

PONTIFÍCIA UNIVERSIDADE CATÓLICA DE MINAS GERAIS
Programa de Pós-graduação em Odontologia

Luciano Augusto de Avelar Francisco

**USO DA INTELIGÊNCIA ARTIFICIAL NA DETECÇÃO DE APLAINAMENTO NO
PROCESSO CONDILAR DA ARTICULAÇÃO TEMPOROMANDIBULAR**

Belo Horizonte
2021

Luciano Augusto de Avelar Francisco

**USO DA INTELIGÊNCIA ARTIFICIAL NA DETECÇÃO DE APLAINAMENTO NO
PROCESSO CONDILAR DA ARTICULAÇÃO TEMPOROMANDIBULAR**

Dissertação apresentada ao Programa de Pós-graduação em Odontologia da Pontifícia Universidade Católica de Minas Gerais, como requisito parcial para obtenção do título de Mestre em Odontologia, Área de Concentração: Clínicas Odontológicas, Área Temática: Radiologia Odontológica e Imaginologia.

Linha de pesquisa: Métodos de diagnóstico por imagem, radiobiologia e radioproteção.

Orientador: Prof. Dr. Amaro Ilídio Vespasiano Silva

Belo Horizonte

2021

FICHA CATALOGRÁFICA

Elaborada pela Biblioteca da Pontifícia Universidade Católica de Minas Gerais

F819u	Francisco, Luciano Augusto de Avelar Uso da inteligência artificial na detecção de aplainamento no processo condilar da articulação temporomandibular / Luciano Augusto de Avelar Francisco. Belo Horizonte, 2021. 65 f.: il. Orientador: Amaro Ilídio Vespasiano Silva Dissertação (Mestrado) – Pontifícia Universidade Católica de Minas Gerais. Programa de Pós-Graduação em Odontologia 1. Articulação temporomandibular. 2. Radiografia panorâmica. 3. Radiografia Dentária Digital. 4. Inteligência artificial. 5. Redes neurais (Computação). 6. Tratamento odontológico. I. Silva, Amaro Ilídio Vespasiano. II. Pontifícia Universidade Católica de Minas Gerais. Programa de Pós-Graduação em Odontologia. III. Título. CDU: 616.724
-------	--

Luciano Augusto de Avelar Francisco

**USO DA INTELIGÊNCIA ARTIFICIAL NA DETECÇÃO DE APLAINAMENTO NO
PROCESSO CONDILAR DA ARTICULAÇÃO TEMPOROMANDIBULAR**

Dissertação apresentada ao Programa de Pós-graduação em Odontologia da Pontifícia Universidade Católica de Minas Gerais, como requisito parcial para obtenção do título de Mestre em Odontologia. Área de Concentração: Clínicas Odontológicas – Área Temática: Radiologia Odontológica e Imaginologia.

COMPOSIÇÃO DA BANCA EXAMINADORA:

- 1- Profa. Dra. Roselaine Moreira Coelho Milagres – UFMG
- 2- Prof. Dr. Flávio Ricardo Manzi – PUC Minas
- 3- Prof. Dr. Amaro Ilídio Vespasiano Silva – PUC Minas

DATA DA APRESENTAÇÃO E DEFESA: 23 de fevereiro de 2021

A dissertação, nesta identificada, foi aprovada pela Banca Examinadora

Prof. Dr. Amaro Ilídio Vespasiano Silva
Orientador

Prof. Dr. Rodrigo Villamarim Soares
**Coordenador do Programa de Pós-graduação
em Odontologia**

*À Deus e a Família,
por serem presentes em minha vida e me guiar com bons exemplos.*

AGRADECIMENTOS

À Deus, pela família na qual permitiu que eu viesse ao mundo, por minha saúde e por todas as demais bênçãos que me deu a oportunidade de usufruir.

Aos meus pais Heraldo e Maria Auxiliadora por me ensinarem o caminho do bem, da honestidade e do trabalho, principalmente por seus exemplos.

À minhas irmãs Walderez e Vanessa e irmãos Bruno, Adriano e Luiz, pelos cuidados e carinho a mim dispensados, pela boa convivência que sempre tivemos, pelas correções feitas quando necessárias e pelos bons exemplos.

À minha querida esposa Ana Cristina, por seu amor, companheirismo, compreensão e apoio incondicional nesta jornada da vida. Que bom que Deus colocou você em minha caminhada!

Aos meus sogros Fernando e Maria Auxiliadora pelo apoio que sempre me prestam e ao meu cunhado Paulo pela prontidão em participar deste projeto e pelo tempo dispensado.

Aos meus contemporâneos de curso, Leonardo, Tânia, Juliana, Mariana e Raquel meus agradecimentos pela troca de experiências e ensinamentos, em especial à Micheline, por ter enfrentado todo o percurso junto comigo, sempre prestando apoio.

Ao coordenador do curso, Dr. Rodrigo Villamarim Soares e à equipe de professores do Mestrado Acadêmico, pela dedicação e qualidade entregue nas aulas e por tornar possível a realização deste sonho.

Às Funcionárias da Secretaria da Pós Graduação em Odontologia, Angélica e Silvânia, por sempre estarem disponíveis ajudando a solucionar qualquer intercorrência da nossa caminhada e aos demais funcionários da PUC Minas por manter tudo em ordem para o bom desempenho dos alunos.

À aluna da graduação, Ariella do Carmo Souza, pelo empenho, disposição e dedicação durante a confecção deste estudo.

Ao professor Dr. Flávio Ricardo Manzi pelo incentivo e apoio prestado desde o curso de especialização e pela motivação para cursar o mestrado e por inspirar seus alunos a querer compartilhar o conhecimento.

Ao Professor Dr. Amaro Ilídio Vespasiano Silva, meu orientador, por ser a excelente pessoa que é, por sua ética, sua dedicação e paciência, por sempre dar bons exemplos, inspirando-me a melhorar a cada dia, me guiando nesta caminhada.

Que Deus abençoe a todos!!!

“A humildade é a única base sólida de todas as virtudes” (CONFÚCIO).

RESUMO

A disfunção da Articulação Temporomandibular é um desafio para o Cirurgião-Dentista desde seu diagnóstico ao tratamento. A identificação de sinais da disfunção, a partir da radiografia panorâmica, possibilita o diagnóstico precoce e maior eficácia no tratamento. Amplamente utilizada pela medicina, a Inteligência Artificial (IA) utiliza redes neurais artificiais capazes de detectar alterações ao padrão convencional de raciocínio semelhante ao cérebro humano. A incorporação da IA representa um novo paradigma na prática odontológica. O objetivo no presente estudo foi comparar a identificação de aplainamento na cabeça da mandíbula, em radiografias panorâmicas digitais, feita por especialistas em Radiologia e Imaginologia Odontológica, com os resultados obtidos através de Redes Neurais Convolucionais, utilizando *Deep Learning*. Um total de 5.120 radiografias panorâmicas digitais, foram submetidas aos critérios de inclusão e exclusão, sendo 3.457 aprovadas e analisadas pelos especialistas. A seguir foram divididas em 2.500 (72.32%) para treinamento e validação da Rede Neural Convolucional, com balanceamento entre as categorias e 957 (27.68%) restantes para teste na identificação do aplainamento condilar, pela IA. As 957 radiografias do *dataset* do teste geraram 1914 imagens, das quais 1.886 não possuíam aplainamento e 28 possuíam. Para equalizar este *dataset*, foram utilizadas 28 de cada categoria, totalizando 56 imagens. O resultado mostrou que o software foi capaz de reconhecer 100% das imagens que possuíam e 42.86% das que não possuíam aplainamento condilar. Concluiu-se que a diferença estatística entre as análises realizadas pelos especialistas e pelo *software* é relevante. Apesar do desempenho do *Script Python* criado ser satisfatório, o mesmo ainda não está apto para ser utilizado como substituto da análise humana devido à baixa acurácia.

Palavras-chave: Inteligência artificial. Aprendizado profundo. Articulação temporomandibular.

ABSTRACT

Temporomandibular joint (TMJ) dysfunction is a challenge for dentists from diagnosis to treatment. The identification of signs of the dysfunction, based on panoramic radiography, allows early diagnosis and greater treatment efficiency. Widely used in medicine, Artificial Intelligence (AI) uses artificial neural networks capable of detecting changes to the conventional reasoning pattern similar to the human brain. The incorporation of AI represents a new paradigm in dental practice. The objective of the present study was to compare the identification of planing in the mandible head, in digital panoramic radiographs, made by two specialists in Radiology and Dental Imaging, with the results obtained through Convolutional Neural Networks, using Deep Learning. A total of 5,120 digital panoramic radiographs were submitted to the inclusion and exclusion criteria, 3,457 being approved and analyzed by two specialists in Radiology and Dental Imaging. Next, they were divided into 2,500 (72.32%) for training and validation of the Convolutional Neural Network, with balance between the categories and 957 (27.68%) remaining for testing in the identification of condylar planing, by AI, comparing its performance to obtained by specialists. The 957 radiographs of the test dataset generated 1914 images, of which 1,886 had no planing and 28 did. To equalize this dataset, 28 of each category were used, totaling 56 images. The result showed that the software was able to recognize 100% of the images they had and 42.86% of those that did not have condylar planning. It was concluded that the statistical difference between the analyzes performed by the specialists and the software is relevant. We understand, however, that the performance of the Python Script is satisfactory, although it is not yet able to be used as a substitute for human analysis.

Keywords: Artificial intelligence. Deep learning. Temporomandibular joint disorders.

LISTA DE ABREVIATURAS E SIGLAS

ATM	Articulação Temporomandibular
DTM	Disfunção Têmporo Mandibular
IA	Inteligência artificial
RNs	Redes Neurais
RNA	Redes Neurais Artificiais
RNC	Redes Neurais Convolucionais

LISTA DE FIGURAS

Figura 1: Padrão do processamento nas radiografias; A) Radiografia panorâmica; B) Corte lado direito; C) Corte lado esquerdo.	31
Figura 2: Distribuição do <i>dataset</i> de treino e validação.....	31
Figura 3: Sumário do modelo adotado	33

SUMÁRIO

1 INTRODUÇÃO	23
2 OBJETIVOS.....	27
2.1 Objetivo geral	27
2.2 Objetivos específicos.....	27
3 MATERIAL E MÉTODOS	29
3.1 Obtenção da amostra.....	29
3.2 Avaliação das imagens	30
3.3 Processamento das imagens	30
3.4 Modelagem da Rede Neural Convolucional	32
3.5 Comparação com profissionais especialistas em Radiologia e Imaginologia Odontológica	34
3.6 Testes estatísticos	34
4 ARTIGO CIENTÍFICO	35
5 CONSIDERAÇÕES FINAIS	59
REFERÊNCIAS.....	61
ANEXO A – Parecer Consubstanciado do CEP PUC Minas.....	63

1 INTRODUÇÃO

A articulação temporomandibular (ATM) é uma das articulações mais exigidas e utilizadas do nosso corpo. Caracteriza-se por unir estruturas fixas da base do crânio com um osso móvel, que se desloca em sincronia com uma articulação idêntica e simétrica, sendo constituída de estruturas ósseas e de tecido mole. As estruturas ósseas são a fossa mandibular e eminência articular do osso temporal e a cabeça do côndilo na mandíbula. Suas faces articulares são recobertas por tecido conjuntivo denso modelado, diferentemente de outras articulações sinoviais, que são cobertas por cartilagem hialina. Os componentes do tecido mole são os músculos da mastigação, ligamentos articulares, disco articular, cápsula articular, vasos e nervos. (SANTOS, 2010).

As disfunções temporomandibulares afetam o sistema estomatognático como um todo. Sua causa e a patogênese são multifatoriais, envolvendo fatores psicológicos, comportamentais e do meio ambiente. Outras causas incluem, trauma local ou procedimentos que causem estresse articular. O exame clínico é de grande valor em seu diagnóstico, porém possui limitações devido à dificuldade de padronização de seus critérios. Métodos auxiliares eficazes são necessários na obtenção de dados que complementem o exame clínico no diagnóstico e tratamento das alterações da ATM. O exame por meio de imagens proporciona informações complementares importantes para a obtenção do diagnóstico (SILVEIRA *et al.*, 2014).

Muitas enfermidades podem afetar a ATM. Doenças não-disfuncionais, de origem inflamatória, neoplásica e traumática, inclusive não diretamente localizadas na articulação, podem promover os mesmos sintomas da Disfunção Temporomandibular (DTM). Os principais sintomas relatados pelos pacientes acometidos são: dor, espasmos musculares, estalido, crepitação, dor ou zumbido no ouvido e restrição funcional (GOYATÁ *et al.*, 2010).

O aplainamento condilar é uma alteração adaptativa à primeira mudança de uma doença ou, uma alteração degenerativa secundária a um desarranjo interno ou resultante de uma sobrecarga sobre a ATM. Pode ser descrito como a perda da convexidade dos processos condilares, sendo um defeito local da rarefação da camada óssea compacta. O aplainamento está entre as alterações degenerativas mais prevalentes (SILVEIRA *et al.*, 2014). Sua prevalência aumenta gradualmente

com a idade sendo a alteração articular mais comumente encontrada (BÄCK *et al.*, 2017).

Inteligência artificial (IA) é um ramo das ciências computacionais que objetiva a criação de sistemas capazes de responderem questões que normalmente exigem uma abordagem humana para serem compreendidos (CHARTRAND *et al.*, 2017). É definida como a teoria e o desenvolvimento de sistemas de computador aptos a realizar tarefas que normalmente necessitariam de inteligência humana. O principal componente da IA é a *Machine Learning* (CHARTRAND *et al.* 2017; KING JÚNIOR, 2017).

Machine learning é um ramo da ciência da computação que constrói algoritmos guiados por dados, treinados para executar tarefas por padrões de aprendizagem de dados em vez de por programação explícita, entre eles, redes neurais (RNs), que consistem em nós e pesos, é um dos primeiros tipos de algoritmos de IA que foram desenvolvidos (HWANG *et al.*, 2019).

Redes Neurais Artificiais (RNA) são modelos matemáticos flexíveis que utilizam múltiplos algoritmos para identificar relações não-lineares complexas dentro de grandes bases de dados. Com isso é possível que o programa seja treinado e seja capaz de identificar variações ao padrão normal (KING JÚNIOR, 2017; MILLER; BROWN, 2018).

A IA tem sido amplamente utilizado na área médica, e mais recentemente na área odontológica, e esse novo campo de pesquisa, que apresenta um crescimento rápido tem demonstrado bons resultados e grande aplicabilidade nas áreas supracitadas, principalmente no auxílio de diagnóstico por imagens (LEE *et al.*, 2018).

Recentemente, várias aplicações clínicas de redes neurais convolucionais (RNC) têm sido propostas e estudadas em Radiologia para tarefas de classificação, detecção e segmentação (CHARTRAND *et al.*, 2017).

Os exames complementares mais utilizados na clínica odontológica são as radiografias, destacando-se a panorâmica por sua abrangência, que propicia a completa visão das estruturas faciais, auxiliando o diagnóstico e o planejamento do tratamento das condições patológicas encontradas, que podem não ser detectadas ao exame clínico (BARBIERI, 2011).

Alguns trabalhos na área da Odontologia utilizam inteligência artificial e radiografia panorâmica, por se tratar de um exame de fácil acesso, baixo custo e

bastante utilizado pelos cirurgiões-dentistas. Hwang *et al.* (2017) tiveram como objetivo desenvolver um modelo de detecção de osteoporose em radiografias panorâmicas, obtendo como resultados aproximados de sensibilidade, especificidade e acurácia de 97,15%, 96,9% e 96,58% respectivamente. Em outro trabalho, Hiraiwa *et al.* (2019) avaliaram a capacidade de uma rede neural artificial em analisar a morfologia da raiz distal de primeiros molares inferiores, identificando a presença de raiz supranumerária em imagem de radiografias panorâmicas, utilizando Tomografia Computadorizada de Feixe Cônico como padrão ouro e comparando com a análise de dois radiologistas, obtendo precisão de diagnóstico de 86,9%.

O presente trabalho é baseado na análise das imagens da radiografia panorâmica, para que um exame de rotina possa ser uma importante ferramenta no diagnóstico precoce do aplainamento condilar em mandíbula, gerando assim benefício aos pacientes, que poderão iniciar o tratamento antes que a condição detectada possa se agravar e ao cirurgião-dentista que pode reconhecer uma condição patológica capaz de influenciar tanto o seu planejamento quanto o tratamento a ser escolhido.

O objetivo neste trabalho foi identificar aplainamento na cabeça da mandíbula em radiografias panorâmicas digitais, por meio de um *Script Python* (software) desenvolvido pelo sistema Deep Learning, de inteligência artificial, para este estudo analisando sua sensibilidade, especificidade e acurácia e comparar estes dados com os obtidos através de avaliação de diagnóstico realizada por dois cirurgiões-dentistas radiologistas.

2 OBJETIVOS

2.1 Objetivo geral

O objetivo no presente estudo foi comparar a identificação de aplainamento na cabeça da mandíbula, em radiografias panorâmicas digitais, feita por dois especialistas em Radiologia e Imaginologia Odontológica, com os resultados obtidos por experimentos de um modelo gerado através de Redes Neurais Convolucionais, utilizando *Deep Learning*, em um *dataset* que utiliza as mesmas radiografias analisadas pelos especialistas.

2.2 Objetivos específicos

- a) comparar os resultados gerados da análise de radiografias panorâmicas digitais, a partir do modelo criado com os dados encontrados pela avaliação de diagnóstico realizada por cirurgiões-dentistas radiologistas;
- b) desenvolver um *Script Python* (software) capaz de consultar imagens de teste e o modelo para detectar aplainamento condilar nas articulações temporomandibulares.

3 MATERIAL E MÉTODOS

O projeto do presente estudo foi enviado para análise prévia pelo Comitê de Ética em Pesquisa por meio do site governamental “Plataforma Brasil”, e após avaliação, foi emitido o parecer número 3.652.333, de 21 de outubro de 2019, favorável à sua execução (ANEXO A).

3.1 Obtenção da amostra

Após cálculo amostral, o n encontrado foi de 364 imagens, o que totaliza 182 radiografias panorâmicas para serem analisadas pela inteligência Artificial. Entendemos que a majoração deste n beneficia o estudo e assim utilizamos um total de 5.120 radiografias panorâmicas digitais, realizadas pelo serviço de Radiologia do Departamento de Odontologia da Pontifícia Universidade Católica de Minas Gerais, entre os anos de 2016 a 2019 e observando os critérios de inclusão e exclusão.

O critério de inclusão dos exames no estudo foi radiografias panorâmicas digitais de boa qualidade técnica, realizadas com o paciente no posicionamento correto, ou seja, com pescoço alongado, ombros para baixo, costas retas e pés juntos. O plano sagital mediano perpendicular ao solo e o plano de Frankfurt, deve ser paralelo ao solo. O posicionamento anteroposterior é determinado pelos bordos incisais dos dentes incisivos superiores e inferiores dentro dos sulcos do posicionador (bite-block), com o apoio do queixo e a língua apoiada contra o palato, para que as estruturas fiquem dentro da zona de corte do equipamento, incluindo a região da articulação temporomandibular (ALENCAR *et al.*, 2020).

Como critério de exclusão cita-se radiografias realizadas com os pacientes mal posicionados, com imagens distorcidas e/ou com artefatos que interfiram na sua análise, com imagens parciais dos côndilos mandibulares e pacientes menores de 10 anos que ainda possuíam dentes decíduos em sua arcada. Além disso, radiografias de pacientes que apresentam outros tipos de doenças nas articulações temporomandibulares tais como artrite, artrose, côndilo bífido, osteófitos, erosão entre outras condições patológicas também foram eliminadas deste estudo.

Após aplicação dos critérios de inclusão e exclusão, obteve-se 3.457 radiografias que geraram 6.914 imagens de cabeças da mandíbula para serem analisadas.

3.2 Avaliação das imagens

A identificação dos pacientes foi mantida em sigilo. As imagens digitais foram avaliadas quanto aos critérios de inclusão e exclusão e as aprovadas analisadas pelos especialistas. A seguir foram interpretadas e processadas diretamente no software desenvolvido para o presente estudo, através da Inteligência Artificial, com a seguinte configuração do computador: iMac (monitor de retina 4K, 21.5 polegadas, 2017), processador Quad-Core Intel Core i5, memória de 8GB 2400 MHz DDR4 e placa de vídeo Radeon Pro 555 2GB.

3.3 Processamento das imagens

Após a seleção dos especialistas, o total de 3457 radiografias foram cortadas e redimensionadas para 3 cm de largura por 3 cm de altura, com resolução de 300dpi, de modo que foram mantidos nas imagens apenas a região da ATM de cada lado, gerando 6.914 imagens (lados direito e esquerdo) (Fig. 1A, 1B e 1C).

A seguir, como sugerido por Brownlee (2019) foram feitos vários experimentos que consideraram inclusive a transferência de aprendizagem usando a aplicação do *Keras* chamada *InceptionV3*¹.

O *InceptionV3* usa um “*input shape*” padrão (299, 299, 3)² e, por isso, as imagens passaram por um novo redimensionamento para atendê-lo, caindo para a resolução de 72 dpi.

As experimentações com o *InceptionV3* apresentaram resultados muito aquém do esperado, com as imagens da forma como haviam sido tratadas. Sendo assim, foi feita uma tentativa aplicando um “*flip horizontal*” nas imagens do lado esquerdo, facilitando o aprendizado do modelo por remover a necessidade de entender o lado que estava sendo analisado. Dessa forma, a análise binária – Possui x Não Possui – seria mantida.

Do total de 6.914 imagens disponíveis para compor o dataset, 5.000 foram utilizadas para treino e validação do modelo, sendo 4.000 para treino e 1.000, para validação. Estas imagens foram igualmente divididas em duas categorias (*labels*): Possui (50%) e Não Possui (50%) aplainamento condilar (Fig. 2).

¹ [InceptionV3 \(keras.io\)](https://keras.io/api/applications/inceptionv3/) - <https://keras.io/api/applications/inceptionv3/>

² 299 pixels de comprimento, 299 pixels de altura, 3 camadas de cores (RGB)


Figura 1: Padrão do processamento nas radiografias; A) Radiografia panorâmica; B) Corte lado direito; C) Corte lado esquerdo



Fonte: Elaborado pelo autor

As 1.914 imagens restantes estavam aptas para testes, já que não eram conhecidas pelo modelo. Entretanto, de acordo com os especialistas, 1.886 não possuíam aplainamento condilar e 28 possuíam. Por causa dessa discrepância nas quantidades, e com o intuito de equilibrar o número entre as categorias para o teste, facilitando a análise final das imagens pelo modelo criado, foi estabelecido que seriam selecionadas 28 imagens que não possuíam aplainamento condilar, totalizando 56 imagens utilizadas para o teste.

Figura 2: Distribuição do *dataset* de treino e validação



Fonte: Elaborado pelo autor

Após essa seleção – feita seguindo apenas a ordem na qual as imagens estavam nos respectivos diretórios (Possui / Não Possui) – foi acionada uma análise automatizada via *Script Python* criado para tal finalidade, usando o modelo como base para categorização das imagens de teste.

3.4 Modelagem da Rede Neural Convolutacional


Segundo Yamashita *et al.* (2018), rede neural convolutacional é uma classe de métodos de aprendizagem profunda que se tornou dominante em várias tarefas de visão computacional e está atraindo interesse em uma variedade de domínios, incluindo a radiologia.

A RNC criada para este trabalho, utiliza a *Sequential API* do Keras. A ideia básica por trás dessa *Sequential API* é organizar as camadas Keras em ordem sequencial, fazendo com que o fluxo de dados ocorra entre as camadas em apenas uma direção.

O modelo final foi estabelecido com 4 camadas convolucionais 2D (com o objetivo de aumentar a “profundidade”), cada uma delas seguida de uma camada de maxpooling 2D (para reduzir o tamanho do volume dos dados), que passaram por um processo de “achatamento” (“*Flatten*”), seguido de 2 camadas densas intercaladas por um “Dropout” (com o objetivo de reduzir *overfitting*), sendo que a última delas usa o classificador *sigmoid* (por serem apenas duas categorias) (Fig. 3).

Segundo Görner (2020), *Flatten* é o achatamento de um cubo de dados em um vetor, para que uma camada densa a possa consumir e o *overfitting* acontece quando uma rede neural aprende “mal”, de uma forma que funciona para os exemplos de treinamento, mas não tão bem em dados desconhecidos. Quando uma rede neural tem muitos graus de liberdade para o problema em questão, ela pode armazenar em seus neurônios todas as nossas imagens de treinamento e reconhecê-las por correspondência de padrões. Este modelo falharia completamente nos dados “do mundo real”. Uma rede neural deve ser um tanto restrita, de modo que seja forçada a generalizar o que aprende durante o treinamento. Nos casos em que houver poucos dados de treinamento, mesmo uma pequena rede pode memorizá-los causando “overfitting”. De modo geral, você sempre precisa de muitos dados para treinar redes neurais convolucionais.

Figura 3: Sumário do modelo adotado



Fonte: Elaborado pelo autor

A função de perda utilizada foi “*Binary Crossentropy*” e o algoritmo de otimização foi o Adam, configurado com a taxa de aprendizagem de 10^{-5} (0.00001).

Foram aplicadas três configurações: 500 *epochs*, um *batch size* de 32 e um *early stop*, sendo que as *epochs* representam quantas vezes o modelo analisa cada imagem, o *batch size* informa quantas imagens são analisadas ao mesmo tempo e o *early stop* foi aplicado para evitar que o treinamento continuasse caso não fosse vista uma melhora significativa na validação da perda – *val_loss* – depois de 20 *epochs*.

3.5 Comparação com profissionais especialistas em Radiologia e Imaginologia Odontológica

As radiografias panorâmicas digitais selecionadas para o teste (3.457) foram avaliadas por dois especialistas em Radiologia e Imaginologia Odontológica, sendo utilizada Escala de Likert com a seguinte configuração:

- a) não possui aplainamento condilar;
- b) provavelmente não possui aplainamento condilar;
- c) impossível classificar;
- d) provavelmente possui aplainamento condilar;
- e) certeza de aplainamento condilar.

3.6 Testes estatísticos

A acurácia obtida através do software posteriormente ao treinamento e teste, foi informada em porcentagem pela própria rede neural. Foi avaliada a precisão do diagnóstico, sensibilidade, especificidade e acurácia nos métodos empregados para análise das alterações do processo condilar, além de realizado teste de McNemar com nível de significância de 5% para comparação entre os grupos. Foi executada a curva ROC para ilustração da acurácia de cada grupo.

4 ARTIGO CIENTÍFICO

Use of Artificial Intelligence in flattening detection in the condylar process of the temporomandibular joint

Article formatted in accordance with the guidelines of the publication **Journal Dentomaxillofacial Radiology (Qualis A2)**.

The submission guidelines can be found at the address below:

<https://www.birpublications.org/page/preparing/dmfr>.

Use of Artificial Intelligence in flattening detection in the condylar process of the temporomandibular joint

Luciano Augusto de Avelar Francisco¹, Ariella do Carmo Souza¹, Ana Cristina Zandona Vieira², Paulo César Zandona Vieira³, Flávio Ricardo Manzi PhD⁴, Amaro Ilídio Vespasiano Silva PhD⁴

¹ Departamento de Odontologia, Pontifícia Universidade Católica de Minas Gerais, Belo Horizonte, Minas Gerais, Brasil.

² Especialista em Radiologia e Imaginologia Odontológica IES – Faipe, Belo Horizonte, Minas Gerais, Brazil.

³ Especialista em Engenharia de Software IEC – Pontifícia Universidade Católica de Minas Gerais, Belo Horizonte, Minas Gerais, Brasil.

⁴ Professor Adjunto, Departamento de Odontologia, Pontifícia Universidade Católica de Minas Gerais, Belo Horizonte, Minas Gerais, Brasil.

Corresponding author:

Amaro Ilídio Vespasiano Silva, Pontifícia Universidade Católica de Minas Gerais, Departamento de Odontologia – Radiologia, Av. Dom José Gaspar, 500/Prédio 45 – Coração Eucarístico, Belo Horizonte, Minas Gerais, Brazil, CEP: 30535-901, Telefone: +55 (31) 3319-4414, E-mail: amarovespasiano@pucminas.br

Statement of Author Contribution

For all articles submitted, DMFR requires that:

- all authors have made substantive contributions to the article and assume full responsibility for its content; and
- all those who made significant contributions to the article were named as authors.

The International Committee of Medical Journal Editors recommends the following definition for an author of a paper, which we ask our authors to follow:

Authorship shall be based on the following 4 criteria [1]:

- Substantial contributions to the conception or design of the work; or acquisition, analysis, or interpretation of data for the work;
- Draft the work or critically review it for important intellectual content;
- Final approval of the version to be published;
- Agree to be responsible for all aspects of the work, ensuring that issues related to the accuracy or integrity of any part of the work are properly investigated and resolved.

List below all the authors of this work and a brief description of how each of them contributed to its submission:

Author's name	Contribution
Luciano Augusto de Avelar Francisco	Acquisition, analysis, and interpretation of research data; wrote the main content of the work
Ariella do Carmo Souza	Image processing
Ana Cristina Zandoná Vieira	Analysis and interpretation of research data
Paulo Cesar Zandoná Vieira	Construction of the Convolutional Neural Network; image testing
Flávio Ricardo Manzi	Interpretation of research data; statistical analysis
Amaro Ilídio Vespasiano Silva	Research conception and design; final approval of the work

Title Page

Full title of study: Use of Artificial Intelligence in flattening detection in the condylar process of the temporomandibular joint

Short title: Flattening detection in the condylar process of the temporomandibular joint by Artificial Intelligence

Type of manuscript: Research Article

Names of authors:

Luciano, AA Francisco – Master's degree student – Department of Dentistry - Radiology - Pontifícia Universidade Católica de Minas Gerais, Brasil.

Ariella, C Souza – Undergraduate student - Department of Dentistry - Radiology - Pontifícia Universidade Católica de Minas Gerais, Brasil.

Ana, CZ Vieira – Specialist in Dental Radiology and Dental Imaging, IES/Faipe, Belo Horizonte, Minas Gerais, Brasil.

Paulo, CZ Vieira – Specialist in IEC Software Engineering – Pontifícia Universidade Católica de Minas Gerais

Flávio, R Manzi – Ph.D. - Department of Dentistry - Radiology - Pontifícia Universidade Católica de Minas Gerais, Brasil.

Amaro, IV Silva - PhD - Department of Dentistry - Radiology - Pontifícia Universidade Católica de Minas Gerais, Brasil.

This study received no outside sources of funding and the authors state that there is no conflict of interest in this research project.

Abstract

Aim: This work aimed to create a Python Script capable of identifying flattening in the mandibular head and compare its result with an analysis made by two specialists in dental radiology.

Methods: This study submitted 5,120 panoramic digital radiographs to inclusion and exclusion criteria, of which 3,457 were approved and analyzed by two specialists in radiology and dental imaging. After processing the radiographs, 6,914 images (two condyles per radiography) were created, which were then divided into 5,000 images for learning and validation of the Neural Network, with a balance between the “Presents” and “Does Not Present” flattening categories, leaving 1,914 images for the test. Of this total, 1,886 did not present flattening, while 28 did. To balance the number of images between categories, 56 images (28 from each category) were used to test the accuracy of the Python Script.

Results: Between the specialists, accuracy, sensitivity, and specificity were 0.95, 0.99, and 1.00, respectively, with no statistical differences between them. The results from the model created showed a specificity of 0.64 for not presenting flattening, 0.58 for presenting flattening; a sensitivity of 0.47 and 0.73, respectively; and a general accuracy of 0.60. There was a statistically significant difference between the specialists' results and those from the model, using the McNemar Test ($p < 0.05$).

Conclusions: A statistically significant difference was found between the specialists' diagnosis and that obtained by artificial intelligence. The Python Script developed for this study shows a good learning potential, although it is not yet able to replace human analysis.

Keywords: Artificial intelligence. Deep learning. Temporomandibular joint.

Introduction

The temporomandibular joint (TMJ) is one of the most required and intensely used joints in our body. It is characterized by joining fixed structures at the base of the skull with a movable bone, which moves in synchronization with an identical and symmetrical joint consisting of bone structures and soft tissue.

Temporomandibular disorders affect the stomatognathic system as a whole. Their causes and pathogenesis are multifactorial, involving psychological, behavioral, and environmental factors. Other causes include local trauma or procedures that cause joint stress. Effective auxiliary methods are needed to obtain data that supplement the clinical examination when diagnosing TMJ changes and recommending treatment. Examination by means of images provides important supplementary information for arriving at a diagnosis. The most frequently used supplementary exams in dental practice are radiographs, which provide a comprehensive panoramic view of the facial structures, helping formulate the diagnosis and treatment planning of pathological conditions that may not be detected through a clinical examination.

Condylar flattening is an adaptive change to the first alteration in a disease or a degenerative change secondary to an internal breakdown or resulting from an overload on the TMJ. It can be described as the loss of convexity of the condylar processes, being a local defect resulting from the rarefaction of the compact bone layer. Flattening is among the most prevalent changes in the mandibular head, and its prevalence gradually increases with age.¹

Artificial Intelligence (AI) is a branch of computer science that aims to create systems capable of answering questions that normally require a human approach to be understood.² A leading component of AI is *Machine Learning*,^{2,3} which is a branch of computer science that builds data-driven algorithms, trained to perform tasks by data learning patterns rather than by

explicit programming, including neural networks (NNs), consisting of nodes and weights and was one of the first types of AI algorithms to be developed.⁴

Artificial Neural Networks (ANN) are flexible mathematical models that use multiple algorithms to identify complex nonlinear relationships within large databases. This makes it possible for the program to be trained and able to identify variations in the normal pattern.^{3,5}

AI has been widely used in the medical field and, more recently, in the dental field. This new field of rapidly growing research has shown promising results and considerable applicability, mainly as an aid in diagnostic imaging.⁶

Some studies in the field of dentistry use artificial intelligence and panoramic radiography, as it is an easy-to-access, low-cost exam widely used by dentists, such as Hwang et al.⁴, who developed a model for detecting osteoporosis in panoramic radiographs, obtaining approximate results of sensitivity, specificity, and accuracy of 97.15%, 96.9%, and 96.58%, respectively, or Hiraiwa et al.⁷, who assessed the ability of an artificial neural network to analyze the morphology of the distal root of first mandibular molars and identified the presence of a supernumerary root in panoramic radiographs using cone beam computed tomography (CBCT) as the gold standard and comparing them with the analysis of two radiologists, achieving an 86.9% diagnostic accuracy.

The purpose of the present study was to identify flattening on the mandibular head in digital panoramic radiographs, using a Python Script (software) developed specifically for this study, through the Deep Learning artificial intelligence system, analyzing its sensitivity, specificity, and accuracy and then comparing these data with those from a diagnostic evaluation conducted by two dental radiologists.

Materials and Methods

The design of this study was approved by the local ethics committee.

Sample collection

Patient identification was kept confidential. The study analyzed 5,120 digital panoramic radiographs, taken by the Radiology Service of the Department of Dentistry of the Pontifícia Universidade Católica de Minas Gerais (PUC Minas) between 2016 to 2019 and submitted to the inclusion and exclusion criteria.

The criterion for including the exams in the study was digital panoramic radiographs of good technical quality, taken with the patient in the correct position and including the region of the temporomandibular joint.

Exclusion criteria included radiographs taken with poorly positioned patients, with distorted images and/or with artifacts that interfered with their analysis, with partial images of the mandibular condyles, and patients under 10 years of age who still had deciduous teeth in their arch. Moreover, radiographs of patients who had other types of diseases in the temporomandibular joints, such as arthritis, arthrosis, bifid condyle, osteophytes, erosion, and other pathological conditions, were also excluded from this study.

After applying the inclusion and exclusion criteria, 3,457 radiographs remained, which generated 6,914 images of the mandibular heads to be analyzed. The distribution of patients by gender and age group is shown in Table 1.

Image evaluation

The 3,457 images were interpreted and processed directly in the software developed for this study, with the following computer configuration: iMac (4K retina monitor, 21.5 inches, 2017), Quad-Core Intel Core i5 processor, 8GB DDR4 2400 MHz memory, and Radeon Pro 555 2GB graphics card.

Image processing

Following the specialists' analysis, a total of 3,457 radiographs were cut and resized to 3cm wide by 3cm high with a resolution of 300dpi, so that only the TMJ region on each side was visible, generating 6,914 images (sides and left) (Figures 1A, 1B, and 1C).

Next, as suggested by Brownlee,⁸ several experiments were conducted that considered the transfer of learning, using the *Keras* application called *InceptionV3*.

Experiments with *InceptionV3* revealed the need to apply “flip horizontal” to the images on one side, with the left side having been randomly chosen, facilitating the learning of the model by removing the need to understand the side that was being analyzed. Thus, the binary analysis – Presents versus Does not present – was maintained.

Out of the total images available for the dataset, 4,000 images were used for training and 1,000 for validation. The training and validation images were equally divided into two categories (labels): Presents (50%) and Does not present (50%) condylar flattening, using the specialists' analysis as a reference (Figure 2).

The remaining 1,914 images were used for testing, as they were not known by the model. However, according to specialists, 1,886 did not present condylar flattening, while 28 did. To balance the number between categories for the test, thereby facilitating the final analysis of the images by the model, only 28 images that did not have condylar flattening were selected, totaling 56 images used for the test.

Convolutional Neural Network Modeling

The CNN created for this study used the *Keras Sequential API*, which organizes the *Keras* layers in sequential order, causing data flow to occur between the layers in only one direction.

The final model was set up with four 2D convolutional layers to increase the “depth”, each one followed by a 2D maxpooling layer to reduce the size of the data volume, which underwent a “flattening”, followed by two dense layers interspersed by a “Dropout” to reduce overfitting, the last of which used the sigmoid classifier, as there are only two categories (Figure 3).

Binary cross-entropy loss was used, and the optimization algorithm was Adam, set with a learning rate of 10^{-5} (0.00001).

Three settings were applied: 500 epochs, a batch size of 32, and an early stop.

Comparison with specialists in radiology and dental imaging

The 3,457 panoramic digital radiographs selected for the test were evaluated by two specialists in radiology and dental imaging, using the Likert Scale with the following setting:

1. Does not present condylar flattening;
2. Probably does not present condylar flattening;
3. Impossible to classify;
4. Probably presents condylar flattening;
5. Certainty of condylar flattening.

Statistical tests

The accuracy obtained through the software after training and testing was reported in percentages by the neural network itself. Diagnostic accuracy, sensitivity, and specificity were evaluated with the methods used to analyze changes in the condylar process, along with the McNemar test with a 5% significance level for comparison between groups. The ROC curve was plotted to illustrate the accuracy of each group.

Results

The characterization of the sample in relation to the patients' gender and age range, after applying the inclusion and exclusion criteria, is shown in Table 1.

Analysis of the mandibular heads revealed that flattening is more prevalent in women than in men. Individual analysis revealed data on flattening between the right and left sides and cases that affect both sides simultaneously, with it being more prevalent on the left side in men, and bilateral in women between 30 and 69 years of age. These data are shown in Tables 2 and 3.

After dividing the image dataset, the testing phase to determine the best CNN formatting began. Accuracy and loss data during the model's training and validation epochs are shown in Graphs 1 and 2.

Accuracy and its validation followed an upward curve throughout the training epochs, while loss and its validation followed a downward trajectory, showing the model's increased efficiency.

Once the tests and validation had been completed, an automated analysis was triggered through Python Script (software), using the model as a basis for categorizing the test images. The results took into account that, while creating the model, it was automatically agreed that 0 (zero) refers to the "Does not present flattening" category and 1 (one), the "Presents flattening" category.

The result showed that the model was able to correctly categorize the images in $\approx 71.43\%$ of the cases, erring in 16.07%, and not recognizing either category in 12.50% of the images (Table 4).

Of the 28 images tested in each category, the model hit 100% of the cases in which the images presented flattening and $\approx 42.86\%$ of those that did not. This result revealed that the model was able to learn to recognize flattening (Table 5).

The validation test results were analyzed using specificity, sensitivity, and accuracy, and are shown in Table 6.

The results of the comparison of the radiograph analysis between the specialists are shown in Table 7.

The ROC curves obtained by comparing the specialists' results with those of the RNC model show a statistically significant difference, as shown in Graph 3.

Discussion

The TMJ is one of the areas of the body with greater difficulty in taking conventional images because of its size and the fact that it is partially covered by dense bone structures of the skull, generating image overlays. The panoramic radiographic image is a complex projection of numerous facial structures with multiple distortions and overlaps that can be exacerbated by technical errors, creating additional challenges in its interpretation.⁹ Conversely, panoramic radiography stands out among the most frequently used supplementary exams used in dental practice due to its scope, which provides a complete view of the facial structures, thereby assisting in the diagnosis and treatment planning of any pathological conditions that may not be detected by clinical examination alone. For this reason, the present study was based on digital panoramic radiographs to identify flattening in the mandibular head.

In a 2018 paper, Hiraiwa et al.⁷ examined the diagnostic performance of a deep learning system in the morphological classification of the root of the lower first molars in panoramic radiographs, using CBCT as the gold standard. Extra roots were observed in the tomographic images in 21.4% of the cases and identified in 86.9% of the cases by artificial intelligence. They concluded that deep learning showed a high level of precision in the differential diagnosis of single root or extra root in the distal roots of the lower first molars.

When compared to our study, it is interesting to note that the area of the first molars shows no type of anatomical overlap, despite the analysis being made using CBCT, which directly influences the results.

Lee et al.¹⁰ published a study that analyzed deep learning in the detection and diagnosis of dental caries in periapical radiographs. These authors used 3,000 images, 2,400 for training and 600 for the validation of results. Diagnostic accuracy was measured in three groups: premolars, molars, and premolars/molars. The diagnostic precision was: premolar 89%, with an accuracy of 0.917; molar 88%, with an accuracy of 0.890; and premolars/molars 82%, with an accuracy of 0.845. In conclusion, they underscored the potential utility of the convolutional neural network architecture for the detection and diagnosis of dental caries. When compared to the present study, a significant difference is observed between the values; however, the periapical radiographs have a much higher definition of details in relation to the panoramic radiographs, directly affecting the results, facilitating machine learning, and thus improving its performance.

When it came to applying a deep learning model in the diagnosis of maxillary sinusitis on panoramic radiographs and measuring its performance, Murata et al.¹¹ used 400 images of healthy sinuses and 400 of inflamed sinuses to conduct the training of the convolutional neural network. This number subsequently rose to 6,000 images for each group, with 200 training epochs. Sixty images were selected for each group for the test, with results of 86.7% sensitivity, 88.3% specificity, and 0.875 accuracy. They concluded that the performance was reasonably high, hoping the model would help inexperienced dentists. A need was perceived in this study to have a large number of images for training and validation of the network, including a balance between the categories for the test, which also occurred in the present study, with 6,914 images having been used and the dataset divided into 5,000 images for the training and validation of the Python Script, and the rest for testing.

Hung et al.¹² conducted a systematic review in 2019 to investigate current clinical applications and the diagnostic performance of AI in dental and maxillofacial radiology, using 50 studies selected from a group of 1,862 studies. Most of the studies were focused on the automated location of cephalometric landmarks, diagnosis of osteoporosis, classification and segmentation of maxillary cysts and/or tumors, and the identification of periodontitis and periodontal disease. The results using cephalometric radiographs in the automated location of cephalometric landmarks showed a success rate ranging from 35% to 84.70% and a tendency to use CBCT images to enhance accuracy. In recent studies on the diagnosis of osteoporosis, 95% were observed in accuracy, sensitivity, and specificity, demonstrating applicability in the near future;. In the classification and segmentation of maxillary cysts and/or tumors, accuracy varied between 81.8% in follicular cysts to 88.9% in root cysts, and in the identification of periodontitis and periodontal disease, a mean specificity of 92.65% and a mean sensitivity of 86.05% were observed. They concluded that the models included in the study indicated broad applications in dental and maxillofacial radiology, with AI performance varying between different models of algorithms, but the reliability and applicability of these AI models need to be verified before being transferred to clinical practice. When considering the findings from this systematic review, we concluded that the regions studied in panoramic radiographs, where there is little overlap, such as the basal cortex for the diagnosis of osteoporosis or the alveolar process in the identification of periodontitis and periodontal disease, presented a better AI performance when compared to regions where there are greater overlaps, such as cephalometric landmarks or segmentation of maxillary cysts and/or tumors. In the present study, the overlapping structures in the TMJ image produced by panoramic radiography may explain the AI's lesser ability to identify flattening in the mandibular head than the results reported in the studies used in the systematic review. It is worth mentioning that the present study is the only one to date to examine the TMJ region.

Tuzoff et al.¹³ conducted a study aimed at detecting and numbering teeth on panoramic radiographs through artificial intelligence, using 1,352 panoramic radiographs for training and 222 for testing and comparison with the specialists' performance. The system reached a sensitivity of 0.9941 in detecting teeth and an accuracy of 0.9945 against a sensitivity of 0.9980 and an accuracy of 0.99998 from the specialists. For the numbering of teeth, sensitivity was 0.9800 and specificity was 0.9994 with the system, while the specialists achieved 0.9893 and 0.9997, respectively. A detailed error analysis revealed that the software system made mistakes generated by similar factors as those for the specialists. In the present study, the greatest difficulty for both specialists and AI learning was in the initial flattening cases, where only a subtle loss in the convexity of the mandibular head was found, which was masked by overlapping structures and, as such, directly affected the machine learning results.

Kuwana et al.¹⁴ conducted a study aimed at using AI to detect the maxillary sinuses and classify them as healthy, inflamed, and with regional cysts, using panoramic radiographs. The result showed a detection sensitivity of healthy and inflamed sinuses of 100% in two sets of tests, and 98% and 89% for regional cysts, respectively. False positive rates were almost zero. The accuracy, sensitivity, and specificities for the diagnosis of maxillary sinusitis were 90% to 91%, 85% to 88%, and 91% to 96%, respectively. For cysts in the region of the maxillary sinuses, the values were 97% to 100%, 80% to 100%, and 100% to 100%, respectively. They concluded that deep learning was able to reliably identify the maxillary sinuses and maxillary sinusitis and cysts in the maxillary sinus region in panoramic radiographs. An important observation when comparing the result from the Kuwana study with that of the present study is that a variation in gray tones in the area of the maxillary sinuses is directly linked to the diagnosis of sinusitis and maxillary cysts, facilitating AI learning, while a variation of gray tones in the area of the TMJs indicate only an overlap of

structures or other changes that are not related to flattening, which makes AI learning more difficult.

Statistically significant differences were observed when comparing the specialists' sensitivity, specificity, and accuracy with those obtained by AI, with better results found when the analysis was performed by the specialists.

Conclusion

The results from making a comparison of flattening detection in the mandibular head by specialists in radiology and dental imaging with the results obtained by experiments with a Convolutional Neural Network model, using Deep Learning, revealed statistically significant differences. However, the sensitivity, specificity, and accuracy of the Python Script were satisfactory, taking into account that the area in question is severely affected by the overlapping of bone structures in panoramic radiographs, which interfered with the artificial neural network's learning.

The software developed for this study has a good learning potential, despite the difficulty in interpreting the TMJ region due to overlapping bone structures. Nevertheless, it is still not able to replace human analysis at this time.

References

1. Bäck K, Ahlqwist M, Hakeberg M, Dahlström L. Occurrence of signs of osteoarthritis/arthrosis in the temporomandibular joint on panoramic radiographs in Swedish women. *Community Dent Oral Epidemiol.* 2017;**45**:478-4. doi: 10.1111/cdoe.12312.
2. Chartrand G, Cheng PM, Vorontsov E, Drozdal M, Turcotte S, Pal CJ, *et al.* Deep learning: a primer for radiologists. *Radiographics.* 2017;**37**:2113-31.
3. King Jr BF. Artificial intelligence and radiology: what will the future hold? *J Am Coll Radiol.* 2018;**15**:501-3.
4. Hwang JJ, Jung YH, Cho BH, Heo MS. An overview of deep learning in the field of dentistry. *Imaging Sci Dent.* 2019;**49**:1-7.
5. Miller DD, Brown EW. Artificial intelligence in medical practice: the question to the answer? *Am J Med.* 2018;**131**:129-33.
6. Lee JS, Adhikari S, Liu L, Jeong HG, Kim H, Yoon SJ. Osteoporosis detection in panoramic radiographs using a deep convolutional neural network-based computer-assisted diagnosis system: a preliminary study. *Dentomaxillofac Radiol.* 2019;**48**:20170344.
7. Hiraiwa T, Arijji Y, Fukuda M, Kise Y, Nakata K, Katsumata A, *et al.* A deep-learning artificial intelligence system for assessment of root morphology of the mandibular first molar on panoramic radiography. *Dentomaxillofac Radiol.* 2019; **48**:20180218.
8. Brownlee J. How to configure the number of layers and nodes in a neural network *Machine Learn Mast.* 2019. Disponível em: <<https://machinelearningmastery.com/how-to-configure-the-number-of-layers-and-nodes-in-a-neural-network/>>. Acesso em: 26 Jan 2021.

9. Perschbacher S. Interpretation of panoramic radiographs. *Aust Dent J.* 2012;**57**::40-5 doi: 10.1111/j.1834-7819.2011.01655.x.
10. Lee JH, Kim DH, Jeong SN, Choi SH. Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. 2018;**77**:106-111. doi: 10.1016/j.jdent.2018.07.015.
11. Murata M, Ariji Y, Ohashi Y, Kawai T, Fukuda M, Funakoshi T, *et al.* Deep-learning classification using convolutional neural network for evaluation of maxillary sinusitis on panoramic radiography. *Oral Radiol.* 2019;**35**:301-7. doi.org/10.1007/s11282-018-0363-7.
12. Hung K, Montalvao C, Tanaka R, Kawai , Bornstein MM. The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review. *Dentomaxillofac Radiol.* 2020;**49**:20190107. doi: 10.1259/dmfr.20190107.
13. Tuzoff DV, Tuzova LN, Bornstein MM. Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofac Radiol.* 2019;**48**:20180051. doi: 10.1259/dmfr.20180051.
14. Kuwana R, Ariji Y, Fukuda M, Kise Y, Nozawa M, Kuwada C, *et al.* Performance of deep learning object detection technology in the detection and diagnosis of maxillary sinus lesions on panoramic radiographs. *Dentomaxillofac Radiol.* 2021;**50**:20200171. doi: 10.1259/dmfr.20200171.

Tables

Table 1 Distribution of patients by gender and age group

AGE GROUP	MALE	FEMALE
10 - 19	318	546
20 - 29	282	652
30 - 39	240	525
40 - 49	136	322
50 - 59	91	195
60 - 69	26	89
70 - 79	9	20
80 - 85	3	3
TOTAL	1105	2352

Table 2 Flattening cases in males by age group

MALES					
AGE GROUP	RIGHT	LEFT	BILATERAL	ABSENT	TOTAL
10 – 19	36	46	32	204	318
20 – 29	29	60	40	153	282
30 – 39	27	60	43	110	240
40 – 49	18	28	27	65	136
50 – 59	12	23	23	33	91
60 – 69	3	3	6	14	26
70 – 79	1	1	3	4	9
80 – 85	1	1	1	0	3
TOTAL	127	220	175	583	1105

Table 3 Flattening cases in females by age group

FEMALES					
AGE GROUP	RIGHT	LEFT	BILATERAL	ABSENT	TOTAL
10 – 19	73	94	80	299	546
20 – 29	100	123	120	309	652
30 – 39	66	103	149	207	525
40 – 49	45	71	87	119	322
50 – 59	28	40	55	72	195
60 – 69	11	14	25	39	89
70 – 79	6	4	5	5	20
80 – 85	1	1	1	0	3
TOTAL	330	450	522	1050	2352

Table 4 Results of images evaluated by AI

Predictions	Nonstandard	Correct	Incorrect
Total	7	40	9
Percentage	12.5%	≈71.43%	16.07%

Table 5 Results by category

Categories	Nonstandard	Correct	Incorrect
Has flattening	0	28	0
Does not have flattening	7	12	9

Table 6 Results of model validation

	Specificity	Sensitivity	Accuracy
0 (Does not have)	0.64	0.47	0.54
1 (Has)	0.58	0.73	0.65
Mean accuracy			0.60


Table 7 Comparison of radiologist vs. AI results

Groups	Accuracy (Az)	Sensitivity	Specificity
Radiologists	0.95 A	0.99 A	1.00 A
Artificial Intelligence	0.60 B	0.60 B	0.61 B


Same letters do not differ statistically and different letters differ statistically, using the McNemar Test ($p < 0.05$)

Graphs


Graph 1 Accuracy during training and validation



Graph 2 Loss during training and validation



Graph 3 ROC curve for specialist (A) and Artificial Intelligence (B) evaluation results




Figures Legend

Figure 1 Radiograph cut pattern; A) Panoramic radiography; B) Right side cut; C) Left side cut.

Figure 2 Training and validation dataset distribution

Figure 3 Summary of adopted model

**Figure 1****Figure 2**




Figure 3

5 CONSIDERAÇÕES FINAIS

Apesar das diferenças estatísticas relevantes entre o modelo de RNC criado para o presente estudo, quando comparado à análise dos especialistas, podemos considerar que no mesmo é promissor, pois mesmo com as dificuldades de interpretação inerentes à região da ATM devido às sobreposições e aos casos em que no aplainamento encontra-se em estágios iniciais, obteve bons resultados. Uma dificuldade encontrada neste estudo foi a necessidade de equalização de imagens entre as classes “Possui” e “Não possui” aplainamento para a realização dos testes e validação do modelo criado, fazendo com que restassem poucas imagens do grupo “Possui” aplainamento para o teste, por causa da sua menor prevalência.

Outros dados revelados por este estudo dizem respeito à prevalência do aplainamento, distribuído por faixa etária e por lado acometido (direito, esquerdo ou bilateral), o que é de grande valia para um trabalho futuro, pois a maioria dos estudos encontrados na literatura citam a prevalência do aplainamento mas não o seu lado de ocorrência.

REFERÊNCIAS

- ALENCAR, P.N.B. *et al.* Padrão de qualidade em radiografia panorâmica: o que o clínico precisa saber?. **Brazilian Journal of Health Review**, Curitiba, v.3, n.4, p. 8904-8909, jul./ago. 2020.
- BÄCK, K. *et al.* Occurrence of signs of osteoarthritis/arthrosis in the temporomandibular joint on panoramic radiographs in Swedish women. **Community Dentistry and Oral Epidemiology**, v.45, n.5, p.478-484, Oct. 2017.
- BARBIERI, A.A. **Importância da radiografia panorâmica como instrumento auxiliar às práticas clínica e odontolegal**. 2011. 78f. Tese (Doutorado em Biopatologia Bucal) – Faculdade de Odontologia de São José dos Campos, Universidade Estadual Paulista, 2011.
- BROWNLEE, J. How to configure the number of layers and nodes in a neural network how to configure the number of layers and nodes in a neural network. **Machine Learning Mastery**, Feb. 2019. Disponível em: <https://machinelearningmastery.com/how-to-control-neural-network-model-capacity-with-nodes-and-layers/>. Acesso em: 26 Jan 2021.
- CHARTRAND, G. *et al.* Deep learning: a primer for radiologists. **Radio Graphics**, v.37, n.7, p. 2113-2131, Nov./Dec. 2017.
- GÖRNER, M. **TensorFlow, Keras and deep learning, without a PhD**. Oct. 2020. Disponível em: <<https://codelabs.developers.google.com/codelabs/cloud-tensorflow-mnist/#10>>. Acesso em: 26 Jan. 2021.
- GOYATÁ, F.R. *et al.* Avaliação de sinais e sintomas de disfunção temporomandibular entre os acadêmicos do curso de odontologia da Universidade Severino Sombra, Vassouras-RJ. **International Journal of Dentistry**, v.9, n.4, p. 181-186, out./dez. 2010.
- 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. 20180218, Mar. 2019.
- HWANG, J.J. *et al.* Strut analysis for osteoporosis detection model using dental panoramic radiography. **Dentomaxillofacial Radiology**, v.46, n.7, p. 20170006, Oct. 2017.
- HWANG, J.J. *et al.* An overview of deep learning in the field of dentistry. **Imaging Science in Dentistry**, v.49, n.1, p.1-7, Mar. 2019.
- KING JÚNIOR, B.F. Artificial intelligence and radiology: what will the future hold? **Journal of the American College of Radiology**, v.15, n.3, Part.B, p. 501-503, Mar. 2017.
- LEE, J.H. *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, Oct. 2018.

MILLER, D.D.; BROWN, E.W. Artificial intelligence in medical practice: the question to the answer? **The American Journal of the Medicine**, v.131, n.2, p. 129-133, Feb. 2018.

SANTOS, N.C.C. **Articulação temporomandibular: anatomia, dinâmica e disfunções temporomandibulares**. 2010. Trabalho de Conclusão de Curso (Bacharelado em Odontologia) – Universidade Estadual Paulista, Faculdade de Odontologia de São José dos Campos, 2010.

SILVEIRA, O.S. *et al.* Utilização da tomografia computadorizada para o diagnóstico da articulação temporomandibular. **Revista CEFAC**, v.16, n.6, p. 2053-2059, nov./dez. 2014.

YAMASHITA, R. *et al.* Convolutional neural networks: an overview and application in Radiology. **Insights into Imaging**, v.9, p. 611-629, 2018. Disponível em: <https://link.springer.com/article/10.1007/s13244-018-0639-9>. Acesso em: 26 Jan. 2021.

ANEXO A – Parecer Consubstanciado do CEP PUC Minas

PONTIFÍCIA UNIVERSIDADE
CATÓLICA DE MINAS GERAIS -
PUCMG

**PARECER CONSUBSTANCIADO DO CEP****DADOS DO PROJETO DE PESQUISA**

Título da Pesquisa: USO DA INTELIGÊNCIA ARTIFICIAL NA DETECÇÃO DE APLAINAMENTO NO PROCESSO CONDILAR DA ARTICULAÇÃO TEMPOROMANDIBULAR

Pesquisador: LUCIANO AUGUSTO DE AVELAR FRANCISCO

Área Temática:

Versão: 1

CAAE: 20234319.8.0000.5137

Instituição Proponente: Pontifícia Universidade Católica de Minas Gerais - PUC-MG

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 3.652.333

Apresentação do Projeto:

A disfunção da Articulação Temporomandibular (ATM) é um desafio para o Cirurgião-Dentista desde seu diagnóstico ao tratamento. A identificação dos problemas causadores da disfunção a partir da radiografia panorâmica possibilita o diagnóstico precoce e a maior eficácia no tratamento. Amplamente utilizados na área médica, os métodos de análise por Inteligência Artificial, Machine Learning e Deep Learning, utilizam de redes neurais artificiais capazes de detectar alterações ao padrão convencional de raciocínio semelhante ao cérebro humano. Neste contexto, a incorporação da Inteligência Artificial pode representar um novo paradigma na prática odontológica. O objetivo no presente estudo é analisar a acurácia da Inteligência Artificial na identificação de aplainamento condilar. Para a análise serão utilizadas três mil radiografias do acervo de imagens do Departamento de Odontologia da PUC Minas.

Objetivo da Pesquisa:

Os objetivos do estudo são: analisar a sensibilidade, especificidade e acurácia da inteligência artificial, pelo sistema Deep Learning, na identificação de aplainamento nos processos condilares da mandíbula, em radiografias panorâmicas digitais; comparar os dados de sensibilidade, especificidade e acurácia dos dados encontrados pela inteligência artificial, com os dados encontrados pela avaliação de diagnóstico realizada por cirurgiões-dentistas radiologistas; desenvolver software de inteligência artificial capaz de detectar aplainamento condilar nas

Endereço: Av. Dom José Gaspar, 500 - Prédio 03, sala 228

Bairro: Coração Eucarístico

CEP: 30.535-901

UF: MG

Município: BELO HORIZONTE

Telefone: (31)3319-4517

Fax: (31)3319-4517

E-mail: cep.proppg@pucminas.br

**PONTIFÍCIA UNIVERSIDADE
CATÓLICA DE MINAS GERAIS -
PUCMG**



Continuação do Parecer: 3.652.333

articulações temporomandibulares.

Avaliação dos Riscos e Benefícios:

Riscos: Todas as radiografias panorâmicas utilizadas neste estudo já foram realizadas com indicação clínica para tratamento odontológico.

Benefícios: A alta acurácia da inteligência artificial na detecção do aplainamento condilar vai possibilitar um diagnóstico precoce e uma intervenção clínica com mínimos danos na estrutura do côndilo, melhorando assim o prognóstico e a qualidade de vida dos pacientes afetados pela condição.

Comentários e Considerações sobre a Pesquisa:

Projeto exequível, não apresentando impedimentos de natureza ética para sua realização.

Considerações sobre os Termos de apresentação obrigatória:

Os termos de apresentação obrigatória foram anexados e estão de acordo com as normas vigentes.

Conclusões ou Pendências e Lista de Inadequações:

Sem pendências.

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_1425642.pdf	04/09/2019 18:09:27		Aceito
Projeto Detalhado / Brochura Investigador	Projeto.pdf	04/09/2019 18:08:13	LUCIANO AUGUSTO DE AVELAR FRANCISCO	Aceito
Declaração de Instituição e Infraestrutura	declaracao.pdf	04/09/2019 18:05:59	LUCIANO AUGUSTO DE AVELAR FRANCISCO	Aceito
Folha de Rosto	Folhaderostoassinada.pdf	04/09/2019 18:05:24	LUCIANO AUGUSTO DE AVELAR FRANCISCO	Aceito

Situação do Parecer:

Aprovado

Endereço: Av. Dom José Gaspar, 500 - Prédio 03, sala 228
Bairro: Coração Eucarístico **CEP:** 30.535-901
UF: MG **Município:** BELO HORIZONTE
Telefone: (31)3319-4517 **Fax:** (31)3319-4517 **E-mail:** cep.propg@pucminas.br

PONTIFÍCIA UNIVERSIDADE
CATÓLICA DE MINAS GERAIS -
PUCMG



Continuação do Parecer: 3.652.333

Necessita Apreciação da CONEP:

Não

BELO HORIZONTE, 21 de Outubro de 2019

Assinado por:
CRISTIANA LEITE CARVALHO
(Coordenador(a))

Endereço: Av. Dom José Gaspar, 500 - Prédio 03, sala 228
Bairro: Coração Eucarístico **CEP:** 30.535-901
UF: MG **Município:** BELO HORIZONTE
Telefone: (31)3319-4517 **Fax:** (31)3319-4517 **E-mail:** cep.propg@pucminas.br