualidade de imagem, a TCMD provê avaliação de estrutura interna de cistos e tumores dos maxilares superior à TCFC (MISHRA *et al.*, 2014). Os valores de cinza determinados por ambas as técnicas são quantificados e traduzidos pela escala *Hounsfield* e apresentam discrepância entre as duas técnicas. Sabe-se que medidas de UH obtidas através de TCFC não são confiáveis, visto que ocorre variação nos níveis de cinza em distintos locais do mesmo material (AZEREDO *et al.*, 2013; RODRIGUES *et al.*, 2015; SILVA *et al.*, 2012).

Sabe-se que há diferença de conteúdo das duas lesões avaliadas, o que se traduz em distintos valores de UH, conseqüentemente, em diferentes tons de cinza. Enquanto o QO é composto por proteínas pouco solúveis como a paraqueratina e o colágeno, resultando em menor média de UH em comparação ao ameloblastoma, esse é constituído por células epiteliais e tecido conjuntivo denso, logo expressa maior média de UH. (ARIJI *et al.*, 2011; CRUSOÉ-REBELLO *et al.*, 2009; TAKATA E SLOOTWEG, 2017). Assim sendo, justifica-se a seleção de imagens por TCMD em razão da necessidade de distinção dos tecidos que compõem tanto massa tumoral quanto cavidade cística, o que se torna viável com o uso desse exame a partir da seleção da janela adequada (WHITE E PHAROAH, 2008).

Alguns autores já reportaram resultados promissores no diagnóstico auxiliado por computadores com o uso de imagens por TCFC na diferenciação entre cistos periapicais e queratocistos odontogênicos (YILMAZ *et al.*, 2017), diagnóstico de lesões radiolúcidas (OKADA *et al.*, 2015; SILVA *et al.*, 2019), cistos na região maxilofacial (ABDOLALI *et al.*, 2016; LEE; KIM; JEONG, 2020), porém nenhum

desses investigou acurácia de classificação de lesões de diferentes natureza, porém características radiográficas similares.

Em investigação da capacidade de diferenciação de cistos dentígeros, periapicais e QOs pela *GoogLe Inception v.3* através de radiografias panorâmicas ou TCFCs, os achados exibem acurácia superior da TCFC em comparação à radiografia panorâmica. Esse resultado reforça a influência positiva da TC na redução de erro diagnóstico. De acordo com o Arijji *et al.* (2011), quando fornecidas TCs aos especialistas, estes alcançaram maiores taxas de acerto quanto à presença ou ausência do queratocisto odontogênico. Visto que o exame fornece quantidade de informações superior à radiografia panorâmica, esse deve ser indicado para fins de diagnóstico tanto por humanos quanto por CNNs.

Embora a capacidade de interpretação radiográfica dos humanos esteja pautada na aquisição de experiência, tendendo a melhorar as taxas de erros com o passar dos anos, a literatura aponta que não houve melhora na acurácia diagnóstica nos últimos 70 anos. A esse fato atribui-se o aumento na complexidade dos exames radiológicos e nos volumes tomográficos adquiridos cada vez maiores (WAITE *et al.*, 2020).

Os erros podem ser classificados entre cognitivos e perceptuais. Erros cognitivos se definem por uma descoberta positiva correta seguida de classificação incorreta devido a raciocínio defeituoso ou falta de conhecimento. Os erros perceptuais são definitivamente mais graves. Com taxas que variam entre 42 e 80% (WAITE *et al.*, 2020), esses se caracterizam pela falha em detectar uma lesão perceptível. Tais taxas de falso negativo podem impactar significativamente no manejo clínico ao qual o paciente será submetido.

Em se tratando de imagens volumétricas, com grandes quantidades de dados a serem interpretados, os radiologistas podem não observar exaustivamente todas as regiões de interesse (WAITE *et al.*, 2020). Contudo, o conhecimento acerca das áreas de maior acometimento das lesões benignas intraósseas dos maxilares e suas características imaginológicas em associação às informações obtidas no exame clínico aumentam as chances de acerto quanto ao diagnóstico sugerido.

Estudos recentes apontam que sistemas baseados em aprendizado profundo alcançaram taxas de erros menores ou similares em comparação a cirurgiões-dentistas (KISE *et al.*, 2019a; KISE *et al.*, 2019b; MURATA *et al.*, 2018; POEDJASTOETI E SUEBNUKARN, 2018). A fim de comparar acurácia diagnóstica

do modelo VGG-16 com 5 cirurgiões buco-maxilofaciais experientes, foi realizado estudo com 500 radiografias panorâmicas de pacientes portadores de QO e Am. Resultados apontam taxas de sensibilidade, especificidade e acurácia de 81,1%, 83,2% e 82,9%, respectivamente, para os profissionais, enquanto a VGG-16 alcançou 81,3%, 83,3% e 83% para os mesmos parâmetros. Embora os dados não tenham apontado significância estatística, a CNN foi capaz de alcançar resultados ligeiramente superiores aos profissionais (POEDJIASTOETI E SUEBNUKARN, 2018).

No estudo para avaliação do desempenho de CNNs para avaliação de sinusite maxilar (MURATA *et al.*, 2018), observou-se taxas de acurácia, sensibilidade e especificidade de 87,5%, 86,7% e 88,3%, respectivamente, as quais não foram superiores aos valores alcançados por radiologistas com vasta experiência. Contudo, a rede neural superou significativamente a capacidade diagnóstica de residentes em Odontologia (acurácia de 76,7%). Ademais, uma vez treinada a rede, o tempo necessário para determinação de presença ou ausência de sinusite maxilar foi de 9s, o que suporta a teoria de potencial de redução de tempo gasto para avaliação clínica.

Para testar a habilidade diagnóstica de Síndrome de Sjögren por CNN VGG16 em comparação a profissionais experientes e inexperientes, imagens de ultrassonografia de glândulas parótida e submandibular foram submetidas a treinamento e teste de validação. Os autores apontaram valores de acurácia, sensibilidade e especificidade superiores a, inclusive, radiologistas com mais de vinte anos de experiência (KISE *et al.*, 2019a). O mesmo grupo de pesquisadores também encontrou resultados animadores para diagnosticar a mesma síndrome a partir de TCMDs e a *AlexNet* manteve acurácia superior a radiologistas inexperientes (KISE *et al.*, 2019b). Todos as pesquisas supracitadas apontam para o grande potencial de aprendizado das CNNs.

De acordo com Waite *et al.* (2020), radiologistas auxiliados por algoritmos baseados em CNN podem fornecer diagnósticos com maior acurácia e rapidez que radiologistas ou algoritmos isoladamente. Além disso, acredita-se que os sistemas demonstram potencial de redução das taxas de erro diagnóstico, melhoria nos resultados clínicos obtidos pelos pacientes, aumento da eficiência e redução de custos (LANGLOTZ *et al.*, 2019).

Como obstáculo à implantação do uso das CNNs na área da saúde destaca-se a necessidade de computadores com muitas Unidades de Processamento Gráfico (*Graphics Processing Unit - GPUs*) para que os resultados sejam obtidos em tempo

razoável; e pessoal treinado e para configuração dos parâmetros da rede e o processo e compreender eventuais entraves como problemas de sobreajuste e a complexidade da fisiologia humana (MCBEE *et al.*, 2018). Contudo, considerando que modelos de redes neurais convolucionais estão disponíveis para livre acesso na internet, a dedicação ao estudo na área possibilitará aos profissionais da saúde, ao invés de adquirir softwares com licenças custosas, desenvolver seu próprio software com as ferramentas que lhe forem úteis e necessárias (LANGLOTZ *et al.*, 2019).

Ressalta-se a natureza inédita do trabalho, visto que ainda não há estudos que reportem avaliação de redes neurais convolucionais para classificação automática de lesões odontogênicas benignas utilizando imagens por TCMD. Ademais, a maior parte das pesquisas já realizadas aplicando CNNs às imagens radiográficas em Odontologia visam a detecção ou o diagnóstico quanto à presença de patologias em comparação a imagens de estruturas saudáveis, não diferenciando duas entidades patológicas complexas e similares como no presente trabalho.

Espera-se que, a médio prazo e após sucessivas rodadas de treinamento e testes, dispondo de *dataset* amplo e altamente variável, esse modelo de CNN possa ser aplicado clinicamente e de maneira gratuita como instrumento auxiliar aos profissionais no que se refere ao diagnóstico imaginológico.



## 7 CONCLUSÃO

De acordo com a metodologia aqui empregada, conclui-se que o modelo de CNN *GoogLe Inception v.3* demonstrou resultados positivos para classificação de imagens tomográficas de queratocistos odontogênicos e ameloblastomas.

## REFERÊNCIAS

- ABDOLALI, F. *et al.* Automated classification of maxillofacial cysts in cone beam CT images using contourlet transformation and Spherical Harmonics. **Computed methods and programs in biomedicine**, v.139, p.197-207, 2017.
- ATARBASHI-MOGHADAM, S. *et al.* Ameloblastoma associated with syndromes: A systematic review. **Journal of stomatology, oral and maxillofacial surgery**, [in press] p.1-4, 2019.
- AUBREVILLE, M. *et al.* Automatic Classification of Cancerous Tissue in Laserendomicroscopy Images of the Oral Cavity using Deep Learning. **SCIENTIFIC Reports** v. 7, 11979: p.1-10, 2017.
- ARIJI, Y. *et al.* Imaging features contributing to the diagnosis of ameloblastomas and keratocyst odontogenic tumours: logistic regression analysis. **Dentomaxillofacial Radiology**, v. 40, p.33-140, 2011.
- 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.
- AZEREDO, F. *et al.* Computed gray levels in multislice and cone-beam computed tomography. **American Journal of Orthodontics and Dentofacial Orthopedics**, v. 144, n. 1, p. 147-155, 2013.
- BARNES, L. *et al.* World Health Organization Classification of Tumours. Pathology and genetics. **Head and Neck Tumours**. Lyon: IARC Press, p. 306–307, 2005.
- BORGHESI, A. *et al.* Odontogenic keratocyst: imaging features of a benign lesion with an aggressive behavior. **Insights into Imaging**, v. 9, n. 5, p. 883-897, 2018.
- BRINKER, T. J. *et al.* Skin Cancer Classification Using Convolutional Neural Networks: Systematic Review. **Journal of Medical Internet Research**, v. 20, n. 10, p. e1193-6, 2018.
- CHA, Y. H. *et al.* In. Frequent oncogenic BRAF V600E mutation in odontogenic keratocyst. **Oral Oncology**, v. 74, p. 62–67, 2017.
- Chang, J. *et al.* A Method for Classifying Medical Images using Transfer Learning: A Pilot Study on Histopathology of Breast Cancer, **IEEE**, 2017.
- CHEN, H. *et al.* A deep learning approach to automatic teeth detection and numbering based on object detection in dental periapical films. **Scientific Reports**, v. 9, n.1, p. 3840, 2019.
- CHO, B.J. *et al.* Automated classification of gastric neoplasms in endoscopic images using a convolutional neural network. **Endoscopy**, v. 51, n. 12, p. 1121-1129, 2019.

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

COUDRAY, N. *et al.* Classification and mutation prediction from non–small cell lung cancer histopathology images using deep learning. **Nature Medicine** v. 24, n. 10, p.1559–1567, 2018.

CRUSOÉ-REBELLO, I. *et al.* Assessment of computerized tomography density patterns of ameloblastomas and keratocyst odontogenic tumors. **Oral Surgery Oral Medicine Oral Pathology Oral Radiology Endodontic**, v. 108, p. 604-608, 2009.

FADEN, D. L. *et al.* Durable treatment of ameloblastoma with single agent BRAFi Re: Clinical and radiographic response with combined BRAF-targeted therapy in stage 4 ameloblastoma. **Journal of the National Cancer Institute**, v. 109, n. 1, p. 1-2, 2017.

FAWCETT, T. An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874, 2006.

FREGNANI, E. R. *et al.* Clinicopathological study and treatment outcomes of 121 cases of ameloblastomas. **International Journal of Oral Maxillofacial Surgery**, v. 39, n. 2, p.145–149, 2010.

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

GAIA, B. F. *et al.* Comparison between cone-beam and multislice computed tomography for identification of simulated bone lesions. **Brazilian Oral Research**, v. 25, n. 4, p. 362-8, 2011.

GOODFELLOW, I. *et al.* Deep learning, volume 1. MIT press Cambridge, 2016.

GOHEL, A. *et al.* Multidetector Row Computed Tomography in Maxillofacial Imaging. **Dental Clinics of North America**, v. 62, n. 3, p. 453-465, 2018.

GONG, J. *et al.* A deep residual learning network for predicting lung adenocarcinoma manifesting as ground-glass nodule on CT images. **European Radiology**, [in press] 2019.

HACKELING, G. Mastering Machine Learning with scikitlearn. Packt Publishing Ltd. (2017).

GÜMÜSOK, M. *et al.* Evaluation of keratocystic odontogenic tumors using cone beam computed tomography. **Journal of Istanbul University Faculty of Dentistry**, v. 50, n. 3; 32-37, 2016.

HENDRA, F. N. *et al.* Global incidence and profile of ameloblastoma: A systematic review and meta-analysis. **Oral Diseases**, v. 26, n. 1, p. 1–10, 2019.

HENDRA, F. N. *et al.* Radical vs conservative treatment of intraosseous ameloblastoma: systematic review and meta-analysis. **Oral Diseases**, v. 25, n. 7, p.1683-1696, 2019.

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, p. 1-7, 2018.

KAUKE, M. *et al.* Volumetric analysis of keratocystic odontogenic tumors and non-neoplastic jaw cysts – comparison and its clinical relevance. **Journal of Cranio-Maxillo-facial Surgery**, v. 46, n. 2, p. 257-263, 2017.

KAYE, F. J. *et al.* Clinical and Radiographic Response With Combined BRAF-Targeted Therapy in Stage 4 Ameloblastoma. **Journal of National Cancer Institute**, v. 107, n. 1, p. 1-3, 2015.

KISE, Y. *et al.* Usefulness of a deep learning system for diagnosing Sjögren's syndrome using ultrasonography images. **Dentomaxillofacial Radiology**, [in press], 2019a.

KISE, Y. *et al.* Preliminary study of the application of the deep learning system to the diagnosis of Sjögren's syndrome on CT images. **Dentomaxillofacial Radiology**, v. 48, n. 6, 2019b.

KOHAVI, R. A Study of Cross Validation and Bootstrap for Accuracy Estimation and Model Selection. In: International Joint Conference on Artificial Intelligence, 1995

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E.; Imagenet classification with deep convolutional neural networks. *In Advances in neural information processing systems*, p.1097-1105, 2012.

LANGLOTZ, C. P. *et al.* A Roadmap for Foundational Research on Artificial Intelligence in Medical Imaging: From the 2018 NIH/RSNA/ACR/The Academy Workshop. **Radiology**, v. 291, n. 3, p. 781–791, 2019.

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

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

LEE, D. *et al.* Deep Convolutional Neural Network–based Software Improves Radiologist Detection of Malignant Lung Nodules on Chest Radiographs. **Radiology**, v. 294, n. 1, p. 199-209, 2019.

LEE, J.; KIM, D.; JEONG, S. Diagnosis of cystic lesions using panoramic and cone beam computed tomographic images based on deep learning neural network. **Oral Diseases**, v. 26, p. 152-158, 2020.

- LECUN, Y. *et al.* Gradient-Based Learning Applied to Document Recognition. **Proc. Of the IEEE**, 1998.
- LEDESMA-MONTES, C. *et al.* Ameloblastomas: a regional Latin-American multicentric study. **Oral diseases**, v. 13, n. 3, p. 303-307, 2007.
- LIEW, C. The future of radiology augmented with Artificial Intelligence: A strategy for success. **European Journal of Radiology**, v. 102, p. 152–156, 2018.
- MACDONALD, D. Lesions of the jaws presenting as radiolucencies on cone-beam CT. **Clinical Radiology**, v. 71, n. 10, 972-985, 2016.
- MCBEE, M. P. *et al.* Deep Learning in Radiology. **Academic Radiology**, v. 25, n. 11, p. 1472-1480, 2018.
- MEDNIKOV Y. *et al.* Transfer Representation Learning using Inception-V3 for the Detection of Masses in Mammography. **Conf Proc IEEE Eng Med Biol Soc**, p. 2587-2590, 2018.
- MISHRA, S. S. *et al.* Comparative study of cone-beam computed tomography and multislice computed tomography in the radiographic evaluation of cysts and tumors of the jaws. **Journal of Indian Academy of Oral Medicine & Radiology**, v. 26, n. 3, p. 253-259, 2014.
- MUPPARAPU, M.; WU, C.; CHEN, Y. Artificial intelligence, machine learning, neural networks, and deep learning: Futuristic concepts for new dental diagnosis. **Quintessence International**, v. 49, n. 9, p. 687-688, 2018.
- MURATA, M. *et al.* Deep-learning classification using convolutional neural network for evaluation of maxillary sinusitis on panoramic radiography. **Oral Radiology**, v. 35, n. 3, p. 301-307, 2018.
- NEAGU, D. *et al.* Surgical management of ameloblastoma. Review of literature. **Journal of Clinical and Experimental Dentistry**, v. 11, n. 1, p. e70-e75, 2019.
- OKADA, K. *et al.* Noninvasive differential diagnosis of dental periapical lesions in cone-beam CT scans. **Medical Physics**, v. 42, n. 4, p. 1653-65, 2015.
- POEDJIASTOETI, W.; SUEBNUKARN, S. Application of Convolutional Neural Network in the Diagnosis of Jaw Tumors. **Healthcare Informatic Research**, v. 24, n. 3, p. 236-241, 2018.
- POGREL, M. A. The keratocystic odontogenic tumour (KCOT) — an odyssey. **International Journal of Oral and Maxillofacial Surgery**, v. 44, n.12, p. 1565-1568, 2015.
- RINGER, Eric; KOLOKYTHAS, Antonia. Bone Margin Analysis for Benign Odontogenic Tumors. **Oral and maxillofacial surgery clinics of North America**, v. 29, n. 3, p. 293-300, 2017.

- RODRIGUES, A. F. *et al.* Use of Gray Values in CBCT and MSCT Images for Determination of Density: Influence of Variation of FOV Size. **Implant Dentistry**, v. 24, n. 5, p. 155-159, 2015.
- SANTOS, J. L. *et al.* Odontogenic Keratocysts as First Manifestation of Nevroid Basal Cell Carcinoma Syndrome: Surgical Management and Immunohistochemical Analysis. **The Journal of Craniofacial Surgery**, v. 29, n. 6, p. 1588-1590, 2018.
- SANTOSH, A. B. R.; OGLE, O.E. Odontogenic Tumors. **Dental clinics of North America**, v. 64, n. 1, p. 121-138, 2020.
- SANTOSH, A. B. R. Odontogenic Cysts. **Dental clinics of North America**, v. 64, n. 1, p. 105–119, 2020.
- SCARFE, W. C.; TOGHYANI, S.; AZEVEDO, B. Imaging of Benign Odontogenic Lesions. **Radiologic clinics of North America**, v. 56, n. 1, p. 45–62, 2018.
- 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.
- SILVA, Y. S. *et al.* Is conservative surgery a better choice for the solid/multicystic ameloblastoma than radical surgery regarding recurrence? A systematic review. **Oral and Maxillofacial Surgery**, v. 22, n. 4, p. 349–356, 2018.
- SIM, Y. *et al.* Deep Convolutional Neural Network-based Software Improves Radiologist Detection of Malignant Lung Nodules on Chest Radiographs. **Radiology**, v. 294, n. 1, p. 199-209, 2020.
- SUZUKI, K. Overview of deep learning in medical imaging. **Radiological Physics and Technology**, v.10, n. 3, p. 257–273, 2017.
- SZEGEDY, C. *et al.* Rethinking the Inception Architecture for Computer Vision. In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 2818-2826, 2016.
- TABRIZI, R. *et al.* Decompression or Marsupialization; Which Conservative Treatment is Associated with Low Recurrence Rate in Keratocystic Odontogenic Tumors? A Systematic Review. **Journal of dentistry (Shiraz, Iran) University of Medical Sciences**, v. 20, n. 3, p.145-151, 2019.
- TAKATA, T.; SLOOTWEG, P.J. Odontogenic and Maxillofacial Bone Tumours. *In*: EL-NAGGAR, A *et al.* **WHO Classification of Head and Neck Tumours**, 4<sup>a</sup> ed, Lyon: IARC, cap. 8, p. 203-260, 2017.
- WAITE, S. *et al.* A Review of Perceptual Expertise in Radiology-How it develops, How we can test it, and Why humans still matter in the era of Artificial Intelligence. **Academic radiology**, v. 27, n. 1, p. 26-38, 2020.

WHITE, S.C.; PHAROAH, M. J. The Evolution and Application of Dental Maxillofacial Imaging Modalities. **Dental Clinics of North America**, v. 52, n. 4, p. 689–705, 2008.

YASAKA, K.; ABE, O. Deep learning and artificial intelligence in radiology: Current applications and future directions. **PLoS Medicine**, v. 15, n. 11, 2018.

YILMAZ, E.; KAYIKCIOGLU, T.; KAYIPMAZ, S. Computer-aided diagnosis of periapical cyst and keratocystic odontogenic tumor on cone beam computed tomography. **Computer methods and programs in biomedicine**, v. 146, p. 91-100, 2017.

## ANEXO – PARECER CONSUBSTANCIADO DO CEP

HOSPITAL SANTO ANTÔNIO/  
OBRAS SOCIAIS IRMÃ DULCE



### PARECER CONSUBSTANCIADO DO CEP

#### DADOS DO PROJETO DE PESQUISA

**Título da Pesquisa:** AVALIAÇÃO DE MICRONUTRIENTES E OLIGOELEMENTOS DE PACIENTES COM TUMORES ODONTOGÊNICOS

**Pesquisador:** Leila Brito de Queiroz Ribeiro

**Área Temática:**

**Versão:** 3

**CAAE:** 13396313.0.0000.0047

**Instituição Proponente:** Hospital Santo Antônio/ Obras Sociais Irmã Dulce

**Patrocinador Principal:** Hospital Santo Antônio/ Obras Sociais Irmã Dulce

#### DADOS DO PARECER

**Número do Parecer:** 366.989

**Data da Relatoria:** 07/08/2013

#### Apresentação do Projeto:

O projeto intitulado "AVALIAÇÃO DE MICRONUTRIENTES E OLIGOELEMENTOS EM PACIENTES COM TUMORES ODONTOGÊNICOS" refere-se a um trabalho de doutorado que será realizado por Leila Brito de Queiroz Ribeiro sob a orientação da Profª Drª Ilda Crusó Rebelo. O estudo é prospectivo e visa avaliar micronutrientes e vitaminas de pacientes com Tumores Odontogênicos atendidos na Faculdade de Odontologia da UFBA e no Hospital Santo Antônio que apresentarem imagens sugestivas de lesões dos referidos tumores.

#### Objetivo da Pesquisa:

**Geral:** Avaliar os resultados dos exames laboratoriais de micronutrientes e vitaminas de pacientes com Tumores Odontogênicos. **Específicos:** Realizar o diagnóstico de lesões intra-ósseas benignas dos maxilares através de exames imaginológicos Panorâmicos e Tomografia computadorizada de Feixe Cônico e análise anatomo-patológica; Caracterizar as lesões quanto à localização, tamanho, coeficiente de atenuação, relação com estruturas vizinhas, margens, expansão óssea, dentre outros parâmetros imaginológicos.

#### Avaliação dos Riscos e Benefícios:

De acordo com a pesquisadora, os riscos são aqueles referentes aos procedimentos médicos necessários para o diagnóstico e tratamento dos pacientes. A pesquisa fará avaliações

Endereço: Av. Bonfim 181

Bairro: Largo de Roma

CEP: 40.420-000

UF: BA

Município: SALVADOR

Telefone: (71)3310-1335

Fax: (71)3310-1335

E-mail: cep@irmadulce.org.br