



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

**ELISA DINIZ DE LIMA**

**TERMOGRAFIA INFRAVERMELHA E INTELIGÊNCIA ARTIFICIAL COMO  
AUXILIARES NO DIAGNÓSTICO DA DISFUNÇÃO TEMPOROMANDIBULAR**

**CAMPINA GRANDE**

**2021**

ELISA DINIZ DE LIMA

**TERMOGRAFIA INFRAVERMELHA E INTELIGÊNCIA ARTIFICIAL COMO  
AUXILIARES NO DIAGNÓSTICO DA DISFUNÇÃO TEMPOROMANDIBULAR**

Tese apresentada ao Programa de Pós-Graduação em Odontologia da Universidade Estadual da Paraíba como parte dos requisitos para a obtenção do título de Doutora em Odontologia.

**Área de concentração:** Clínicas odontológicas.

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

CAMPINA GRANDE

2021

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

L7321 Lima, Elisa Diniz de.  
Termografia infravermelha e inteligência artificial como auxiliares no diagnóstico da disfunção temporomandibular [manuscrito] / Elisa Diniz de Lima. - 2021. 112 p.  
Digitado.  
Tese (Doutorado em Odontologia) - Universidade Estadual da Paraíba, Centro de Ciências Biológicas e da Saúde, 2021. "Orientação : Profa. Dra. Daniela Rita de Melo, Coordenação do Curso de Odontologia - CCBS."  
1. Termografia. 2. Diagnóstico. 3. Inteligência artificial. 4. Síndrome da disfunção da articulação temporomandibular. I. Título  
21. ed. CDD 616.0754

ELISA DINIZ DE LIMA

**TERMOGRAFIA INFRAVERMELHA E INTELIGÊNCIA ARTIFICIAL COMO  
AUXILIARES NO DIAGNÓSTICO DA DISFUNÇÃO TEMPOROMANDIBULAR**

Tese apresentada ao Programa de Pós-Graduação em Odontologia da Universidade Estadual da Paraíba como parte dos requisitos para a obtenção do título de Doutora em Odontologia.

Área de concentração: Clínicas odontológicas.

DATA DA DEFESA: 23/ 07/ 2021.

  
Prof. Dra. Daniela Pina de Melo  
Orientadora e Presidente da Banca

  
Prof. Dr. Paulo Eduardo e Silva Barbosa  
Examinador Interno

  
Prof. Dra. Patricia Meira Bento  
Examinadora Interna

  
Prof. Dra. Márcia Luiza dos Anjos Pontual  
Examinadora Externa

  
Prof. Dra. Karina Lopes Devito  
Examinadora Externa

**A minha família!**

## AGRADECIMENTOS

A Deus, por ter plantado em meu coração esse sonho e me permitido concluir, dando-me tanta força para enfrentar os obstáculos que apareceram no caminho.

À minha querida orientadora, Prof. Dr<sup>a</sup> Daniela Pita de Melo, pela relação de confiança estabelecida durante esses quase seis anos de orientação. Por toda compreensão e companheirismo que sempre teve comigo. És um exemplo de ser humano, professora, orientadora e pesquisadora que, mesmo diante de tantas dificuldades encontradas no caminho, ama e se dedica ao que faz. Além disso, é dona de uma alegria e alto astral contagiante. Estar perto de professora Daniela e não se sentir bem, é impossível.

Ao Programa de Pós-graduação em Odontologia da Universidade Estadual da Paraíba (PPGO – UEPB), coordenado pela Prof. Dr<sup>a</sup> Daniela Pita de Melo e Prof. Dr. Cassiano Nonaka, por toda dedicação para o que o programa cresça e se destaque, por tantas oportunidades de aulas, pesquisas e aprendizados.

A todos os professores que compõem o PPGO-UEPB por serem exemplos de professores, orientadores e pesquisadores éticos e responsáveis e por todo esforço despendido para manter e fazer com que o programa cresça.

Aos professores da banca examinadora, pela disponibilidade em ler e ajudar a melhorar o meu trabalho.

À Ahyanna, secretária do PPGO, por toda dedicação ao trabalho e por não medir esforços para ajudar sempre que é solicitada.

Aos meus colegas de turma, pela relação de amizade, companheirismo e cumplicidade estabelecida. Juntos, conseguimos concluir essa etapa tão importante na nossa vida profissional.

A Alberto, por ser parte essencial nessa pesquisa. Sem sua ajuda teria sido muito difícil executá-la. Por toda paciência, disponibilidade e disposição em ajudar sempre que precisei. Serei eternamente grata.

Ao grupo de pesquisa em radiologia, em especial a Ana Priscila, Eraldo, Jussara e Diego, pela parceria estabelecida para que a pesquisa pudesse ser desenvolvida.

Aos meus companheiros de trabalho da equipe de Caldas Brandão, por todos os momentos de companheirismo, cumplicidade, diversão e comilanças. Trabalhar com vocês tornou os meus dias mais leves. Mesmo distantes, guardo cada um em meu coração.

A minha grande amiga Carol Magna, por tanto carinho que temos uma pela outra, pela relação de irmandade que temos, por toda força, torcida e incentivo que recebo sempre.

A minha família, por todo amor, apoio e compreensão que têm por mim. Souberam entender quando não estive disponível para ajudar nos afazeres de casa, sair para conversar na sala ou para outros lugares, pois precisava dedicar-me ao doutorado.

Ao meu amor, meu sobrinho Bernardo, meu “pitoquinho”, que consegue me tirar os meus melhores sorrisos e diz que me ama de um jeito lindo e fofo. Você nasceu para trazer mais união e felicidade a nossa família. Amo-te!!!

Às psicólogas Liana e Rachel por toda ajuda que recebi durante esses anos e terem me feito enxergar as coisas pelo melhor ângulo e poder resolvê-las da maneira mais adequada. Vocês foram fundamentais para que eu conseguisse realizar esse sonho.

A minha amada Universidade Estadual da Paraíba, por todas as oportunidades de crescimento profissional nesses mais de 10 anos de estudo. Por ter me levado a Campina Grande, cidade que me transformou em uma pessoa mais madura, segura e me trouxe muitas alegrias.

À CAPES, pelo apoio financeiro.

Não fui eu que lhe ordenei? Seja forte e corajoso! Não se apavore, nem se desanime, pois o Senhor, o seu Deus, estará com você por onde você andar".

**Josué 1:9**

## RESUMO

As disfunções temporomandibulares (DTM) são definidas como um conjunto de condições musculoesqueléticas e neuromusculares envolvendo as articulações temporomandibulares (ATM), os músculos mastigatórios e estruturas associadas. O RDC/TMD (Research diagnostic criteria for temporomandibular disorders) é o principal e mais aceito instrumento de diagnóstico de DTM. No entanto, a aplicação desse instrumento demanda tempo e treinamento dos profissionais. Em casos de distúrbios musculares, a termografia infravermelha (TI) vem apresentando resultados positivos por fornecer informações referentes a microcirculação local. O uso de técnicas de inteligência artificial pode auxiliar na avaliação de termogramas e contribuir para um diagnóstico rápido e preciso de DTM. Este trabalho teve como objetivo avaliar três métodos de aprendizado de máquina (AM) para extração de atributos, radiômicos, semânticos e a associação de atributos radiômicos e semânticos, na detecção de DTM utilizando TI e dados de dor à palpação; e determinar qual algoritmo classificador de AM: KNN, SVM e MLP, é o mais eficiente para esse propósito. Trata-se de um estudo observacional do tipo transversal, aprovado pelo comitê de ética em pesquisa com o protocolo CAAE: 73417017200005187. A amostra desse estudo foi de 41 pacientes com DTM, selecionados por meio da aplicação do RDC/TMD, e 37 pacientes sem DTM, voluntários que tiveram a ausência de DTM confirmada a partir do Índice anamnésico de Fonseca. Os pacientes tinham entre 18 e 60 anos de idade, de ambos os sexos. Todos os pacientes que tiveram alterações sistêmicas que pudessem interferir na avaliação dos termogramas foram excluídos do estudo. Os exames termográficos foram realizados no laboratório de termografia infravermelha da Universidade Estadual da Paraíba seguindo os protocolos da Academia Americana de Termologia, utilizando a câmera térmica FLIR T650sc, fixada em um tripé a uma distância de 0,8m da face do paciente. Foram adquiridos dois termogramas em norma lateral (lateral direita e lateral esquerda) de cada paciente. Para análise dos dados de temperatura obtidos por meio do software FLIR Tools v.6.4, um avaliador utilizando a ferramenta círculo obteve as temperaturas em duas regiões no músculo temporal anterior e em seis regiões no músculo masseter. Os dados de temperatura e de dor à palpação foram tabulados e utilizados como atributos semânticos. Para a extração dos atributos radiômicos, o programa Fiji Image J (versão 1.8.0) foi utilizado para a segmentação das regiões de interesse (ROI) correspondentes aos músculos masseter e temporal anterior. Após a segmentação, vinte atributos de textura (radiômicos), dez por músculo avaliado, foram extraídos através de matrizes de co-ocorrência na angulação padrão de 0°: contraste, correlação, energia, homogeneidade, entropia, média aparada, curtose, assimetria, desvio padrão e variância. Posteriormente, os atributos de textura passaram pelo procedimento de redução de dimensionalidade através da análise por componentes principais. Utilizando os algoritmos classificadores de AM, KNN, SVM e MLP, foram calculadas a acurácia, precisão, sensibilidade e especificidade para os métodos de extração de atributos, radiômico, semântico e radiômico-semântico associados para o diagnóstico de DTM. Os dados foram analisados estatisticamente utilizando o teste de Hopkins para avaliação de clusters, teste ANOVA para medidas repetidas e pós teste de Tukey. O valor de acurácia da amostra de treinamento e a amostra teste só diferiu estatisticamente para a associação dos métodos de extração de atributos radiômicos-semânticos ( $p < 0,05$ ). O algoritmo classificador MLP apresentou os melhores valores de acurácia, diferindo de KNN e SVM para métodos radiômico-semântico associados ( $p < 0,05$ ). Os valores de acurácia, precisão e sensibilidade dos atributos semânticos e a associação radiômico-semântico diferiram estatisticamente dos atributos radiômicos ( $p < 0,05$ ). Os atributos semânticos apresentaram os melhores valores de especificidade e diferiram estatisticamente dos atributos radiômicos ( $p < 0,05$ ). Os métodos de extração de atributos semânticos e a associação dos atributos radiômicos e semânticos apresentaram melhores resultados que o método radiômico

para a detecção de DTM utilizando TI e escala de dor. O algoritmo classificador MLP deve ser utilizado para esse fim quando se optar pela extração de atributos radiômicos e semânticos. O uso de IA associada a TI apresenta resultados promissores para a detecção de DTM.

**Palavras-chave:** síndrome da disfunção da articulação temporomandibular; diagnóstico; termografia; inteligência artificial.

## ABSTRACT

Temporomandibular disorders (TMD) are defined as set of musculoskeletal and neuromuscular conditions involving the temporomandibular joints (TMJ), masticatory muscles and associated structures. The RDC/TMD (Research diagnostic criteria for temporomandibular disorders) is the main and most accepted diagnostic tool for TMD. However, the application of this instrument is time consuming and demands professionals training. In cases of muscle disorders, infrared thermography (IT) has shown positive results by providing information regarding local microcirculation. The use of artificial intelligence techniques can help in the evaluation of thermograms and contribute to the diagnosis of TMD. This study assessed three methods of attribute extraction machine learning (ML) techniques: radiomic, semantic and the association of radiomic and semantic features on TMD detection using IT and palpation pain data; and to determine which ML classification algorithm, KNN, SVM e MLP, is the most efficient for this purpose. This is a cross-sectional observational study, approved by the research ethics committee protocol CAAE: 73417017200005187. The sample of this study was composed of 41 patients with TMD, selected using the RDC/TMD, and 37 patients without TMD, volunteers who had the absence of TMD confirmed by the Fonseca anamnestic index. The selected patients had 18 to 60 years of age, of both sexes. All patients who had systemic changes that could interfere with thermograms assessment were excluded from the study. The thermographic exams were carried out in the infrared thermography laboratory of the State University of Paraíba following the protocols of the American Academy of Thermology, using the FLIR T650 infrared thermal camera, mounted on a tripod at 0.8m from the patient's face. Two thermograms in lateral norm (right and left side) of each patient were acquired. To analyze the temperature data, obtained using the FLIR Tools v.6.4 software, an observer using the circle tool obtained the temperatures in two regions in the anterior temporal muscle and in six regions in the masseter muscle. Temperature and pain on palpation data were tabulated and used as semantic features. To extract radiomic features, Fiji Image J software (version 1.8.0) was used to segment the regions of interest (ROI) corresponding to the masseter and anterior temporal muscles. After segmentation, twenty (radiomic) texture attributes, ten per assessed muscle, were extracted through co-occurrence matrices at the standard 0° angle: contrast, correlation, energy, homogeneity, entropy, trimmed mean, kurtosis, asymmetry, deviation pattern and variance. Subsequently, the texture attributes underwent dimensionality reduction procedure through principal component analysis. Using the ML classification algorithms: KNN, SVM and MLP, the accuracy, precision, sensitivity, and specificity were calculated for the associated radiomic, semantic and radiomic-semantic attribute extraction methods for the diagnosis of TMD. Data were statistically analyzed using the Hopkins test for cluster evaluation, ANOVA test for repeated measures and post Tukey test. The accuracy values of the training sample and the test sample only differed statistically for the association of radiomic-semantic attribute extraction methods ( $p < 0,05$ ). The MLP classifier algorithm showed the best accuracy values, differing from KNN and SVM MLP for the radiomic-semantic association method ( $p < 0,05$ ). The accuracy, precision and sensitivity values of the semantic attributes and the radiomic-semantic association differed statistically from the radiomic attributes ( $p < 0,05$ ). The semantic attributes had the best specificity values and differed statistically from the radiomic attributes ( $p < 0,05$ ). The semantic attribute extraction method and the association of radiomic and semantic attributes method showed better results than the radiomic method for the detection of TMD using IT and pain scale data. The MLP classifier algorithm must be used for this purpose when using radiomic and semantic attributes extraction methods. The use of AI associated with IT presents promising results for the detection of TMD.

**Keywords:** temporomandibular joint dysfunction syndrome; diagnosis thermography; artificial intelligence.

## LISTA DE ILUSTRAÇÕES

<b>Figura 1.</b> Descrição dos Transtornos da ATM. ....	23
<b>Figura 2.</b> Descrição dos distúrbios dos músculos mastigatórios, dor de cabeça e estruturas associadas. ....	24
<b>Figura 3.</b> Valores (ângulos possíveis) para calcular uma matriz de co-ocorrência. ....	35
<b>Figura 4.</b> Representação do classificador SVM. ....	37
<b>Figura 5.</b> Representação do classificador KNN. ....	38
<b>Figura 6.</b> Arquitetura de uma rede neural multicamada. ....	39
<b>Figura 7.</b> Câmera térmica FLIR T650. ....	43
<b>Figura 8.</b> Visão do local onde é realizado o exame termográfico, mostrando a parede revestida por E.V.A preto, câmera térmica posicionada no tripé e a cadeira utilizada. ....	44
<b>Figura 9.</b> Câmera posicionada no tripê e cadeira utilizada. ....	45
<b>Figura 10.</b> Imagem termográfica em normal lateral direita. ....	45
<b>Figura 11.</b> Imagem termográfica em norma lateral esquerda. ....	46
<b>Figura 12.</b> Utilização da ferramenta círculo para medição de temperatura em ROIs nos músculos temporal anterior e masseter (Visão lateral direita). ....	47
<b>Figura 13.</b> Utilização da ferramenta círculo para medição de temperatura em ROIs nos músculos temporal anterior e masseter (Visão lateral direita). ....	47
<b>Figura 14.</b> Programa Fiji ImageJ. ....	48
<b>Figura 15.</b> Utilização da ferramenta “Polygon” para seleção das ROI. ....	50
<b>Figura 16.</b> Utilização da ferramenta “Crop” para extração da ROI. ....	50
<b>Figura 17.</b> ROI extraída. ....	51
<b>Figura 18.</b> ROI extraída apresentando uma matriz de 108*115 pixels e padrão RGB, sendo salva em formato JPEG. ....	51
<b>Figura 19.</b> Transformação da imagem em norma lateral esquerda em norma lateral direita. ....	52
<b>Figura 20.</b> Imagem em norma lateral esquerda transformada em lateral direita. ....	52
<b>Figura 21.</b> Redução de dimensionalidade com PCA. ....	54
<b>Figura 22.</b> Descrição dos métodos de inteligência artificial utilizados. ....	57

## ARTIGO

<b>Figure 1.</b> A-Left side lateral norm thermogram; B-Right side lateral norm thermogram of the same patient. ....	65
<b>Figure 2.</b> A-Thermographic image assessed with Fiji ImageJ software using the “polygon” selection tool to select the ROI; B- Standardization of the lateral right and left norms to the right-side norm by using the tools “transform” e “flip horizontally”; C-left-side lateral norm transformed into right-side lateral form; D- ROI of the masseter muscle; E -ROI of the temporal muscle. ....	66
<b>Figure 3.</b> Multilayer Perceptron (MLP) for radiomic features. ....	69
<b>Figure 4.</b> Multilayer Perceptron (MLP) for semantic features. ....	70
<b>Figure 5.</b> Multilayer Perceptron (MLP) for associated radiomics and semantics features. ....	70

## LISTA DE QUADROS E TABELAS

<b>Quadro 1.</b> Definições de atributos.....	36
---	----

### ARTIGO

<b>Table 1.</b> Accuracy values of the ML classifiers for the training and testing datasets and the studied feature extraction methods.....	71
<b>Table 2.</b> Testing dataset accuracy, precision, sensitivity, and specificity values for the studied feature extraction methods for each assessed classifier.....	72

## LISTA DE ABREVIATURAS E SIGLAS

<b>ATM</b>	Articulação Temporomandibular
<b>AUC</b>	Area Under the Curve
<b>CEP</b>	Comitê de Ética em Pesquisa
<b>CNS</b>	Conselho Nacional de Saúde
<b>DC/TMD</b>	Diagnostic criteria for temporomandibular disorders/Critérios diagnósticos para desordens temporomandibulares
<b>DTM</b>	Disfunção Temporomandibular
<b>EPS</b>	Placas de Poliestireno Expandido
<b>FPA</b>	Focal Plane Array/ Matriz de plano focal
<b>IA</b>	Inteligência Artificial
<b>IAM</b>	Índice Anamnésico de Fonseca
<b>IGR</b>	Information gain ratio/Razão de ganho de informação
<b>IRM</b>	Imagem por Ressonância Magnética
<b>IT</b>	Infrared Thermography/Termografia Infravermelha
<b>KNN</b>	K Nearest Neighbors
<b>LDA</b>	Linear Discriminant Analysis/Análise discriminante linear
<b>LWIR</b>	Long Wavelength Infrared/Infravermelho de onda longo
<b>MWIR</b>	Medium Wavelength Infrared/Infravermelho de onda médio
<b>NDA</b>	Non-parametric Discriminant Analysis/Análise discriminante não paramétrica
<b>NIR</b>	Near Infrared/Infravermelho próximo
<b>PCA</b>	Principal Component Analysis/Análise de componentes principais
<b>RDC</b>	Research Diagnostic Criteria for Temporomandibular Disorders/ Critérios Diagnósticos em Pesquisa para Desordens Temporomandibulares
<b>RNM (MLP)</b>	Redes Neurais Multicamadas/Multilayer perceptron
<b>ROC</b>	Receiver Operating Characteristic
<b>ROI</b>	Região de interesse dinâmica
<b>SVM</b>	Support Vector Machine
<b>SWIR</b>	Short-Wavelength Infrared /infravermelho de onda curto

<b>TC</b>	Tomografia Computadorizada
<b>TCFC</b>	Tomografia Computadorizada por Feixe Cônico
<b>TCLE</b>	Termo de Consentimento Livre e Esclarecido
<b>TEP</b>	Tomografia por Emissão de Pósitrons
<b>UEPB</b>	Universidade Estadual da Paraíba

## LISTA DE SÍMBOLOS

$\Delta T$	Gradiente conjugado
$\Delta \theta$	Temperatura Normalizada

## SUMÁRIO

<b>1</b>	<b>CONSIDERAÇÕES INICIAIS</b> .....	<b>20</b>
<b>1.1</b>	<b>Disfunção Temporomandibular</b> .....	<b>20</b>
<b>1.2</b>	<b>Diagnóstico da disfunção temporomandibular</b> .....	<b>21</b>
<b>1.3</b>	<b>Temperatura e Termografia infravermelha</b> .....	<b>24</b>
1.3.1	Radiação infravermelha e Câmeras térmicas (infravermelhas) .....	26
1.3.2	Protocolos para realização de exames termográficos .....	27
1.3.3	Termografia infravermelha como auxiliar no diagnóstico DTM.....	27
<b>1.4</b>	<b>Inteligência Artificial</b> .....	<b>30</b>
1.4.1	Semântica e Radiômica.....	31
1.4.2	Atributos radiômicos e estratégias de redução de dimensionalidade .....	35
1.4.3	Utilização de classificadores.....	37
1.4.3.1	<i>Classificar SVM</i> .....	37
1.4.3.2	<i>Classificador KNN</i> .....	38
1.4.3.3	<i>Redes neurais multicamadas</i> .....	38
<b>2</b>	<b>OBJETIVO</b> .....	<b>40</b>
<b>2.1</b>	<b>Objetivo Geral</b> .....	<b>40</b>
<b>2.2</b>	<b>Objetivos Específicos</b> .....	<b>40</b>
<b>3</b>	<b>METODOLOGIA</b> .....	<b>41</b>
<b>3.1</b>	<b>Tipo de estudo</b> .....	<b>41</b>
<b>3.2</b>	<b>Localização do estudo</b> .....	<b>41</b>
<b>3.3</b>	<b>Aspectos éticos</b> .....	<b>41</b>
<b>3.4</b>	<b>Universo e amostra</b> .....	<b>41</b>
3.4.1	Critérios de inclusão .....	42
3.4.2	Critérios de exclusão.....	42
<b>3.5</b>	<b>Diagnóstico de DTM</b> .....	<b>42</b>
<b>3.6</b>	<b>Exame termográfico infravermelho</b> .....	<b>42</b>
3.6.1	Câmera térmica .....	42
3.6.2	Sala de realização dos exames .....	43
3.6.3	Preparo do paciente.....	44
<b>3.7</b>	<b>Análise das imagens termográficas</b> .....	<b>46</b>
<b>3.8</b>	<b>Tabulação dos dados</b> .....	<b>47</b>
<b>3.9</b>	<b>Análise termográfica auxiliada por técnicas de inteligência artificial</b> .....	<b>48</b>
3.9.1	Atributos radiômicos.....	48

3.9.2	Atributos semânticos.....	53
3.9.3	Associação de atributos semânticos e radiômicos .....	53
<b>3.10</b>	<b>Processamento após a segmentação das imagens.....</b>	<b>53</b>
<b>3.11</b>	<b>Classificação .....</b>	<b>55</b>
3.11.1	Classificador KNN.....	55
3.11.2	Classificador SVM.....	55
3.11.3	Classificador MLP .....	56
<b>3.12</b>	<b>Análise estatística dos dados .....</b>	<b>56</b>
<b>4</b>	<b>FLUXOGRAMA.....</b>	<b>57</b>
<b>5</b>	<b>RESULTADOS .....</b>	<b>58</b>
<b>6</b>	<b>ARTIGO .....</b>	<b>59</b>
<b>7</b>	<b>CONSIDERAÇÕES FINAIS.....</b>	<b>81</b>
	<b>REFERÊNCIAS.....</b>	<b>82</b>
	<b>APÊNDICE A – Termo de Consentimento Livre e Esclarecido (TCLE).....</b>	<b>90</b>
	<b>APÊNDICE B – Orientações prévias à realização das termografias.....</b>	<b>91</b>
	<b>APÊNDICE C – Ficha de exame termográfico .....</b>	<b>92</b>
	<b>ANEXO A – Parecer do Comitê de Ética em Pesquisa (CEP).....</b>	<b>94</b>
	<b>ANEXO B – Research Diagnostic Criteria for Temporomandibular Disorders (RDC/TMD) .....</b>	<b>97</b>
	<b>ANEXO C – Índice Anamnésico de Fonseca (IAM).....</b>	<b>106</b>
	<b>ANEXO D – Normas da Revista.....</b>	<b>107</b>

# 1 CONSIDERAÇÕES INICIAIS

## 1.1 Disfunção Temporomandibular

Disfunção Temporomandibular (DTM) é o termo utilizado para descrever as doenças que afetam a articulação temporomandibular e estruturas associadas (CONVILLE; MORIARTY; ATKINS, 2019). É uma das principais causas de dor de origem não dentária da região orofacial e os casos mais graves afetam de maneira significativa a qualidade de vida dos pacientes (BITINIENE et al., 2018).

A DTM é mais prevalente no sexo feminino, com pico de incidência entre os 19 e 40 anos de idade (FERREIRA; DA SILVA; DE FELÍCIO, 2016) e apresenta etiologia multifatorial que pode incluir estímulos biológicos, ambientais, sociais, emocionais e cognitivos, causando desde um leve desconforto até dores exacerbadas com limitação da função mandibular (GAUER; SEMIDEY, 2015).

A localização das dores relacionadas à DTM inicia-se na região pré-auricular, estendendo-se para borda inferior da mandíbula até a região do músculo temporal (CONVILLE; MORIARTY; ATKINS, 2019). Já os sinais e sintomas incluem dor difusa e intermitente, sensibilidade e/ou dor nos músculos mastigatórios e na área das ATMs (Articulação Temporomandibular), abertura bucal limitada e “travamento” da mandíbula, facetas de desgaste nos dentes, cefaleia, estalidos, crepitação, zumbido, deficiência auditiva e otalgia (BOENING et al., 2015; CONVILLE; MORIARTY; ATKINS, 2019).

A dor miofascial é um subgrupo dos distúrbios dos músculos mastigatórios (SCHIFFMAN; OHRBACH, 2016) e é um termo utilizado para designar às síndromes de dor que se originam em estruturas miofasciais (FREESE, 1961). A síndrome da dor miofascial é um dos distúrbios mais prevalentes na população, sendo caracterizada por pontos de gatilho que afetam mais de um grupo muscular e dor associada a espasmo muscular e sensibilidade causada à palpação (ALTINDIS; GUNGORMUS, 2019; MACHOY et al., 2020).

A etiologia da síndrome da dor miofascial ainda não foi totalmente elucidada, mas acredita-se que fatores genéticos, bruxismo, estresse, fatores ocupacionais, lassidão e lesões crônicas causadas por microtraumas frequentes estejam associados ao seu desenvolvimento (ALTINDIS; GUNGORMUS, 2019). Os pontos de gatilho são um dos critérios diagnósticos da síndrome da dor miofascial e, clinicamente, são definidos como uma área pequena, circunscrita e hipersensível, localizada em uma faixa tensa do músculo esquelético (FREESE,

1961; HADDAD; BRIOSCH; ARITA, 2012). Devido ao seu tamanho e funcionalidade, um único músculo mastigatório pode ter mais de um ponto de gatilho. Acredita-se que esses pontos tenham início a partir de uma alteração muscular ou do tecido conjuntivo que cria um feedback positivo com o sistema nervoso central, resultando em alterações sensoriais, motoras e autonômicas (HADDAD; BRIOSCH; ARITA, 2012).

Essas patologias musculares frequentemente estão associadas a problemas circulatórios e/ou processos inflamatórios e o principal mecanismo que pode explicar a mialgia é uma diminuição do fluxo sanguíneo intramuscular, causado por compressão dos vasos sanguíneos e acúmulo de metabólitos (RUGH, 1965; BARÃO et al., 2011; RAHMAYANI et al., 2020). Logo, essa condição muscular parece estar relacionada à vasoconstrição causada pela rigidez da estrutura muscular como resultado da hiperatividade muscular. O transporte adequado de nutrientes e metabólitos são impedidos, levando ao acúmulo de subprodutos responsáveis por desencadear a dor. Portanto, com uma menor irrigação sanguínea, a temperatura muscular tende a diminuir (BARÃO et al., 2011; RAHMAYANI et al., 2020).

## **1.2 Diagnóstico da disfunção temporomandibular**

Historicamente, teorias biomédicas sobre a etiologia da DTM foram amplamente divulgadas. De acordo com essas teorias, a DTM era diagnosticada como patologia da ATM - e "ATM" se tornou o termo quase universal pelo qual a condição era conhecida pela Odontologia e pelo público leigo. No entanto, nenhuma dessas teorias iniciais foi apoiada por qualquer evidência científica confiável (DUBNER; OHRBACH; DWORKIN, 2016).

Em 1992, surgiu o RDC/TMD (Research Diagnostic Criteria for Temporomandibular Disorders/ Critérios de Diagnóstico em Pesquisa para Desordens Temporomandibulares), diante da necessidade reconhecida de um sistema de diagnóstico confiável para fins de pesquisa epidemiológica e clínica, e que definisse e diagnosticasse diferencialmente subtipos comuns de DTMs relacionadas à dor crônica (DWORKIN; LERESCHE, 1992).

Os princípios básicos contidos na elaboração do RDC/TMD incluem 1) um modelo biopsicossocial de avaliação e classificação de doenças e enfermidades; 2) dados epidemiológicos que diferenciam a distribuição da sintomatologia por sexo e idade e identificam normas populacionais a partir das quais a doença pode ser mais bem definida; 3) um sistema de eixo duplo composto por diagnósticos físicos (eixo I) e perfis psicossociais (eixo II); 4) definições operacionais estritas de termos, incluindo especificações precisas para o exame clínico, bem como a classificação dos achados e protocolos para estudos de

confiabilidade e validade exigidos; e 5) reconhecimento de que o esforço inicial exigiu a geração de dados futuros como base de evidências para as revisões inevitáveis (DUBNER; OHRBACH; DWORKIN, 2016).

Look et al. (2011) e Truelove et al. (2011) afirmaram que a aceitação do RDC/TMD por médicos e cirurgiões dentistas como um sistema taxonômico para disfunções temporomandibulares foi necessariamente baseada em avaliações rigorosas de sua confiabilidade e validade, pois o nível de confiabilidade da medição (concordância ou reprodutibilidade da medição) associado a instrumentos de diagnóstico pode ser um fator restritivo para sua validade (precisão).

Em estudo realizado por Schiffman et al. (2010) foi verificado que os diagnósticos revisados do RDC/TMD, eixo I, são recomendados como confiáveis e válidos para dor miofascial e dor nas articulações. Mas, esses critérios clínicos revisados por si só, sem o auxílio de exames de imagem, são inadequados para o diagnóstico de alguns tipos de deslocamento de disco e osteoartrite/osteoartrose. Além disso, as modalidades de imagem convencionais (Radiografias, Tomografia Computadorizada, Tomografia Computadorizada de Feixe Cônico e Imagem por Ressonância Magnética) carecem de informações na análise de aspectos fisiológicos funcionais, como a microcirculação e sistema nervoso autônomo. Essas informações são de grande importância para avaliação das dores miofasciais (HADDAD et al., 2014).

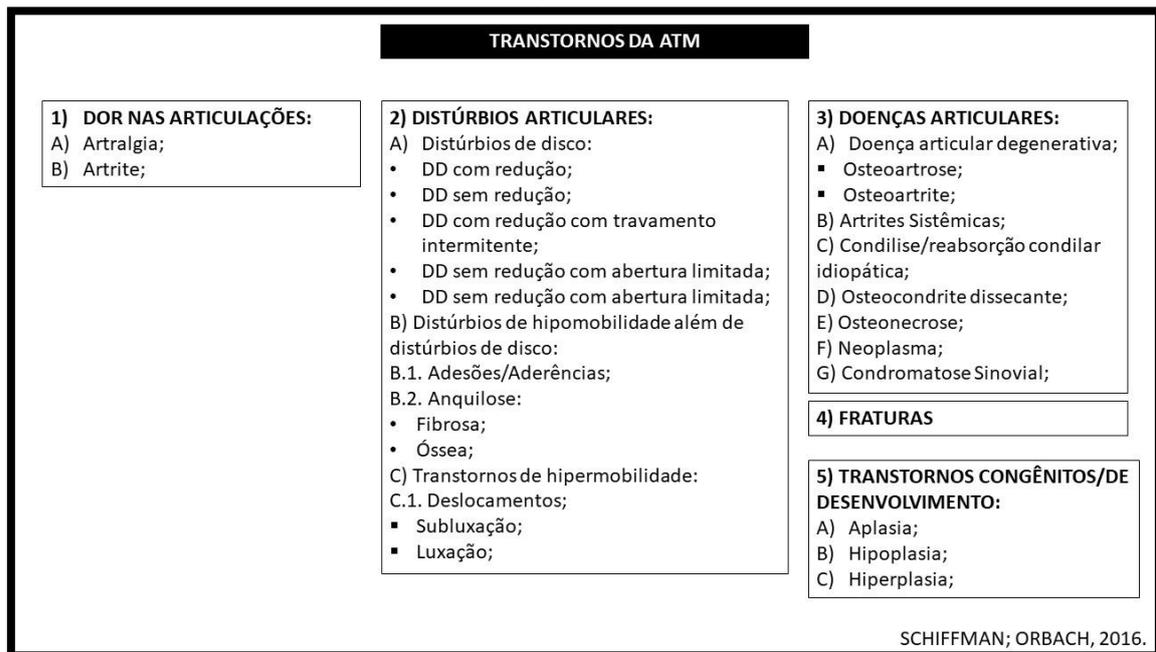
Desde a publicação do RDC/TMD, os autores afirmaram que a validade dos critérios de diagnóstico físicos (eixo I) precisava ser mais testada, pois eles foram derivados de consenso, opinião de especialistas e revisão de literatura (PECK et al., 2014). Sendo assim, a modificação desse sistema de classificação iniciou em 2001 com o apoio do Instituto Nacional de Pesquisa Odontológica e Craniofacial que financiou um projeto de validação durante 5 anos para verificar a confiabilidade e validade dos componentes do eixo I e II e, assim, recomendar revisões (PECK et al., 2014). Após uma série de simpósios, workshops e testes de campo de especificações do examinador do eixo I e instrumentos de autorrelato dos eixos I e II, a versão expandida DC/TMD (Diagnostic Criteria for Temporomandibular disorders/Critérios diagnósticos para desordens tempomandibulares) foi finalizada em 2013 (PECK et al., 2014).

Comparando a classificação original (RDC/TMD) com a versão atualizada (DC/TMD), verifica-se que o DC/TMD inclui questionários de triagem e algoritmos de diagnóstico para o

eixo I que são válidos e confiáveis para identificar casos de DTM relacionada à dor, como parte de uma estrutura abrangente de classificação taxonômica de DTM (SHIFFMAN et al., 2014).

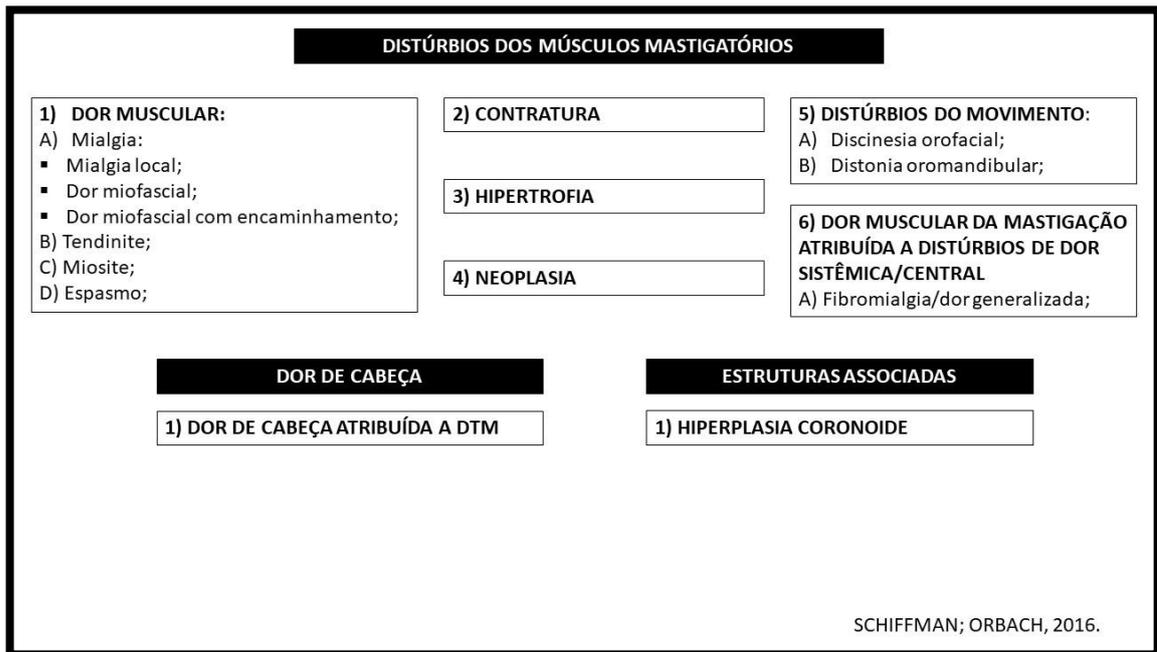
A classificação taxonômica para desordens temporomandibulares pode ser dividida em quatro grandes grupos com suas subdivisões: Transtornos da Articulação Temporomandibular, Distúrbios dos Músculos Mastigatórios, Dor de cabeça e Estruturas associadas, exemplificados nas imagens abaixo (SCHIFFMAN; OHRBACH, 2016).

**Figura 1.** Descrição dos Transtornos da ATM.



**Fonte:** Arquivo pessoal.

**Figura 2.** Descrição dos distúrbios dos músculos mastigatórios, dor de cabeça e estruturas associadas.



**Fonte:** Arquivo pessoal.

No que diz respeito ao Eixo II, uma série de oito questionários são recomendados para auxiliar na identificação dos fatores psicossociais e comportamentais que podem impactar no tratamento e prognóstico dos pacientes (SCHIFFMAN; OHRBACH, 2016).

Sendo assim, até o momento, o DC/TMD é o único sistema de classificação que utiliza questionários padronizados e confiáveis de autorrelato, procedimentos de exame clínico, sistemas de pontuação, árvores de decisão e avaliação do impacto que a dor tem no comportamento do paciente (KLASSER; MANFREDINI; DE LAAT, 2018).

### 1.3 Temperatura e Termografia infravermelha

As mudanças na temperatura corporal são consideradas um importante fator de diagnóstico (WOZNIAK et al., 2015). A temperatura é um dos parâmetros básicos de estado corporal, sendo definida em termodinâmica como a energia cinética média das moléculas que compõem um determinado sistema. Aulus Celsus Cornelius definiu os sinais cardinais da inflamação e o aumento da temperatura (calor) é um desses sinais, associado à vermelhidão (rubor), edema (tumor) e a dor. Logo, desde o início do desenvolvimento do diagnóstico médico, calor, é tido como a característica mais básica e perceptível de um processo de adoecimento em curso (MACHOY et al., 2020).

Os primeiros métodos para medição da temperatura corporal utilizavam termômetros de mercúrio de contato. Com o avanço da tecnologia, termômetros eletrônicos de contato foram desenvolvidos e os locais de medição são a boca, o reto, a axila e a base da uretra (YU CHEN; CHEN; CHEN, 2020).

Quando a temperatura de um objeto natural é maior que a temperatura absoluta, a superfície emite radiação térmica. Existem dois métodos para detecção da radiação infravermelha dos corpos e determinação da temperatura. O primeiro é o termômetro infravermelho sem contato, utilizado para medição da temperatura timpânica ou da testa. O termômetro infravermelho detecta a radiação liberada pelo objeto e a converte em um sinal elétrico que é processado e a temperatura pode ser exibida. O segundo método é a termografia infravermelha ou imagem térmica, na qual o detector térmico é utilizado para detectar a radiação recebida dos alvos (YU CHEN; CHEN; CHEN, 2020).

A termografia infravermelha começou a ser usada na medicina na década de 1960 e, com o avanço tecnológico, seu uso se tornou mais comum na década de 1990. É um método não invasivo para monitoramento sem contato de campos térmicos dinâmicos em uma superfície ou, neste caso, no corpo humano (GHASSEMI et al., 2018). Esta técnica é baseada na detecção de radiação infravermelha, que é emitida naturalmente da superfície do corpo e por todos os objetos com temperaturas acima do zero absoluto, incluindo organismos vivos de sangue quente (FRICOVA et al., 2018; MACHOY et al., 2020).

A emissão de radiação está relacionada à temperatura da superfície. A emissividade da pele humana é de  $0,96 \text{ } ^\circ\text{C} - 0,98 \text{ } ^\circ\text{C}$  ( $0 =$  refletor perfeito e  $1 =$  emissor perfeito). A radiação é convertida em um sinal elétrico, que é então transformado em uma imagem térmica denominada termograma que ilustra a distribuição espacial das temperaturas superficiais através de uma representação bidimensional em cores (RING; AMMER, 2012; OWEN; RAMLAKHAN, 2017; FRICOVA et al., 2018; SINGH; ARORA, 2018).

A temperatura da pele é influenciada pela circulação sanguínea, que é controlada pelo sistema nervoso autônomo (HADDAD; BRIOSCHI; ARITA, 2012). A fisiologia humana tem a capacidade de manter a temperatura corporal constante, independente da temperatura ambiente e mudanças de temperatura afetam ambos os lados do corpo de maneira uniforme, apresentando-se com uma simetria de gradientes térmicos em torno do eixo central do corpo (RUSTEMEYER; RADTKE; BREMERICH, 2007; SINGH; ARORA, 2018; FRICOVA et al., 2018). Em caso de anormalidades clínicas, os tecidos envolvidos experimentam uma mudança

na fisiologia, que é refletido por mudanças nos padrões de temperatura (hipertermia e hipotermia) (LAHIRI et al., 2012; SINGH; ARORA, 2018).

Diferentes regiões do corpo humano emitem radiação infravermelha em graus distintos, caracterizando a chamada heterogeneidade térmica, que depende muito do fluxo sanguíneo e do tipo de tecido localizado diretamente abaixo dele. Assim, a superfície da pele acima do tecido muscular, caracterizada por alta atividade metabólica, emite mais radiação do que a pele que recobre o osso ou tecido conjuntivo (WOZNIAK et al., 2015).

### 1.3.1 Radiação infravermelha e Câmeras térmicas (infravermelhas)

A radiação infravermelha emitida ou refletida pelo corpo humano, objetos e superfícies é registrada por um detector que faz parte da composição das câmeras infravermelhas (KIRIMTAT et al., 2020). A lente da câmera focaliza a radiação infravermelha na superfície de uma matriz que consiste em sensores infravermelhos. Os sensores de matriz reagem à absorção da radiação infravermelha modificando um dos parâmetros do sistema, como, pressão, polarização, resistência e temperatura, e então são transformados em uma imagem térmica nos diversos formatos de cores disponíveis na câmera. Como resultado, a termografia infravermelha fornece imagens que refletem os processos fisiológicos dos organismos vivos, observando a distribuição da temperatura na superfície externa do sistema examinado, sem a necessidade de qualquer contato ou radiação ionizante (ANBAR; GRATT; HONG, 1998; GRATT; ANBAR, 1998; KIRIMTAT et al., 2020; MACHOY et al., 2020).

Dentre as câmeras infravermelhas disponíveis no mercado, as do tipo FLIR são mais utilizadas nas detecções do que as do tipo SEEK, por possuírem detectores FPA (Focal Plane Array/ Matriz de plano focal), que funcionam como detectores térmicos. Os modelos de câmeras FLIR detectam diferenças de temperatura abaixo de 0,02°C, o que permite detectar alterações térmicas nas camadas mais profundas do corpo (KIRIMTAT et al., 2020).

Grande parte da faixa infravermelha do espectro eletromagnético não é utilizada pela termografia infravermelha, devido ao bloqueio sofrido pela atmosfera. As porções restantes definem a parte utilizável do infravermelho pela TI: Infravermelho próximo (NIR) de 0,75 – 1,4  $\mu\text{m}$ ; infravermelho de comprimento de onda curto (SWIR) de 1,4 -3  $\mu\text{m}$ ; infravermelho de comprimento de onda médio (MWIR) de 3 – 8  $\mu\text{m}$ .; infravermelho de comprimento de onda longo (LWIR) de 8 - 15  $\mu\text{m}$  (USAMENTIAGA et al., 2014).

Das regiões citadas acima, MWIR e LWIR são os mais usados pela TI. Existem dois motivos: a faixa de pico de emissões e a transmitância atmosférica. O primeiro motivo é devido

à relação entre temperatura e comprimento de onda. A medição mais eficaz para uma determinada temperatura deve ser realizada para o comprimento de onda em que a maior intensidade é emitida. Medir em um comprimento de onda diferente exigiria uma câmera muito mais sensível para obter um desempenho idêntico. Assim, para a maioria das aplicações, são necessários comprimentos de onda maiores que SWIR (USAMENTIAGA et al., 2014).

### 1.3.2 Protocolos para realização de exames termográficos

A temperatura da superfície da pele pode ser influenciada por vários fatores internos e externos, como o ritmo circadiano, o consumo de calorias, a atividade física, o estado emocional, a umidade relativa do ar e a temperatura atmosférica (HADDAD et al., 2014; LAHIRI et al., 2012). Logo, é um requisito fundamental que exames termográficos, sejam realizados em ambientes controlados, especialmente na área médica onde as mudanças de temperatura podem ser mínimas (LAHIRI et al., 2012).

Para sua realização, é necessário seguir alguns parâmetros definidos internacionalmente pela Academia Americana de Termologia, a fim de obter imagens no estado de equilíbrio térmico mais próximo entre a superfície da pele do corpo e a temperatura ambiente, sem tremer ou suar durante a captação das imagens (HADDAD et al., 2014).

O processo de captura da imagem térmica requer um protocolo rigoroso. Sendo assim, os pacientes devem receber orientações prévias a realização dos exames: (a) não se deve ingerir café, álcool, tabaco ou drogas antes do exame; (b) não podem ser usados maquiagem, creme hidratante ou joias; (c) nenhum banho deve ser tomado pelo menos uma hora antes do exame; (d) nenhum exercício físico deve ser realizado pelo menos quatro horas antes do exame. Além disso, o paciente deve ser submetido às imagens térmicas em sala sem luz natural, sob controle de temperatura e umidade e a câmera térmica utilizada deve ser fixada em um tripé a uma distância fixa necessária para obtenção das imagens (CLEMENTE et al., 2018).

### 1.3.3 Termografia infravermelha como auxiliar no diagnóstico DTM

A termografia infravermelha é uma modalidade de imagem que apresenta vantagens, como, baixo custo, rápida aquisição, não necessita de contato direto com o paciente e não utiliza radiação ionizante (LAHIRI et al., 2012; WOZNIAK et al., 2015). Logo, vem se tornando uma boa ferramenta de diagnóstico para patologias que apresentam mudanças nos padrões de temperatura.

De maneira geral, os músculos necessitam de oxigênio para realizarem seus movimentos de contração e relaxamento e esse oxigênio é fornecido pelo fluxo sanguíneo. Além disso, sabe-

se que a temperatura da pele é regulada pelo sistema nervoso autônomo e que pode variar de acordo com o fluxo sanguíneo (ALTINDIS; GUNGORMUS, 2019). Em casos de distúrbios associados aos músculos mastigatórios, esse fluxo sanguíneo pode ser modificado e afetar diretamente os padrões térmicos musculares (COSTA et al., 2013).

Um dos problemas para utilização de imagens térmicas como ferramenta auxiliar no diagnóstico de distúrbios associados aos músculos mastigatórios é a falta de um protocolo padronizado para aquisição e avaliação dessas imagens (MACHOY et al., 2020; RITYVAARA et al., 2021). Além disso, os resultados dos estudos existentes são conflitantes e as mudanças de temperatura nas regiões avaliadas são muito pequenas ( $0,1^{\circ}\text{C} - 0,5^{\circ}\text{C}$ ) e difíceis de avaliar, sendo necessárias ferramentas analíticas computacionais que ajudem nessa avaliação, o que até o momento não existe (KAWANO et al., 1993; MACHOY et al., 2020; RHAMAYANI et al., 2020).

Haddad; Brioschi; Arita (2012) realizaram estudo com o objetivo de correlacionar exames clínicos por meio de algometria e termografia infravermelha, correspondendo à diferença entre dor referida e localização nos pontos de gatilho miofasciais (temporal e masseter) e verificaram que a temperatura diminui à medida que aumenta a gravidade da disfunção miofascial. Uma explicação para essa diminuição da temperatura é que durante a contração sarcomérica da fibra muscular, há uma redução do fluxo sanguíneo, diminuindo a oxigenação muscular local (hipóxia). Essa hipóxia pode desencadear uma hiperatividade simpática regional na área de projeção cutânea do músculo, diminuindo a temperatura local por meio da atividade vasoconstritora. Além disso, o parâmetro utilizado na avaliação da termografia infravermelha foi a assimetria térmica, também conhecida como gradiente conjugado ( $\Delta T$ ) entre os lados opostos correspondentes. Pela avaliação dos pontos de corte, o valor do gradiente conjugado ( $\Delta T$ ) foi superior a  $0,3^{\circ}\text{C}$  e o valor da temperatura normalizada ( $\Delta\theta$ ) foi superior a  $0,036^{\circ}\text{C}$ .

Dibai Filho et al., (2013) realizaram estudo em 104 mulheres com o objetivo de avaliar a precisão da termografia infravermelha para o diagnóstico de DTM miogênica através dos valores de temperatura e assimetria de temperatura no ponto central dos músculos masseter e temporal anterior. Com os dados desse estudo, verificou-se uma menor acurácia do que a recomendada, a qual variou de 0,433 a 0,502. Os valores de sensibilidade e especificidade variaram de 38,5% para 76,9% e de 22,8% para 71,2%, respectivamente. Os autores afirmaram que essa menor acurácia pode ter sido devido a medição da temperatura da superfície da pele no ponto central do músculo e não no ponto muscular dolorido previamente identificado.

Rodrigues-Bigaton et. al., (2014) avaliaram a precisão de duas formas de análise de imagem infravermelha (área e extensão) dos músculos masseter e temporal anterior no diagnóstico de DTM miogênica. A amostra desse estudo foi de 104 mulheres divididas em dois grupos e foi utilizado o Índice Anamnésico de Fonseca (1994) para estabelecer o diagnóstico de DTM. Nesse estudo, uma diferença significativa na temperatura da pele entre os grupos só foi encontrada na medição da área do músculo temporal anterior esquerdo, com uma temperatura mais baixa encontrada nas mulheres com DTM em comparação com o grupo controle.

Dibai-Filho et. al., (2014) investigaram a correlação entre a cronicidade da DTM miogênica e a temperatura da pele sobre os músculos masseter e temporal anterior. A amostra desse estudo foi de 30 mulheres e o diagnóstico de DTM miogênica foi estabelecido com base no RDC/TMD. Como resultado, foi encontrada uma associação positiva entre a duração da DTM e assimetria de temperatura no músculo temporal anterior, enquanto nenhuma associação significativa foi encontrada em relação ao músculo masseter. Logo, de acordo com o estudo, a cronicidade da DTM miogênica altera a temperatura da pele sobre o músculo temporal anterior. Esse aumento de temperatura na região do temporal anterior pode ser explicado pela sua anatomia, pois esse músculo é mais fino que o músculo masseter e é influenciado pelo trajeto superficial da artéria temporal, que faz com que a região fique mais hiper radiante.

Haddad et. al., (2014) tiveram como objetivo medir a temperatura da pele em uma amostra de 23 mulheres, com o auxílio da termografia infravermelha, de regiões selecionadas (ROI) dos músculos masseter e temporal anterior de pacientes com e sem DTM. A termografia infravermelha revelou uma diferença de 1,4 °C entre as temperaturas médias do temporal anterior e do músculo masseter e uma diferença de 0,09 entre as temperaturas normalizadas correspondentes em indivíduos assintomáticos, indicando que o temporal estava significativamente mais hiper radiante do que o masseter ( $p < 0,05$ ).

Dibai-Filho et al., (2015) tiveram como objetivo correlacionar o grau de severidade da DTM com temperaturas da pele na região da ATM. A amostra desse estudo foi de sessenta mulheres e o Índice anamnésico de Fonseca (1994) foi utilizado para definir o diagnóstico de DTM. A medição da temperatura foi realizada na região do meato acústico externo, usado como parâmetro para localização da ATM. Nesse estudo, foi verificada uma associação entre a gravidade da DTM e as temperaturas da pele ao longo das ATMs direita e esquerda. Além disso, as comparações demonstraram um maior aumento nas temperaturas da pele em grupos com DTM mais grave. De acordo com Anbar e Gratt (1998), uma possível explicação fisiopatológica

para o aumento da temperatura da pele sobre a ATM em indivíduos com DTM é a hipertermia induzida por vasodilatação regional, condicionada pelo óxido nítrico produzido no espaço extravascular da articulação.

De Melo et. al., (2019) realizaram revisão sistemática com o objetivo de verificar a precisão e confiabilidade da termografia infravermelha no diagnóstico da disfunção temporomandibular. Após os critérios de inclusão e exclusão, apenas nove estudos foram incluídos. Nessa revisão, quatro estudos concluíram que a termografia apresenta baixa precisão ou não é um bom instrumento para diagnóstico de DTM, mas houve variação substancial na sensibilidade, especificidade e valores da curva ROC. Cinco estudos concluíram que a termografia parece ser promissor ou pode auxiliar no diagnóstico da DTM. Além disso, todos os estudos foram julgados como "em risco de viés" e como tendo "preocupações quanto à aplicabilidade". Logo, os autores verificaram que a literatura ainda é escassa quanto à confiabilidade da termografia para o diagnóstico da DTM.

Um dos estudos mais recentes que utilizou a termografia como instrumento auxiliar de diagnóstico para a DTM foi o de Barbosa et al. (2020). Nesse estudo, 45 pacientes com DTM foram selecionados com o auxílio do RDC/TMD e 41 pacientes sem DTM foram selecionados com o Índice anamnésico de Fonseca (1994). Os valores das temperaturas foram medidos em regiões selecionadas da ATM e dos músculos masseter e temporal anterior. Os autores verificaram que, para os dois grupos, os valores da temperatura média absoluta e adimensional não apresentaram diferenças estatisticamente significativas. Ao correlacionar a temperatura com a intensidade de dor à palpação, foi observada uma correlação negativa para o músculo masseter. Sendo assim, a termografia infravermelha apresentou dificuldade para diferenciar pacientes com e sem DTM e a intensidade de dor à palpação em pacientes com DTM é acompanhada por diminuição da temperatura local.

#### **1.4 Inteligência Artificial**

O termo "Inteligência Artificial" (IA) refere-se à ideia de que máquinas são capazes de desempenhar tarefas que os humanos comumente fazem e surgiu por volta de 1950, diante do avanço da ciência da computação e da disponibilidade de grandes volumes de dados de pacientes (SCHWENDICKE; SAMEK; KROIS, 2020; TANDON; RAJAWAT, 2020). A inteligência artificial pode ser dividida em três subáreas: aprendizagem de máquina, ciência de dados e aprendizado profundo. O uso clínico de programas de IA vem ganhando popularidade,

tornando-se uma realidade na odontologia nos últimos anos, sobretudo na radiologia odontológica (PARK, W.; PARK, J., 2018; SUR et al., 2020).

De acordo com Khanagar et al., (2021) e Nagi et al., (2020), o aprendizado de máquina é uma subárea da inteligência artificial que pode ser definida como a ciência de programar computadores para que eles possam aprender com os dados. O aprendizado de máquina utiliza métodos estatísticos e conceitos de estrutura de dados da álgebra linear para reconhecer e/ou caracterizar padrões. Redes neurais são um conjunto de algoritmos que reúnem sinais por meio de neurônios artificiais que mimetizam os neurônios do cérebro humano. Aprendizado profundo utiliza as redes neurais com múltiplas camadas para extrair e/ou classificar os dados de entrada. É muito comum utilizar o aprendizado profundo para problemas de classificações de imagens e, para este tipo de problema, são utilizadas as redes neurais convolucionais. Diferente dos algoritmos clássicos de visão computacional, as redes neurais convolucionais realizam a extração dos atributos e classificação automaticamente. No entanto, ela só é adotada normalmente em grandes bases de dados. (RABUNAL; DOURADO, 2005; J AKST, 2019).

#### 1.4.1 Semântica e Radiômica

Ao avaliar as diversas modalidades de imagem, os radiologistas só conseguem extrair o que é perceptível aos seus olhos, são as chamadas características ou atributos semânticos das imagens. Sendo assim, os atributos semânticos podem ser definidos como características qualitativas que são coletadas de acordo com a avaliação pontual e subjetiva dos radiologistas, mesmo que esses dados sejam adquiridos com a ajuda de softwares (YIP et al., 2017; COROLLER et al., 2017; PAN et al., 2020). São exemplos de características semânticas: tamanho, contorno, presença de septos, nódulos murais, dentre outros (PAN et al., 2020).

Embora os recursos semânticos sejam altamente intuitivos, eles estão inerentemente sujeitos a variabilidade interobservador e as escalas binárias e categóricas empregadas para classificá-los podem ser insuficientes para descrever as características sutis de determinadas lesões, o que pode influenciar nas decisões clínicas (YIP et al., 2017; COROLLER et al., 2017).

Um campo emergente da Inteligência artificial é a Radiômica que tem por objetivo extrair informações quantitativas de alto rendimento de imagens radiológicas para realizar análises de dados e auxiliar nas decisões clínicas (WU et al., 2019; SHI et al., 2020). Em radiômica, são utilizadas fórmulas matemáticas que descrevem quantitativamente várias qualidades de imagem (contraste, homogeneidade, textura, dentre outras), definidas em uma região de interesse e têm valores em escala contínua que podem fornecer mais detalhes para

alterações nas características de um tumor, por exemplo (YIP et al., 2017; WU et al., 2019). Tecnicamente, as imagens são transformadas em dados dimensionais mais elevados para pesquisar correlações que possam definir um fenótipo radiográfico útil antes, durante ou após o tratamento (HAWKINS et al., 2016; WU et al., 2019).

As imagens digitais médicas contêm informações ocultas que refletem a fisiopatologia subjacente e essas informações podem ser reveladas com o auxílio da radiômica (GILLIES; KINAHAN; HRICAK, 2016; SOLLINI et al., 2019). A radiômica possui a capacidade de lidar com grande quantidade de dados em comparação com os métodos estatísticos tradicionais. Modelos preditivos e prognósticos com alta precisão, confiabilidade e eficiência são os fatores que estão impulsionando o seu sucesso (HOSNY et al., 2018; KOÇAK et al., 2019; PARMAR et al., 2015).

Tecnicamente, quando se deseja fazer uma análise com base em métodos radiômicos, as seguintes etapas são necessárias: aquisição das imagens, pré-processamento, segmentação das regiões de interesse e extração de características (GILLIES; KINAHAN; HRICAK, 2016; HUNG et al., 2019).

Imagens de TC, TCFC, IRM, Tomografia por Emissão de Pósitrons (TEP), radiografias convencionais e ultrassonografia podem ser utilizadas pela radiômica. Essas modalidades de imagens podem ser obtidas com diferentes parâmetros/protocolos de aquisição e reconstrução. Com isso, quando as imagens são analisadas numericamente para extração de dados significativos, as variações nos parâmetros de aquisição e reconstrução da imagem podem introduzir alterações que não ocorrem devido aos efeitos biológicos subjacentes. Isso tem sido bem reconhecido no campo emergente da imagem quantitativa, em que a intenção é gerar imagens médicas com limites descritíveis de viés e variância (GILLIES; KINAHAN; HRICAK, 2016; KOÇAK et al., 2019).

A segmentação é a etapa mais crítica na radiômica devido ao fato de as características serem extraídas das áreas ou volumes segmentados. Além disso, algumas alterações apresentam margens mal definidas (KOÇAK et al., 2019). A segmentação pode ser realizada através de métodos de segmentação manuais, semiautomáticos e automáticos (LIU et al., 2019). A segmentação manual é considerada padrão ouro, quando é realizada por especialistas, mas consome muito tempo. Apesar das técnicas de segmentação automática serem objetivas, elas são susceptíveis a erros, principalmente quando as imagens apresentam artefatos e ruídos e as lesões de interesse são muito heterogêneas (KOÇAK et al., 2019).

A extração de atributos ou características é tida como o coração da radiômica e é realizada executando algoritmos conhecidos como extratores de atributos. Os algoritmos de extração de atributos executam procedimentos de imagem quantitativos, como construção de histograma, classificação de textura, reconhecimento de forma e reconhecimento de contorno, assim como estimativas de área e volume. Após as extrações dos atributos pelos algoritmos, os valores são armazenados em um vetor de atributos. Os atributos radiômicos podem ser classificados em três tipos: descritores de forma, descritores de textura e descritores de frequência (GONZALES; WOODS, 2008). No campo da visão computacional, a adoção de cada tipo depende diretamente do problema adotado, podendo ser utilizado um ou mais tipos no mesmo algoritmo.

Geralmente, muitos atributos de imagem quantitativos podem ser obtidos após a extração. No entanto, muitos podem incluir informações redundantes e causar sobreajustes (modelo estatístico se ajusta muito bem ao conjunto de dados anteriormente observado, mas se mostra ineficaz para prever novos resultados). Portanto, a seleção de atributos deve ser realizada para preservar os mais relevantes, procedimento chamado de redução de dimensão ou de dimensionalidade. Um modelo de predição pode então ser construído com os principais atributos selecionados de acordo com o desfecho clínico (LIU et al., 2019; KOÇAK et al., 2019).

A redução de dimensionalidade trata-se da etapa de ajuste dos dados e, após esta adequação, a próxima etapa é construir um modelo de predição dos resultados clínicos com os atributos selecionados. O aprendizado de máquina fornece vários métodos de modelagem para atingir esse objetivo. Normalmente, a aprendizagem supervisionada, não supervisionada e aprendizagem por reforço são estratégias fundamentais usadas de acordo com os diferentes níveis de resultados clínicos disponíveis (NAGI et al., 2020; LIU et al., 2019).

A aprendizagem supervisionada baseia-se na realização de cálculos e depois ajuste do erro para obter uma saída esperada, com a função inferida de dados de treinamento definidos à mão que são um conjunto de exemplos de treinamento. Na prática, esses sistemas aprendem a detectar características normais e anormais analisando imagens marcadas à mão. Esses programas são de 2 tipos: classificação, em que a variável de saída é uma categoria como duas cores, como doente e saudável (ou seja, há 2 saídas possíveis), e regressão, em que a variável de saída é real ou valor contínuo (por exemplo, peso, preço ou tamanho) (NAGI et al., 2020).

O aprendizado não supervisionado é o aprendizado de máquina por conta própria com base no padrão de entrada. Os dados especificados para o aluno não são definidos e são divididos em diferentes grupos. Logo, esses modelos também são conhecidos como algoritmos de agrupamento (NAGI et al., 2020). Já a aprendizagem por reforço é baseada na saída que interage com o ambiente para atingir certos objetivos, com uma recompensa pela saída correta e uma penalidade pela saída errada (NAGI et al., 2020).

Sendo assim, o desenvolvimento de um método de aprendizado de máquina envolve a criação de uma função de treinamento para um conjunto de dados (os vetores de atributos, no caso de classificação de imagens) e o uso de inferência lógica. Quando as aulas (diagnósticos ou desfechos clínicos) para decisão final do modelo são pré-estabelecidas, o processo de treinamento é supervisionado. Quando não há classe definida, o processo não é supervisionado (SANTOS et al., 2019).

Para desenvolver o modelo de IA é preciso treinar um modelo, ajustar os hiperparâmetros e avaliar o desempenho do modelo. A validação de amostra dividida e a validação cruzada k-fold (VC) são duas técnicas utilizadas para o desenvolvimento dos modelos. A validação de amostra dividida é recomendada diante de muitos dados disponíveis e todos os dados devem ser divididos aleatoriamente em três conjuntos de dados. A validação cruzada é mais aplicável a conjuntos de dados de pequeno a médio porte. Esta técnica tem um parâmetro denominado k, e quando um valor específico para k é determinado, todos os dados devem ser divididos em conjuntos de dados k. Um desses conjuntos de dados é usado para validação, enquanto os dados nos conjuntos restantes (k-1) servem como dados de treinamento. Este processo será repetido k vezes até que cada conjunto de dados tenha sido servido uma vez como um conjunto de validação. Posteriormente, o desempenho do modelo será avaliado pela média de cada um dos resultados separados obtidos (HUNG et al., 2019; THRALL et al., 2018).

A avaliação de desempenho das classificações geralmente pode ser feita usando a área sob a curva ROC (Receiver Operating Characteristic)/AUC (Area Under the Curve) Deve-se ter em mente que o AUC pode ser um avaliador de desempenho ruim caso o conjunto de dados tiver um desequilíbrio de classe. Por isso, outras métricas de desempenho como exatidão, sensibilidade, especificidade, precisão, medida F1 e coeficiente de correlação de Matthews devem ser fornecidas para avaliação posterior (KOÇAK et al., 2019).

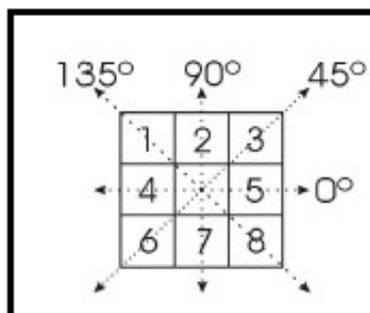
#### 1.4.2 Atributos radiômicos e estratégias de redução de dimensionalidade

Quando se pretende extrair atributos de imagens termográficas infravermelhas, esses atributos são obtidos através de ROIs selecionadas previamente. Essas características podem ser analisadas através de estatísticas de primeira ordem, como temperatura média (média), desvio padrão, entropia, curtose, assimetria e variância; ou através de estatísticas de segunda ordem, como homogeneidade, contraste, energia, correlação, entropia e probabilidade máxima. As matrizes de co-ocorrência são muito utilizadas para extrair essas características (VARDASCA; VAZ; MENDES, 2018).

Matriz de co-ocorrência é uma tabulação de quantas combinações possíveis de valores de intensidade dos pixels (níveis de cinza) ocorrem em uma imagem. Ela considera a relação entre dois pixels por vez, um denominado pixel referência e o outro de pixel vizinho. Este processo é feito pixel a pixel, da primeira até a última linha da imagem, sempre da esquerda para direita (VARDASCA; VAZ; MENDES, 2018).

Teoricamente, uma matriz de co-ocorrência pode ser construída por uma matriz de frequências relativas  $P(i, j; d, q)$ , na qual dois elementos vizinhos, separados por uma distância “d” em uma orientação “q” ocorrem na imagem, um com propriedade “i” e o outro com propriedade “j”. Sendo assim, os elementos são pixels e as propriedades são os níveis de cinza. Os valores possíveis para “q” podem ser visualizados na imagem a seguir (VARDASCA; VAZ; MENDES, 2018).

**Figura 3.** Valores (ângulos possíveis) para calcular uma matriz de co-ocorrência.



**Fonte:** Arquivo pessoal.

Atributos, como, contraste, correlação, energia, homogeneidade, entropia, média aparada, curtose, assimetria, variância e desvio padrão vêm sendo utilizados em pesquisas (COROLLER et al., 2017; YIP et al., 2017; BASHIR et al., 2019; PAULINO et al., 2019) e algumas definições podem ser vistas no quadro a seguir (quadro 1).

**Quadro 1.** Definições de atributos

<b>NOME DO ATRIBUTO</b>	<b>DEFINIÇÃO</b>
<b>Assimetria</b>	É um indicador da concentração de valores em relação à mediana. Distribuições como a Gaussiana apresentam assimetria nula, enquanto assimetria negativa está presente em distribuições concentradas à esquerda da mediana.
<b>Contraste</b>	Caracteriza-se pela diferença entre os tons de cinza.
<b>Correlação</b>	Mede a dependência linear entre os tons de cinza presentes em uma imagem.
<b>Curtose</b>	Indica o achatamento da função de distribuição e apresenta valores negativos em distribuições com forma mais achatada que a Gaussiana, ou seja, distribuições cujas regiões de alta probabilidade não se encontram tão concentradas próxima à média quanto à distribuição Gaussiana.
<b>Entropia</b>	Expressa a desordem contida na textura.
<b>Homogeneidade</b>	Assume valores altos quando a textura apresenta pequenas variações de níveis de cinza entre pares de pixels.
<b>Média</b>	Representa o valor esperado da distribuição dos níveis de cinza presentes na textura.
<b>Variância</b>	Descreve quanto os valores estão dispersos em torno da média, em que “ $g_i$ ” representa o tom de cinza para o $i$ -ésimo pixel e “ $n$ ” o número de pixels presentes na textura.
<b>SMA (Segundo Momento Angular)</b>	Também conhecido como energia, expressa a uniformidade de uma textura.

Transformações estatísticas como a análise por componentes principais (PCA), análise discriminante não paramétrica (NDA), análise discriminante linear (LDA) e razão de ganho de informação (IGR) podem ser utilizadas para reduzir ou simplificar as variáveis, também chamada de redução de dimensionalidade (VARDASCA; VAZ; MENDES, 2018).

Dentre as transformações citadas acima, com a análise por componentes principais é possível analisar os dados, eliminar sobreposições e escolher as formas mais representativas dos dados a partir de combinações lineares das variáveis originais. Através da PCA, imagens podem ser tratadas como padrões em um espaço linear a fim de efetuar o reconhecimento estatístico. Logo, sendo  $A$  o número de linhas em uma imagem e  $B$  o número de colunas, pode-se dizer que uma imagem é um padrão de  $A \times B$  características ou um vetor ( $A \times B$ ), o qual é denominado de “espaço de imagens”, representado por  $I$  (VARDASCA; VAZ; MENDES, 2018).

### 1.4.3 Utilização de classificadores

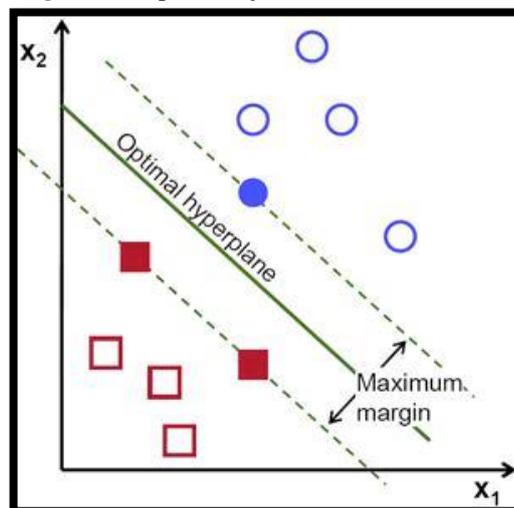
Dentre os classificadores utilizados, o SVM (Support Vector Machine), o KNN (Kernel Nearest Neighbors) e as redes neurais vêm sendo usadas em problemas de classificação de imagens termográficas (OLESZKIEWICZ et al., 2016; PAULINO et al., 2019).

#### 1.4.3.1 Classificador SVM

O SVM (Support Vector Machine) tem seu conceito baseado na teoria de aprendizagem estatística e pode ser aplicado a um conjunto de métodos de classificação que analisam dados e reconhecem padrões. É um procedimento automático de aprendizagem construtiva, baseado na minimização de risco estrutural, ou seja, pretende minimizar os erros existentes nos dados que não estão incluídos no algoritmo de construção. Sua vantagem se deve aos limites (borderlines) criados pelo aprendizado automático de máquina durante a fase de construção (ABE, 2005; WANG, 2005).

De maneira geral, um classificador SVM produz resultados lineares binários, analisando um conjunto de dados iniciais e atribui o resultado a uma das duas categorias possíveis. Normalmente, este algoritmo funciona bem quando aplicado a novos dados, pois os dados aplicados durante a fase de construção são geralmente os mais difíceis de classificar. Em um modelo representativo, o SVM usa um mapeamento de pontos em espaço, e há, no espaço de representação criado, um hiperplano que separa as duas classes. Desta forma, os pontos são distribuídos no espaço de acordo com o pertencimento à classe (ABE, 2005; WANG, 2005). Na imagem a seguir, é possível visualizar a representação desse classificador.

**Figura 4.** Representação do classificador SVM.

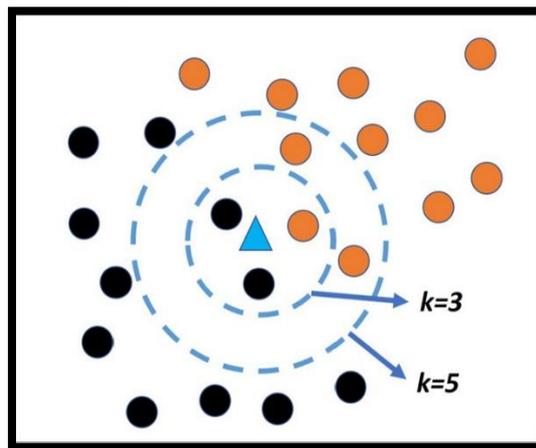


**Fonte:** ABE, 2005; WANG, 2005.

### 1.4.3.2 Classificador KNN

O KNN (Kernel Nearest Neighbors) é classificado como um algoritmo de aprendizagem supervisionada e pode ser usado para classificação e/ou agrupamento (LAROSE, D., LAROSE, C, 2005). É um dos algoritmos de classificação mais utilizados na aprendizagem de máquina e baseia-se na procura dos  $k$ -vizinhos mais próximos do padrão de teste. A busca pela vizinhança é feita utilizando uma medida de distância nessa procura e o padrão é classificado de acordo com a soma dos pesos dos  $k$ -vizinhos, o peso é o inverso das distâncias (DINIZ; SILVA; ALENCAR, 2016; DINIZ et al., 2013). Na imagem a seguir, é possível visualizar a representação desse classificador.

**Figura 5.** Representação do classificador KNN.



Fonte: KOÇAK et al., 2019.

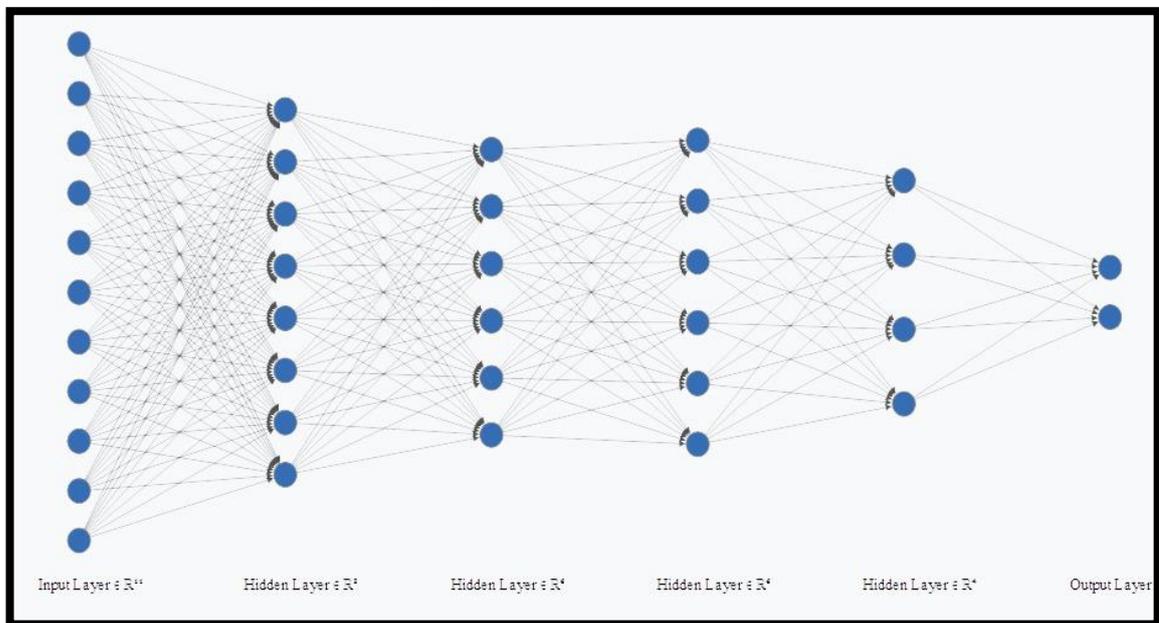
### 1.4.3.3 Redes neurais multicamadas

Aprendizado profundo é uma parte do aprendizado de máquina baseado em uma estrutura de rede neural inspirada no cérebro humano. Essas estruturas aprendem recursos discriminativos de dados automaticamente, sem a necessidade de definição prévia por especialistas humanos, e obtêm a capacidade de aproximar relacionamentos não lineares muito complexos, podendo fornecer uma avaliação quantitativa de maneira automatizada (HOSNY et al., 2018). Logo, devido à sua capacidade de aprender representações de dados complexos, o aprendizado profundo é frequentemente robusto contra variações indesejadas, como a variabilidade entre leitores, podendo ser aplicado a uma grande variedade de condições clínicas e parâmetros (HOSNY et al., 2018).

Teoricamente, as redes neurais multicamadas são constituídas por blocos de construção empilhados, também chamados de camadas de convolução, camadas de pool e camadas

totalmente conectadas. Essas redes aprendem diretamente dos dados, reconhecem os padrões nas imagens e classificam a saída final em classes com base em sua tarefa. As duas primeiras camadas, conhecidas como camadas de convolução e agrupamento, trabalham na extração de recursos, enquanto as camadas totalmente conectadas fornecem a saída final e a última camada de ativação classifica os recursos extraídos em categorias. Um conjunto de parâmetros aprendíveis (Kernels) são aplicados em cada posição da imagem. Hiperparâmetros, como o número arbitrário e o tamanho dos Kernels (3x3;5x5;7x7), são determinados antes do treinamento. As camadas de convolução executam operações de down-sampling, reduzindo o número de parâmetros aprendíveis. Ao final, os recursos de amostragem inferior são mapeados pelas camadas totalmente conectadas para a saída final na qual a função de ativação é aplicada para determinar as categorias (NAGI et al., 2020; DOI, 2007; HOPFIELD, 1982). A seguir, é possível visualizar a arquitetura de uma rede neural multicamada.

**Figura 6.** Arquitetura de uma rede neural multicamada.



**Fonte:** Arquivo pessoal.

Diante das vantagens da utilização da TI como instrumento de diagnóstico de DTM e da possibilidade de aprimorar a avaliação de termogramas utilizando inteligência artificial, esse estudo se propõe a avaliar essas ferramentas como auxiliares no diagnóstico da disfunção temporomandibular.

## **2 OBJETIVO**

### **2.1 Objetivo Geral**

- Avaliar três métodos de aprendizado de máquina para extração de atributos e três algoritmos de classificação utilizando imagens termográficas, dados de temperatura e escala de dor à palpação na detecção de disfunção temporomandibular (DTM).

### **2.2 Objetivos Específicos**

- Avaliar qual método de aprendizado de máquina para extração de atributos: radiômicos, semânticos e radiômicos-semânticos associados, é o mais efetivo para estabelecer o diagnóstico de DTM;
- Analisar a acurácia, precisão, sensibilidade e especificidade de três algoritmos de classificação (SVM, KNN, MLP) na realização do diagnóstico de DTM;
- Verificar qual associação entre método de extração de atributo e algoritmo de classificação é o mais adequado para estabelecer o diagnóstico de DTM;

### **3 METODOLOGIA**

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

Este estudo é caracterizado como um estudo observacional do tipo transversal.

#### **3.2 Localização do estudo**

Este estudo foi realizado no departamento de Odontologia do campus I da Universidade Estadual da Paraíba (UEPB), através de parceria entre a clínica de atendimento a portadores de dor orofacial e os pesquisadores do laboratório de termografia infravermelha.

#### **3.3 Aspectos éticos**

O projeto referente a este estudo foi cadastrado na Plataforma Brasil e encaminhado ao Comitê de Ética em Pesquisa com seres humanos (CEP) da UEPB para que fosse realizada a sua apreciação. O projeto obteve o parecer aprovado com o CAAE: 73417017200005187 (Anexo A). Além disso, esteve em conformidade com as resoluções do Conselho Nacional de Saúde (CNS) nº 466/2012 e nº580/2018 que estabelecem as diretrizes e normas regulamentadoras de pesquisas envolvendo seres humanos. Os pacientes assinaram o Termo de Consentimento Livre e Esclarecido (TCLE) concordando em participar da pesquisa (APÊNDICE A).

A pesquisa não ofereceu quaisquer riscos aos pacientes, tendo em vista que a termografia infravermelha é um exame não invasivo, pois não utiliza radiação ionizante.

#### **3.4 Universo e amostra**

O universo da pesquisa foi composto por pacientes com queixas de dor orofacial que procuraram atendimento na clínica para atendimento de pacientes portadores de dor orofacial do departamento de Odontologia do Campus I da UEPB.

A amostra foi composta por dois grupos de pacientes: 41 pacientes com DTM e 37 pacientes sem DTM. Todos os pacientes foram examinados de acordo com o Índice Anamnésico de Fonseca (IAF) e, aqueles que tiveram o diagnóstico DTM, de acordo com este índice, foram examinados seguindo os parâmetros RDC/TMD a fim de confirmar o diagnóstico de DTM. Já o grupo de pacientes sem DTM (controle) foi composto por voluntários que não tiveram diagnóstico de DTM, realizado através do Índice anamnésico de Fonseca. Os pacientes dos dois grupos foram pareados o máximo possível quanto às características físicas, como peso e altura, para que o índice de massa corporal não fosse diferente e não causasse diferenças de temperatura, acarretando viés na análise das imagens.

### 3.4.1 Critérios de inclusão

Os critérios de inclusão desse estudo foram: pacientes adultos (18 a 60 anos), de ambos os sexos, com DTM muscular ou mista (muscular e articular) e sem DTM, de acordo com o RDC/TMD e Índice anamnésico de Fonseca.

### 3.4.2 Critérios de exclusão

Foram excluídos da amostra os pacientes que apresentaram as seguintes características:

- Odontalgia;
- Febre;
- Alterações sistêmicas (hipoglicemia, hipotireoidismo ou hipertireoidismo, hipertensão, doenças respiratórias, artrite reumatóide, fibromialgia, gravidez, alterações reumatológicas, menopausa, alterações neurológicas);
- Pacientes oncológicos;
- Pacientes em tratamento com medicação miorrelaxante, analgésica e/ou anti-inflamatória ou que fazem reposição hormonal;
- Pacientes que apresentem cicatrizes faciais e/ou pápulas.

## 3.5 Diagnóstico de DTM

Para realizar o diagnóstico da DTM, foi realizado o exame físico e aplicação dos questionários correspondentes ao RDC/TMD, índice de classificação diagnóstica universalmente aceito, validado e utilizado em pesquisas (DWORKIN; LE RESCHE, 1992) (ANEXO B).

Foi realizada a coleta dos dados da palpação e da intensidade da dor, de acordo com o RDC/TMD, sendo classificada em quatro graus: 0 – Sem dor; 1- Dor leve; 2- Dor moderada; 3- Dor severa. Tais dados foram analisados com as temperaturas dos pacientes com DTM.

Como o diagnóstico de DTM utilizando o RDC/TMD demanda muito tempo e com o intuito de simplificar o diagnóstico de DTM no grupo controle, o Índice anamnésico de Fonseca foi utilizado para confirmar a ausência de sintomatologia de DTM nos pacientes convidados para formar esse grupo (GONÇALVES et al., 2010) (ANEXO C).

## 3.6 Exame termográfico infravermelho

### 3.6.1 Câmera térmica

Os exames termográficos infravermelhos foram realizados utilizando uma câmera térmica portátil de sensor infravermelho FLIR modelo T650 Infrared (Figura 7) que foi fixada

em um tripé. Esse modelo apresenta lente de 25 mm e resolução espacial de 640 x 480 pixels, é capaz de produzir imagens térmicas e visuais com boa qualidade e sensibilidade térmica (0,05 a 30 °C), capta imagens com temperatura de -40°C a 150°C, e possui emissividade regulável.

**Figura 7.** Câmera térmica FLIR T650.



**Fonte:** Google Imagens.

### 3.6.2 Sala de realização dos exames

A sala de realização de exames está localizada no Laboratório de Termografia Infravermelha do departamento de Odontologia do Campus I, UEPB. A sala possui temperatura de ambiente padronizada. Para isso, é utilizado um termohigrômetro digital durante todos os exames que é posicionado próximo ao paciente e monitora a temperatura ambiente e a umidade relativa do ar.

Essa sala possui ar-condicionado com capacidade térmica suficiente para o seu tamanho e não fica direcionado diretamente para o paciente. A temperatura da sala é mantida entre 22°C e 24°C. Além disso, não possui janelas, o que contribui significativamente para evitar insolações diretas no paciente. Lâmpadas fluorescentes, tipo frias, são utilizadas para iluminação do ambiente.

As paredes de fundo onde a cadeira do paciente é posicionada são revestidas com placas de Poliestireno Expandido (EPS - isopor) com espessura de 25 mm, papel alumínio e E.V.A na cor preta (AIRES et al., 2018), formando uma barreira térmica isolante contra possíveis fontes externas de calor e fazem com que nenhuma imagem fantasma seja formada ou refletida no momento do exame, o que pode interferir na imagem térmica (Figura 8).

No momento de realização dos exames, no máximo três pessoas devem estar na sala, para evitar o risco de aumento da temperatura ambiente. Ademais, é necessário ligar a câmera previamente e aguardar 20 minutos para estabilização da temperatura ambiente.

**Figura 8.** Visão do local onde é realizado o exame termográfico, mostrando a parede revestida por E.V.A preto, câmera térmica posicionada no tripé e a cadeira utilizada.



**Fonte:** Arquivo pessoal.

### 3.6.3 Preparo do paciente

Os exames termográficos foram realizados seguindo as diretrizes preconizadas pela Academia Americana de Termologia (SCHWARTZ, 2008) e, previamente a sua realização, todos os pacientes receberam orientações (APÊNDICE B), para evitar que fatores externos interferissem na temperatura da região. Para cada paciente, foi preenchida uma ficha que avaliou o perfil termográfico e a história médica (APÊNDICE C).

Todos os voluntários foram orientados a fazer a limpeza facial em casa, sem esfoliação, no dia do exame para fidedignidade dos dados registrados pela câmera termográfica; e a não utilizar no dia do exame: fontes de calor, como secador e/ou alisador de cabelos; cremes, talcos, perfumes, maquiagens, entre outros; Os homens deveriam se barbear pelo menos seis horas antes do exame; não ingerir alimentos quentes; não fazer uso de analgésicos, anti-inflamatórios, anti-hipertensivos; não praticar qualquer tipo de exercício físico; se fumante, interrompesse o uso de cigarros e cachimbos por 4 horas antes do exame; não tomar banho quente; estar em jejum por no mínimo três horas antes do exame, nem consumir estimulantes e substâncias com cafeína; não tocar, esfregar ou coçar a pele a ser examinada; e não usar joias.

Cada voluntário aguardou 15 minutos na sala de exame com temperatura média de  $23 \pm 1$  °C e umidade relativa do ar entre 40% e 60% para atingir o equilíbrio térmico preconizado (BRIOSCHI et al., 2003). Para aquisição da imagem, o participante foi acomodado em uma cadeira, utilizou gorro descartável para prender os cabelos e foi posicionado de modo ereto, com plano sagital perpendicular ao solo. A medição padronizada de 0,80 m (distância entre a

câmera e o paciente) foi realizada a cada aquisição de imagem (Figura 9). A emissividade da pele considerada para esse estudo foi de 98% (BARBOSA et al., 2020; WOZNIAK et al., 2015; DIBAI-FILHO et al., 2014; RODRIGUES-BIGATON et al., 2014; BRIOSCHI et al., 2010) configurada na máquina previamente a aquisição.

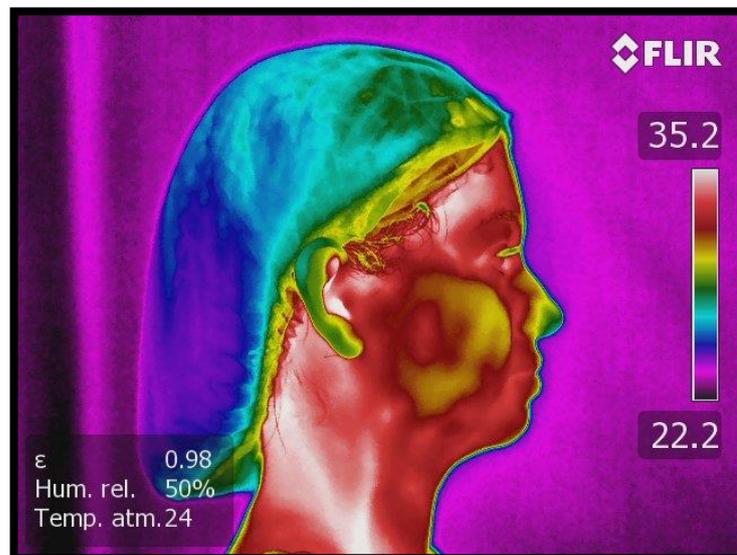
Foram realizadas duas aquisições para cada paciente: lateral direita e esquerda, de forma padronizada (Figuras 10 e 11).

**Figura 9.** Câmera posicionada no tripê e cadeira utilizada.



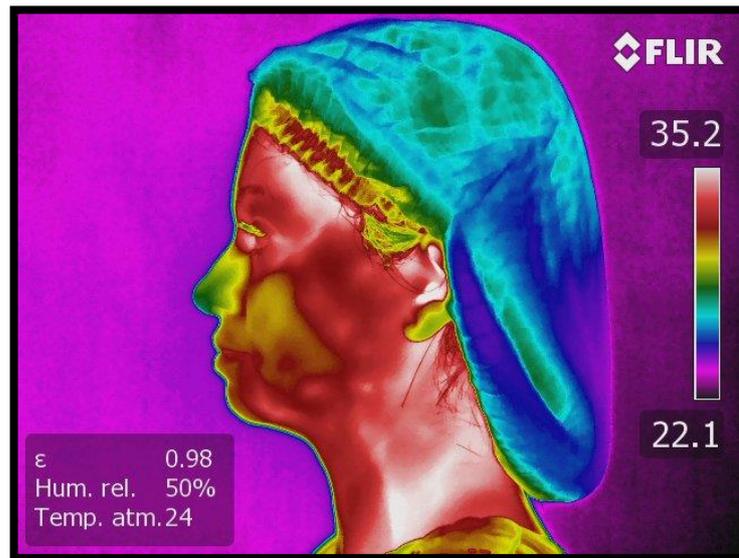
**Fonte.** Arquivo pessoal.

**Figura 10.** Imagem termográfica em normal lateral direita.



**Fonte:** Arquivo pessoal.

**Figura 11.** Imagem termográfica em norma lateral esquerda.



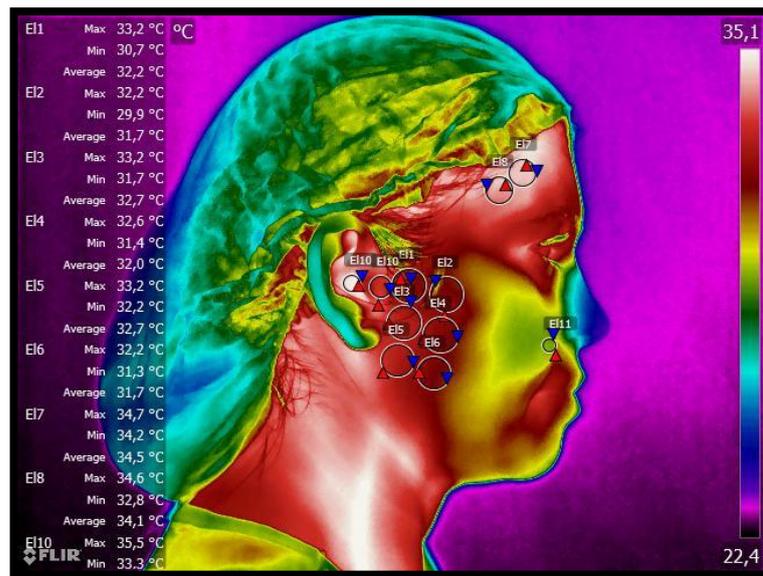
Fonte: Arquivo pessoal.

### 3.7 Análise das imagens termográficas

Todas as imagens adquiridas foram separadas e armazenadas em pastas individuais para cada participante e analisadas por um examinador cego. O software utilizado para avaliação foi o FLIR Tools v. 6.4 (Reino Unido), disponibilizado pela empresa da câmera e produzido, prioritariamente, para análise dos parâmetros de temperatura

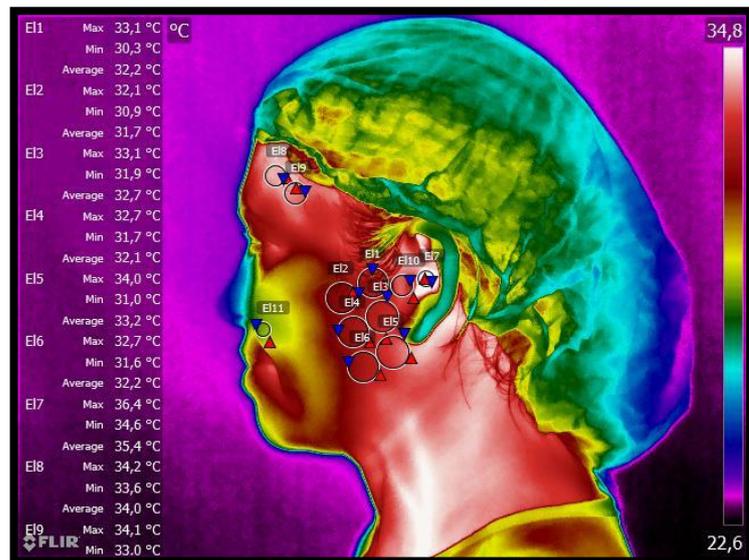
Para medição do gradiente térmico dos pontos faciais nas ROI, a ferramenta “círculo” (diâmetro de  $22 \pm 3$  mm) foi utilizada para facilitar a sua adaptação aos pontos anatômicos analisados. Logo, oito pontos faciais bilaterais de cada paciente foram analisados, dois correspondentes ao músculo temporal anterior e seis ao músculo masseter que foi dividido em superior, médio e inferior (dois pontos para cada região) (Figuras 12 e 13). Foram realizadas médias absolutas das temperaturas dos terços do músculo masseter e dos pontos do músculo temporal anterior, para facilitar a análise dos dados.

**Figura 12.** Utilização da ferramenta círculo para medição de temperatura em ROIs nos músculos temporal anterior e masseter (Visão lateral direita).



Fonte: Arquivo pessoal.

**Figura 13.** Utilização da ferramenta círculo para medição de temperatura em ROIs nos músculos temporal anterior e masseter (Visão lateral esquerda).



Fonte: Arquivo pessoal.

### 3.8 Tabulação dos dados

Os dados correspondentes à intensidade de dor à palpação e às médias de temperatura absolutas das ROI dos músculos “temporal anterior” e “masseter” foram tabulados e analisados posteriormente.

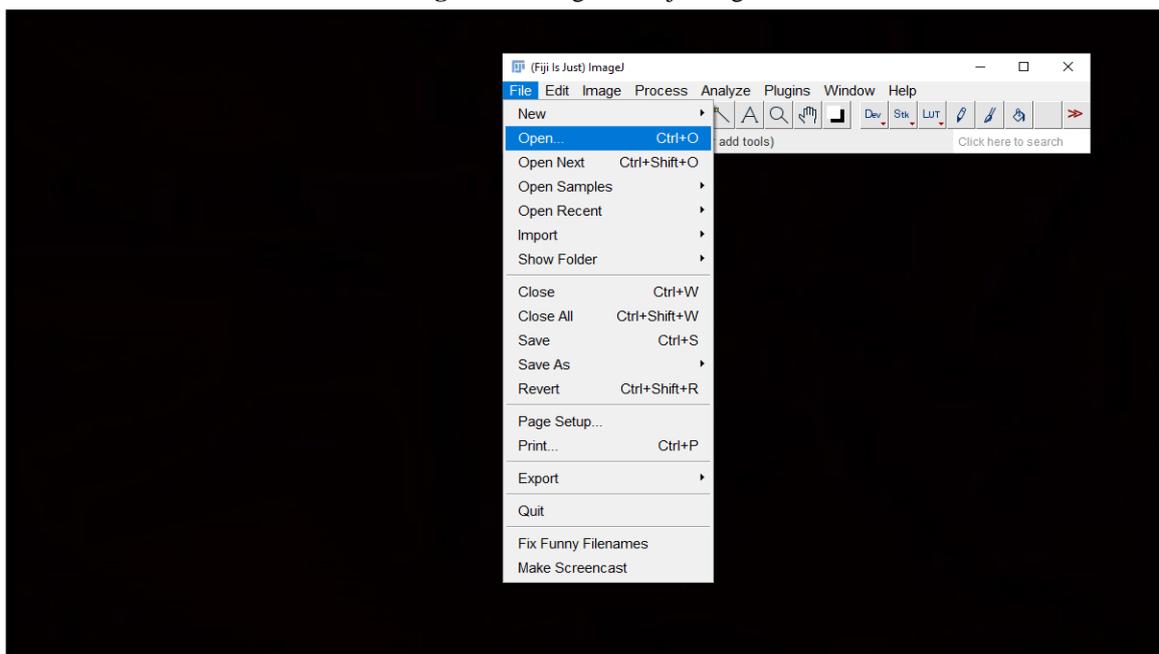
### 3.9 Análise termográfica auxiliada por técnicas de inteligência artificial

As imagens termográficas foram analisadas com o auxílio de algoritmos de inteligência artificial que utilizaram três tipos de atributos extraídos das imagens: Atributos radiômicos, semânticos e radiômico-semânticos associados. Os atributos radiômicos (atributos de textura) foram extraídos das imagens com técnicas clássicas de visão computacional. Os atributos semânticos foram as temperaturas das regiões dos músculos masseter (superior, médio e inferior) e temporal anterior, extraídas pelo avaliador, e dados de palpação, coletados de acordo com o RDC/TMD. Logo, foi criado um conjunto de dados adequados a cada tipo de atributo.

#### 3.9.1 Atributos radiômicos

A construção do vetor de atributos de cada imagem foi feita inicialmente com a segmentação. Para definição da ROI, foi adotada a segmentação manual utilizando o programa Fiji ImageJ (versão java 1.8.0; 64 bits), isolando separadamente as áreas dos músculos masseter e temporal anterior (Figura 14). Este método de segmentação é conhecido como padrão-ouro e sua aplicação justifica-se por conservar de forma precisa apenas a região relevante da face e descarta áreas com potencial de interferência na classificação, como regiões com pelos faciais, por exemplo.

**Figura 14.** Programa Fiji ImageJ



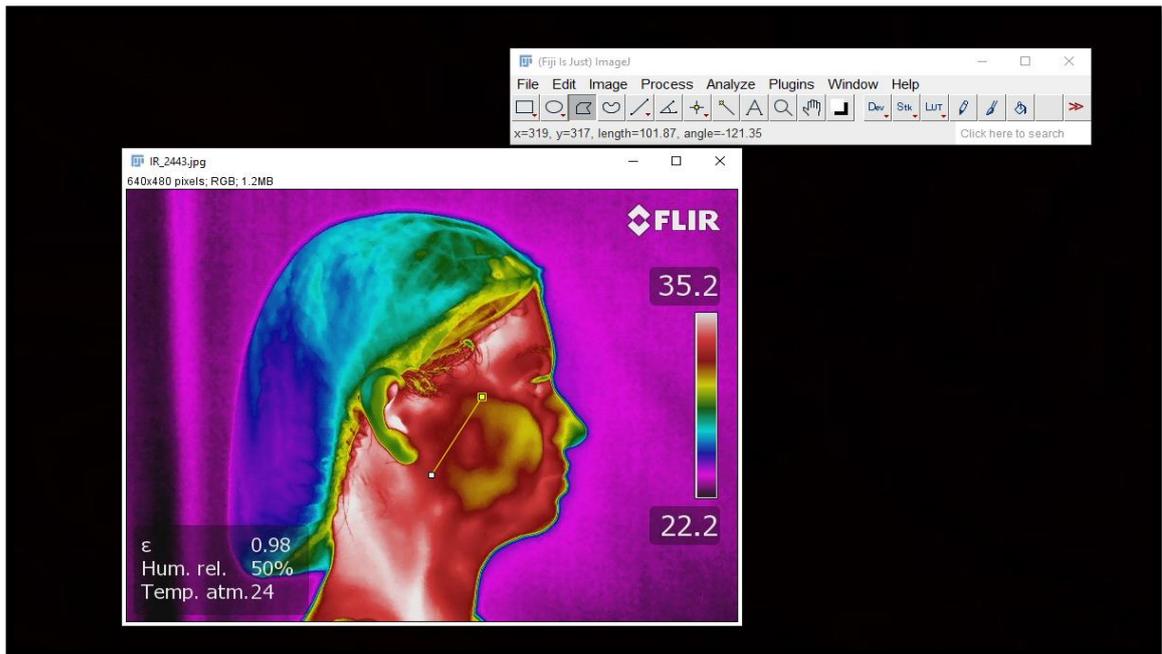
**Fonte:** Arquivo pessoal.

O músculo masseter tem formato retangular. É formado por duas partes: superficial e profunda. A parte superficial tem origem na margem inferior do osso zigomático e se estende até a sutura zigomático-temporal, e, a parte profunda tem origem na margem inferior e na face medial do arco zigomático, estendendo-se até a eminência articular. Insere-se nos dois terços inferiores da face lateral do ramo da mandíbula. Já o músculo temporal tem forma de leque e é coberto pela fáscia temporal. Suas fibras apresentam três sentidos: anterior, média e posterior. Parte de suas fibras tem origem no assoalho da fossa temporal e parte na superfície medial da fáscia temporal. A inserção encontra-se na face medial do processo coronóide, na crista temporal até as proximidades do trígono retromolar (DU PONT; BROWN, 2014).

A referência para definição das ROI do músculo masseter foram o arco zigomático (inserção proximal) e a face lateral do ângulo mandibular (inserção distal). O músculo temporal foi avaliado apenas em sua parte anterior sem pelos (HADDAD; BRIOSCH; ARITA, 2012).

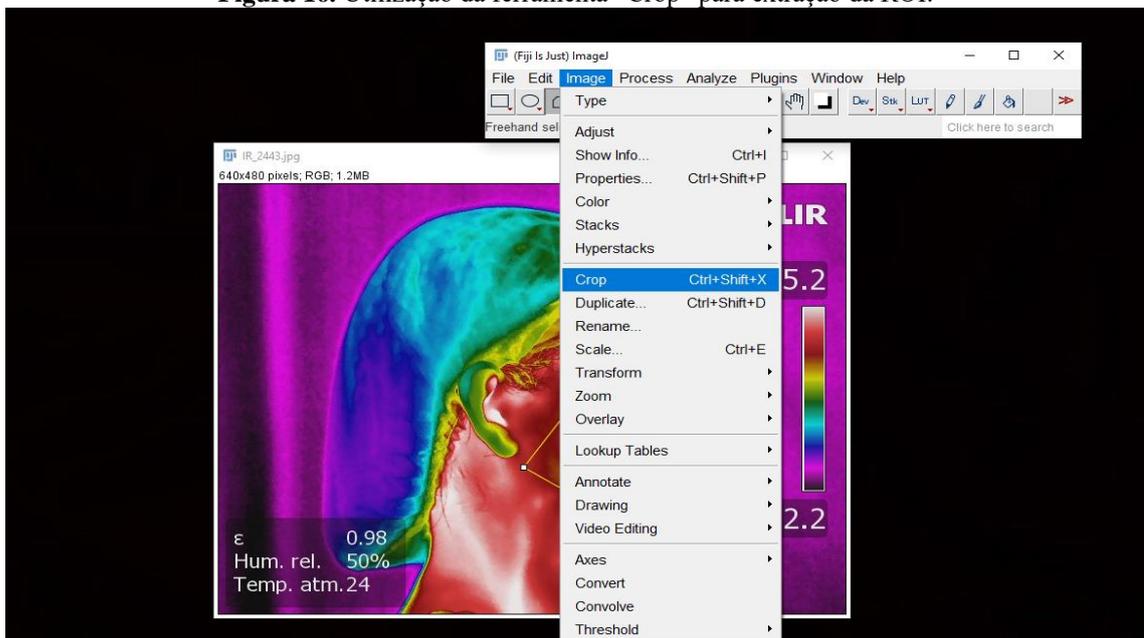
Logo, para realização deste método, foram utilizadas as imagens em norma lateral direita e esquerda, sendo 74 imagens para o grupo controle (Sem DTM) e 82 imagens para o grupo dos pacientes com DTM. Utilizando a ferramenta de seleção “polygon”, do programa Fiji ImageJ (versão java 1.8.0; 64 bits), as regiões correspondentes aos músculos masseter e temporal foram selecionadas (figura 15). No menu Editar e selecionando a ferramenta “Crop”, as ROI foram retiradas da imagem (figura 16). No menu Editar, ferramentas “selection” e “make inverse” e no menu Imagem, ferramenta “Clear”, o fundo da imagem foi removido, ficando apenas a região de interesse selecionada da imagem original em fundo preto (figura 17 e 18). As imagens foram salvas no padrão RGB e no formato JPEG, com tamanho variando de acordo a face do paciente.

**Figura 15.** Utilização da ferramenta “Polygon” para seleção das ROI.



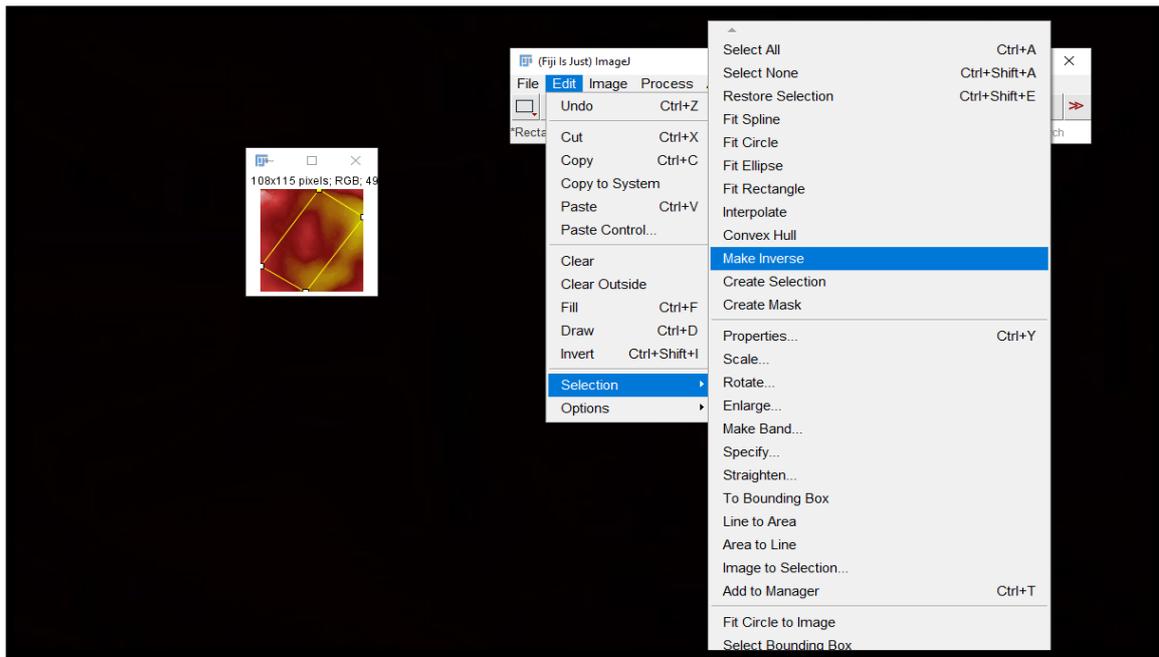
Fonte: Arquivo pessoal.

**Figura 16.** Utilização da ferramenta “Crop” para extração da ROI.



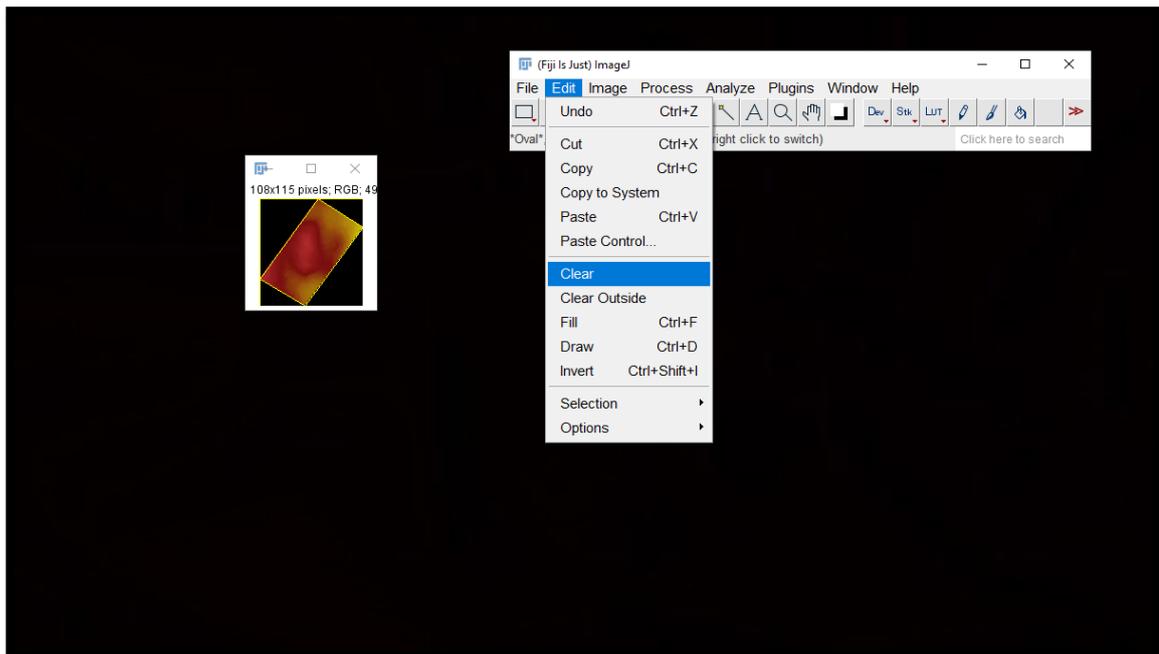
Fonte: Arquivo pessoal.

**Figura 17.** ROI extraída.



**Fonte:** Arquivo pessoal.

**Figura 18.** ROI extraída apresentando uma matriz de 108\*115 pixels e padrão RGB, sendo salva em formato JPEG.

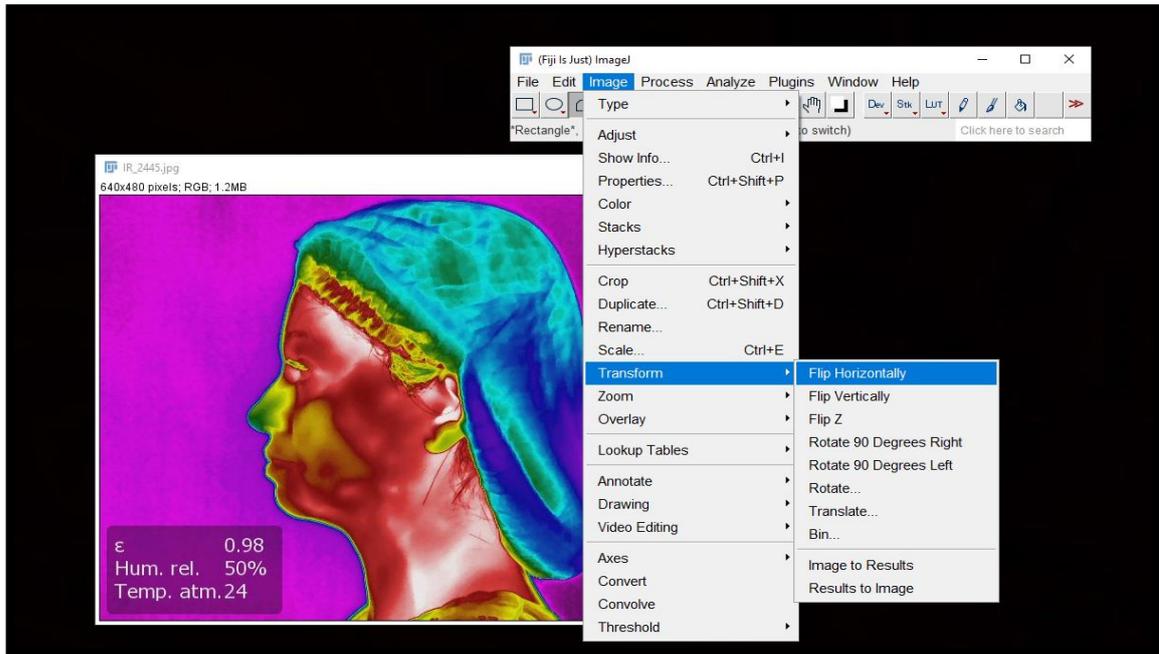


**Fonte:** Arquivo pessoal.

As regiões de interesse foram selecionadas inicialmente da imagem em norma lateral direita e para que pudessem ser utilizadas as imagens em norma lateral esquerda e ambas ficassem na mesma norma, utilizando o menu imagem, ferramentas “transform” e “flip

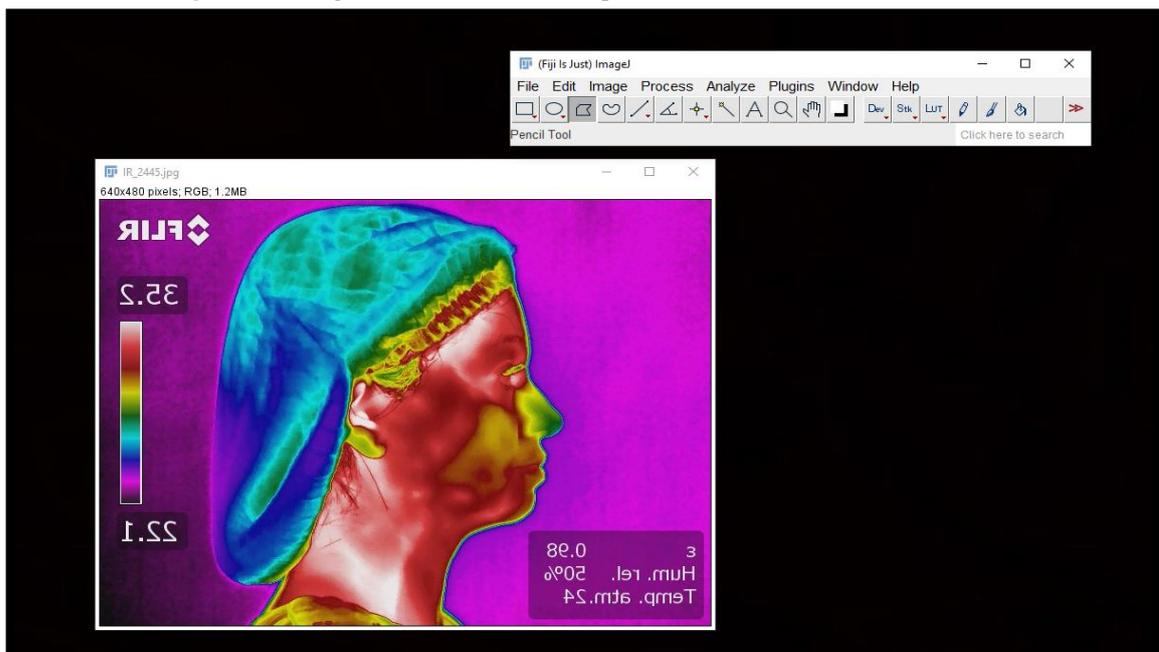
horizontally”, as imagens em norma lateral esquerda foram convertidas em norma lateral direita (Figuras 19 e 20).

**Figura 19.** Transformação da imagem em norma lateral esquerda em norma lateral direita.



Fonte: Arquivo pessoal.

**Figura 20.** Imagem em norma lateral esquerda transformada em lateral direita.



Fonte: Arquivo pessoal.

Para caracterizar o padrão das classes (diferenciar pacientes com DTM e sem DTM) foram extraídos atributos radiômicos (de textura) obtidos por meio de método estatístico em uma matriz de co-ocorrência na angulação padrão de 0°. Ao todo, foram extraídos vinte

atributos, dez por músculo: contraste, correlação, energia, homogeneidade, entropia, média aparada, curtose, assimetria, desvio padrão e variância. Sendo assim, foi criado um conjunto de dados com 156 amostras e cada uma apresentando 20 atributos.

### 3.9.2 Atributos semânticos

A construção dos vetores de atributos que contemplou as medidas de temperatura e escala de dor à palpação foi realizada no ato da aquisição da imagem de 78 pacientes, sendo 41 pacientes com DTM e 37 pacientes sem DTM. Os valores de temperatura foram mapeados por meio do software da câmera, medidos com o auxílio da ferramenta círculo. As regiões de interesse utilizadas correspondem ao masseter e temporal, sendo que a região do masseter foi dividida em três partes: superior, médio e inferior, totalizando quatro regiões.

Para cada região foi obtida, foi verificada a intensidade da dor à palpação, de acordo com o RDC/TMD, variando entre 0 e 3, sendo 0 a ausência de dor e 3 o seu nível mais intenso (dor severa). Por fim, este processo de extração gerou um conjunto de dados com 156 amostras em estrutura tabular, cada amostra com 8 atributos. Os atributos foram: temperatura masseter superior, dor masseter superior, temperatura masseter médio, dor masseter médio, temperatura masseter inferior, dor masseter inferior, temperatura temporal e dor temporal.

### 3.9.3 Associação de atributos semânticos e radiômicos

Além dos conjuntos de dados formados, de maneira isolada, para os atributos semânticos e radiômicos, foi criado um conjunto de dados através da associação entre os dois atributos. Logo, foi formado um conjunto de dados com 156 amostras e cada uma apresentou 28 atributos: temperatura masseter superior, dor masseter superior, temperatura masseter médio, dor masseter médio, temperatura masseter inferior, dor masseter inferior, temperatura temporal, dor temporal, contraste temporal e masseter, correlação temporal e masseter, energia temporal e masseter, homogeneidade temporal e masseter, entropia temporal e masseter, média aparada temporal e masseter, curtose temporal e masseter, assimetria temporal e masseter, desvio padrão temporal e masseter e variância temporal e masseter.

## 3.10 Processamento após a segmentação das imagens

Uma das etapas mais importantes na organização dos dados é a normalização dos valores dos atributos. Em geral, os algoritmos de aprendizagem de máquina não possuem um bom desempenho quando há uma diferença grande de escala entre os atributos de entrada. Deste modo, foi realizada a normalização, que consiste em realizar operações aritméticas para que o valor dos atributos esteja no intervalo entre 0 e 1.

Após normalização foi aplicada a redução de dimensionalidade, cujo objetivo foi diminuir a complexidade computacional e gerar novos atributos mais relevantes a partir dos atributos de entrada originais. Foi utilizado o método PCA (Análise por Componentes Principais) para redução da dimensionalidade e considerando uma variância de 95% para geração dos novos atributos.

Após aplicação do PCA o número de atributos do primeiro conjunto de dados (Atributos radiômicos - de textura) passou de vinte para oito, no segundo conjunto de dados (Atributos semânticos - atributos térmicos e escala subjetiva de dor) o valor foi reduzido de oito para quatro e no conjunto dos atributos associados, passou de vinte e oito para onze atributos. Na imagem abaixo (figura 21), é possível visualizar um exemplo de redução de dimensionalidade, onde um conjunto de dez atributos foi reduzido a um conjunto com quatro atributos.

**Figura 21.** Redução de dimensionalidade com PCA.



**Fonte:** Arquivo pessoal.

Ao imaginar estes conjuntos de dados em formato tabular, compreende-se que ao aplicar o PCA obteve-se um novo conjunto de dados com o mesmo número de amostras (linhas) que o conjunto original, mas com menos atributos (colunas). Com o conjunto de dados prontos, este foi particionado em dois subconjuntos, seguindo o método *hold-out*, nas proporções 70/30. O subconjunto com 70% foi destinado a etapa de treinamento e o outro, com 30%, para realização dos testes. Foi adotada a estratificação para esse particionamento, ou seja, foi garantida a proporcionalidade para ambas as classes saudável (sem DTM) e patologia (DTM).

Para os subconjuntos com 70% das amostras (de treinamento) foi empregada a validação cruzada, um método de reamostragem que consiste em utilizar várias combinações do mesmo conjunto de dados durante o treinamento. Esse método é extremamente útil para ampliar a capacidade de generalização de um modelo. Nesse estudo, foram definidas 10 iterações para a reamostragem da base de treinamento via validação cruzada.

### 3.11 Classificação

O planejamento dos modelos adotados para classificação tomou como base outras pesquisas aplicadas às imagens térmicas para a escolha dos classificadores, à exemplo de Paulino et al. 2019 e Gonçalves, 2020.

Em aprendizado supervisionado, o KNN e o SVM se destacam como dois dos classificadores mais utilizados na literatura, ambos consolidados e de fácil implementação. Além desses, também foram utilizadas as Redes neurais multicamadas.

A métrica adotada para avaliar os classificadores foi a acurácia, que corresponde ao nível de acertos de um modelo. Além da acurácia, outras métricas importantes também foram utilizadas: a precisão, que avaliou quais das amostras classificadas como corretas são efetivamente corretas; a sensibilidade, que avaliou quantas amostras, que deveriam ter sido classificadas em uma classe, foram realmente classificadas na mesma e a especificidade que diz respeito a capacidade de dizer que um indivíduo não pertence a uma classe, com ele não pertencendo à classe. A precisão está diretamente relacionada aos falsos positivos e a sensibilidade aos falsos negativos.

#### 3.11.1 Classificador KNN

O KNN teve o objetivo de determinar o rótulo de classificação de uma amostra baseado nas amostras vizinhas. O valor do *kerner* correspondeu a quantidade de vizinhos que o algoritmo teve que considerar para realizar a classificação. Para a construção desse modelo, foi utilizado o *kernel* = 5. Este valor foi definido após executar iterativamente a classificação variando o *k* (*kernel*) de 1 até 50 e comparar a acurácia do modelo no treinamento em cada valor de *k*.

#### 3.11.2 Classificador SVM

Ao utilizar o classificador SVM, as classes foram separadas por uma linha denominada fronteira de decisão e o espaço entre as classes deveria ser o maior possível. Quanto maior o espaço da fronteira de decisão melhor a classificação do modelo. Devido à não linearidade dos dados utilizados nessa pesquisa, foi utilizada uma função polinomial de grau 3 para definir a fronteira de decisão. Foram testados ainda polinômios de graus diferentes, mas não houve ganho na acurácia nessa abordagem.

### 3.11.3 Classificador MLP

Além do KNN e do SVM, foi criado também um classificador usando redes neurais multicamadas, através de um de seus tipos (MLP-Multilayer Perceptron), devido aos recentes avanços obtidos com técnicas desta natureza na última década. Nesse estudo, a primeira camada da MLP corresponde à camada de entrada (input), a segunda com 8 neurônios e a terceira e quarta com 6 neurônios, a quinta com 4 neurônios e a última é a camada de saída (output). Logo, para os atributos radiômicos, semânticos e radiômicos e semânticos associados, a MLP teve, respectivamente, 8, 4 e 11 neurônios na camada de entrada (input).

## 3.12 Análise estatística dos dados

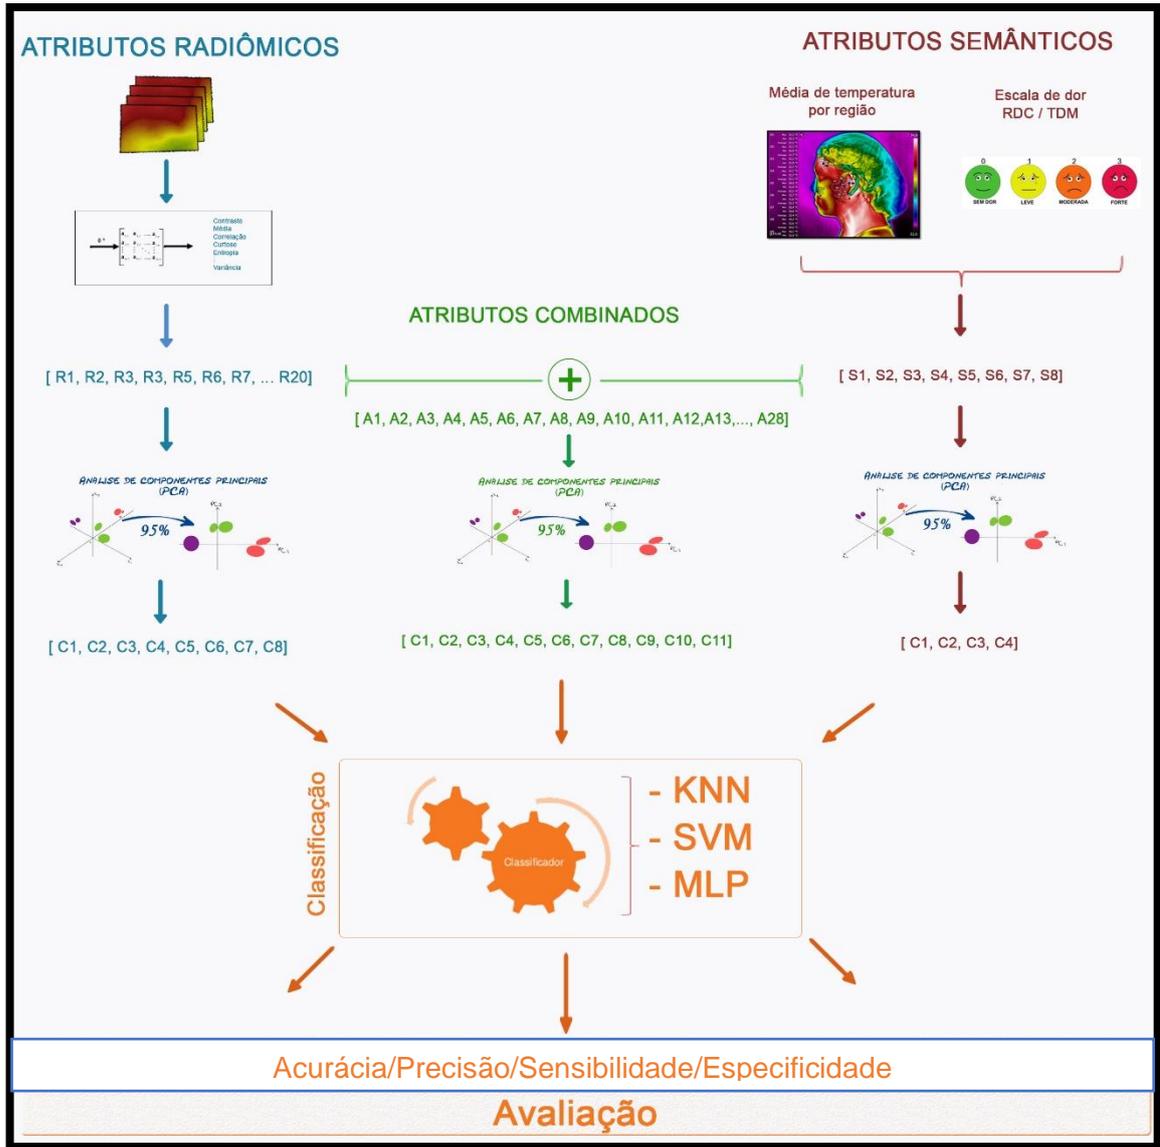
Primeiramente, foi verificado se havia tendência de agrupamento dos conjuntos de dados utilizados, essa tendência foi medida por meio do Teste da Estatística Hopkins. Neste teste, a hipótese nula foi a hipótese homogênea, em que o conjunto de dados foi distribuído uniformemente e não continha clusters (agrupamentos) significativos. Já a hipótese alternativa, ou seja, não homogênea, apontou que a distribuição não era uniforme e conseqüentemente havia ocorrência de clusters. O teste foi conduzido interativamente usando como limiar o valor de  $H = 0.5$  para rejeitar a hipótese alternativa. Ou seja, se o valor obtido estivesse próximo de 0.5 então seria improvável que de dados tivesse clusters estatisticamente significativos e quanto mais distante, maior seria a tendência de clusters.

A distribuição dos dados foi analisada utilizando o teste de Shapiro-Wilk e verificou-se distribuição normal dos dados ( $p > 0,05$ ). Os testes estatísticos ANOVA para medidas repetidas e pós teste de Tukey foram utilizados para avaliar entre quais grupos houve diferença estatisticamente significativa. Foi adotado o nível de significância de 5% ( $p < 0,05$ ).

O Software utilizado para as análises estatísticas foi o JAMOVI (versão 1.6, 2021, Sydney, Austrália).

4 FLUXOGRAMA

Figura 22. Descrição dos métodos de inteligência artificial utilizados.



Fonte: Arquivo pessoal.

## **5 RESULTADOS**

Os resultados desse estudo serão apresentados em formato de artigo que será submetido à revista Dentomaxillofacial Radiology que apresenta um fator de impacto de 2.419.

**6 ARTIGO**

***Artificial intelligence and infrared thermography as auxiliary tools in the diagnosis of temporomandibular disorder***

**Running Title:** TMD assessment with AI and infrared thermography

Elisa Diniz de Lima, DDS, MSD - Department of Oral Diagnosis, State University of Paraíba, Campina Grande, Brazil. Email: elisadinizdelima@gmail.com

José Alberto Souza Paulino, BSC, MS (health technology)- Computer Science Phd Student, Federal University of Campina Grande, Brazil. Email: souzapaulino@gmail.com

Diego F Bezerra Silva, DDS, MSD– Department of Oral Diagnosis, State University of Paraíba, Campina Grande, Brazil. Email: diegofilipeb@gmail.com

José Eraldo Viana Ferreira, DDS, MSD– Department of Oral Diagnosis, State University of Paraíba, Campina Grande, Brazil. Email: vianaeraldo43@gmail.com

Jussara S Barbosa, DDS, MSD– Department of Oral Diagnosis, State University of Paraíba, Campina Grande, Brazil. Email: barbosajsara@gmail.com

Ana Priscila Lira de Farias Freitas, DDS, MSD- Department of Oral Diagnosis, State University of Paraíba, Campina Grande, Brazil. Email: anapriscula\_f@hotmail.com

Patrícia Meira Bento, DDS, MSD, PhD – Department of Oral Diagnosis, State University of Paraíba, Campina Grande, Brazil. Email: patmeira@uol.com.br

Ana Marly Araújo Maia Amorim, DDS, MSD– Department of Oral Diagnosis, State University of Paraíba, Campina Grande, Brazil. Email: anamarlyamaia@gmail.com

Daniela Pita de Melo, DDS, MSD, PhD – Department of Oral Diagnosis, State University of Paraíba, Campina Grande, Brazil. Email: danipita@gmail.com

**Corresponding author:**

**Daniela Pita de Melo**

**Rua Baraúnas, 351, Bairro Universitário**

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

**e-mail: danipita@gmail.com**

**\*This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior–Brasil (CAPES) – Finance Code 001.**

## Abstract

**Aim:** To assess three machine learning (ML) attribute extraction methods: radiomic, semantic and radiomic-semantic association on temporomandibular disorder (TMD) detection using infrared thermography (IT); and to determine which ML classifier, KNN, SVM and MLP, is the most efficient for this purpose.

**Material and Methods:** 78 patients were selected by applying the Fonseca questionnaire for control patients (37) and RDC/TMD for TMD patients (41). IT lateral projections of each patient were acquired. The masseter and temporal muscles were selected as regions of interest (ROI) for attribute extraction. Three methods of extracting attributes were assessed: radiomic, semantic and radiomic-semantic association. For radiomic attribute extraction, twenty texture attributes were assessed using co-occurrence matrix in a standardized angulation of 0°. The assessed semantic features were the ROI mean temperature and pain intensity. For radiomic-semantic association a single dataset composed of twenty-eight features was assessed. The classification algorithms assessed were KNN, SVM and MLP. Hopkins's statistic, Shapiro-Wilk test, ANOVA and Tukey test were used to assess data. The significance level was set at 5% ( $p < 0.05$ ).

**Results:** Training and testing accuracy values differed statistically for the radiomic-semantic association ( $p = 0.003$ ). MLP differed from the other classifiers for the radiomic-semantic association ( $p = 0.004$ ). Accuracy, precision and sensitivity values of semantic and radiomic-semantic association differed statistically from radiomic features ( $p = 0.008$ ,  $p = 0.016$  and  $p = 0.013$ ).

**Conclusion:** Semantic and radiomic-semantic associated ML feature extraction methods and MLP classifier should be chosen for TMD detection using IT images and pain scale data. IT associated with AI presents promising results for TMD detection.

**Keywords:** Temporomandibular Joint Disorders; Thermography; Artificial Intelligence.

## INTRODUCTION

Temporomandibular disorders (TMD) are characterized by a set of musculoskeletal and neuromuscular disorders that affect the temporomandibular joint (TMJ).<sup>1,2</sup> Masticatory muscle disorders are the most prevalent subgroup of TMD and are characterized by trigger points affecting more than one muscle group and myofascial pain associated with muscle spasm and tenderness during palpation.<sup>3,4</sup>

TMD diagnosis is based on the clinical history and clinical examination;<sup>2</sup> and its detection and classification can be challenging. The Research Diagnostic Criteria for Temporomandibular Disorders (RDC/TMD) is a widely used diagnostic protocol,<sup>5,6</sup> which requires a certain amount of training and is time- and resource-consuming. A precise TMD diagnosis and effective treatment improves the quality of patients' lives significantly.<sup>4</sup>

Computed tomography (CT), cone beam computed tomography (CBCT) and magnetic resonance images (MRI) are often indicated as complementary image exams to assist TMD diagnosis.<sup>7</sup> However, these imaging modalities are more useful for evaluating cases of degenerative alterations and disc displacements, not providing information on local microcirculation, which is important in cases of masticatory muscle disorders.<sup>8</sup>

Infrared Thermography (IT) is a promising non-ionizing and non-invasive screening method for measuring skin temperature and temperature variation remotely.<sup>7,9</sup> Several studies have investigated the use of IT on TMD diagnosis<sup>7-8, 10-16</sup> presenting controversial results. The interpretation of IT exceedingly small temperature variations (0.1°C - 0.5°C) may be a reason for its divergent results. Therefore, this image modality may benefit from computational analytical tools.<sup>4,17-18</sup> Therefore, computer-aided interpretation of thermograms is of great relevance and may improve the information assessed by IT, since the link between the disease and heat pattern is subtle and usually non-linear.

Artificial intelligence (AI) is defined as the ability of a machine to emulate intelligent human behavior to execute complex tasks.<sup>19</sup> In general, computerized methods often employ data mining and machine learning (ML) algorithms, which are considered computer-aided diagnostic tools that assist doctors in making diagnostic decisions.<sup>20</sup> Therefore, a computer-aided approach has three benefits: reduced interobserver variability, AI may outperform humans on specific tasks, and the performance of these objective systems can be measured.<sup>21</sup>

The use of AI is progressing on dental practice based on semantic features (data from clinical exams and auxiliary tools) and radiomic features (image data).<sup>22</sup> Radiomic features are image hidden quantitative information which can be extracted with the aid of algorithms called

attribute extractors or feature extractors. Radiomic features represent patterns quantitatively in an image and can be classified into three types of descriptors: shape, texture, and frequency.<sup>23</sup> Radiomic features can be associated with semantic features (qualitative data) for a more robust characterization of a given pattern.

ML is one of the subfields of AI that allows a computer model to learn and predict by recognizing patterns.<sup>19</sup> ML classifiers are algorithm classification techniques widely used in machine learning. K-Nearest Neighbors (KNN) classification algorithm is one of the most used non-parametric classification methods to determine a sample's classification label based on neighboring samples; however, it is limited due to high memory consumption when using large datasets.<sup>24</sup> Support Vector Machine (SVM) is a computer algorithm that learns by pattern to assign labels to objects,<sup>25</sup> and needs long training time for large datasets.<sup>26</sup> Artificial neural networks (ANNs) are non-linear models inspired by the neural architecture of the brain and a typical ANN architecture is a multilayer perceptron (MLP) that contains a series of layers, composed of neurons and their connections.<sup>27</sup> When assessing ML classifiers, it is important to establish which one shows higher accuracy for the assessed diagnostic task, image modality and type of extracted data (radiomic or semantic).

Therefore, this study aimed to assess three ML attribute extractor methods: radiomic, semantic and the association of semantic and radiomic methods on TMD detection using IT; and to determine which ML classifier, KNN, SVM and MLP, is the most efficient for this purpose.

## **MATERIAL AND METHODS**

This cross-sectional observational study was approved by the University's Ethics and Research Committee (protocol n° 73417017.2.0000.5187) and follows the Helsinki Declaration.

### *Sample Selection*

IT exams were performed in 41 patients with temporomandibular disorders and 37 patients without temporomandibular disorders (control group), referred to the University's Orofacial Pain clinic. The control group was composed of volunteers who did not present TMD signs and symptoms, according to the Fonseca questionnaire. The selected patients should be 18 to 60 years old.

Patients with toothache, fever, systemic changes (hypoglycemia, hypothyroidism or

hyperthyroidism, hypertension, respiratory diseases, rheumatoid arthritis, fibromyalgia, pregnancy, rheumatological disorders, menopause, neurological disorders); cancer patients; patients under treatment with myorelaxant medication, analgesic and/or anti-inflammatory, or who underwent hormone replacement; and patients who had facial scars or papules were excluded from this study.

#### *Palpation and Pain Scale Assessment*

The diagnosis of TMD was performed using RDC/TMD (Axes I and II).<sup>28</sup> Palpation was performed and pain intensity data was collected according to the following characterization: 0 – without pain; 1- slight pain; 2- moderate pain; 3- severe pain, in accordance the RDC / TMD.

#### *IT acquisition*

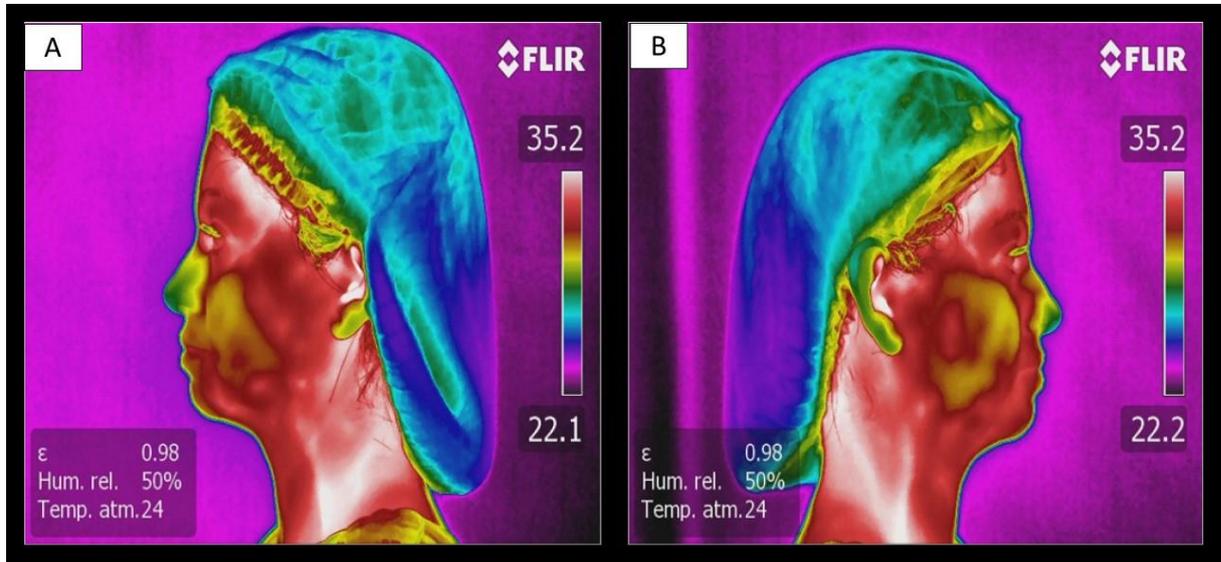
For the acquisition of IT exams, a handheld FLIR model T650 infrared sensor camera (FLIR Systems, Wilsonville, USA), with 25mm lens and 640x480 pixels spatial resolution, capable of capturing images with temperature variation between -40°C to 150°C and thermal sensitivity of 0.05°C to 30°C was used. The thermographic camera was attached to a tripod and switched on 20 min prior image acquisition.

All images were acquired in the University's Infrared Thermography Laboratory in a room with standardized temperature (22°C to 24°C) and no windows. Cold-cathode fluorescent lamps were used for ambient lighting and the walls where the patient's chair was positioned were covered with 25mm thick Expanded Polystyrene (EPS-Styrofoam) plates, aluminum foil and Ethylene-vinyl acetate (EVA) in black color.

The exams were performed in the lateral (right and left sides) norm (Figure 1) following the recommendations of the American Academy of Thermology.<sup>29</sup> All patients received written and oral instructions one day prior the IT exam (do not apply make-up or lotion to the face; do not use sources of heat such as hairdryers or hair straighteners; do not take analgesics, corticoids, anti-inflammatory drugs; do not carry out any kind of physical exercise; and do not touch, rub, or scratch the area of skin that is to be examined). The patients should wait 15 minutes in the examination room with an average temperature of  $23 \pm 1$  °C and relative humidity between 40 and 60% to achieve the recommended thermal balance.<sup>30</sup>

The patient was seated in a swivel-chair, maintaining an erect posture, with the sagittal plane perpendicular to the ground and camper plane parallel to the ground. A standardized

distance of 0.80 m between the camera and the patient was set for all image acquisitions. The emissivity of the skin was set at 98%.<sup>13-14, 16, 31-32</sup> To minimize the reflection of thermal radiation, only the patient and the operator should be present in the room during image acquisition.



**Figure 1.** A-Left side lateral norm thermogram; B-Right side lateral norm thermogram of the same patient.

156 thermographic images were acquired, which were stored in individualized folders and subsequently evaluated by an observer with the aid of the *FLIR Tools* v. 6.4 software (FLIR Systems, Wilsonville, USA). The thermographic images were used for both semantics and radiomics attribute extractions.

The regions of interest (ROI) were selected in the image region of the temporal and masseter muscles on the right and left lateral norms, with two points in the temporal region and 6 points in the masseter region. The “circle” tool (diameter  $22 \pm 3$  mm) was used to check the thermal gradient. Absolute averages of temperatures were obtained for each ROI. The average temperature values for each patient, muscle and ROI were tabulated in a spreadsheet for posterior analysis.

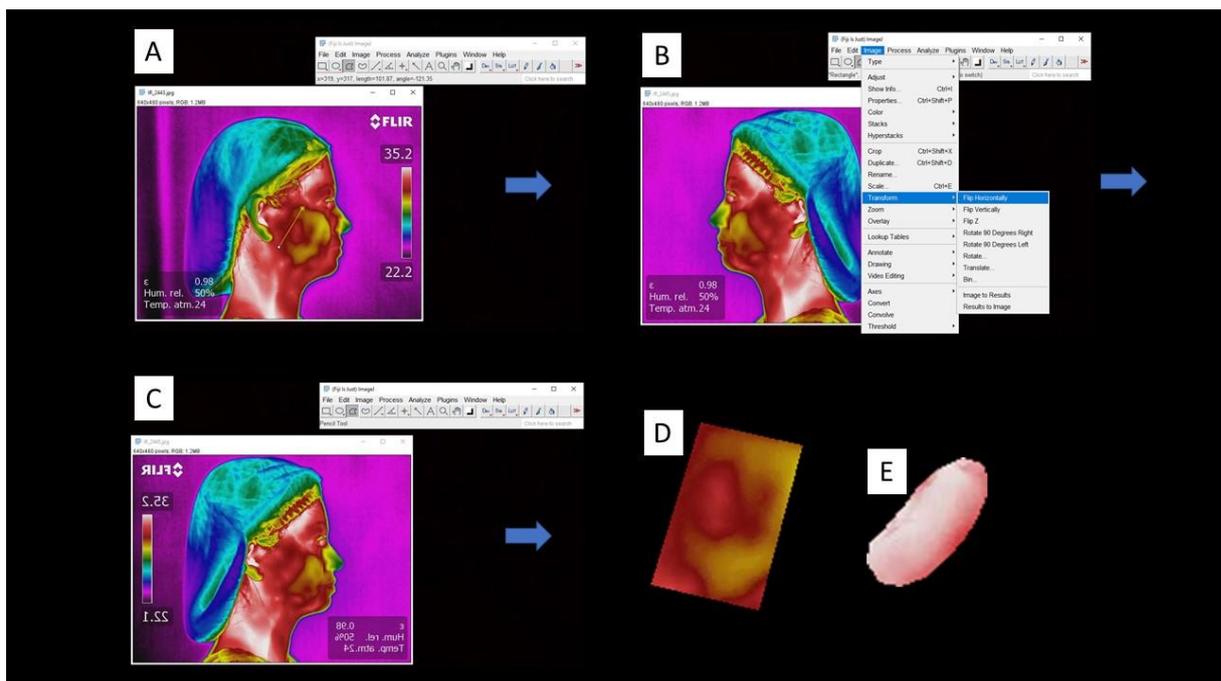
Thermographic images were also analyzed with the aid of AI using three ML methods of feature extraction. The first ML method was the extraction of radiomics features which are the characteristics extracted from an image through mathematical formulas that describe quantitatively various characteristics related to the image texture within ROI. The second ML method used was the extraction of semantic features which are qualitative characteristics that

are collected according to a subjective assessment done by a radiologist or a health professional.<sup>33-35</sup> The third method used was an association of radiomic and semantic features to create a single dataset.

To perform the technique of extracting image texture radiomic features, right and left lateral norm images were used (74 images for the control group and 82 images for the TMD group). With the aid of Fiji ImageJ software (64-bit Java 1.8.0\_172, National Institutes of Health, Bethesda, MD), the regions corresponding to the masseter and temporal muscles were selected using the “polygon” selection tool. By selecting the “crop” tool, the ROI was removed from the image. To remove the image background, “make-inverse” and “clear” tools were used. The lateral right and left norms were standardized to the right-side norm by using the tools “transform” e “flip horizontally”, to improve image assessment (Figure 2).

The semantic features were extracted from a set of tabulated data. A spreadsheet containing temperature data from the masseter and temporal regions obtained using FLIR Tools v. 6.4 software in addition to the categorized scale of pain on palpation data was used for this technique.

The third method used radiomics and semantics features extracted previously and transformed these features in a single dataset for further assessment.



**Figure 2.** A-Thermographic image assessed with Fiji ImageJ software using the “polygon” selection tool to select the ROI; B- Standardization of the lateral right and left norms to the right-side norm by using the tools “transform” e “flip horizontally”; C-left-side lateral norm transformed into right-side lateral form; D- ROI of the masseter muscle; E -ROI of the temporal muscle.

### *Radiomic features (texture attributes)*

The vector of attributes construction of each image was done initially with the segmentation of the ROI. For the definition of the ROI, manual segmentation was adopted, isolating the masseter and temporal areas separately, as previously described. This segmentation method application is justified by precisely selecting only the relevant region of the thermogram and discarding areas with potential for interference in the attribute classification, such as regions with facial hair.

To characterize the pathology (TMD) and healthy (control) patterns, twenty texture attributes were extracted from the co-occurrence matrices on a 0° standardized angulation. The attributes extracted from the temporal and masseter muscles were contrast, correlation, energy, homogeneity, entropy, trimmed means, kurtosis, asymmetry, standard deviation, variance. Therefore, a dataset of 156 samples was created and each sample had 20 attributes (ten attributes for each muscle assessed).

### *Semantic features (temperature and pain scale data attributes)*

The construction of the temperature and pain scale data attribute vectors started during image acquisition. The temperature values were mapped using the infrared camera software (FLIR Tools v. 6.4 software). The ROIs used to assess temperature values were the same described for radiomic features.

For each region, the corresponding pain intensity values were assessed in accordance with the RDC/TMD.<sup>28</sup> Finally, this extraction process generated a dataset with 156 samples in a tabular format, each sample with 8 attributes (masseter temperature at its superior region, pain data at the masseter's superior region, masseter temperature at its middle region, pain data at the masseter's middle region, masseter temperature at its inferior region, pain data at the masseter's inferior region, anterior temporal temperature, and pain at the anterior temporal).

### *Association of radiomic and semantic attributes*

To verify if the association of radiomic and semantic attributes could improve TMD detection, a dataset was created associating both ML methods. For each one of the 156 samples, 28 attributes were extracted. The attributes extracted from the temporal and masseter muscles were contrast, correlation, energy, homogeneity, entropy, trimmed mean, kurtosis, asymmetry, standard deviation, variance, temperature (superior, middle, and inferior masseter and temporal muscles), pain (superior, middle, and inferior masseter and temporal muscles).

### *Data processing*

The Principal Component Analysis (PCA) method was used to reduce the dimensionality and a 95% variance was considered to generate the new features; therefore, generic features were generated statistically based on the existing features. After applying PCA, the number radiomic features was reduced from 20 to 8, the semantic features were reduced from 8 to 4 and the radiomic-semantic association features were reduced from 28 to 11.

Considering these datasets in a tabular format, it is understood that when applying the PCA a new set with the same number of samples (rows) as the original set will be obtained, however with fewer attributes (columns). The datasets are then partitioned into two subsets, following the holdout method, in 70/30 proportions. The subset with 70% was destined to the training stage and the 30% subset was used to carry out the tests. It is important to highlight that the stratification adopted for this partitioning is proportionality guaranteed for both classes (healthy and pathology).

For subsets with 70% of the samples (training), cross-validation was used, which is a method that consists of using various combinations of the same dataset during training. This method is extremely useful to increase the generalizability of a model. In this research, 10 iterations were defined for resampling the training base via cross-validation.

### *Classification algorithms (classifiers)*

Kernel nearest neighbor (KNN), Support Vector Machine (SVM) and Multilayer Perceptron (MLP) classifiers were implemented and compared.

The metric adopted to evaluate the classification algorithms was the accuracy, which corresponds to the level of correctness of a model. In addition to accuracy, precision, sensitivity, and specificity were assessed.

#### *KNN Classifier*

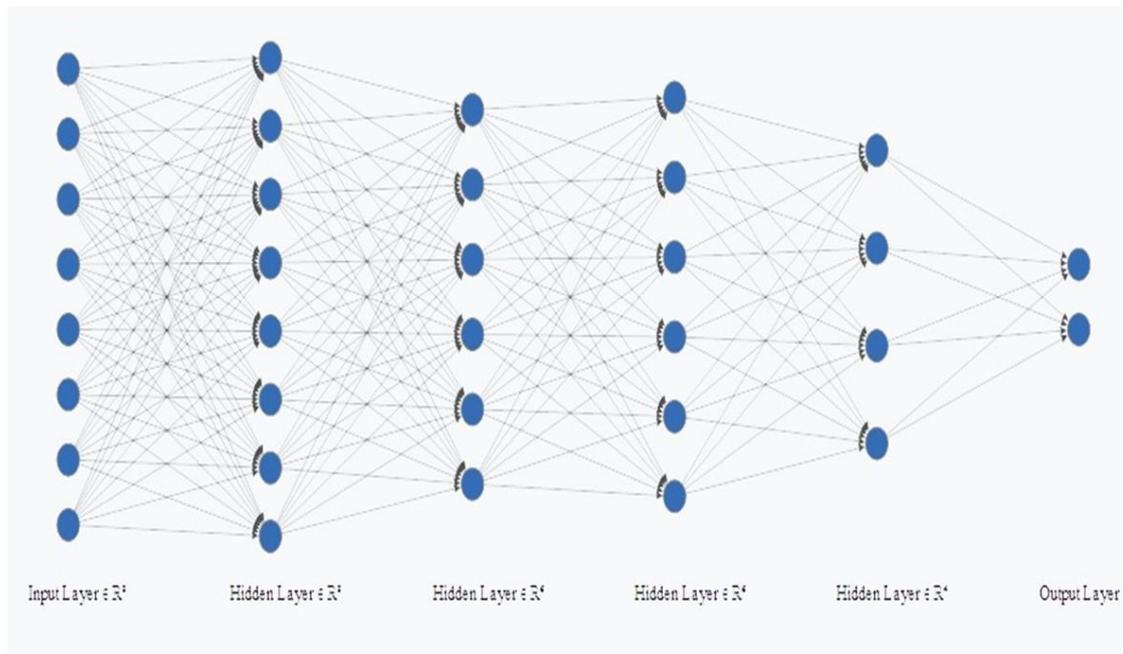
The KNN aims to determine a sample's classification label based on neighboring samples. The Kerner value corresponds to the number of neighbors that the algorithm must consider performing the classification. For the construction of this model, kernel value 5 was used. This value was defined after an iterative execution of the classification varying the k (kernel) from 1 to 50 and comparing the accuracy of the model training in each k value.

#### *SVM Classifier*

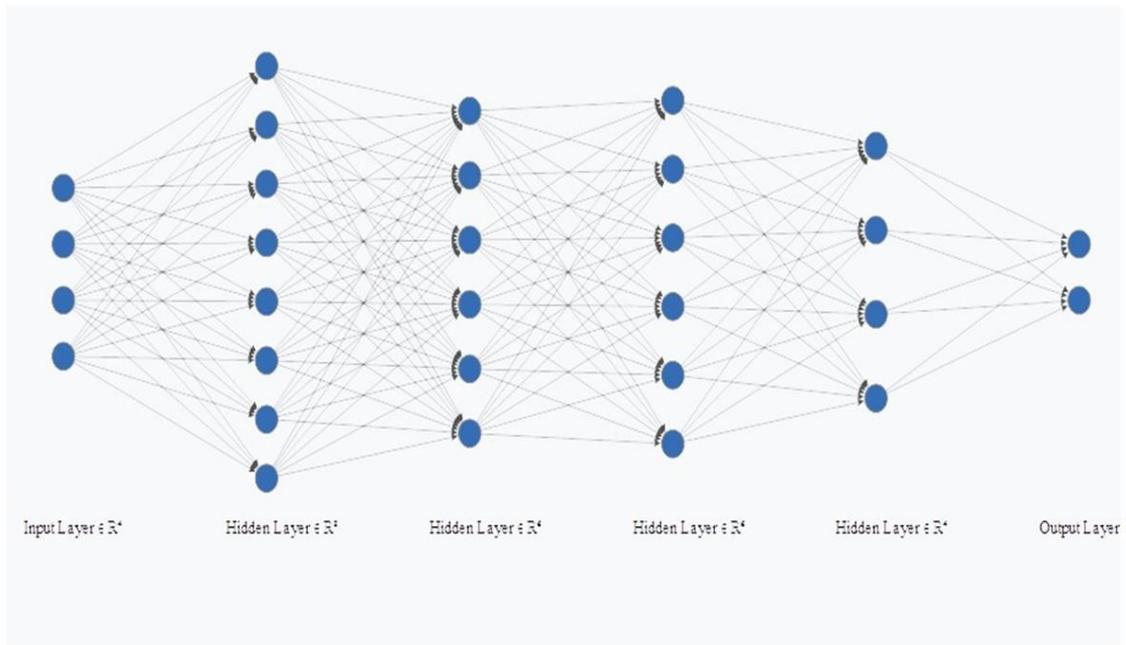
In the SVM technique, classes are separated by a line named the decision boundary and the space between classes which must be as large as possible. The greater the space of the decision boundary, the better the classification of the model. Due to the non-linearity of the data used in this research, a degree 3 polynomial function was used to define the decision boundary. Polynomials of different degrees were also tested, but there was no gain in accuracy using this approach.

### *Multilayer Perceptron (MLP)*

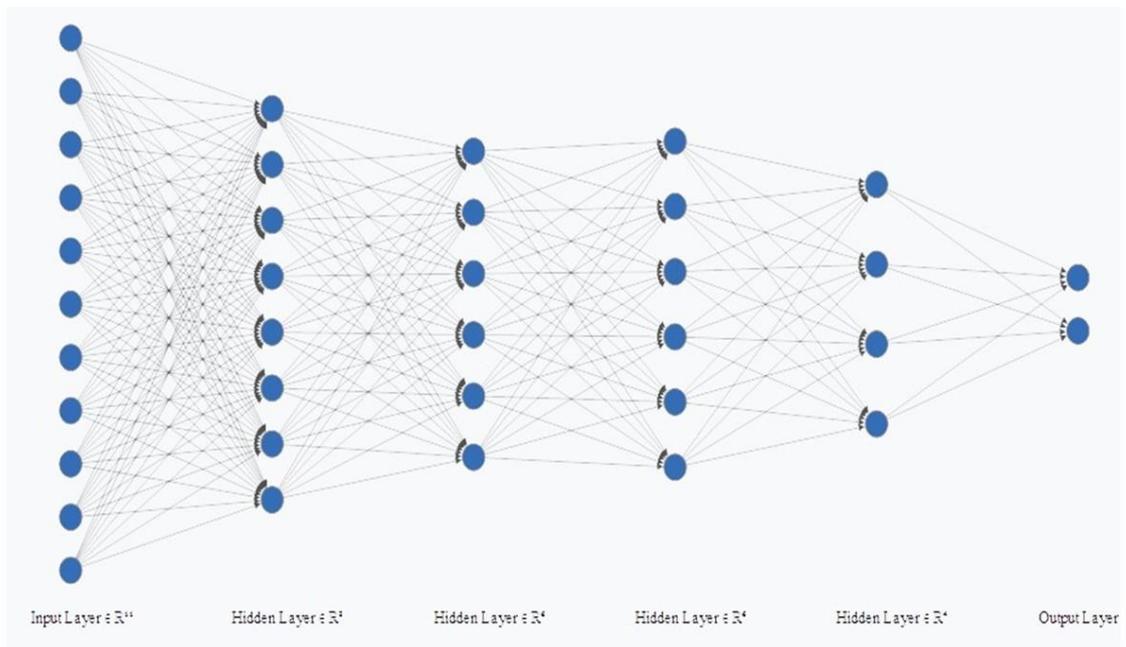
In addition to KNN and SVM, a classifier was also created using MLP. The first layer corresponded to the input layer, the second layer has 8 neurons and the third and fourth have 6, the fifth has 4 neurons and the last layer corresponded to the output. Therefore, for the radiomic, semantic and the radiomic-semantic association features, the MLP had 8,4, 11 neurons in the input layer, respectively (Figures 3,4,5). The input layer corresponds to the number of features after principal components analyses (PCA).



**Figure 3.** Multilayer Perceptron (MLP) for radiomic features.



**Figure 4.** Multilayer Perceptron (MLP) for semantic features.



**Figure 5.** Multilayer Perceptron (MLP) for associated radiomics and semantics features.

### *Data analysis*

To prove the clustering tendency of the datasets, Hopkins's statistic was used. This statistical test has the threshold of 0.5 ( $H=0.5$ ) as reference, and the result statistical data will be a value between 0 and 1. The closer the H value is to 0, the greater the clustering tendency

of the dataset, and the closer the H value is to the threshold, the greater the randomness of the data distribution (lower tendency of clustering).

Data analysis was done using the Jamovi software (version 1.6, 2021, Sydney, Australia). The Shapiro–Wilk test was used to assess data distribution, which was found to be normal for all groups ( $p>0.05$ ). For each tested ML method and classifier accuracy, precision (positive predictive value), sensitivity (true positive rate) and specificity (true negative rate) were calculated. ANOVA for repeated measures and Tukey test were used to compare the studied variables.

## RESULTS

The H value obtained in this study for the radiomic, semantic and radiomic-semantic features were 0.19, 0.21 and 0.16, respectively. Therefore, there is a cluster tendency for the studied datasets.

Table 1 shows the accuracy values of the classifiers for the training and testing assessments for each studied feature extraction method. The training and testing accuracy only differed statistically for the radiomic semantic associated features ( $p=0.003$ ). MLP presented the best accuracy values and differed from SVM and KNN for the radiomic-semantic associated features ( $p=0.004$ ). Although SVM presented the best accuracy values for radiomic and semantics features assessed separately, it did not differ from KNN and MLP (Table 1).

**Table 1.** Accuracy values of the ML classifiers for the training and testing datasets and the studied feature extraction methods.

ACCURACY	RADIOMIC FEATURES			p-value	SEMANTICS FEATURES			p-value	ASSOCIATED FEATURES			p-value
	KNN <sup>A</sup>	SVM <sup>A</sup>	MLP <sup>A</sup>		Intra	KNN <sup>A</sup>	SVM <sup>A</sup>		MLP <sup>A</sup>	Intra	KNN <sup>A</sup>	
				0.695				0.499				0.004
<b>TRAINING</b>	71.54% <sup>a</sup>	79.52% <sup>a</sup>	90.90% <sup>a</sup>	<b>Inter</b>	89.90% <sup>a</sup>	89.91% <sup>a</sup>	91.95% <sup>a</sup>	<b>Inter</b>	89% <sup>a</sup>	93.63% <sup>a</sup>	98.68% <sup>a</sup>	<b>Inter</b>
<b>TESTING</b>	68.08% <sup>a</sup>	76.59% <sup>a</sup>	63.82% <sup>a</sup>	0.296	87.23% <sup>a</sup>	95.74% <sup>a</sup>	91.48% <sup>a</sup>	0.758	82.97% <sup>b</sup>	87.23% <sup>b</sup>	91.49% <sup>b</sup>	0.003

\*\* Different letters indicate statistically significant differences between groups.

\*\* ANOVA test for repeated measures and post Tukey test.

\*\*\* Intra corresponds to KNN, SVM and MLP.

\*\*\*\* Inter corresponds to training and testing.

When assessing and comparing the testing accuracy, precision and sensitivity values of each feature extraction method, semantic features and radiomic-semantic features associated

differed statistically from radiomic features ( $p=0.008$ ,  $p=0.016$  and  $p=0.013$ ). The semantic features presented the best specificity values, followed by radiomic–semantic associated features and the semantic features attribute extractors differed statistically from radiomic features ( $p=0.045$ ) (Table 2).

**Table 2.** Testing dataset accuracy, precision, sensitivity, and specificity values for the studied feature extraction methods for each assessed classifier.

		KNN	SVM	MLP	MEAN	SD	p-value
ACCURACY	RADIOMICS <sup>A</sup>	68.08%	76.59%	63.82	69.50%	6.5	0.008
	SEMANTICS <sup>B</sup>	87.23%	95.74%	91.48%	91.15%	4.26	
	ASSOCIATED <sup>B</sup>	82.97%	87.23%	91.49%	87.20%	4.26	
PRECISION	RADIOMIC <sup>A</sup>	70.08%	79.16%	66.66%	72%	6.46	0.016
	SEMANTIC <sup>B</sup>	82.75%	96%	88.88%	89.20%	6.63	
	ASSOCIATED <sup>B</sup>	84%	85.18%	86.20%	85.10%	1.10	
SENSITIVITY	RADIOMIC <sup>A</sup>	68%	76%	64%	69.30%	6.11	0.013
	SEMANTIC <sup>B</sup>	96%	96%	96%	96%	0	
	ASSOCIATED <sup>B</sup>	84%	92%	100%	92%	8	
SPECIFICITY	RADIOMIC <sup>A</sup>	68.18%	77.27%	63.63%	69.70%	6.94	0.045
	SEMANTIC <sup>B</sup>	77.27%	95.45%	86.36%	86.40%	9.09	
	ASSOCIATED <sup>AB</sup>	81.81%	81.81%	81.81%	81.81%	0	

\* Different letters indicate statistically significant differences between groups.

\*\* ANOVA test for repeated measures and post Tukey test.

## DISCUSSION

IT is a non-invasive and rapid screening method that reveals the dynamics of microcirculation on the skin surface in real time, detecting the extent of functional, nervous, and vascular changes caused by inflammatory processes, endocrine disorders, or oncological conditions.<sup>7</sup> This diagnostic method has been assessed previously in dentistry in studies on oral candidiasis,<sup>36</sup> caries,<sup>37</sup> lip herpes<sup>38</sup> and endodontic tasks.<sup>39</sup>

Muscles need oxygen provided by the blood flow to perform their contraction and relaxation movements. The blood flow can also affect the skin temperature which is regulated by the autonomic nervous system.<sup>3</sup> In cases of masticatory muscles disorders, the blood flow can be altered and directly affect the muscles thermal patterns;<sup>40</sup> therefore, IT would be indicated to assess muscles thermal alterations. IT diagnostic usefulness in identifying patients with TMD presents limited effectiveness;<sup>32</sup> however, the literature is still scarce regarding the reliability of IT in the diagnosis of TMD.<sup>7</sup>

Regarding the use of AI in the medical field, studies on the detection of breast cancer,<sup>41</sup> respiratory frequency,<sup>42</sup> cellulite stages<sup>4</sup>,<sup>43</sup> differentiation of potentially malignant lesions and lower lip cancer,<sup>44</sup> facial analysis<sup>45</sup> and thermographic findings related to orofacial pain have shown promising results.<sup>46</sup> Recently, at the 8th European Medical and Biological Engineering Conference, a conference paper sought to investigate the ability of infrared thermal image on TMD detection, using AI, and found promising AUC values (0.71), thus suggesting that infrared thermal imaging can be a relatively inexpensive and simple to use tool for assessing TMD<sup>47</sup>. Therefore, the use AI may improve IT diagnostic efficiency increasing productivity and diagnostic accuracy, aiding the subjective interpretation of the clinician.

According to Hung (2020),<sup>19</sup> reports on AI techniques in the dentomaxillofacial radiology field focus on four main applications including automatic localization of cephalometric landmarks, diagnosis of osteoporosis, classification/segmentation of the maxillofacial cysts and/or tumors, and identification of periodontitis/periapical disease. Previous studies have used AI in TMD diagnosis using CBCT scans and have shown satisfactory results.<sup>20, 48-50</sup> A recently published study used AI through the extraction of radiomic features (texture attributes) to assess thermographic findings related to TMD symptoms of 19 TMD patients and 21 control patients, using the texture attribute homogeneity.<sup>46</sup> The authors stated that there is a potential for texture attribute analysis assessing IT on TMD diagnosis, as TMD pain affects all masticatory system, and can affect thermal changes in muscles unevenly.

Automatic segmentation tools are paramount for the creation of diagnostic task specific software and apps so AI can be used as an auxiliary tool in the dental clinic routine. IT automatic segmentation is difficult because heat distribution is not delimited by anatomical structures, segmentation errors due to similar temperatures between the environment and object of study can occur and different shapes and sizes of the object of interest may difficult the machine learning process<sup>51</sup>. Therefore, a large dataset must be used with the purpose of obtaining high accuracy automatic segmentation of IT images. Several semi-automatic methods have been proposed for segmentation, however, this process often depends on hand-crafted image features and preprocessing operations.<sup>52</sup> Previous studies using IT have attempted automatic segmentation using active shape approach, a thermal and a color image synchronously. Studies with large sample sizes are needed to establish the best IT automatic segmentation method.

The total number of published predictive modeling studies using radiomic features has been rapidly rising, a consensus on which features are repeatable and reproducible has not yet emerged.<sup>53</sup> Radiomic features characteristics have values in a continuous scale which can

provide details distinguishing for example odontogenic tumors.<sup>33, 54</sup> Technically, the images are transformed into dimensional data to search for correlations that can define a radiographic phenotype useful before, during or after treatment.<sup>54-55</sup> Entropy has been consistently reported as one of the most stable radiomic features; however, contrast appears among the least reproducible radiomic features.<sup>53</sup> In this study, 10 texture attributes (contrast, correlation, energy, homogeneity, entropy, trimmed means, kurtosis, asymmetry, standard deviation, variance) were assessed, in order to extract as much quantitative texture attributes as possible to improve TMD diagnostic efficiency. A previous study<sup>46</sup> assessing TMD pain using IT and AI in a smaller study sample used only one radiomic feature, homogeneity, obtaining lower accuracy values than this study.

Additionally, three classification algorithms were used in this study (KNN, SVM and MLP) to assess ML feature extraction accuracy. KNN and SVM classifiers are easy to implement and widespread in the field of ML.<sup>44</sup> SVM is less computationally demanding than KNN and is easier to interpret but can identify only a limited set of patterns.<sup>56</sup> SVM presented satisfying accuracy values for all assessed ML feature extraction methods and performed better than the other studied classifiers for semantic features.

ANN are non-linear models inspired by the brain's neural architecture and were developed aiming to model the learning capacity of biological neural systems. Multilayer perceptron (MLP) is a typical artificial networks architecture containing a series of layers, composed of artificial neurons and their connections, which can calculate the weighted sum of its inputs and then apply an activation function to obtain a signal that will be transmitted to the next neuron. A MLP must have a good architecture with the necessary connections to solve the problem in question and training with the right amount of data, which can be time-consuming for large datasets.<sup>27</sup> Convolutional Neuro Networks (CNN) are a class of artificial neural networks that has increased in the radiology field with promising results; however, this class of ANN needs larger image samples than the one used in this study. Although this study sample was larger than previous studies, the limited sample size is a limitation and studies with larger samples sizes and using CNN are needed.

Our study has a certain degree of novelty and a methodology with potential to be used in future studies. Furthermore, more studies assessing the use of AI as an auxiliary tool of image exams (IT, CBCT, MRI) on TMD detection are needed to create a software to be used in dental clinics and radiology centers.

## **CONCLUSION**

Semantic and radiomic-semantic associated ML feature extraction methods perform better than radiomic features for TMD detection. The radiomic-semantic attribute extraction method associated with the MLP classifier should be chosen for TMD detection using IT images and pain scale data. IT associated with AI presents promising results for TMD detection.

## REFERENCES

1. Conville RM, Moriarty F, Atkins S. The management of temporomandibular disorders: A headache in general practice. *Br J Gen Pract.* [internet]. 2019; 69(687): 523–4. Available from: <https://pubmed.ncbi.nlm.nih.gov/31558543/>. doi: 0.3399/bjgp19X705977.
2. Gauer RL, Semidey MJ. Diagnosis and treatment of temporomandibular disorders. *Am Fam Physician.* [internet]. 2015; 91(6): 378–86. Available from: <https://pubmed.ncbi.nlm.nih.gov/25822556/>.
3. Altindis T, Gungormus M. Thermographic evaluation of occlusal splint and low level laser therapy in myofascial pain syndrome. *Complement Ther Med.* [internet]. 2019; 44(1): 277–81. Available from: <https://pubmed.ncbi.nlm.nih.gov/31126567/>. doi: 10.1016/j.ctim.2019.05.006.
4. Machoy M, Szyszka-Sommerfeld L, Rahnema M, Koprowski R, Wilczyński S, Woźniak K. Diagnosis of Temporomandibular Disorders Using Thermovision Imaging. *Pain Res Manag.* [internet]. 2020; 2020(1): 8-1. Available from: <https://pubmed.ncbi.nlm.nih.gov/31126567/>. doi: 10.1016/j.ctim.2019.05.006.
5. Brochado FT, Jesus LH, Carrard VC, Freddo AL, Chaves KD, Martins MD. Comparative effectiveness of photobiomodulation and manual therapy alone or combined in TMD patients: a randomized clinical trial. *Braz Oral Res.* [internet]. 2018; 32e50(1) 12-1. Available from: <https://www.scielo.br/j/bor/a/SBJRkrpYnCTmzZhnRTprssd/?lang=en&format=html>. doi: <https://doi.org/10.1590/1807-3107bor-2018.vol32.0050>.
6. de Paiva Bertoli FM, Bruzamolín CD, de Almeida Kranz GO, Losso EM, Brancher JA, de Souza JF. Anxiety and malocclusion are associated with temporomandibular disorders in adolescents diagnosed by RDC/TMD. A cross-sectional study. *J Oral Rehabil.* [internet]. 2018; 45(10): 755-747. Available from: <https://pubmed.ncbi.nlm.nih.gov/29972708/>. doi: doi: 10.1111/joor.12684.
7. de Melo DP, Bento PM, Peixoto LR, Martins SKLD, Martins CC. Is infrared thermography effective in the diagnosis of temporomandibular disorders? A systematic review. *Oral Surg Oral Med Oral Pathol Oral Radiol.* [internet]. 2019; 127(2): 185–92. Available from: <https://pubmed.ncbi.nlm.nih.gov/30482738/>. doi: 0.1016/j.oooo.2018.09.006.
8. Haddad DS, Brioschi ML, Vardasca R, Weber M, Crosato EM, Arita ES. Thermographic characterization of masticatory muscle regions in volunteers with and without myogenous temporomandibular disorder: Preliminary results. *Dentomaxillofacial Radiol.* [internet]. 2014

[cited 2020 nov 17]; 43(8): 2-7. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4240258/>. doi: 10.1259 / dmfr.20130440.

9. Lahiri BB, Bagavathiappan S, Jayakumar T, Philip J. Infrared Physics & Technology Medical applications of infrared thermography: A review. *Infrared Phys Technol.* [internet]. 2012; 55(4): 221–35. Available from: <https://pubmed.ncbi.nlm.nih.gov/32288544/>. doi: 10.1016/j.infrared.2012.03.007.

10. Biagioni PA, Longmore RB, McGimpsey JG, Lamey PJ. Infrared thermography. Its role in dental research with particular reference to craniomandibular disorders. *Dentomaxillofac Radiol.* [internet]. 1996 [cited 2020 Nov 17]; 25(3): 119-24. Available from: <https://pubmed.ncbi.nlm.nih.gov/9084259/>. doi: 10.1259/dmfr.25.3.9084259.

11. Haddad DS, Brioschi ML, Arita ES. Thermographic and clinical correlation of myofascial trigger points in the masticatory muscles. *Dentomaxillofacial Radiol.* [internet]. 2012 [cited 2021 Jun 16]; 41(8): 621–9. Available from: <https://pubmed.ncbi.nlm.nih.gov/23166359/>. doi: 10.1259/dmfr/98504520.

12. Dibai-Filho AV, De Souza Costa AC, Packer AC, Rodrigues-Bigaton D. Correlation between skin surface temperature over masticatory muscles and pain intensity in women with myogenous temporomandibular disorder. *J Back Musculoskelet Rehabil.* [internet]. 2013 [cited May 2020]; 26(3): 323–8. Available from: <https://pubmed.ncbi.nlm.nih.gov/23893148/>. doi: 10.3233/BMR-130387.

13. Rodrigues-Bigaton D, Dibai-Filho AV, Packer AC, Costa AC de S, de Castro EM. Accuracy of two forms of infrared image analysis of the masticatory muscles in the diagnosis of myogenous temporomandibular disorder. *J Bodyw Mov Ther.* [internet]. 2014 [cited 2020 Nov 17]; 18(1): 49–55. Available from: <https://pubmed.ncbi.nlm.nih.gov/24411149/>. doi: 10.1016/j.jbmt.2013.05.005.

14. Dibai-Filho AV, Packer AC, de Souza Costa AC, Rodrigues-Bigaton D. The chronicity of myogenous temporomandibular disorder changes the skin temperature over the anterior temporalis muscle. *J Bodyw Mov Ther.* [internet]. 2014 [cited 2020 May 1]; 18(3): 430–4. Available from: <https://pubmed.ncbi.nlm.nih.gov/25042314/>. doi: 10.1016/j.jbmt.2013.11.001.

15. Dibai-Filho AV, Costa AC de S, Packer AC, de Castro EM, Rodrigues-Bigaton D. Women with more severe degrees of temporomandibular disorder exhibit an increase in temperature over the temporomandibular joint. *Saudi Dent J.* [internet]. 2015; 27(1): 44–9. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4273257/>. doi: 10.1016/j.sdentj.2014.10.002.

16. Barbosa JS, Amorim AMAM, Arruda MJALLA, Medeiros GBS, Freitas APLF, Vieira LEM, et al. Infrared thermography assessment of patients with temporomandibular disorders. *Dentomaxillofacial Radiol.* [internet]. 2020 [cited 2020 Nov 17]; 49(4): 8-2. Available: <https://pubmed.ncbi.nlm.nih.gov/31794257/>. doi: 10.1259/dmfr.20190392.

17. Kawano W, Kawazoe T, Tanaka M, Hikida Y. Deep thermometry of temporomandibular joint and masticatory muscle regions. *J Prosthet Dent.* [internet]. 1993; 69(2): 216–21. Available from: <https://pubmed.ncbi.nlm.nih.gov/8429516/>. doi: 10.1016/0022-

3913(93)90143-c.

18. Rahmayani L, Yahya M, Soraya C, Syahreza S. Thermal Condition of Muscle Area Around the Temporomandibular Joint in Patient with Systemic Lupus Erythematosus Using Infrared Thermography Application: A Case Report. *J Int Soc Prev Community Dent.* [internet]. 2020; 10(5): 674-679. Available from: <https://pubmed.ncbi.nlm.nih.gov/33282779/>. doi: 10.4103/jispcd.JISPCD\_126\_20. eCollection Sep-Oct 2020.
19. Hung K, Montalvao C, Tanaka R, Kawai T, Bornstein MM. The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review. *Dentomaxillofac Radiol.* [internet]. 2019 [2021 Jun 10]; 49(1): 22-1. Available from: <https://pubmed.ncbi.nlm.nih.gov/31386555/>. doi: 10.1259/dmfr.20190107.
20. de Dumast P, Mirabel C, Cevidanes L, Ruellas A, Yatabe M, Ioshida M, et al. A web-based system for neural network based classification in temporomandibular joint osteoarthritis. *Comput Med Imaging Graph.* [internet]. 2018; 67: 45-54. Available from: <https://pubmed.ncbi.nlm.nih.gov/29753964/>. doi: 10.1016/j.compmedimag.2018.04.009.
21. Faust O, Rajendra Acharya U, Ng EYK, Hong TJ, Yu W. Application of infrared thermography in computer aided diagnosis. *Infrared Phys Technol.* [internet]. 2014; 66(1): 175–160. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7108233/>. doi: 10.1016/j.infrared.2014.06.001.
22. Bindushree V, Sameen R J, Vasudevan V, Shrihari T G, Devaraju D, Mathew NS. Artificial intelligence: In modern dentistry. *J Dent Res Rev.* [internet]. 2020; 7(1): 27-31. Available from: [https://www.researchgate.net/publication/342802168\\_Artificial\\_intelligence\\_In\\_modern\\_dentistry](https://www.researchgate.net/publication/342802168_Artificial_intelligence_In_modern_dentistry).
23. Gonzalez RC, Woods RE, Prentice Hall P. *Digital Image Processing. Third Edition.* Pearson International Edition prepared by Pearson Education; 2008.
24. Salvador-Meneses J, Ruiz-Chavez Z, Garcia-Rodriguez J. Compressed kNN: K-nearest neighbors with data compression. *Entropy.* [internet]. 2019; 21(3): 1–20. Available from: <https://www.mdpi.com/1099-4300/21/3/234>. doi: <https://doi.org/10.3390/e21030234>.
25. Noble WS. What is a support vector machine? *Nat Biotechnol.* [internet]. 2006; 24(12): 1565–7. Available from: <https://www.nature.com/articles/nbt1206-1565>. doi: 10.1038/nbt1206-1565.
26. Nalepa J, Kawulok M. Selecting training sets for support vector machines: a review. *Artif Intell Rev.* [Internet]. 2019; 52(2): 857–900. Available from: <https://link.springer.com/article/10.1007/s10462-017-9611-1>. doi: <https://doi.org/10.1007/s10462-017-9611-1>.
27. Castro W, Oblitas J, Santa-Cruz R, Avila-George H. Multilayer perceptron architecture optimization using parallel computing techniques. *PLoS One.* [internet]. 2017; 12(12): 1–17. Available from: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0189369>.

doi: <https://doi.org/10.1371/journal.pone.0189369>.

28. Dworkin SF, LeResche L. Research diagnostic criteria for temporomandibular disorders: review, criteria, examinations and specifications, critique. *J Craniomandib Disord*. [internet]. 1992 [cited 2021 Jul 5.]; 6(4): 301-55. Available from: <https://pubmed.ncbi.nlm.nih.gov/1298767/>.
29. Schwartz RG. Temporomandibular disorders. *N Eng J Med*. 2008; 359: 447-66.
30. Briosch ML, Macedo JF, Macedo RAC. Skin thermometry: new concepts. *J Vasc Bras*. [internet]. 2003; 2(2) 151-160. Available from: <https://www.jvascbras.org/article/5e21f58c0e8825a7456d0101/pdf/jvb-2-2-151.pdf>.
31. Brioschi ML. Princípios e indicações da termografia médica. 1. ed. [place unknown]: Andreoli; 2010.
32. Woźniak K, Szyszka-Sommerfeld L, Trybek G, Piątkowska D. Assessment of the sensitivity, specificity, and accuracy of thermography in identifying patients with TMD. *Med Sci Monit*. [internet]. 2015 [cited 2020 Nov 17]; 21: 1485–93. Available from: <https://pubmed.ncbi.nlm.nih.gov/26002613/>. doi: 10.12659/MSM.893863.
33. Yip SSF, Liu Y, Parmar C, Li Q, Liu S, Qu F, et al. Associations between radiologist-defined semantic and automatically computed radiomic features in non-small cell lung cancer. *Sci Rep*. [internet]. 2017; 7(3519): 11-1. Available from: <https://www.nature.com/articles/s41598-017-02425-5>.
34. Coroller TP, Bi WL, Huynh E, Abedalthagafi M, Aizer AA, Greenwald NF, et al. Radiographic prediction of meningioma grade by semantic and radiomic features. *PLoS One*. [internet]. 2017 [cited 2021 Jul 2]; 12(11): 15-1. Available from: <https://pubmed.ncbi.nlm.nih.gov/29145421/>. doi: 10.1371/journal.pone.0187908.
35. Pan S, Ding Z, Zhang L, Ruan M, Shan Y, Deng M, et al. Nomogram Combined Radiomic and Semantic Features as Imaging Biomarker for Classification of Ovarian Cystadenomas. [internet]. 2010; 10(895): 10-1. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7277787/>. doi: 10.3389/fonc.2020.00895.
36. Iosif L, Preoteasa CT, Murariu-Măgureanu C, Preoteasa E. Clinical study on thermography, as modern investigation method for Candida-associated denture stomatitis. *Rom J Morphol Embryol*. [internet]. 2016; 57(1): 191-5. Available from: <https://pubmed.ncbi.nlm.nih.gov/27151707/>.
37. Zakian CM, Taylor AM, Ellwood RP, Pretty IA. Occlusal caries detection by using thermal imaging. *J Dent*. [internet]. 2010; 38(10): 788-95. Available from: <https://pubmed.ncbi.nlm.nih.gov/20599464/>. doi: 10.1016/j.jdent.2010.06.010.
38. Biagioni PA, Lamey PJ. Electronic infrared thermography as a method of assessing herpes labialis infection. *Acta Derm Venereol*. [internet]. 1995[cited 2017 Sep 15]; 75(4): 264-8.

Available from: <https://pubmed.ncbi.nlm.nih.gov/8578944/>. doi: 10.2340/0001555575264268.

39. Kilic K, Er O, Kilinc HI, Aslan T, Bendes E, Sekerci AE, et al. Infrared thermographic comparison of temperature increases on the root surface during dowel space preparations using circular versus oval fiber dowel systems. *J Prosthodont*. 2013; 22(3): 203-7.
40. Costa ACS, Dibai Filho A V, Packer AC, Rodrigues-Bigaton D. Intra and inter-rater reliability of infrared image analysis of masticatory and upper trapezius muscles in women with and without temporomandibular disorder. *Brazilian J Phys Ther*. 2013; 17(1): 24–31.
41. Mambou SJ, Maresova P, Krejcar O, Selamat A, Kuca K. Breast Cancer Detection Using Infrared Thermal Imaging and a Deep Learning Model. *Sensors (Basel)*. [internet]. 2018; 18(9): 2799. Available: <https://pubmed.ncbi.nlm.nih.gov/30149621/>. doi: 10.3390/s18092799.
42. Jagadev P, Giri LI. Human respiration monitoring using infrared thermography and artificial intelligence. *Biomed Phys Eng Express*. 2020; 6(3): 19-1.
43. Bauer J, Hoq MN, Mulcahy J, Tofail SAM, Gulshan F, Silien C, et al. Implementation of artificial intelligence and non-contact infrared thermography for prediction and personalized automatic identification of different stages of cellulite. *EPMA J*. 2020; 11(1): 17-29. doi: 10.1007/s13167-020-00199-x.
44. Paulino JAS, Da Silva Alves AV, De Sousa RP, Galdino KE, Alves PM, Oliveira EJ. The use of hybrid classifier to assist in the diagnosis of lip lesions in thermal images: A preliminary study. *Proc - 2019 IEEE Int Conf Bioinforma Biomed BIBM 2019*. [internet]. 2019; 1585–8. Available from: <https://ieeexplore.ieee.org/document/8983008>.
45. Müller D, Ehlen A, Valeske B. Convolutional Neural Networks for Semantic Segmentation as a Tool for Multiclass Face Analysis in Thermal Infrared. *J Nondestr Eval*. [internet]. 2021; 40(9): 11-1. Available from: <https://link.springer.com/article/10.1007/s10921-020-00740-y>. doi: 10.1007/s10921-020-00740-y.
46. Rytivaara R, Näpänkangas R, Kainulainen T, Sipola A, Kallio-Pulkkinen S, Raustia A, et al. Thermographic findings related to facial pain—a survey of 40 subjects. *Cranio - J Craniomandib Pract*. 2021; 00(00): 1–8.
47. Perpetuini D., Trippetti N., Cardone D., Breda L., D’Attilio M., Merla A. (2021) Detection of Temporomandibular Joint Dysfunction in Juvenile Idiopathic Arthritis Through Infrared Thermal Imaging and a Machine Learning Procedure. In: Jarm T., Cvetkoska A., Mahnič-Kalamiza S., Miklavcic D. (eds) 8th European Medical and Biological Engineering Conference. *EMBE 2020. IFMBE Proceedings*, vol 80. Springer, Cham; 2020. p. 367-30.
48. Yi PH, Lin A, Wei J, Yu AC, Sair HI, Hui FK, et al. Deep-Learning-Based Semantic Labeling for 2D Mammography and Comparison of Complexity for Machine Learning Tasks. *J Digit Imaging*. 2019; 32(4): 565–70.
49. Bianchi J, de Oliveira Ruellas AC, Gonçalves JR, Paniagua B, Prieto JC, Styner M, et al.

Osteoarthritis of the Temporomandibular Joint can be diagnosed earlier using biomarkers and machine learning. [internet]. 2020 [cited 2021 Jul 5]; 10(8012): 14-1. Available from: <https://pubmed.ncbi.nlm.nih.gov/32415284/>. doi: 10.1038/s41598-020-64942-0.

50. Lee KS, Kwak HJ, Oh JM, Jha N, Kim YJ, Kim W, et al. Automated Detection of TMJ Osteoarthritis Based on Artificial Intelligence. *J Dent Res*. [internet]. 2020 [cited 2021 Jul 2]; 99(12): 1363-1367. Available from: <https://pubmed.ncbi.nlm.nih.gov/32609562/>. doi: 10.1177/0022034520936950.

51. Liu Z, Wang S, Dong D, Wei J, Fang C, Zhou X, et al. The applications of radiomics in precision diagnosis and treatment of oncology: Opportunities and challenges. *Theranostics*. [internet]. 2019; 9(5): 1303–22. Available from: <https://www.thno.org/v09p1303.htm> . doi:10.7150/thno.30309

52. Tayel MB, Elbagoury AZ. Breast infrared thermography segmentation based on adaptative tuning of fully convolutional network. *Current Medical Imaging*. [internet]. 2020; 16(5): 611–621. Available from: <https://pubmed.ncbi.nlm.nih.gov/32484096/>. doi: 10.2174/1573405615666190503142031.

53. Traverso A, Wee L, Dekker A, Gillies R. Repeatability and Reproducibility of Radiomic Features: A Systematic Review. *Int J Radiat Oncol Biol Phys*. [Internet]. 2018; 102(4): 1143–58. Available from: <https://pubmed.ncbi.nlm.nih.gov/30170872/>. doi: 10.1016/j.ijrobp.2018.05.053.

54. Wu W, Pierce LA, Zhang Y, Pipavath SNJ, Randolph TW, Lastwika KJ, et al. Comparison of prediction models with radiological semantic features and radiomics in lung cancer diagnosis of the pulmonary nodules: a case-control study. *Eur Radiol*. [internet]. 2019 [cited 2021 Jun 15]; 29(11): 6100-6108. Available from: <https://pubmed.ncbi.nlm.nih.gov/31115618/>. doi: 10.1007/s00330-019-06213-9.

55. Hawkins S, Wang H, Liu Y, Garcia A, Stringfield O, Krewer H, et al. Predicting Malignant Nodules from Screening CT Scans. *J Thorac Oncol*. [internet]. 2016 [cited 2021 Jun 3]; 11(12): 2120-2128. Available from: <https://pubmed.ncbi.nlm.nih.gov/27422797/>. doi: 10.1016/j.jtho.2016.07.002.

56. Bzdok D, Krzwinski M, Altman N. Machine learning: Supervised methods, SVM and kNN. *Nature Methods*. Nature Publishing Group. [internet]. 2018; 15(1): 1-6. Available from: <https://www.nature.com/articles/nmeth.4551>.

## 7 CONSIDERAÇÕES FINAIS

- A avaliação de imagens termográficas auxiliadas por métodos de aprendizagem de máquina apresentou resultados promissores para o estabelecimento do diagnóstico da disfunção temporomandibular;
- Os métodos de extração de atributos semânticos e a associação dos atributos semântico-radiômicos apresentaram melhores resultados que o método de extração de atributos radiômicos para detecção da disfunção temporomandibular utilizando imagens térmicas e escala de dor à palpação.
- A rede neural multicamada foi o algoritmo classificador que apresentou melhor desempenho na extração de atributos semânticos e radiômicos associados.

## REFERÊNCIAS

- ABE, S. **Support vector machines for pattern classification**. v. 2. London: Springer, 2005.
- ALTINDIS, T.; GUNGORMUS, M. Thermographic evaluation of occlusal splint and low level laser therapy in myofascial pain syndrome. **Complementary Therapies in Medicine**, v. 44, p. 277–281, 2019. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/31126567/>. Acesso em: 20 maio. 2021.
- AIRES JÚNIOR, F.A.F. **Otimização do processo metodológico para aquisição de imagens termográficas da face**. 2018. 95f. Tese (Doutorado em Engenharia de Processos) – Universidade Federal de Campina Grande, Campina Grande, 2018.
- AKST, J. **Inteligência artificial versus redes neurais: inovação Inspiradora. O cientista explorando a vida: uma cartilha**. 2019. p. 65802.
- ANBAR, M.; GRATT, B. M. Termology and facial telethermography: part II. Current and future clinical applications in dentistry. **Dentomaxillofacial Radiology**, v. 27, n. 2, p. 68–74, 1998. DOI: 10.1038/sj/dmfr/4600324. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/9656869/>. Acesso em: 15 maio. 2021.
- ANBAR, M.; GRATT, B.M.; HONG, D. Thermology and facial telethermography. Part I: history and technical review. **Dentomaxillofac Radiol**, v. 27, p. 61–67, 1998.
- BARÃO, V. A. R. et al. Effect of occlusal splint treatment on the temperature of different muscles in patients with TMD. **Journal of Prosthodontic Research**, v. 55, n. 1, p. 19–23, 2011.
- BARBOSA, J.S. et al. Infrared thermography assessment of patients with temporomandibular disorders. **Dentomaxillofac Radiol**, v. 49, n. 4, 2020. DOI:10.1259/dmfr.20190392. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7213526/>. Acesso em: 20 maio. 2021.
- BASHIR, U. et al. Non-invasive classification of non-small cell lung cancer: a comparison between random forest models utilising radiomic and semantic features. **Br J Radiol**, v. 92, n.1099, 2019. DOI: 10.1259/bjr.20190159. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6636267/>. Acesso em: 20 maio.2021.
- BITINIENE, D. et. al. Quality of life in patients with temporomandibular disorders. A systematic review. **Stomatologija**, v. 20, n. 1, p. 3-9, 2018.
- BOENING, K. et al. Temporomandibular disorders and oral parafunctions: Mechanism, diagnostics, and therapy. **BioMed Research International**, v. 2015, p. 2–4, 2015. DOI: <https://dx.doi.org/10.1155%2F2015%2F354759>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4446467/>. Acesso em: 22 abr. 2021.
- BRIOSCHI, M. L; MACEDO J. F.; MACEDO, R. A. C. Skin thermometry: new concepts. **J Vasc Bras**, v. 2, n. 2, p. 151-60, 2003. Disponível em: [https://www.researchgate.net/publication/285633038\\_Skin\\_thermometry\\_New\\_concepts](https://www.researchgate.net/publication/285633038_Skin_thermometry_New_concepts). Acesso em: 10 abr. 2021.
- BRIOSCHI M. L. et al. **Princípios e Indicações da Termografia Médica**. 1. ed. São Paulo: Andreoli, 2010.
- CLEMENTE, M. P. et al. Wind instrumentalists and temporomandibular disorder: From

diagnosis to treatment. **Dentistry Journal**, v. 6, n. 3, 2018. DOI:

<https://dx.doi.org/10.3390%2Fdj6030041>. Disponível em:

<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6162503/>. Acesso em: 02 mar. 2021.

CONVILLE, R. M.; MORIARTY, F.; ATKINS, S. The management of temporomandibular disorders: A headache in general practice. **British Journal of General Practice**, v. 69, n. 687, p. 523–524, 2019. DOI: <https://dx.doi.org/10.3399%2Fbjgp19X705977>. Disponível em:

<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6774690/>. Acesso em: 03 jan. 2021.

COSTA, A. C. S. et al. Intra and inter-rater reliability of infrared image analysis of masticatory and upper trapezius muscles in women with and without temporomandibular disorder. **Brazilian Journal of Physical Therapy**, v. 17, n. 1, p. 24–31, 2013. Disponível em:

<https://www.scielo.br/j/rbfis/a/xF6QWhMRB99b7XWMbR3Tg9g/abstract/?lang=en>. Acesso em: 20 maio. 2021.

COROLLER, T. P. et al. Radiographic prediction of meningioma grade by semantic and radiomic features. **PLoS ONE**, v. 12, n. 11, 2017. Disponível em:

<https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0187908>. Acesso em: 23 maio. 2021.

DE MELO, D. P. et al. Is infrared thermography effective in the diagnosis of temporomandibular disorders? A systematic review. **Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology**, v. 127, n. 2, p. 185–192, 2019. DOI: 10.1016 /

j.oooo.2018.09.006. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/30482738/>. Acesso em: 22 fev. 2021.

DIBAI FILHO, A. V. et al. Accuracy of infrared thermography of the masticatory muscles for the diagnosis of myogenous temporomandibular disorder. **Journal of Manipulative and Physiological Therapeutics**, v. 36, n. 4, p. 245–252, 2013. DOI:

<https://doi.org/10.1016/j.jmpt.2013.04.007>. Disponível em:

[https://www.jmptonline.org/article/S0161-4754\(13\)00059-6/fulltext](https://www.jmptonline.org/article/S0161-4754(13)00059-6/fulltext). Acesso em: 05 mar. 2021.

DIBAI-FILHO, A. V. et al. The chronicity of myogenous temporomandibular disorder changes the skin temperature over the anterior temporalis muscle. **Journal of Bodywork and Movement Therapies**, v. 18, n. 3, p. 430–434, 2014. DOI:

<https://doi.org/10.1016/j.jbmt.2013.11.001>. Disponível em:

[https://www.bodyworkmovementtherapies.com/article/S1360-8592\(13\)00183-6/fulltext](https://www.bodyworkmovementtherapies.com/article/S1360-8592(13)00183-6/fulltext). Acesso em: 03 fev. 2021.

DIBAI-FILHO, A. V. et al. Women with more severe degrees of temporomandibular disorder exhibit an increase in temperature over the temporomandibular joint. **Saudi Dental Journal**, v. 27, n. 1, p. 44–49, 2015. DOI: <https://dx.doi.org/10.1016%2Fj.sdentj.2014.10.002>.

Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4273257/>. Acesso em: 02

mar. 2021.

DINIZ, F. A. et al. RedFace: um sistema de reconhecimento facial baseado em técnicas de análise de componentes principais e autofaces: comparação com diferentes classificadores. **Revista Brasileira de Computação Aplicada**, Passo Fundo, v. 5, n. 1, p. 42-54, 2013. DOI:

<https://doi.org/10.5335/rbca.2013.2627>. Disponível em:

<http://seer.upf.br/index.php/rbca/article/view/2627>. Acesso em: 08 fev. 2021.

<http://seer.upf.br/index.php/rbca/article/view/2627>. Acesso em: 08 fev. 2021.

DINIZ, F. A.; SILVA, T. R. DA; ALENCAR, F. E. S. Um estudo empírico de um sistema de reconhecimento facial utilizando o classificador KNN. **Revista Brasileira de Computação**

**Aplicada**, v. 8, n. 1, p. 50–63, 2016. DOI: <https://doi.org/10.5335/rbca.2015.5227>. Disponível em: <http://seer.upf.br/index.php/rbca/article/view/5227>. Acesso em: 02 mar. 2021.

DOI, K. Computer aided diagnosis in medical imaging: historical review, current status, and future potential. **Comput Med Imag Graph**, v. 31, n. 4-5, p. 198-211, 2007. DOI: <https://dx.doi.org/10.1016%2Fj.compmedimag.2007.02.002>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC1955762/>. Acesso em: 22 fev. 2021.

DWORKIN, S. F.; LE RESCHE, L. Research diagnostic criteria for temporomandibular disorders: review, criteria, examinations and specifications, critique. **The Journal of Craniomandibular Disorders**, v. 6, n. 4, p. 301-55, 1992. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/1298767/>. Acesso em: 20 jan. 2021.

DUBNER, R.; OHRBACH, R.; DWORKIN, S. F. The Evolution of TMD Diagnosis: : Past, Present, Future. **Journal of Dental Research**, v. 95, n. 10, p. 1093–1101, 2016. DOI: <https://dx.doi.org/10.1177%2F0022034516653922>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5004241/>. Acesso em: 02 mar. 2021.

FERREIRA, C. L.; DA SILVA, M. A. M. R.; DE FELÍCIO, C. M. Signs and symptoms of temporomandibular disorders in women and men. **Codas**, v. 28, n. 1, p. 17–21, 2016. Disponível em: [https://www.scielo.br/pdf/codas/v28n1/en\\_2317-1782-codas-28-01-00017.pdf](https://www.scielo.br/pdf/codas/v28n1/en_2317-1782-codas-28-01-00017.pdf). Acesso em: 13 jan. 2021.

FREESE, A.S. The myofascial trigger mechanism temporomandibular joint and allied disturbances, **Oral Surg Oral Med Oral Pathol**, v.14, n.8, p. 933-97, 1961. DOI: [https://doi.org/10.1016/0030-4220\(61\)90006-8](https://doi.org/10.1016/0030-4220(61)90006-8). Disponível em: <https://pubmed.ncbi.nlm.nih.gov/13701657/>. Acesso em: 10 maio. 2021.

FRICOVA, J. et al. Thermovision: a new diagnostic method for orofacial pain? **Journal of pain research**, v. 11, p. 3195-3203, 2018. DOI: 10.2147/JPR.S183096. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6300380/>. Acesso em: 10 maio. 2021.

GAUER, R. L.; SEMIDEY, M. J. Diagnosis and treatment of temporomandibular disorders. **American Family Physician**, v. 91, n. 6, p. 378–386, 2015. Disponível em: <https://www.aafp.org/afp/2015/0315/p378.html>. Acesso em: 15 jan. 2021.

GHASSEMI, P. et al. Best practices for standardized performance testing of infrared thermographs intended for fever screening. **PLoS ONE**, v. 13, n. 9, p. 1–24, 2018. DOI: <https://dx.doi.org/10.1371%2Fjournal.pone.0203302>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6145558/>. Acesso em: 15 fev. 2021.

GILLIES, R. J.; KINAHAN, P. E.; HRICAK, H. Radiomics: Images are more than pictures, they are data. **Radiology**, v. 278, n. 2, p. 563–577, 2016. DOI: <https://dx.doi.org/10.1148%2Fradiol.2015151169>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4734157/>. Acesso em: 28 fev. 2021.

GONÇALVES, D. A. et al. Symptoms of temporomandibular disorders in the population: an epidemiological study. **J Orofac Pain**, v. 24, p. 270–278, 2010. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/20664828/>. Acesso em: 03 mar. 2021.

GONÇALVES, I.M.F. **Termografia como técnica auxiliar de diagnóstico diferencial de queilite actínica e carcinoma de células escamosas de lábio**. 2020. 108 f. Tese (Doutorado em Odontologia) – Universidade Estadual da Paraíba, Campina Grande, 2020.

GONZALES, C. R; WOODS, R. E. **Digital imaging processing**. 3. ed. Pearson education international, 2008.

HADDAD, D. S. et al. Thermographic characterization of masticatory muscle regions in volunteers with and without myogenous temporomandibular disorder: Preliminary results.

**Dentomaxillofacial Radiology**, v. 43, n. 8, 2014. DOI:

<https://dx.doi.org/10.1259%2Fdmfr.20130440>. Disponível em:

<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4240258/>. Acesso em: 13 jan. 2021.

HADDAD, D. S.; BRIOSCHI, M. L.; ARITA, E. S. Thermographic and clinical correlation of myofascial trigger points in the masticatory muscles. **Dentomaxillofac Radiol.**, v. 41, n. 8, p.

621-9, 2012. DOI: <https://dx.doi.org/10.1259%2Fdmfr%2F98504520>. Disponível em:

<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3528192/>. Acesso em: 01 mar. 2021.

HAWKINS, S. et al. Predicting Malignant Nodules from Screening CT Scans [published correction appears. **J Thorac Oncol**, v. 13, n. 2, p, 280-281, 2016. DOI:

10.1016/j.jtho.2016.07.002. Disponível em:

<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5545995/>. Acesso em: 10 maio. 2021.

HOPFIELD, J. J. Neural networks and physical systems with emergent collective

computational abilities. **Proc Natl Acad Sci USA**, v. 79, n. 8, p. 2554-2558, 1982. DOI:

<https://doi.org/10.1073/pnas.79.8.2554>. Disponível em:

<https://www.pnas.org/content/79/8/2554>. Acesso em: 22 fev. 2021.

HOSNY, A. et al. Artificial intelligence in radiology. **Nature Reviews Cancer**, v. 18, n. 8, p.

500–510, 2018. DOI: <https://dx.doi.org/10.1038%2Fs41568-018-0016-5>. Disponível em:

<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6268174/>. Acesso: 22 fev. 2021.

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

2019. DOI: <https://dx.doi.org/10.1259%2Fdmfr.20190107>. Disponível em:

<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6957072/>. Acesso em: 15 jan. 2021.

KLASSER, G. D. et. al. Oro-facial pain and temporomandibular disorders classification

systems: A critical appraisal and future directions. **J Oral Rehabil**, v. 45, n. 3, p. 258-268,

2018. DOI: <https://doi.org/10.1111/joor.12590>. Disponível em:

<https://onlinelibrary.wiley.com/doi/abs/10.1111/joor.12590>. Acesso em: 07 fev. 2021.

KHANAGAR, S. B. et al. Developments, application, and performance of artificial

intelligence in dentistry – A systematic review. **Journal of Dental Sciences**, v. 16, n. 1, p.

508–522, 2021. DOI: <https://doi.org/10.1016/j.jds.2020.06.019>. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S1991790220301434>. Acesso em: 07 fev. 2021.

KIRIMTAT, A. et al. FLIR vs SEEK thermal cameras in biomedicine: Comparative diagnosis through infrared thermography. **BMC Bioinformatics**, v. 21, n. 2, p. 1–10, 2020. Disponível

em: <https://bmcbioinformatics.biomedcentral.com/articles/10.1186/s12859-020-3355-7>.

Acesso em: 28 fev. 2021.

KAWANO, W. et al. Deep thermometry of temporomandibular joint and masticatory muscle regions. **The Journal of Prosthetic Dentistry**, v. 69, n. 2, p. 216–221, 1993. DOI:

10.1016/0022-3913(93)90143-c. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/8429516/>.

Acesso em: 24 maio. 2021.

KOÇAK, B. et al. Radiomics with artificial intelligence: A practical guide for beginners. **Diagnostic and Interventional Radiology**, v. 25, n. 6, p. 485–495, 2019. DOI: <https://dx.doi.org/10.5152%2Fdir.2019.19321>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6837295/>. Acesso em: 21 fev. 2021.

LAHIRI, B. B. et al. Infrared Physics & Technology Medical applications of infrared thermography : A review. **Infrared Physics and Technology**, v. 55, n. 4, p. 221–235, 2012. DOI: <https://doi.org/10.1016/j.infrared.2012.03.007>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1350449512000308>. Acesso em: 21 fev. 2021.

LAROSE, D. T.; LAROSE, C. D. **Discovering Knowledge in Data: An Introduction to data mining**. 2. ed. Nova Jersey: John Wiley & Sons, 2014

LIU, Z. et al. The applications of radiomics in precision diagnosis and treatment of oncology: Opportunities and challenges. **Theranostics**, v. 9, n. 5, p. 1303–1322, 2019. DOI: <https://dx.doi.org/10.7150%2Fthno.30309>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6401507/>. Acesso em: 28 fev. 2021.

LOOK, J. O.; JOHN, M. T.; TAI, F. et al. The Research Diagnostic Criteria For Temporomandibular Disorders. II: reliability of Axis I diagnoses and selected clinical measures. **J Orofac Pain**, v. 24, n.1, p.25-34, 2010. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3098131/>. Acesso em: 21 fev. 2021.

MACHOY, M. et al. Diagnosis of Temporomandibular Disorders Using Thermovision Imaging. **Pain Research and Management**, v. 2020, p. 1-8, 2020. DOI: <https://doi.org/10.1155/2020/5481365>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7685803/>. Acesso em: 20 abr. 2021.

NAGI, R. et al. Clinical applications and performance of intelligent systems in dental and maxillofacial radiology: A review. **Imaging Science in Dentistry**, v. 50, n. 2, p. 81–92, 2020. DOI: <https://dx.doi.org/10.5624%2Fisd.2020.50.2.81>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7314602/>. Acesso em: 17 fev. 2021.

OLESZKIEWICZ, W. et al. Application of SVM classifier in thermographic image classification for early detection of breast cancer. **Photonics Applications in Astronomy, Communications, Industry, and High-Energy Physics Experiments 2016**, v. 10031, p. 100312T, 2016.

OWEN, R.; RAMLAKHAN, S. termografia infravermelha em pediatria: uma revisão narrativa do uso clínico. **BMJ Paediatr Open**. v. 1, n. 1, 2017. DOI: <https://dx.doi.org/10.1136%2Fbmjpo-2017-000080>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5862192/>. Acesso em: 17 fev. 2021.

PAN, S. et al. A Nomogram Combined Radiomic and Semantic Features as Imaging Biomarker for Classification of Ovarian Cystadenomas. **Front Oncol**, v. 10, n. 895, 2020. DOI:10.3389/fonc.2020.00895. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7277787/>. Acesso em :17 fev.2021.

PARMAR, C. et al. Machine Learning methods for Quantitative Radiomic Biomarkers. **Scientific Reports**, v. 5, n. 13087, p. 1–11, 2015. DOI: <https://dx.doi.org/10.1038%2Fsrep13087>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4538374/>. Acesso em: 03 mar. 2021.

PARK, W. J.; PARK, J. B. História e aplicação de redes neurais artificiais em odontologia. **European Journal of dentistry**, v. 12, n. 4, p. 594–601, 2018.

PAULINO, J. A. S. et al. The use of hybrid classifier to assist in the diagnosis of lip lesions in thermal images: A preliminary study. *In: IEEE INTERNATIONAL CONFERENCE ON BIOINFORMATICS AND BIOMEDICINE*, 2019, San Diego. **Anais [...]**. San Diego: CA, 2019. Disponível em: <https://ieeexplore.ieee.org/document/8983008>. Acesso em: 02 mar. 2021.

PECK, C. C. et al. Expanding the taxonomy of the diagnostic criteria for temporomandibular disorders. **Journal of Oral Rehabilitation**, v. 41, n. 1, p. 2–23, 2014. DOI: <https://dx.doi.org/10.1111%2Fjoor.12132>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4520529/>. Acesso em: 03 mar. 2021.

RABUÑAL, J. R.; DORADO, J. Redes neurais artificiais em aplicações da vida real. IGI Global: Hershey, p. 166–346, 2005.

RAHMAYANI, L. et al. Thermal Condition of Muscle Area Around the Temporomandibular Joint in Patient with Systemic Lupus Erythematosus Using Infrared Thermography Application: A Case Report. **J Int Soc Prev Community Dent**, v. 10, n. 5, p. 674-679, 2020. DOI: 10.4103/jispcd.JISPCD\_126\_20. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7685285/>. Acesso em: 20 maio. 2021.

RYTIVAARA, R. et al. Thermographic findings related to facial pain – a survey of 40 subjects. **The Journal of Craniomandibular & Sleep Practice**, 2021. DOI: 10.1080/08869634.2021.1894859. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/08869634.2021.1894859>. Acesso em: 15 maio. 2021.

RODRIGUES-BIGATON, D. et al. Accuracy of two forms of infrared image analysis of the masticatory muscles in the diagnosis of myogenous temporomandibular disorder. **Journal of Bodywork and Movement Therapies**, v. 18, n. 1, p. 49–55, 2014. DOI: <https://doi.org/10.1016/j.jbmt.2013.05.005>. Disponível em: [https://www.bodyworkmovementtherapies.com/article/S1360-8592\(13\)00072-7/fulltext](https://www.bodyworkmovementtherapies.com/article/S1360-8592(13)00072-7/fulltext). Acesso em: 10 fev. 2021.

RUGH, T.C. Pathophysiology of pain. **Neurophysiology**, p .345-363, 1965.

SANTOS, M. K. et al. Artificial intelligence, machine learning, computer-aided diagnosis, and radiomics: Advances in imaging towards to precision medicine. **Radiologia Brasileira**, v. 52, n. 6, p. 387–396, 2019. DOI: <http://dx.doi.org/10.1590/0100-3984.2019.0049>. Disponível em: [https://www.scielo.br/scielo.php?pid=S0100-39842019000600011&script=sci\\_abstract](https://www.scielo.br/scielo.php?pid=S0100-39842019000600011&script=sci_abstract). Acesso em: 12 fev. 2021.

SCHIFFMAN, E. L. et al. The Research Diagnostic Criteria for Temporomandibular Disorders. V: Methods Used to Establish and Validate Revised Axis I Diagnostic Algorithms. **J Orofac Pain**, v. 24, n. 1, p. 63-78, 2010.

SCHIFFMAN, E. et al. Diagnostic Criteria for Temporomandibular Disorders (DC/TMD) for Clinical and Research Applications: Recommendations of the International RDC/TMD Consortium Network\* and Orofacial Pain Special Interest Group. **J Oral Facial Pain Headache**, v. 28, n. 1, p. 6-27, 2014. DOI: <https://dx.doi.org/10.11607%2Fjop.1151>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4478082/>. Acesso em 5 maio. 2021.

- SCHIFFMAN, E.; OHRBACH, R. Executive summary of the Diagnostic Criteria for Temporomandibular Disorders for clinical and research applications. **Journal of the American Dental Association**, v. 147, n. 6, p. 438–445, 2016. DOI: <https://dx.doi.org/10.1016%2Fj.adaj.2016.01.007>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4884471/>. Acesso em: 10 fev. 2021.
- SHI, R. et al. Prediction of KRAS, NRAS and BRAF status in colorectal cancer patients with liver metastasis using a deep artificial neural network based on radiomics and semantic features. **Am J Cancer Res**, v. 10, n. 12, p. 4513–4526, 2020. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7783758/>. Acesso em: 20 maio. 2021.
- SCHWARTZ, R. G.; PHILLIP. et al. Temporomandibular disorders. **The New England Journal of Medicine**, v. 359, p. 447–66, 2008.
- SCHWENDICKE, F.; SAMEK, W.; KROIS, J. Artificial Intelligence in Dentistry: Chances and Challenges. **Journal of Dental Research**, v. 99, n. 7, p. 769–774, 2020. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0306456517303996>. Acesso em: 10 maio. 2021.
- SINGH, J.; ARORA, A. S. An automated approach to enhance the thermographic evaluation on orofacial regions in lateral facial thermograms. **Journal of Thermal Biology**, v. 71, p. 91–98, 2018. Disponível em:
- SOLLINI, M. et al. Towards clinical application of image mining: a systematic review on artificial intelligence and radiomics. **European Journal of Nuclear Medicine and Molecular Imaging**, v. 46, n. 13, p. 2656–2672, 2019. DOI: <https://dx.doi.org/10.1007%2Fs00259-019-04372-x>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6879445/>. Acesso em: 10 jan. 2021.
- SUR, J. et al. Knowledge, attitudes, and perceptions regarding the future of artificial intelligence in oral radiology in India: A survey. **Imaging Science in Dentistry**, v. 50, n. 3, p. 193–198, 2020. DOI: <https://dx.doi.org/10.5624%2Fisd.2020.50.3.193>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7506091/>. Acesso em: 10 jan. 2021.
- TANDON, D.; RAJAWAT, J. Present and future of artificial intelligence in dentistry. **Journal of Oral Biology and Craniofacial Research**, v. 10, n. 4, p. 391–396, 2020. DOI: <https://doi.org/10.1016/j.jobcr.2020.07.015>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S2212426820301093>. Acesso em: 25 fev. 2021.
- THRALL, J. H. et al. Artificial Intelligence and Machine Learning in Radiology: Opportunities, Challenges, Pitfalls, and Criteria for Success. **Journal of the American College of Radiology**, v. 15, n. 3, p. 504–508, 2018. DOI: <https://doi.org/10.1016/j.jacr.2017.12.026>. Disponível em: [https://linkinghub.elsevier.com/retrieve/pii/S1546-1440\(17\)31671-X](https://linkinghub.elsevier.com/retrieve/pii/S1546-1440(17)31671-X). Acesso em: 25 fev. 2021.
- TRUELOVE, E. et al. The Research Diagnostic Criteria for Temporomandibular Disorders. III: validity of Axis I diagnoses. **J Orofac Pain**, v. 24, n. 1, p. 35–47, 2010. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3157051/>. Acesso em: 22 fev. 2021.
- USAMENTIAGA, R. et al. Infrared thermography for temperature measurement and non-destructive testing. **Sensors (Switzerland)**, v. 14, n. 7, p. 12305–12348, 2014. DOI:

<https://dx.doi.org/10.3390%2Fs140712305>. Disponível em:

<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4168422/>. Acesso em: 22 fev. 2021.

VARDASCA, R.; VAZ, L.; MENDES, J. Classification and decision making of medical infrared thermal images. **Lecture Notes in Computational Vision and Biomechanics**, v. 26, p. 79–104, 2018.

WANG, L. **Support vector machines: theory and applications**. v. 177. Berlin: Springer Science & Business Media, 2005. *E-book*.

WOŹNIAK, K. et al. Assessment of the Sensitivity, Specificity, and Accuracy of Thermography in Identifying Patients with TMD. Medical Science Monitor: **International Medical Journal of Experimental and Clinical Research**, v. 21, p. 1485-1493, 2015. DOI: <https://dx.doi.org/10.12659%2FMJM.893863>. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4451701/>. Acesso em: 22 fev. 2021.

WU, W. et al. Comparison of prediction models with radiological semantic features and radiomics in lung cancer diagnosis of the pulmonary nodules: a case-control study. **Eur Radiol**, v.29, n.11, p. 6100-6108, 2019. DOI: 10.1007/s00330-019-06213-9. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6880400/>. Acesso em 20 maio 2021.

YIP, S.S.F. et al. Associations between radiologist-defined semantic and automatically computed radiomic features in non-small cell lung cancer. **Sci Rep**, v. 7, n.1, 2017. DOI:10.1038/s41598-017-02425-5. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5471260/>. Acesso em 20 maio 2021.

YU, CHEN.; CHEN, A.; CHEN, C. Investigation of the Impact of Infrared Sensors on Core Body Temperature Monitoring by Comparing Measurement Sites. **Sensors (Basel)**, v.20, n.10, 2020. DOI:10.3390/s20102885. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7284737/>. Acesso em 10 maio 2021.

**APÊNDICE A – Termo de Consentimento Livre e Esclarecido (TCLE)****LABORATÓRIO DE TERMOGRAFIA****TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO**

Por este instrumento, dou pleno consentimento para realização dos exames necessários ao diagnóstico e tratamento. Declaro que recebi esclarecimento sobre o estudo e os exames realizados, ainda, concedo o direito da utilização do meu histórico de antecedentes pessoal e familiar, bem como da retenção e do uso de radiografias, fotografias, modelos e resultados de exames clínicos e laboratoriais, além de quaisquer outros documentos e informações contidas neste prontuário, referentes inclusive ao meu estado de saúde bucal e sistêmico, para fins de ensino e divulgação (dentro das normas vigentes), em congressos, jornais, revistas científicas nacionais e internacionais. Estou ciente que serão utilizados materiais e técnicas na tentativa de promover uma melhor qualidade de vida.

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

---

Assinatura do paciente

RG: \_\_\_\_\_

## **APÊNDICE B – Orientações prévias à realização das termografias**

**CARO PARTICIPANTE, SIGA CORRETAMENTE ESSAS ORIENTAÇÕES ANTES REALIZAR O EXAME TERMOGRÁFICO:**

- Não utilize fontes de calor, como secador e/ou alisador de cabelo, no dia do exame;
- Higienize bem o local da pele que será examinado, mas não tome banho quente;
- Não utilize cremes, talcos, perfumes, maquiagens, etc.
- Não use acessórios (como colar, brincos, enfeites de cabelo);
- Estar em jejum por no mínimo três horas antes do exame;
- Não consuma alimentos quentes próximo da hora do exame;
- Não consuma estimulantes ou substâncias com cafeína por, no mínimo, 3 horas antes do exame;
- Não faça uso de analgésicos, corticoides, anti-inflamatórios, anti-hipertensivos;
- Não pratique qualquer exercício físico no dia do exame e evite fazer massagens, fisioterapia, exposição prolongada ao sol no dia do exame;
- Se fumante: interromper o uso de cigarros e cachimbos por 4 horas antes do exame;
- Evite tocar a pele a ser examinada;
- Para os homens: não se barbear seis horas antes do exame.

**Muito obrigado!**

## APÊNDICE C – Ficha de exame termográfico

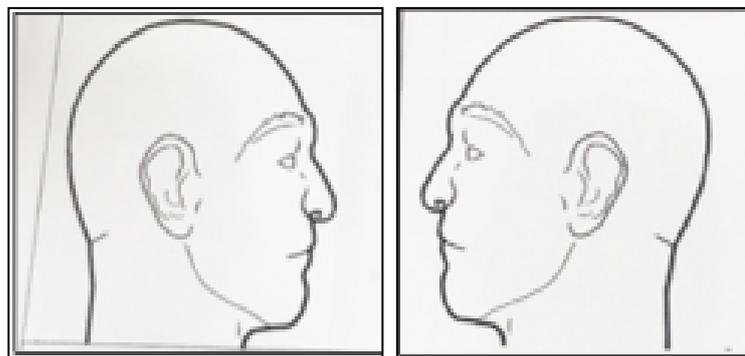


### AVALIAÇÃO DO PERFIL TERMOGRÁFICO

IDENTIFICAÇÃO DO PACIENTE		
Nome:		Prontuário N°:
Idade:	Sexo: ( ) M ( ) F	Cor Declarada: ( ) Branca ( ) Preta ( ) Parda ( ) Amarela ( ) Indígena ( ) NDE
Endereço:		
Cidade:		Bairro:
Telefone:		E-mail:
Data:		Hora de chegada:
Peso:		Altura:
ANAMNESE		
1- Você sente dor ao abrir a boca ou mastigar?	( ) Sim ( ) Não	Há quanto tempo?
2- Você sente dor na Articulação Temporomandibular (ATM)?	( ) Sim ( ) Não	Há quanto tempo?
3- Você sente ou já sentiu sua boca travar? Sente desconforto ao abri-la?	( ) Sim ( ) Não	Há quanto tempo?
4- Você sente dor de cabeça mais de uma vez por semana?	( ) Sim ( ) Não	Há quanto tempo?
5- Você é fumante?	( ) Sim ( ) Não ( ) Parei de fumar	→ Respondeu <i>sim</i> : Fumou hoje? ( ) Sim - Hora: _____ ( ) Não  → Respondeu <i>parei de fumar</i> : Por quanto tempo parou de fumar: _____
6- Consome bebida alcoólica?	( ) Todos os dias ( ) Às vezes - Quantos dias? _____ ( ) Quase não bebo ( ) Não bebo	→ Se <i>sim</i> : Consumiu hoje? ( ) Sim ( ) Não
7- Você é hipertenso?	( ) Sim ( ) Não	PA: _____ (Verificar)
8- Tem alguma alergia no rosto?	( ) Sim ( ) Não	Qual?
9- Costuma usar protetor solar no rosto?	( ) Sim ( ) Não	
10- Costuma usar protetor solar nos lábios?	( ) Sim ( ) Não	
11- Costuma usar base/maquiagem com frequência?	( ) Sim ( ) Não	
12- Costuma usar batom/gloss?	( ) Sim ( ) Não	
13- Costuma tomar banho quente?	( ) Sim ( ) Não	
14- Como você considera a sua pele?	( ) Seca ( ) Mista ( ) Oleosa	

HISTÓRIA MÉDICA		
Problemas neurológicos:	( ) Sim ( ) Não	Quais:
Epilepsia:	( ) Sim ( ) Não	
Cardiopatias:	( ) Sim ( ) Não	Quais:
Problemas na tireóide	( ) Sim ( ) Não	Quais:
Diabetes Mellitus	( ) Sim ( ) Não	Tipo:
Problemas respiratórios:	( ) Sim ( ) Não	Quais:
Problemas renais:	( ) Sim ( ) Não	Quais:
Alterações hepáticas	( ) Sim ( ) Não	Quais:
Alterações Vasculares	( ) Sim ( ) Não	Quais:
Alterações hematológicas	( ) Sim ( ) Não	Quais:
Doenças reumáticas:	( ) Sim ( ) Não	Quais:
Alergias/Rinite:	( ) Sim ( ) Não	Quais:
Sofreu alguma cirurgia?	( ) Sim ( ) Não	Qual:
Uso de medicamentos	( ) Sim ( ) Não	Se sim:
Quais as medicações de uso atual? (CIRCULE OS QUE INGERIU HOJE)		
REGISTROS DAS IMAGENS TERMOGRÁFICAS:		
1ª Tomada - Data:	Hora:	Nº Imagem:
Temperatura ambiente (°C):		
Umidade relativa do ar (%):		
Distâncias (cm):	Direita:	Esquerda: Frontal:

### PACIENTE MARCA O LOCAL DA DOR



## ANEXO A – Parecer do Comitê de Ética em Pesquisa (CEP)



UNIVERSIDADE ESTADUAL DA PARAÍBA  
PRÓ-REITORIA DE PÓS-GRADUAÇÃO E PESQUISA  
COMITÊ DE ÉTICA EM PESQUISA ENVOLVENDO SERES HUMANOS



**Pesquisador Responsável:** Profa. Dra. Patrícia Meira Bento

**Orientandos:** Jussara da Silva Barbosa

**CAAE Plataforma Brasil:** 73417017.2.0000.5187

**Data da relatoria:** 15 de agosto de 2017

**Situação do parecer:** APROVADO

**Apresentação do Projeto:** O Projeto é intitulado: "ANÁLISE TERMOGRÁFICA INFRAVERMELHA DE PACIENTES COM DISFUNÇÃO TEMPOROMANDIBULAR SUBMETIDOS À TERAPIA COM LASER DE BAIXA INTENSIDADE", encaminhado ao Comitê de Ética em Pesquisa da Universidade Estadual da Paraíba para análise e parecer com fins de obtenção de autorização para elaboração da Dissertação de Conclusão do Curso de Mestrado em odontologia da Universidade Estadual da Paraíba. A termografia infravermelha é um método de imagem que pode ser utilizado para complementar a avaliação clínica, podendo servir para indicar a causa da dor do paciente, bem como para acompanhar e planejar o tipo de tratamento que poderá ser empregado. A pesquisa a ser realizada consistirá de um ensaio clínico randomizado e controlado, que acontecerá no Departamento de Odontologia da Universidade Estadual da Paraíba (UEPB). A amostra do estudo será obtida através de demanda espontânea e formada por pacientes

diagnosticados com DTM miogênica pelo RDC/TMD (Research Diagnostic Criteria for Temporomandibular Disorders) e pacientes que não apresentem esta condição. Este estudo tem como critérios de inclusão: pacientes adultos (18 a 60 anos), de ambos os sexos, com e sem DTM miogênica, de acordo com o protocolo RDC/TMD. Os voluntários serão divididos igualmente em dois grupos: a) Grupo I (controle): Pacientes não diagnosticados com DTM; b) Grupo II – (experimental): Pacientes portadores de DTM miogênica que serão tratados com laser de baixa intensidade. Para os voluntários de ambos os grupos serão realizados exames termográficos para identificar mudanças de temperatura entre os grupos, sendo realizados em diferentes momentos: Dia 0 – Aquisição termográfica inicial para os grupos I e II; Dia 30: Aquisição termográfica final após 30 dias de tratamento para o grupo II. Inicialmente, será empregada a análise estatística descritiva. Em seguida, será realizada a análise inferencial e comparativa objetivando determinar a influência da terapia com laser de baixa intensidade na atividade muscular dos pacientes com DTM miogênica, como também buscar comparações entre os grupos. O nível de significância será fixado em 5%.

**Objetivos Geral e Específicos da Pesquisa:** . O objetivo deste estudo será avaliar a eficiência da terapia com laser de baixa intensidade em pacientes portadores de DTM miogênica por meio da termografia infravermelha. **Objetivos Específicos:** Comparar a atividade muscular de pacientes portadores de DTM miogênica submetidos à laserterapia de baixa intensidade com pacientes que não foram diagnosticados com esta doença, por meio da termografia infravermelha; Monitorar e quantificar o perfil térmico inflamatório de pacientes com DTM miogênica; Comparar a temperatura nas regiões dos músculos masseter e temporal anterior entre pacientes portadores e não portadores de DTM miogênica; Detectar mudanças de temperatura antes e após a terapia com laser de baixa intensidade em pacientes diagnosticados com DTM miogênica; Determinar um protocolo de uso da termografia para diagnóstico e acompanhamento de pacientes portadores de DTM miogênica.

**Avaliação dos Riscos e Benefícios:** Conforme a RESOLUÇÃO 466/12/CNS/MS, Item V, toda pesquisa com seres humanos envolve riscos com graus variados. Para este estudo segundo a pesquisadora responsável junto a Plataforma Brasil: "Riscos: O exame termográfico e a aplicação do laser de

baixa intensidade não trazem riscos para os voluntários da pesquisa, visto que são técnicas não invasivas e não ionizantes. **Benefícios:** A laserterapia de baixa intensidade é uma modalidade de tratamento não farmacológica que proporcionará sensação de alívio para o paciente portador de DTM miogênica, além de ser uma técnica não invasiva, bem como a termografia infravermelha que não apresenta radiação ionizante, como também não se utiliza contraste intravenoso para realização desta técnica. Portanto, esta pesquisa trará benefícios aos pacientes portadores de DTMs, visto que ela servirá para mensurar a eficácia de mais um tipo de exame por imagem que possa ser usado para o diagnóstico e avaliação de tratamentos indicados para as DTMs miogênicas”.

**Comentários e Considerações sobre a Pesquisa:** O projeto apresenta: Resumo; introdução; justificativa; hipóteses; objetivo geral e objetivo específico; riscos e benefícios; desfecho primário; referencial teórico; metodologia; cronograma; referências; anexos e apêndices. De um modo geral, os elementos estão bem articulados, não havendo pendências entre eles.

**Considerações sobre os Termos de apresentação obrigatória:** Ao analisar os documentos necessários para a integração do protocolo científico, encontramos os documentos necessários e obrigatórios: Folha de Rosto gerada na Plataforma Brasil; Termo de Compromisso em cumprir os Termos da Resolução 468/12/CNS/MS; Declaração de Concordância com Projeto de Pesquisa; Termo de Consentimento Livre e Esclarecido; Instrumentos da Coleta de Dados composto por: ( Ficha para o Exame termográfico; Dados Sociodemográfico e Questionário Clínico; Orientação ao paciente quanto à realização do exame termográfico), não havendo pendências com relação a estes.

**Recomendações:** Não há.

**Conclusões ou Pendências e Lista de Inadequações:** O referido estudo ao fim que se destina, segue sem pendências.

**ANEXO B – Research Diagnostic Criteria for Temporomandibular Disorders  
(RDC/TMD)**

 <b>RDC - TMD</b> Research Diagnostic Criteria for Temporomandibular Disorders Português – BRASIL		
Nome	Prontuário / Matrícula n°	RDC n°
Examinador	Data ____ / ____ / ____	
<b>HISTÓRIA - QUESTIONÁRIO</b>		
Por favor, leia cada pergunta e marque somente a resposta que achar mais correta.		
<b>1. Como você classifica sua saúde em geral?</b>		
<input type="checkbox"/> 1	Excelente	
<input type="checkbox"/> 2	Muito boa	
<input type="checkbox"/> 3	Boa	
<input type="checkbox"/> 4	Razoável	
<input type="checkbox"/> 5	Ruim	
<b>2. Como você classifica a saúde da sua boca?</b>		
<input type="checkbox"/> 1	Excelente	
<input type="checkbox"/> 2	Muito boa	
<input type="checkbox"/> 3	Boa	
<input type="checkbox"/> 4	Razoável	
<input type="checkbox"/> 5	Ruim	
<b>3. Você sentiu dor na face, em locais como na região das bochechas (maxilares), nos lados da cabeça, na frente do ouvido ou no ouvido, nas últimas 4 semanas?</b>		
<input type="checkbox"/> 0	Não	
<input type="checkbox"/> 1	Sim	
[Se sua resposta foi não, PULE para a pergunta 14.a] [Se a sua resposta foi sim, PASSE para a próxima pergunta]		
<b>4. Há quanto tempo a sua dor na face começou pela primeira vez?</b>		
[Se começou há um ano ou mais, responda a pergunta 4.a] [Se começou há menos de um ano, responda a pergunta 4.b]		
<b>4.a. Há quantos anos a sua dor na face começou pela primeira vez?</b>		
<input type="text"/>	<input type="text"/>	Ano(s)
<b>4.b. Há quantos meses a sua dor na face começou pela primeira vez?</b>		
<input type="text"/>	<input type="text"/>	Mês(es)
<b>5. A dor na face ocorre?</b>		
<input type="checkbox"/> 1	O tempo todo	
<input type="checkbox"/> 2	Aparece e desaparece	
<input type="checkbox"/> 3	Ocorreu somente uma vez	
<b>6. Você já procurou algum profissional de saúde (médico, cirurgião-dentista, fisioterapeuta, etc.) para tratar a sua dor na face?</b>		
<input type="checkbox"/> 1	Não	
<input type="checkbox"/> 2	Sim, nos últimos seis meses.	
<input type="checkbox"/> 3	Sim, há mais de seis meses.	

7. Em uma escala de 0 a 10, se você tivesse que dar uma nota para sua dor na face agora, NESTE EXATO MOMENTO, que nota você daria, onde 0 é “nenhuma dor” e 10 é “a pior dor possível”?												
NENHUMA DOR	0	1	2	3	4	5	6	7	8	9	10	A PIOR DOR POSSÍVEL
8. Pense na pior dor na face que você já sentiu nos últimos seis meses, dê uma nota pra ela de 0 a 10, onde 0 é “nenhuma dor” e 10 é “a pior dor possível”?												
NENHUMA DOR	0	1	2	3	4	5	6	7	8	9	10	A PIOR DOR POSSÍVEL
9. Pense em todas as dores na face que você já sentiu nos últimos seis meses, qual o valor médio você daria para essas dores, utilizando uma escala de 0 a 10, onde 0 é “nenhuma dor” e 10 é “a pior dor possível”?												
NENHUMA DOR	0	1	2	3	4	5	6	7	8	9	10	A PIOR DOR POSSÍVEL
10. Aproximadamente quantos dias nos últimos seis meses você esteve afastado de suas atividades diárias como: trabalho, escola e serviço doméstico, devido a sua dor na face?												
<input type="text"/> <input type="text"/> Dias												
11. Nos últimos seis meses, o quanto esta dor na face interferiu nas suas atividades diárias utilizando uma escala de 0 a 10, onde 0 é “nenhuma interferência” e 10 é “incapaz de realizar qualquer atividade”?												
NENHUMA INTERFERÊNCIA	0	1	2	3	4	5	6	7	8	9	10	INCAPAZ DE REALIZAR QUALQUER ATIVIDADE
12. Nos últimos seis meses, o quanto esta dor na face mudou a sua disposição de participar de atividades de lazer, sociais e familiares, onde 0 é “nenhuma mudança” e 10 é “mudança extrema”?												
NENHUMA MUDANÇA	0	1	2	3	4	5	6	7	8	9	10	MUDANÇA EXTREMA
13. Nos últimos seis meses, o quanto esta dor na face mudou a sua capacidade de trabalhar (incluindo serviços domésticos) onde 0 é “nenhuma mudança” e 10 é “mudança extrema”?												
NENHUMA MUDANÇA	0	1	2	3	4	5	6	7	8	9	10	MUDANÇA EXTREMA
14.a. Alguma vez sua mandíbula (boca) já ficou travada de forma que você não conseguiu abrir totalmente a boca?												
<input type="checkbox"/> 0 Não												
<input type="checkbox"/> 1 Sim												
[Se você nunca teve travamento da mandíbula, PULE para a pergunta 15.a]												
[Se já teve travamento da mandíbula, PASSE para a próxima pergunta]												
14.b. Este travamento da mandíbula (boca) foi grave a ponto de interferir com a sua capacidade de mastigar?												
<input type="checkbox"/> 0 Não												
<input type="checkbox"/> 1 Sim												
15.a. Você ouve estalos quando mastiga, abre ou fecha a boca?												
<input type="checkbox"/> 0 Não												
<input type="checkbox"/> 1 Sim												
15.b. Quando você mastiga, abre ou fecha a boca, você ouve um barulho (rangido) na frente do ouvido como se fosse osso contra osso?												
<input type="checkbox"/> 0 Não												
<input type="checkbox"/> 1 Sim												

<p><b>15.c. Você já percebeu ou alguém falou que você range (ringi) ou aperta os seus dentes quando está dormindo?</b></p> <p><input type="checkbox"/> 0 Não</p> <p><input type="checkbox"/> 1 Sim</p> <p><b>15.d. Durante o dia, você range (ringi) ou aperta os seus dentes?</b></p> <p><input type="checkbox"/> 0 Não</p> <p><input type="checkbox"/> 1 Sim</p> <p><b>15.e. Você sente a sua mandíbula (boca) “cansada” ou dolorida quando você acorda pela manhã?</b></p> <p><input type="checkbox"/> 0 Não</p> <p><input type="checkbox"/> 1 Sim</p> <p><b>15.f. Você ouve apitos ou zumbidos nos seus ouvidos?</b></p> <p><input type="checkbox"/> 0 Não</p> <p><input type="checkbox"/> 1 Sim</p> <p><b>15.g. Você sente que a forma como os seus dentes se encostam é desconfortável ou diferente/ estranha?</b></p> <p><input type="checkbox"/> 0 Não</p> <p><input type="checkbox"/> 1 Sim</p>
<p><b>16.a. Você tem artrite reumatóide, lúpus, ou qualquer outra doença que afeta muitas articulações (juntas) do seu corpo?</b></p> <p><input type="checkbox"/> 0 Não</p> <p><input type="checkbox"/> 1 Sim</p> <p><b>16.b. Você sabe se alguém na sua família, isto é seus avós, pais, irmãos, etc. já teve artrite reumatóide, lúpus, ou qualquer outra doença que afeta várias articulações (juntas) do corpo?</b></p> <p><input type="checkbox"/> 0 Não</p> <p><input type="checkbox"/> 1 Sim</p> <p><b>16.c. Você já teve ou tem alguma articulação (junta) que fica dolorida ou incha sem ser a articulação (junta) perto do ouvido (ATM)?</b></p> <p><input type="checkbox"/> 0 Não</p> <p><input type="checkbox"/> 1 Sim</p> <p>[Se você <b>não</b> teve dor ou inchaço, PULE para a pergunta 17.a.] [Se você <b>já</b> teve, dor ou inchaço, PASSE para a próxima pergunta]</p>
<p><b>16.d. A dor ou inchaço que você sente nessa articulação (junta) apareceu várias vezes nos últimos 12 meses (1 ano)?</b></p> <p><input type="checkbox"/> 0 Não</p> <p><input type="checkbox"/> 1 Sim</p>
<p><b>17.a. Você teve recentemente alguma pancada ou trauma na face ou na mandíbula (queixo)?</b></p> <p><input type="checkbox"/> 0 Não</p> <p><input type="checkbox"/> 1 Sim</p> <p>[Se sua resposta foi <b>não</b>, PULE para a pergunta 18] [Se sua resposta foi <b>sim</b>, PASSE para a próxima pergunta]</p> <p><b>17.b. A sua dor na face (em locais como a região das bochechas (maxilares), nos lados da cabeça, na frente do ouvido ou no ouvido) já existia antes da pancada ou trauma?</b></p> <p><input type="checkbox"/> 0 Não</p> <p><input type="checkbox"/> 1 Sim</p>
<p><b>18. Durante os últimos seis meses você tem tido problemas de dor de cabeça ou enxaquecas?</b></p> <p><input type="checkbox"/> 0 Não</p> <p><input type="checkbox"/> 1 Sim</p>

**19. Quais atividades a sua dor na face ou problema na mandíbula (queixo), impedem, limitam ou prejudicam?**

	NÃO	SIM
a. Mastigar	0	1
b. Beber (tomar líquidos)	0	1
c. Fazer exercícios físicos ou ginástica	0	1
d. Comer alimentos duros	0	1
e. Comer alimentos moles	0	1
f. Sorrir/gargalhar	0	1
g. Atividade sexual	0	1
h. Limpar os dentes ou a face	0	1
i. Bocejar	0	1
j. Engolir	0	1
k. Conversar	0	1
l. Ficar com o rosto normal: sem a aparência de dor ou triste	0	1

**20. Nas últimas quatro semanas, o quanto você tem estado angustiado ou preocupado:**

	Nem um pouco	Um pouco	Moderadamente	Muito	Extremamente
a. Por sentir dores de cabeça	0	1	2	3	4
b. Pela perda de interesse ou prazer sexual	0	1	2	3	4
c. Por ter fraqueza ou tontura	0	1	2	3	4
d. Por sentir dor ou "aperto" no peito ou coração	0	1	2	3	4
e. Pela sensação de falta de energia ou lentidão	0	1	2	3	4
f. Por ter pensamentos sobre morte ou relacionados ao ato de morrer	0	1	2	3	4
g. Por ter falta de apetite	0	1	2	3	4
h. Por chorar facilmente	0	1	2	3	4
i. Por se culpar pelas coisas que acontecem ao seu redor	0	1	2	3	4
j. Por sentir dores na parte inferior das costas	0	1	2	3	4
k. Por se sentir só	0	1	2	3	4
l. Por se sentir triste	0	1	2	3	4
m. Por se preocupar muito com as coisas	0	1	2	3	4
n. Por não sentir interesse pelas coisas	0	1	2	3	4

**21. Como você classificaria os cuidados que tem tomado com a sua saúde de uma forma geral?**

- 1 Excelente  
 2 Muito bom  
 3 Bom  
 4 Razoável  
 5 Ruim

**22. Como você classificaria os cuidados que tem tomado com a saúde da sua boca?**

- 1 Excelente  
 2 Muito bom  
 3 Bom  
 4 Razoável  
 5 Ruim

**23. Qual a data do seu nascimento?**

Dia   Mês   Ano

**24. Qual seu sexo?**

- 1 Masculino  
 2 Feminino

**25. Qual a sua cor ou raça?**

- 1 Aleútas, Esquimó ou Índio Americano  
 2 Asiático ou Insulano Pacífico  
 3 Preta  
 4 Branca  
 5 Outra [Se sua resposta foi **outra**, PASSE para as **próximas alternativas** sobre sua cor ou raça]

6 Parda

7 Amarela

8 Indígena

**26. Qual a sua origem ou de seus familiares?**

1 Porto Riquenho

2 Cubano

3 Mexicano

4 Mexicano Americano

5 Chicano

6 Outro Latino Americano

7 Outro Espanhol

8 Nenhuma acima [Se sua resposta foi **nenhuma acima**, PASSE para as **próximas alternativas** sobre sua origem ou de seus familiares]

9 Índio

10 Português

11 Francês

12 Holandês

13 Espanhol

14 Africano

15 Italiano

16 Japonês

17 Alemão

18 Árabe

19 Outra, favor especificar

20 Não sabe especificar

**27. Até que ano da escola / faculdade você freqüentou?**

Nunca freqüentei a escola		0
Ensino fundamental (primário)	1ª Série	1
	2ª Série	2
	3ª Série	3
	4ª Série	4
Ensino fundamental (ginásio)	5ª Série	5
	6ª Série	6
	7ª Série	7
	8ª Série	8
Ensino médio (científico)	1º ano	9
	2º ano	10
	3º ano	11
Ensino superior (faculdade ou pós-graduação)	1º ano	12
	2º ano	13
	3º ano	14
	4º ano	15
	5º ano	16
	6º ano	17

**28a. Durante as 2 últimas semanas, você trabalhou no emprego ou em negócio pago ou não (não incluindo trabalho em casa)?**

0 Não

1 Sim

[Se a sua resposta foi **sim**, PULE para a **pergunta 29**]  
 [Se a sua resposta foi **não**, PASSE para a **próxima pergunta**]



EXAME CLÍNICO																					
<p><b>1. Você tem dor no lado direito da sua face, lado esquerdo ou ambos os lados?</b></p> <p><input type="checkbox"/> 0 Nenhum</p> <p><input type="checkbox"/> 1 Direito</p> <p><input type="checkbox"/> 2 Esquerdo</p> <p><input type="checkbox"/> 3 Ambos</p>																					
<p><b>2. Você poderia apontar as áreas aonde você sente dor ?</b></p> <table border="1" style="width: 100%; border-collapse: collapse; margin-top: 10px;"> <thead> <tr> <th style="width: 50%; text-align: center; padding: 5px;">Direito</th> <th style="width: 50%; text-align: center; padding: 5px;">Esquerdo</th> </tr> </thead> <tbody> <tr> <td style="padding: 5px;"><input type="checkbox"/> 0 Nenhuma</td> <td style="padding: 5px;"><input type="checkbox"/> 0 Nenhuma</td> </tr> <tr> <td style="padding: 5px;"><input type="checkbox"/> 1 Articulação</td> <td style="padding: 5px;"><input type="checkbox"/> 1 Articulação</td> </tr> <tr> <td style="padding: 5px;"><input type="checkbox"/> 2 Músculos</td> <td style="padding: 5px;"><input type="checkbox"/> 2 Músculos</td> </tr> <tr> <td style="padding: 5px;"><input type="checkbox"/> 3 Ambos</td> <td style="padding: 5px;"><input type="checkbox"/> 3 Ambos</td> </tr> </tbody> </table>		Direito	Esquerdo	<input type="checkbox"/> 0 Nenhuma	<input type="checkbox"/> 0 Nenhuma	<input type="checkbox"/> 1 Articulação	<input type="checkbox"/> 1 Articulação	<input type="checkbox"/> 2 Músculos	<input type="checkbox"/> 2 Músculos	<input type="checkbox"/> 3 Ambos	<input type="checkbox"/> 3 Ambos										
Direito	Esquerdo																				
<input type="checkbox"/> 0 Nenhuma	<input type="checkbox"/> 0 Nenhuma																				
<input type="checkbox"/> 1 Articulação	<input type="checkbox"/> 1 Articulação																				
<input type="checkbox"/> 2 Músculos	<input type="checkbox"/> 2 Músculos																				
<input type="checkbox"/> 3 Ambos	<input type="checkbox"/> 3 Ambos																				
<p><b>3. Padrão de abertura:</b></p> <p><input type="checkbox"/> 0 Reto</p> <p><input type="checkbox"/> 1 Desvio lateral direito (não corrigido)</p> <p><input type="checkbox"/> 2 Desvio lateral direito corrigido ("S")</p> <p><input type="checkbox"/> 3 Desvio lateral esquerdo (não corrigido)</p> <p><input type="checkbox"/> 4 Desvio lateral esquerdo corrigido ("S")</p> <p><input type="checkbox"/> 5 Outro tipo _____ (Especifique)</p>																					
<p><b>4. Extensão de movimento vertical</b></p> <p><i>Incisivo superior utilizado</i> <input type="checkbox"/> 11 <input type="checkbox"/> 21</p> <p><b>a. Abertura sem auxílio sem dor</b> <input type="text"/> <input type="text"/> mm</p> <p><b>b. Abertura máxima sem auxílio</b> <input type="text"/> <input type="text"/> mm</p> <table border="1" style="width: 100%; border-collapse: collapse; margin-top: 10px;"> <thead> <tr> <th style="width: 50%; text-align: center; padding: 5px;">Dor Muscular</th> <th style="width: 50%; text-align: center; padding: 5px;">Dor Articular</th> </tr> </thead> <tbody> <tr> <td style="padding: 5px;"><input type="checkbox"/> 0 Nenhuma</td> <td style="padding: 5px;"><input type="checkbox"/> 0 Nenhuma</td> </tr> <tr> <td style="padding: 5px;"><input type="checkbox"/> 1 Direito</td> <td style="padding: 5px;"><input type="checkbox"/> 1 Direito</td> </tr> <tr> <td style="padding: 5px;"><input type="checkbox"/> 2 Esquerdo</td> <td style="padding: 5px;"><input type="checkbox"/> 2 Esquerdo</td> </tr> <tr> <td style="padding: 5px;"><input type="checkbox"/> 3 Ambos</td> <td style="padding: 5px;"><input type="checkbox"/> 3 Ambos</td> </tr> </tbody> </table> <p><b>c. Abertura máxima com auxílio</b> <input type="text"/> <input type="text"/> mm</p> <table border="1" style="width: 100%; border-collapse: collapse; margin-top: 10px;"> <thead> <tr> <th style="width: 50%; text-align: center; padding: 5px;">Dor Muscular</th> <th style="width: 50%; text-align: center; padding: 5px;">Dor Articular</th> </tr> </thead> <tbody> <tr> <td style="padding: 5px;"><input type="checkbox"/> 0 Nenhuma</td> <td style="padding: 5px;"><input type="checkbox"/> 0 Nenhuma</td> </tr> <tr> <td style="padding: 5px;"><input type="checkbox"/> 1 Direito</td> <td style="padding: 5px;"><input type="checkbox"/> 1 Direito</td> </tr> <tr> <td style="padding: 5px;"><input type="checkbox"/> 2 Esquerdo</td> <td style="padding: 5px;"><input type="checkbox"/> 2 Esquerdo</td> </tr> <tr> <td style="padding: 5px;"><input type="checkbox"/> 3 Ambos</td> <td style="padding: 5px;"><input type="checkbox"/> 3 Ambos</td> </tr> </tbody> </table> <p><b>d. Trespasse incisal vertical</b> <input type="text"/> <input type="text"/> mm</p>		Dor Muscular	Dor Articular	<input type="checkbox"/> 0 Nenhuma	<input type="checkbox"/> 0 Nenhuma	<input type="checkbox"/> 1 Direito	<input type="checkbox"/> 1 Direito	<input type="checkbox"/> 2 Esquerdo	<input type="checkbox"/> 2 Esquerdo	<input type="checkbox"/> 3 Ambos	<input type="checkbox"/> 3 Ambos	Dor Muscular	Dor Articular	<input type="checkbox"/> 0 Nenhuma	<input type="checkbox"/> 0 Nenhuma	<input type="checkbox"/> 1 Direito	<input type="checkbox"/> 1 Direito	<input type="checkbox"/> 2 Esquerdo	<input type="checkbox"/> 2 Esquerdo	<input type="checkbox"/> 3 Ambos	<input type="checkbox"/> 3 Ambos
Dor Muscular	Dor Articular																				
<input type="checkbox"/> 0 Nenhuma	<input type="checkbox"/> 0 Nenhuma																				
<input type="checkbox"/> 1 Direito	<input type="checkbox"/> 1 Direito																				
<input type="checkbox"/> 2 Esquerdo	<input type="checkbox"/> 2 Esquerdo																				
<input type="checkbox"/> 3 Ambos	<input type="checkbox"/> 3 Ambos																				
Dor Muscular	Dor Articular																				
<input type="checkbox"/> 0 Nenhuma	<input type="checkbox"/> 0 Nenhuma																				
<input type="checkbox"/> 1 Direito	<input type="checkbox"/> 1 Direito																				
<input type="checkbox"/> 2 Esquerdo	<input type="checkbox"/> 2 Esquerdo																				
<input type="checkbox"/> 3 Ambos	<input type="checkbox"/> 3 Ambos																				

5. Ruídos articulares (palpação)	
<b>a. abertura</b>	
<b>Direito</b>	<b>Esquerdo</b>
<input type="checkbox"/> 0 Nenhum	<input type="checkbox"/> 0 Nenhum
<input type="checkbox"/> 1 Estalido	<input type="checkbox"/> 1 Estalido
<input type="checkbox"/> 2 Crepitação grosseira	<input type="checkbox"/> 2 Crepitação grosseira
<input type="checkbox"/> 3 Crepitação fina	<input type="checkbox"/> 3 Crepitação fina
<input type="text"/> <input type="text"/> mm	<input type="text"/> <input type="text"/> mm
<i>(Medida do estalido na abertura)</i>	
<b>b. Fechamento</b>	
<b>Direito</b>	<b>Esquerdo</b>
<input type="checkbox"/> 0 Nenhum	<input type="checkbox"/> 0 Nenhum
<input type="checkbox"/> 1 Estalido	<input type="checkbox"/> 1 Estalido
<input type="checkbox"/> 2 Crepitação grosseira	<input type="checkbox"/> 2 Crepitação grosseira
<input type="checkbox"/> 3 Crepitação fina	<input type="checkbox"/> 3 Crepitação fina
<input type="text"/> <input type="text"/> mm	<input type="text"/> <input type="text"/> mm
<i>(Medida do estalido no fechamento)</i>	
<b>c. Estalido recíproco eliminado durante abertura protrusiva</b>	
<b>Direito</b>	<b>Esquerdo</b>
<input type="checkbox"/> 0 Não	<input type="checkbox"/> 0 Não
<input type="checkbox"/> 1 Sim	<input type="checkbox"/> 1 Sim
<input type="checkbox"/> 8 NA	<input type="checkbox"/> 8 NA
<i>(NA: Nenhuma das opções acima)</i>	
<b>6. Excursões</b>	
<b>a. Excursão lateral direita</b> <input type="text"/> <input type="text"/> mm	
<b>Dor Muscular</b>	<b>Dor Articular</b>
<input type="checkbox"/> 0 Nenhuma	<input type="checkbox"/> 0 Nenhuma
<input type="checkbox"/> 1 Direito	<input type="checkbox"/> 1 Direito
<input type="checkbox"/> 2 Esquerdo	<input type="checkbox"/> 2 Esquerdo
<input type="checkbox"/> 3 Ambos	<input type="checkbox"/> 3 Ambos
<b>b. Excursão lateral esquerda</b> <input type="text"/> <input type="text"/> mm	
<b>Dor Muscular</b>	<b>Dor Articular</b>
<input type="checkbox"/> 0 Nenhuma	<input type="checkbox"/> 0 Nenhuma
<input type="checkbox"/> 1 Direito	<input type="checkbox"/> 1 Direito
<input type="checkbox"/> 2 Esquerdo	<input type="checkbox"/> 2 Esquerdo
<input type="checkbox"/> 3 Ambos	<input type="checkbox"/> 3 Ambos
<b>c. Protrusão</b> <input type="text"/> <input type="text"/> mm	
<b>Dor Muscular</b>	<b>Dor Articular</b>
<input type="checkbox"/> 0 Nenhuma	<input type="checkbox"/> 0 Nenhuma
<input type="checkbox"/> 1 Direito	<input type="checkbox"/> 1 Direito
<input type="checkbox"/> 2 Esquerdo	<input type="checkbox"/> 2 Esquerdo
<input type="checkbox"/> 3 Ambos	<input type="checkbox"/> 3 Ambos

d. Desvio de linha média <input type="text"/> <input type="text"/> mm									
<input type="checkbox"/>	Direito								
<input type="checkbox"/>	Esquerdo								
<input type="checkbox"/>	NA								
(NA: Nenhuma das opções acima)									
<b>7. Ruídos articulares nas excursões</b>									
<b>Ruídos direito</b>									
		Nenhum	Estalido	Crepitação grosseira	Crepitação fina				
<b>7.a Excursão Direita</b>		0	1	2	3				
<b>7.b Excursão Esquerda</b>		0	1	2	3				
<b>7.c Protrusão</b>		0	1	2	3				
<b>Ruídos esquerdo</b>									
		Nenhum	Estalido	Crepitação grosseira	Crepitação fina				
<b>7.d Excursão Direita</b>		0	1	2	3				
<b>7.e Excursão Esquerda</b>		0	1	2	3				
<b>7.f Protrusão</b>		0	1	2	3				
<b>INSTRUÇÕES, ÍTENS 8-10</b>									
O examinador irá palpar (tocando) diferentes áreas da sua face, cabeça e pescoço. Nós gostaríamos que você indicasse se você não sente dor ou apenas sente pressão (0), ou dor (1-3). Por favor, classifique o quanto de dor você sente para cada uma das palpações de acordo com a escala abaixo. Marque o número que corresponde a quantidade de dor que você sente. Nós gostaríamos que você fizesse uma classificação separada para as palpações direita e esquerda.									
0 = Somente pressão (sem dor)									
1 = dor leve									
2 = dor moderada									
3 = dor severa									
<b>8. Dor muscular extraoral com palpação</b>									
	<b>Direita</b>				<b>Esquerda</b>				
<b>a. Temporal posterior</b> (1,0 Kg.) "Parte de trás da têmpora (atrás e imediatamente acima das orelhas)."	0	1	2	3	0	1	2	3	
<b>b. Temporal médio</b> (1,0 Kg.) "Meio da têmpora (4 a 5 cm lateral à margem lateral das sobrancelhas)."	0	1	2	3	0	1	2	3	
<b>c. Temporal anterior</b> (1,0 Kg.) "Parte anterior da têmpora (superior a fossa infratemporal e imediatamente acima do processo zigomático)."	0	1	2	3	0	1	2	3	
<b>d. Masseter superior</b> (1,0 Kg.) "Bochecha/ abaixo do zigoma (comece 1 cm a frente da ATM e imediatamente abaixo do arco zigomático, palpando o músculo anteriormente)."	0	1	2	3	0	1	2	3	
<b>e. Masseter médio</b> (1,0 Kg.) "Bochecha/ lado da face (palpe da borda anterior descendo até o ângulo da mandíbula)."	0	1	2	3	0	1	2	3	
<b>f. Masseter inferior</b> (1,0 Kg.) "Bochecha/ linha da mandíbula (1 cm superior e anterior ao ângulo da mandíbula)."	0	1	2	3	0	1	2	3	
<b>g. Região mandibular posterior</b> (estilo-hióideo/ região posterior do digástrico) (0,5 Kg.) "Mandíbula/ região da garganta (área entre a inserção do esternocleidomastóideo e borda posterior da mandíbula. Palpe imediatamente medial e posterior ao ângulo da mandíbula)."	0	1	2	3	0	1	2	3	
<b>h. Região submandibular</b> (pterigóideo medial/ supra-hióideo/ região anterior do digástrico) (0,5 Kg.) "abaixo da mandíbula (2 cm a frente do ângulo da mandíbula)."	0	1	2	3	0	1	2	3	
<b>9. Dor articular com palpação</b>									
<b>a. Polo lateral</b> (0,5 Kg.) "Por fora (anterior ao trago e sobre a ATM)."	0	1	2	3	0	1	2	3	
<b>b. Ligamento posterior</b> (0,5 Kg.) "Dentro do ouvido (pressione o dedo na direção anterior e medial enquanto o paciente está com a boca fechada)."	0	1	2	3	0	1	2	3	
<b>10. Dor muscular intraoral com palpação</b>									
<b>a. Área do pterigóideo lateral</b> (0,5 Kg.) "Atrás dos molares superiores (coloque o dedo mínimo na margem alveolar acima do último molar superior. Mova o dedo para distal, para cima e em seguida para medial para palpar)."	0	1	2	3	0	1	2	3	
<b>b. Tendão do temporal</b> (0,5 Kg.) "Tendão (com o dedo sobre a borda anterior do processo coronóide, mova-o para cima. Palpe a área mais superior do processo)."	0	1	2	3	0	1	2	3	

### ANEXO C – Índice Anamnésico de Fonseca (IAM)

**Nome do Paciente:** \_\_\_\_\_ **Ficha:** \_\_\_\_\_

**Data:** \_\_\_\_/\_\_\_\_/\_\_\_\_

Pergunta	Sim (10)	Não (0)	Às vezes (5)
Sente dificuldade para abrir a boca?	_____	_____	_____
Você sente dificuldades para movimentar sua mandíbula para os lados?	_____	_____	_____
Tem cansaço/dor muscular quando mastiga?	_____	_____	_____
Sente dores de cabeça com frequência?	_____	_____	_____
Sente dor na nuca ou torcicolo?	_____	_____	_____
Tem dor de ouvido ou na região das articulações (ATMs)?	_____	_____	_____
Já notou se tem ruídos na ATM quando mastiga ou quando abre a boca?	_____	_____	_____
Você já observou se tem algum hábito como apertar e/ou ranger os dentes (mascar chiclete, morder o lápis ou lábios, roer a unha)?	_____	_____	_____
Sente que seus dentes não se articulam bem?	_____	_____	_____
Você se considera uma pessoa tensa ou nervosa?	_____	_____	_____
Obtenção do índice:	Índice anamnésico		Grau de acometimento
Soma dos pontos atribuídos acima	0 - 15		Sem DTM
	20 - 40		DTM leve
	45 - 65		DTM moderada
	70 - 100		DTM severa

## ANEXO D – Normas da Revista

For guidelines regarding word count, figure/table count and references for all DMFR article types see [here](#).

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

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

### Author contribution statement

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

### Title page

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

**Blind title page**

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

**Abstract**

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

**Main text**

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

**In addition:**

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

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

## References

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

### Examples of references:

#### Journal article:

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

#### Journal article, in press:

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

#### Complete book:

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

#### Chapter in book:

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

#### Abstract:

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

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

**Letter to the Editor:**

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

**Journal article on the internet:**

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

**Homepage/Web site:**

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

**Tables**

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

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

**Figures**

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

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

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

### **Files**

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

### **Colour**

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

### **Resolution**

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

### **Composition**

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

### **Additional points to note:**

- Do not put a box around graphs, diagrams or other artwork.
- Avoid background gridlines unless these are essential (e.g. confidence limits).

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

### **Appendices**

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

### **Supplementary material**

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

### **Units, symbols and statistics**

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

### **Statistical Guidelines**

The aim of the study should be clearly described and a suitable design, incorporating an

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

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

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

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

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

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

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

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