

## Identificação de regiões císticas dentárias em imagens de radiografia panorâmica utilizando algoritmos de segmentação e classificação por textura

Danilo Alves Oliveira\*. Leila Maria Rodrigues de Sousa\*\*. Marcelo Bonifácio da Silva Sampieri\*\*\*. Filipe Nobre Chaves\*\*\*\*. Iális Cavalcante de Paula Júnior\*.

\*Programa de Pós-Graduação em Engenharia Elétrica e Computação, Universidade Federal do Ceará (UFC)

\*\*Graduação em Engenharia da Computação, Universidade Federal do Ceará (UFC)

\*\*\* Graduação em Odontologia, Universidade Federal do Ceará (UFC)

E-mails: danilo.alves@alu.ufc.br, rodrigues.leila@gmail.com, mar\_sampieri@hotmail.com, filipenobrechaves@gmail.com, ialis@sobral.ufc.br

**Abstract:** The dental cyst is a pathology that presents characteristics of expansion and bone absorption, its early identification is fundamental for the treatment. Several computer vision systems seek to carry out the identification of cysts. Therefore, the present research aims to provide a methodology for automatic identification of cystic regions in radiographic examinations. For this, investigations of initial segmentation algorithms and texture descriptors applied in a neural network are carried out. The best initial segmentation results were from the Otsu multilevel, with accuracy of 68.56%, sensitivity of 66.29% and specificity of 68.10%. The best mean final classification results were LBP, with 92.97% accuracy, 89.24% sensitivity and 96.68% specificity.

**Resumo:** O cisto dentário é uma patologia que apresenta características de expansão e absorção óssea, sua identificação precoce é fundamental para o tratamento. Diversos sistemas de visão computacional buscam realizar a identificação dos cistos. Dessa forma, a presente pesquisa tem o objetivo de fornecer uma metodologia para identificação automática de regiões císticas em exames de radiografia. Para isso, são realizadas investigações de algoritmos de segmentação inicial e descritores de textura aplicados em uma rede neural. Os melhores resultados de segmentação inicial foram do multinível de Otsu, com acurácia de 68,56%, sensibilidade de 66,29% e especificidade de 68,10%. Os melhores resultados médios de classificação final foram do LBP, com 92,97% de acurácia, 89,24% de sensibilidade e 96,68% de especificidade.

**Keywords:** Cystic region; segmentation; texture classification;

**Palavras-chaves:** Região cística; segmentação; classificação de textura;

### 1. INTRODUÇÃO

A radiografia é de grande importância para identificação de anomalias dentárias, principalmente porque a maioria destas possuem localização de difícil visualização, como exemplo, em tecidos lisos ou sob a placa cortical. Além disso, ela também é necessária ao tratamento, seja para o planejamento de intervenções cirúrgicas ou acompanhamento do progresso destas (Li et al. 2007).

Essas imagens mostram detalhes de estruturas externas e internas da região bucal, como canais radiculares dos dentes e região da gengiva (Lakhani et al. 2016). Sendo necessárias para diagnóstico de diversas patologia e anomalias bucais, devido a inspeção visual não ser o suficiente.

O cisto odontológico é uma das doenças possíveis de identificar com essas imagens e apresenta uma variedade de desordem na mandíbula humana. Essas são classificadas clinicamente como cistos ou tumores (Nurtanio et al. 2013). As desordens podem ser causadas pelo crescimento de cistos

que inflam reabsorvendo a região óssea e pressionando outras estruturas anatômicas, provocando dor ao paciente (Banumathii et al. 2005).

Os cistos são clinicamente definidos como cavidades patológicas, possuem cápsula, epitélio e são conhecidos por apresentar preenchimento líquido ou mole, semelhantes a sacos ou bolsas. A parede do cisto atua como uma membrana semipermeável, permeável na direção do líquido e não permeável na direção externa sólida, isso permite que seu crescimento seja expansivo (Mikulka et al. 2012).

Devido essa capacidade de expansão, torna-se necessário a identificação dessas patologias com antecedência, seja para prevenir seu avanço ou evitar forte dor no paciente (Banumathii et al. 2005). Segundo Nurtanio et al. (2011) a identificação precoce da lesão cística previne o gasto que seria usado no tratamento avançado e auxilia em maior simplicidade na prática clínica. Dessa forma, diversas pesquisas de visão computacional têm sido desenvolvidas para auxiliar a identificação e diagnóstico de cistos em imagens radiográficas (Devi et al. 2018; Alsmadi 2018; Birdal et al. 2016).

Baseado na importância que sistemas de identificação de cistos apresentam para o meio clínico e acadêmico, o presente trabalho tem como objetivo apresentar uma metodologia para identificação de regiões císticas em imagens de radiografia panorâmica. Para isso é utilizando uma análise de algoritmos de segmentação inicial e classificação por textura de candidatos a cistos. A segmentação inicial consiste em separar as regiões da imagem primária, afim de manter as mais semelhantes à patologia buscada. A classificação por textura consiste na extração de características de textura de regiões císticas e não-císticas, para aplicá-las em um algoritmo de aprendizagem de máquina e obter sua correta identificação.

A análise da segmentação inicial é feita através da comparação das técnicas de multinível de Otsu, limiarização adaptativa, *k-means* e *watershed*, buscando a que separa melhor o cisto do restante da imagem. Os descritores de textura investigados são o *Local Binary Patterns* (LBP) e de Haralick. Essas texturas são aplicadas no algoritmo de Redes Neurais Artificiais (RNA), verificando qual descritor e sua configuração de janela que apresenta melhor resultado na identificação final do cisto.

Na seção 2, apresenta-se uma revisão bibliográfica relacionada a identificação de cistos odontológicos em imagens de radiografia. Na seção 3, são descritas as técnicas utilizadas na pesquisa e o banco de imagens. A seção 4 descreve a metodologia desenvolvida, com pré-processamento, abordagem para obtenção da região mandibular e aplicação dos algoritmos. Os resultados obtidos são apresentados e discutidos na seção 5. Por fim, na seção 6 são consideradas as conclusões e trabalhos futuros dessa pesquisa.

## 2. REVISÃO BIBLIOGRÁFICA

Na literatura, diversos esforços foram realizados relacionados a identificação de cistos odontológicos. Para este fim, utilizaram diversas técnicas, baseadas em curvas geodésicas, lógica fuzzy, proximidade por regiões, aprendizado de máquinas, entre outros.

Devi et al. (2018) propuseram uma técnica automatizada e híbrida para detectar e extrair a região cística usando propriedades simétricas de curvas geodésicas *isophotes* e o *fast method marching* (FMM). A segmentação utilizada é baseada a partir do máximo isocentro das curvas obtidas. Nesse ponto é aplicado o FMM e obtido a região cística. O método foi testado com 3 imagens de radiografia e comparado com outros 4 métodos de segmentação, em que obteve maiores resultados com acurácia média de 95%.

Alsmadi (2018) desenvolveu um método automático para detecção e segmentação de lesões ocasionadas por cistos e tumores na mandíbula, utilizando imagens de radiografia panorâmicas. O método proposto utiliza a lógica do Fuzzy C-mean (NFCM) para a segmentação. Os testes foram realizados com 95 exames e comparado com híbridos do Fuzzy C-mean com outros algoritmos, obtendo a maior taxa de similaridade com 94,71%.

Birdal et al. (2016) propuseram uma metodologia automatizada para detecção de lesões periapicais ocasionadas por cistos ou outros fatores, utilizando imagens de radiografia

panorâmica. A técnica consiste dos seguintes módulos: separação das mandíbulas, utilizando transformada *wavelet* com regressão polinomial, localização das raízes e aplicação de crescimento de região. O método foi testado em 9 imagens e obteve sensibilidade de 70% e especificidade de 89%.

Nurtanio et al. (2013) desenvolveram um sistema de classificação de cistos assistida por computador, através de radiografias panorâmicas. A proposta utiliza a segmentação através da região de interesse e texturas estatísticas de primeira ordem, matriz de co-ocorrência de nível de cinza e comprimento de primitiva a nível de cinza. As características foram classificadas usando o *Support Vector Machine* (SVM) e testadas com 39 imagens, obtendo melhor acurácia de 87,18%.

Estas pesquisas demonstram o desempenho do desenvolvimento de sistemas para auxílio ao diagnóstico de cistos odontológicos. Observa-se que as diferentes metodologias utilizadas carecem de uma análise detalhada da segmentação inicial da imagem. Nesse trabalho, essa etapa é explorada na busca de avaliar algoritmos de segmentação. Além disso, também é aplicada uma nova metodologia de identificação, através da investigação da variação das janelas amostrais das texturas de LBP e Haralick empregadas em uma RNA.

## 3. MATERIAIS E MÉTODOS

Nesta seção são apresentados os fundamentos teóricos dos principais métodos utilizados. São explanados o banco de imagens, os algoritmos de segmentação e os descritores de textura.

### 3.1. Banco de imagens

O banco de imagens utilizado na pesquisa foi adquirido com ajuda do curso de Odontologia da Universidade Federal do Ceará (UFC) – campus Sobral. São imagens de radiografia panorâmica de dimensões 1030x500, com presença de diversificados tipos de cistos. A base é composta por 38 imagens e as marcações do *ground truth* foram realizadas por dois professores especialistas.

### 3.2. Algoritmos de segmentação

Nessa pesquisa, realiza-se uma análise comparativa da aplicação em imagens odontológicas de quatro técnicas clássicas de segmentação: multinível de Otsu, limiarização adaptativa, *k-means* e *watershed*.

O método de multinível de Otsu busca determinar valores de limiares ideais que separem os pixels da imagem em grupos. Sua abordagem busca maximizar a variância entre as classes, definida por:

$$\sigma^2(T_1, T_2, \dots, T_k) = P_1(m_1 - m_G)^2 + P_2(m_2 - m_G)^2 + \dots + P_{k+1}(m_{k+1} - m_G)^2. \quad (1)$$

Considerando  $n \in (1, 2, \dots, k)$ , temos que,  $T_n$  representam os limiares,  $P_n(k)$  é a probabilidade do nível de cinza  $k$  ser da classe  $n$ ,  $m_n$  são as taxas médias dos pixels atribuídos às classes e  $m_G$  é a intensidade média global (Liao et al. 2001).

A limiarização adaptativa utilizada é proposta por Bradley e Roth (2007), em que seu limiar é obtido com base na intensidade média local de cada pixel, seguindo estatísticas de primeira ordem. Em sua abordagem, é calculada a média de uma janela centrada em torno de cada pixel da imagem inicial.

A segmentação baseada em transformada *watershed* utiliza linhas divisórias para separar as áreas buscadas. Nessa técnica a imagem é interpretada como um relevo topográfico. Considera-se que ocorra uma inundação na imagem, a água primeiramente preenche os vales, quando estes sobem de nível e encontra a água de outro vale ocorre a formação da divisória, o processo termina quando a água atinge seu relevo (Gonzalez e Woods 2006).

O *k-means* é um algoritmo não supervisionado que permite o agrupamento de acordo com características dos próprios dados. Sua clusterização é obtida a partir da quantidade *k* de grupos desejados. Em uma imagem, sua segmentação é realizada buscando formar os clusters de acordo a intensidade dos pixels (Gonzalez e Woods 2006).

### 3.3. Local Binary Patterns

Este algoritmo descreve a imagem através de análises de cada pixel, comparando com uma vizinhança, essa comparação gera um código binário chamado de LBP. Com os LBPs de uma região são formados histogramas que os representam. As equações 2 e 3 apresentam o cálculo do código.

$$LBP_{p,R} = \sum_{p=0}^{p-1} s(g_p - g_c)2^p \quad (2)$$

$$s = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3)$$

Nesse cálculo  $g_c$  é o pixel central em valor de cinza,  $g_p$  é o valor de cinza do pixel vizinho corrente,  $p$  é o valor do vizinho corrente,  $R$  é o raio da vizinhança e  $s$  é a função de limiarização (Ojala et al. 2002).

### 3.4. Descritor de Haralick

Os descritores de Haralick são medidas estatísticas calculadas através de uma matriz de co-ocorrência, elas representam a textura de uma imagem. Essa matriz contém a quantidade de ocorrências de combinações dos níveis de cinza de acordo com a orientação e a distância considerada.

Essa matriz é obrigatoriamente quadrada e suas dimensões modificam de acordo com a variação de tons de cinza da imagem de entrada. Através dessa matriz são realizados os cálculos para extrair os 14 descritores de Haralick, parâmetros que representam estatísticas de segunda ordem (Haralick et al. 1973).

### 3.5. Métricas de avaliação

As estatísticas utilizadas na avaliação da segmentação e classificação baseiam-se em analisar a resposta do algoritmo com a resposta correta do *ground truth*.

Com essa análise são obtidos os valores de Verdadeiro Positivo (VP), Verdadeiro Negativo (VN), Falso Positivo (FP) e Falso Negativo (FN). VPs são amostras císticas que são

corretamente selecionadas pelos algoritmos. As VNs são amostras não-císticas que são corretamente selecionadas pelos algoritmos. FPs são amostras não-císticas que são selecionadas como císticas pelos algoritmos. E por fim, FNs são amostras císticas que são selecionadas como não-císticas pelos algoritmos.

Através desses valores são calculadas as estatísticas de Acurácia (Ac), sensibilidade (Se) e especificidade (Es) demonstradas nas equações 4, 5 e 6, respectivamente.

$$Ac = \frac{VP+VN}{VP+VN+FP+FN} \quad (4)$$

$$Se = \frac{VP}{VP+FN} \quad (5)$$

$$Es = \frac{VN}{VN+FP} \quad (6)$$

A acurácia é a relação entre todas as verificações corretas, representa a taxa de acerto total, a sensibilidade é a taxa que indica a aptidão de selecionar corretamente uma amostra cística e a especificidade é a taxa que indica a aptidão de selecionar corretamente uma amostra não-cística.

## 4. METODOLOGIA

Para realizar a identificação de cistos são necessários diversos procedimentos. Estes procedimentos são realizados em quatro etapas: aquisição e pré-processamento, obtenção da região de interesse, aplicação das segmentações, e por fim, extração e classificação. Essas etapas são ilustradas na Figura 1

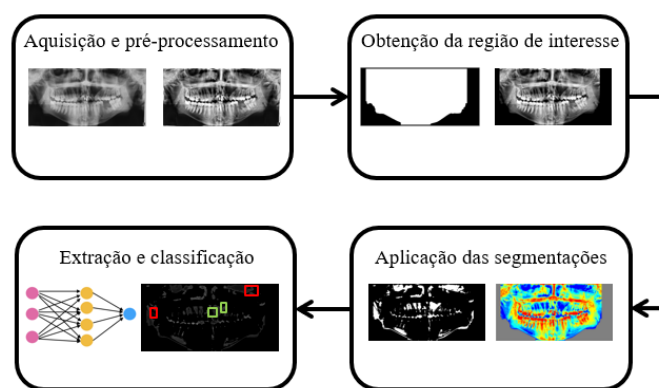


Fig. 1 Metodologia proposta.

As técnicas utilizadas no pré-processamento têm o objetivo de filtrar ruídos presentes nas imagens e de melhorar o contraste de suas estruturas. Na obtenção da região de interesse, é buscado manter somente a área interna da mandíbula, com o objetivo de limitar a busca nas regiões de interesse, reduzindo o processamento do algoritmo.

A próxima etapa aplica as técnicas de segmentação dentro da região obtida, buscando separar as regiões com maior possibilidade de cisto das demais. Por fim, a etapa final, extrai as duas características de textura das regiões para serem aplicadas a um algoritmo de classificação.

#### 4.1. Aquisição e pré-processamento

Os valores de referência do *ground truth* do banco foram marcados por 2 professores especialistas do curso de Odontologia. Ao todo, foram encontrados 28 cistos de diversos tipos.

O pré-processamento é uma etapa de grande importância, principalmente para imagens médicas, onde existe presença de ruído significativo. Nessa pesquisa é utilizado o filtro gaussiano com  $\sigma=1$ , buscando remover ruídos e atenuar sinais de alta frequência.



Fig. 2 Operação de pré-processamento. (a) imagem de entrada; (b) imagem processada com filtro e realce de contraste.

Após isso, é realizado uma operação de contraste na imagem, com o objetivo de realçar as regiões císticas. A técnica aplicada é baseada em Birdal et al. (2016), que utiliza operações aritméticas com as transformações de Top-hat e Bottom-hat.

A Figura 2 apresenta o pré-processamento com a marcação do cisto em vermelho, a Figura 2a ilustra o exame inicial e a Figura 2b o resultado do pré-processamento.

#### 4.2. Obtenção da região de interesse

Esta etapa busca obter a região da estrutura mandibular do paciente, devido o cisto apresenta-se em sua área interna. Para isto, é formada uma máscara automática que busca remover as zonas externas da mandíbula, geralmente formada pelo ar, ruídos ou estruturas que não são de interesse. O processo de obtenção dessa máscara é ilustrado na Figura 3.

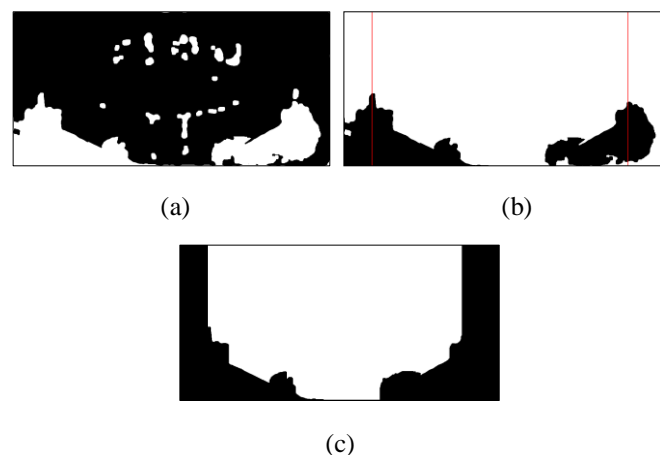


Fig. 3 Processo de obtenção da RI. (a) limiarização da imagem pré-processada; (b) seleção da região interna e limites laterais; (c) máscara final.

Primeiramente, uma operação de limiarização interativa é realizada na imagem pré-processada. Aplica-se um valor de limiar inicial, buscando manter as regiões mais escuras com tom de cinza de 255 e as mais claras com 0. Após isso, é analisado se a área das duas maiores regiões brancas é maior que 20000 pixels. Em caso positivo, esse é o limiar buscado; em caso contrário, o valor de limiar é incrementado até atingir a condição. O resultado dessa operação é mostrado na Figura 3a.

Em seguida, são selecionadas para uma nova imagem apenas as duas maiores regiões com tom de cinza 255, correspondentes às áreas externas da mandíbula. Os tons são invertidos e com a imagem resultante são buscados os maiores picos de pixels pretos, com objetivo de selecionar a área entre eles. A Figura 3b, mostra o resultado desse processo e exhibe em vermelho as linhas encontradas nos limites dos picos.

A Figura 3c destaca o resultado da máscara final. As regiões laterais aos limites encontrados são removidas, e o contorno da mandíbula é percorrido eliminando qualquer região abaixo dele. Os algoritmos de segmentação serão aplicados na área do exame correspondente a essa máscara.

#### 4.3. Aplicação das Segmentações

Os algoritmos de segmentação são aplicados no resultado da interseção da máscara com a imagem pré-processada. O objetivo é separar as regiões internas da mandíbula para selecionar as mais semelhantes ao cisto dentro dessa área. São utilizadas as técnicas de multinível de Otsu, limiarização adaptativa, *watershed* e *k-means*.

O algoritmo de multinível de Otsu é utilizado com 4 limiares e o *k-means* com 4 clusters, valores obtidos através de testes de variação de quantidade e análise da acurácia e porcentagem da área cística mantida nas regiões selecionadas.

No limiar adaptativo o parâmetro do tamanho da janela da vizinhança é escolhido baseado por

$$s = 2 \cdot \text{Int\_min}\left(\frac{S}{16}\right) + 1, \quad (7)$$

em que,  $S$  são as dimensões da imagem e  $\text{Int\_min}$  retorna o inteiro mais próximo menor ou igual ao valor informado. O valor obtido com a equação 7 é de uma vizinhança com dimensões 63x129 para cada pixel da imagem.

Na transformada *watershed* é utilizado vizinhança-8 para verificar o encontro das inundações. Entre as regiões fornecidas, são selecionadas aquelas com rótulos entre 6 e 200, valor obtido pela verificação da maior presença de cisto nesses valores.

A Figura 4 demonstra as imagens obtidas com o processo de segmentação. A Figura 4a ilustra as classes separadas pelo método de multinível de Otsu. A Figura 4b ilustra o método de limiarização adaptativa. Na Figura 4c é apresentado a segmentação da *watershed*. Por fim, a Figura 4d demonstra a aplicação do *k-means*. Em cada técnica é escolhido o grupo de regiões que predomina na área cística, afim de avaliar e escolher o melhor algoritmo para esta etapa.

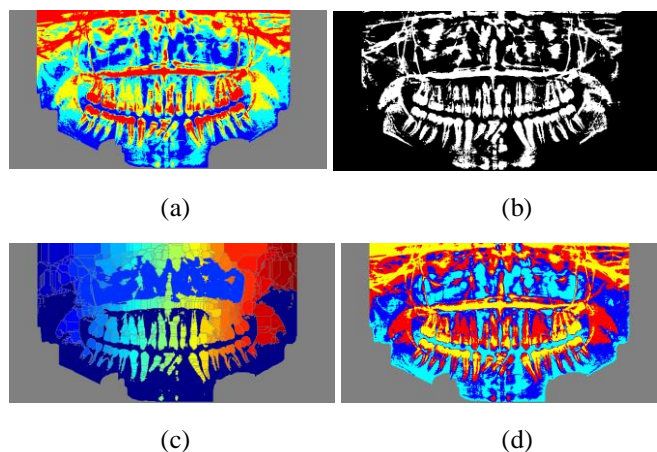


Fig. 4 Aplicação das segmentações. (a) multinível de Otsu; (b) limiarização adaptativa; (c) watershed; (d) k-means.

#### 4.4. Extração e classificação

Após aplicadas as segmentações e escolhido o melhor algoritmo, as texturas das regiões obtidas como semelhantes são extraídas para serem classificadas pela rede. Esse processo é feito através da convolução de janelas com dimensões 13x13, 15x15, 17x17, 19x19, 21x21, 23x23, 25x25, 27x27 e 29x29 nas regiões obtidas. Para cada pixel das regiões são extraídas as texturas de LBP e Haralick para sua vizinhança nas dimensões das janelas. Na extração do LBP são obtidas 10 características de texturas, na extração de textura Haralick para cada janela é calculada a matriz de co-ocorrência dos níveis de cinza e obtidas suas 12 características. Essas são as entradas da rede neural para cada descritor.

Os bancos de características são formados para cada variação de janela, com 55142 amostras para cada textura, sendo 27571 amostras de cistos e não-cistos. As amostras desses bancos são separadas em dois grupos, para treinamento e teste do modelo de aprendizagem. O algoritmo utilizado é a rede neural artificial *Multi-layer Perceptron* (MLP), um modelo que utiliza mais de uma camada com neurônios conectados e apresenta características de classificação não linear. Sua configuração apresenta 60 neurônios na camada intermediária, função de ativação sigmoide, treinamento com o algoritmo *Backpropagation* e otimização por *Levenberg-Marquardt*.

### 5. RESULTADOS E DISCURSSÃO

Os métodos foram aplicados na base coletada. Sua implementação foi feita em MATLAB® e executada em um PC com processador Intel core i7 e 8 GB de memória RAM.

As etapas da metodologia influenciam significativamente nos resultados finais. A primeira reduz o ruído e realça as estruturas, que melhora a diferenciação do cisto e qualidade do descritor extraído. Na segunda etapa, a obtenção da região mandibular influencia na redução da imagem e garante que as buscas serão realizadas dentro da mandíbula. A terceira e quarta etapa apresentam um estudo de algoritmos de segmentação e classificação por textura, que terão resultados apresentados nessa seção.

Os resultados são discutidos em duas etapas: resultados das segmentações e resultados das classificações de textura.

#### 5.1. Resultados das segmentações iniciais

Os algoritmos de segmentação são aplicados nos exames de acordo com a Seção 4.2, obtendo as regiões selecionadas para cada imagem. O gráfico da Figura 7 apresenta os resultados médios das métricas para os 38 exames em cada técnica de segmentação.




Fig. 5 Resultados dos algoritmos de segmentação inicial.

No gráfico da Figura 5, os maiores valores obtidos para cada métrica estão destacados em negrito. Dentre os valores observados, a maior acurácia média de 68,56% e a maior sensibilidade média de 66,29%, pertencem a segmentação do multinível de Otsu. Na especificidade o *k-means* apresenta a maior média de 68,65%.

A segmentação por *watershed* foi a única que apresentou todas as métricas abaixo de 60%, isso devido à instabilidade do algoritmo que apresentou grandes variações estatísticas entre os exames. A limiarização adaptativa tem a menor métrica média, com sensibilidade de 18,92%, ocasionada por apresentar grandes quantidades de FPs. Esse resultado pode ser entendido devido sua característica de selecionar por medidas locais os limiares, e isso ocasionar na adesão de diversas regiões não císticas a área de interesse.

De forma geral, o multinível de Otsu e o *k-means* apresentaram resultados próximos, com diferenças de 0,36% de acurácia, 0,97% de sensibilidade e 0,55 de especificidade. No entanto o multinível de Otsu demonstra-se superior obtendo máxima média em duas das métricas avaliadas.

#### 5.2. Resultados da classificação por textura

Os métodos descritos na seção 4.3 são aplicados nos resultados das segmentações do multinível de Otsu, obtendo as amostras para os descritores de textura LBP e Haralick em cada variação de janela investigada. A classificação dessas amostras como cística ou não-cística consiste na etapa final da metodologia proposta.

O método de validação da classificação utilizado é o *holdout*. A técnica consiste em separar uma porcentagem das amostras para treino do algoritmo de classificação e outra para testar sua aprendizagem. As amostras foram separadas em 70% para treino e 30% para teste.

Para cada variação de janela da textura LBP e Haralick, foram realizadas 10 execuções de treino e teste com a RNA,

utilizando a separação aleatória das amostras nessas execuções. Os valores médios dessas execuções foram utilizados para calcular as estatísticas de avaliação.

A Tabela 1 apresenta os resultados obtidos pela RNA para as variações de janelas nas duas texturas. Os valores destacados em negrito representam as maiores médias obtidas.

**Tabela 1. Resultados de classificação**

Janelas	Haralick			LBP		
	Ac(%)	Se(%)	Es(%)	Ac(%)	Se(%)	Es(%)
13x13	76,58	72,22	80,96	74,87	73,53	76,21
15x15	77,53	73,69	81,41	78,50	76,30	80,69
17x17	79,41	76,35	82,46	81,55	78,93	84,18
19x19	80,82	77,83	83,81	84,36	80,87	87,85
21x21	82,26	79,31	85,23	86,21	82,56	89,86
23x23	83,54	80,92	86,15	88,14	84,41	91,85
25x25	84,55	82,18	86,91	89,97	86,17	93,77
27x27	86,29	83,63	88,93	91,61	87,44	95,72
29x29	<b>86,88</b>	<b>84,32</b>	<b>89,42</b>	<b>92,97</b>	<b>89,24</b>	<b>96,68</b>

Analisando a variação de janelas, observa-se que o Haralick apresenta melhores resultados de acurácia e especificidade para as janelas de 13x13 e 15x15. Essas métricas são superadas pelo LBP a partir da janela 17x17 em diante. As maiores médias de sensibilidade em todas as variações testadas foi do LBP.

Conforme o aumento das janelas amostrais de textura, as taxas de acertos crescem. Esse efeito observado é devido áreas maiores conseguirem representar melhor as estruturas e permitir que a RNA classifique com melhores resultados.

Comparando os dois descritores, é possível observar que a textura de Haralick apresenta melhor representação das estruturas para janelas menores e o LBP para janelas maiores. Dessa forma o LBP possui maior crescimento das taxas com aumento da janela, atingindo as maiores médias observadas.

Nas duas texturas os melhores resultados foram obtidos com a janela de 29x29. O LBP resultou nas maiores médias da pesquisa, com acurácia de 92,97%, sensibilidade de 89,24% e especificidade de 96,68%.

## 6. CONCLUSÕES

Neste trabalho apresentou-se uma metodologia para identificação de cistos odontológicos, utilizando algoritmos de segmentação e classificação com textura por RNA.

A pesquisa cumpre o objetivo proposto, desenvolvendo uma metodologia para identificação de cistos. Os resultados demonstraram que o algoritmo de multinível de Otsu com 4 limiares resulta na melhor segmentação inicial. Também foi verificado que a textura LBP é superior a Haralick na aplicação testada. As melhores métricas foram do descritor LBP através da janela amostral de 29x29.

Para trabalhos futuros pretende-se implementar essa metodologia com mais imagens, novos descritores e realizar mais formas de validação na etapa de classificação. Também

pretende-se disponibilizar o banco de imagens com as marcações e os algoritmos utilizados na pesquisa em uma plataforma que está em desenvolvimento.

## REFERÊNCIAS

- Alsmadi, M. K. (2018) A hybrid Fuzzy C-Means and Neutrosophic for jaw lesions segmentation. *Ain Shams Engineering Journal*, 9(4), 697 – 706.
- Banumathii, A., Kannammai, A., Arthee, R., Raju, S., Abhaikumar, V. (2005) Automated Diagnosis and Severity Measurement of Cysts in Dental X-ray Images Using Neural Network. *Biomedical Soft Computing and Human Sciences*, 11(1), 15 – 19.
- Birdal, R. G., Gumus, E., Sertbas, A., Birdal, I. S. (2016) Automated lesion detection in panoramic dental radiographs. *Oral Radiology*, 32(1), 111 – 118.
- Bradley, D. and Roth, G. (2007) Adapting Thresholding Using the Integral Image. *Journal of Graphics Tools*, 12(2), 13 – 21.
- Devi, R. K., Banumathi, A., Ulaganathan, G. (2018) An automated and hybrid method for cyst segmentation in dental X-ray images. *Cluster Comput*, 21(80), 1 – 13.
- Gonzalez, R. C. and Woods, R. E. (2006). *Digital Image Processing*. Prentice-Hall, Upper Saddle River, NJ, USA.
- Haralick R., Shanmugam K., Dinstein I. (1973) Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, 6, 610–621.
- Jain, K. R. e Chauhan, N. C. (2017) An Automatic Segmentation Approach Towards the Objectification of Cyst Diagnosis in Periapical Dental Radiograph. *Information and Communication Technology for Intelligent Systems*, 1(1), 164 – 172.
- Lakhani, K., Minocha, B., Gugnani, N. (2016). Analyzing edge detection techniques for feature extraction in dental radiographs. *Perspectives in Science*, 8(1), 395-398.
- Liao, P. S., Chen, T. S., Chung, P. C. (2001) A Fast Algorithm for Multilevel Thresholding. *Journal of Information Science and Engineering*, 17(1), 713 – 727.
- Li, S., Fevens, T., Krzyzak, A., Jin, C., Li, S. (2007). Semi-automatic computer aided lesion detection in dental X-rays using variational level set. *Pattern Recognition*, 40(10), 2861–2873.
- Mikulka, J., Kabrda, M., Gescheidtová, E., Perina, V. (2012) Classification of Jawbone Cysts via Orthopantomogram Processing. *International Conference on Telecommunications and Signal Processing (TSP)*, 35(1), 499 – 502.
- Nurtanio, I., Astuti, E. R., Purnama, K. E., Hariadi, M., Purnomo, M. H. (2013) Classifying Cyst and Tumor Lesion Using Support Vector Machine Based on Dental Panoramic Images Texture Features. *IAENG International Journal of Computer Science*, 40(1), 29–37.
- Nurtanio, I., Purnama, K. R., Hariadi, M., Purnomo, M. H. (2011) Cyst and Tumor Lesion Segmentation on Dental Panoramic Images using Active Contour Models. *The Journal for Technology and Science*, 22(3), 152 – 158.
- Ojala T, Pietikainen M, Maenpaa T. (2002) Multiresolution grayscale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 34, 971–987.