

Técnicas de Processamento Digital de Imagens e Inteligência Artificial Aplicadas ao Diagnóstico Odontológico

Maria Alice Andrade Calazans¹, Maria de Lourdes Melo Guedes Alcoforado¹,
Francisco Madeiro¹

¹ Escola Politécnica de Pernambuco – Universidade de Pernambuco (UPE)
Recife, PE, Brasil

{maac, mlmga, madeiro}@poli.br

Abstract. *In Dentistry, imaging techniques assist in the analysis of inaccessible regions in clinical examination and, consequently, perform a crucial function in supporting diagnosis. The vast demand for images is motivation for the development of an automatic classification system that can be used for diagnostic support. In this work a modified version of the K-Means algorithm is applied to segmentation of panoramic radiographs, which led to slightly better results than those obtained with the conventional K-Means, Fuzzy K-Means and Morphological Chan Vese. In addition, an automatic classification system is proposed for detecting lesions on molar teeth in the maxillary region for cone beam computed tomography scans, with accuracy up to 81.25%.*

Resumo. *Na odontologia, técnicas de imageamento auxiliam na análise de regiões inacessíveis no exame clínico e, conseqüentemente, desempenham um papel fundamental no apoio ao diagnóstico. A vasta demanda por imagens é motivação para o desenvolvimento de um sistema de classificação automática que possa ser usado para suporte ao diagnóstico. Neste trabalho uma versão modificada do algoritmo K-Means é implementada para segmentação de radiografias panorâmicas, a qual levou a resultados levemente superiores aos obtidos com os algoritmos K-Means, Fuzzy K-Means e Morphological Chan Vese. Além disso, é proposto um sistema de classificação automática para detecção de lesões em dentes molares na região da maxila para tomografias computadorizadas de feixe cônico, com acurácia de até 81,25%.*

1. Introdução e Motivação

Na odontologia, o uso de exames de imagens é considerado indispensável, uma vez que é por meio destes que se torna possível a obtenção de informações sobre raízes dentárias e ossos faciais inacessíveis na rotina clínica [Nelson 2014].

A radiografia panorâmica é amplamente adotada na prática odontológica, já que expõe o paciente a uma baixa dosagem de radiação e sua imagem provê informações globais sobre a arcada do paciente [Molander 1996, Muresan et al. 2020]. Em contrapartida, por se tratar de um exame bidimensional, possui limitações associadas, como a sobreposição de estruturas [Goebel et al. 2005].

A tomografia computadorizada de feixe cônico é um exame também bastante aceito, principalmente, na endodontia, em que, a partir das imagens tridimensionais, é

possível diagnosticar lesões periapicais, avaliar tratamentos anteriores e verificar a necessidade de novos tratamentos [Scarfe et al. 2006, Silva et al. 2022]. Todavia, possui a desvantagem de expor o paciente a uma dosagem mais de quatro vezes maior que a radiografia e também é um método financeiramente mais dispendioso [Mozzo et al. 1998].

Com a crescente demanda por exames de imagens, ocorre um conseqüente aumento na solicitação de análise de imagem, que é um trabalho, por vezes, de alta complexidade e que exige do especialista uma vasta experiência e conhecimento da área, a fim de que possa oferecer um diagnóstico assertivo [Khanagar et al. 2021]. Nesse caso, os sistemas inteligentes se apresentam como possibilidade para amparo aos especialistas, atuando na segmentação, detecção e classificação [Silva et al. 2018]. A vantagem do uso de sistemas computacionais reside no fato de que podem prover aos odontólogos uma análise veloz, precisa e econômica [Schwendicke et al. 2019].

Este trabalho tem como objetivo avaliar técnicas para segmentação de radiografias panorâmicas odontológicas e desenvolver um sistema automático de classificação de tomografias computadorizadas para fins de diagnóstico odontológico, identificando a presença ou ausência de lesão endodôntica. Como contribuições, pode-se destacar o uso do *K-Means* Modificado, pois não há relatos anteriores de seu uso para segmentação de imagens odontológicas, e o uso de técnicas de aprendizagem profunda no auxílio ao diagnóstico para dentes na região posterior da maxila já tratados endodônticamente.

2. Materiais e Métodos

Este trabalho foi dividido em duas etapas. Inicialmente são avaliadas técnicas de segmentação de imagens aplicadas a radiografias panorâmicas odontológicas, em que os dentes e implantes são considerados como objetos de interesse a serem detectados. A segunda parte do trabalho consiste no desenvolvimento de um sistema de classificação automática, baseado em técnicas de aprendizagem profunda, para detecção de lesões endodônticas em imagens de tomografias computadorizadas de feixe cônico.

2.1. Segmentação de Radiografia Panorâmica

Para a segmentação de radiografias panorâmicas, utilizou-se a Base de Dados UFBA-UESC [Silva et al. 2018], que consiste em 1.500 radiografias panorâmicas de 1991×1127 pixels no formato JPG, agrupadas em dez categorias, de acordo com o número de dentes, presença ou ausência de implantes, restaurações e aparelho ortodôntico. Foram utilizadas quatro técnicas, das quais duas já possuem resultados relatados na literatura para esse mesmo conjunto de imagens: *K-Means* [Linde et al. 1980] e *Fuzzy K-Means* [Bezdek et al. 1984]. As outras duas técnicas foram o *K-Means* Modificado [Lee et al. 1997] e o *Morphological Chan Vese* [Chan and Vese 2001].

Para realizar a segmentação, foram considerados dois *clusters*, um com os objetos de interesse, que correspondem aos dentes e implantes, e um segundo, referente às regiões de fundo, ossos e tecidos. Para o *K-Means* Modificado foram considerados valores de fator de escala $s = 1,1$ até $s = 2,0$, com variações de 0,1, a fim de encontrar aquele que apresenta o melhor resultado e compará-lo com as demais técnicas.

2.2. Classificação de Tomografia Computadorizada de Feixe Cônico

A pesquisa foi aprovada pelo Comitê de Ética em Pesquisa da Universidade de Pernambuco, sob o parecer de número 4.881.124, em 03 de agosto de 2021. A Base de

Dados para a classificação automática de lesões endodônticas foi desenvolvida no Departamento de Clínica e Odontologia Preventiva da Universidade Federal de Pernambuco. O conjunto é composto por 1.000 dentes endodonticamente tratados, localizados na região posterior da maxila, com 115×186 *pixels* no formato PNG. Como a tomografia computadorizada é um exame tridimensional foram selecionados pares de cortes por dente, os cortes coronais e sagitais, de maneira que a análise seja mais segura e completa.

Os especialistas que realizaram a seleção das imagens para a elaboração da base de dados fizeram duas classificações para cada dente, a primeira referente à presença ou ausência de lesão periapical, e uma segunda, para os dentes que apresentam lesão, que diz respeito ao tamanho da lesão, pequena (0,5 a 1,9 mm) ou grande (acima de 2,0 mm).

A divisão para treino, teste e validação foi de 60%, 20% e 20%, respectivamente. O número de iterações foi de 150, com *batch size* de 32, otimizador RMSprop, taxa de aprendizagem de 0,001 e função de ativação sigmoide. Foi utilizada uma estratégia baseada na rede Siamesa, o que tornou possível a rede processar um par de imagens como entrada. Foi utilizado o aprendizado por transferência, com treinamento baseado na ImageNet [Deng et al. 2009]. As redes consideradas foram a DenseNet-121 [Huang et al. 2017] e a VGG-16 [Simonyan and Zisserman 2014], pois apresentaram melhor desempenho em relação às demais do pacote Keras. Foram usadas técnicas de aumento de dados (inversão horizontal, rotação e *zoom*), para um treinamento com um maior número de exemplos, porém de maneira que o objeto de interesse fosse preservado, sem interferir na análise. Por fim, foi adotado um *dropout* com taxa de 0,2.

As simulações foram realizadas para três cenários, um com a base de dados completa; outro considerando apenas os dentes sem lesões e os dentes com lesões pequenas; e um último cenário levando em conta os dentes sem lesões e com lesões grandes.

3. Resultados e Discussão

Os desempenhos, tanto para a segmentação de radiografias quanto para a classificação automática de tomografias, foram avaliados com o uso de cinco métricas: acurácia, *recall*, precisão, especificidade e *F1-score*.

3.1. Segmentação de Radiografia Panorâmica

Para a análise dos resultados das cinco métricas, os cálculos foram realizados para cada uma das dez categorias em que as imagens são distribuídas, porém, para a obtenção do desempenho final, foi feita uma média ponderada entre o resultado por categoria e o seu número de imagens, o que torna os valores finais mais legítimos.

Com relação ao *K-Means* Modificado, as variações de fator de escala apresentaram diferenças sutis, porém o fator de escala de 1,1 proveu um desempenho superior de acurácia, especificidade e precisão, e, por este motivo, foi escolhido para fins comparativos com os demais métodos, como apresentado na Tabela 1. Os valores em negrito são os melhores resultados de cada métrica. Observa-se que o *K-Means* Modificado é levemente superior às demais técnicas, em termos de acurácia, especificidade e precisão.

3.2. Classificação de Tomografia Computadorizada de Feixe Cônico

O sistema de classificação foi implementado em três cenários, sempre considerando as redes pré-treinadas DenseNet-121 e VGG-16, e usando a estratégia da rede Siamesa. Os resultados são dados sobre o conjunto de teste.

Tabela 1. Resultado por métrica para as técnicas distintas de segmentação.

Método	Métricas				
	Acurácia	F1-score	Especificidade	Precisão	Recall
<i>K-Means</i>	0,7862	0,5785	0,7956	0,5012	0,7556
<i>K-Means</i> Modificado (s = 1,1)	0,7893	0,5786	0,8014	0,5056	0,7462
<i>Fuzzy K-Means</i>	0,7837	0,5788	0,7903	0,4955	0,7653
<i>Morphological Chan Vese</i>	0,7875	0,5799	0,7974	0,5004	0,7563

No primeiro momento o sistema de classificação teve como entrada todos os dentes sem lesão e com lesão grande e pequena. Na Tabela 2 são exibidos os resultados, e por meio dos valores em destaque observa-se a superioridade da rede DenseNet-121, neste caso, em razão de seu melhor desempenho em quatro das métricas consideradas.

Tabela 2. Resultado por métrica para as redes pré-treinadas considerando a base de dados na íntegra.

Método	Métricas				
	Acurácia	F1-score	Especificidade	Precisão	Recall
DenseNet-121	0,7000	0,6970	0,7634	0,7582	0,6449
VGG-16	0,6800	0,6832	0,7204	0,7263	0,6449

O segundo cenário de avaliação se refere aos dentes sem lesão e com lesão grande (maiores de 2,0 mm). Os resultados obtidos são apresentados na Tabela 3 e mostram mais uma vez a superioridade da rede DenseNet-121, pois apresenta melhor desempenho em três das cinco métricas, alcançando 92,39% de especificidade.

Tabela 3. Resultado por métrica para as redes pré-treinadas considerando os dentes sem lesão e com lesão maior que 2,0 mm.

Método	Métricas				
	Acurácia	F1-score	Especificidade	Precisão	Recall
DenseNet-121	0,7917	0,6591	0,9239	0,8055	0,5577
VGG-16	0,8125	0,6582	0,9100	0,7429	0,5910

O último cenário considerou apenas dentes sem lesão e com lesão pequena (0,5 até 1,9 mm). A rede DenseNet-121 apresentou melhor desempenho em quatro das cinco métricas, apesar das diferenças numéricas serem discretas, como mostrado na Tabela 4.

Os resultados dos três cenários mostram que os melhores desempenhos ocorreram quando foram utilizados os dentes sem lesão e com lesão grande, tornando a classificação mais assertiva. Em contrapartida, o pior resultado foi alcançado quando foram levados em conta os dentes com lesão pequena, o que pode ser explicado pela dificuldade em distinguir a presença ou ausência de lesão, para esse caso em particular.

4. Conclusão

É inegável o aumento na solicitação de exames de imagens e, em paralelo a isso, crescem também os estudos no âmbito da inteligência computacional para o reconheci-

Tabela 4. Resultado por métrica para as redes pré-treinadas considerando os dentes sem lesão e com lesão entre 0,5 e 1,9 mm.

Método	Métricas				
	Acurácia	F1-score	Especificidade	Precisão	Recall
DenseNet-121	0,6667	0,4494	0,8571	0,6060	0,3571
VGG-16	0,6599	0,4318	0,8041	0,5000	0,3800

mento de padrões em imagens médicas.

Neste trabalho foram apresentadas soluções viáveis para dois problemas não triviais e frequentemente encontrados em exames odontológicos: a segmentação e a classificação. O algoritmo *K-Means* Modificado foi aplicado à segmentação de radiografias panorâmicas, com desempenho levemente superior ao apresentado por outras técnicas da literatura.

Além disso, foi desenvolvido um sistema de classificação automática para tomografias computadorizadas, com o propósito de diagnosticar a presença de lesão periapical. Para tanto, foi utilizada uma nova base de dados, construída para este trabalho.

5. Agradecimentos

À Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco (FACEPE) pelo apoio financeiro.

6. Publicações e Destaques

Até o momento o trabalho gerou: publicação de artigo na edição especial Sensing and Imaging Technology in Dentistry, do periódico *Sensors* [Calazans et al. 2022]; publicação de artigo e apresentação na XI Conferência Nacional em Comunicações, Redes e Segurança da Informação [Calazans et al. 2021]; menção honrosa pelo destaque obtido na dissertação de mestrado pela Universidade de Pernambuco.

Referências

- Bezdek, J. C., Ehrlich, R., and Full, W. (1984). FCM: the Fuzzy C-Means clustering algorithm. *Computers & Geosciences*, 10(2-3):191–203.
- Calazans, M. A. A., Ferreira, F. A. B. S., Alcoforado, M. d. L. M. G., and Madeiro, F. (2021). Avaliação do algoritmo k-means modificado em segmentação de imagens odontológicas. *Anais da XI Conferência Nacional em Comunicações, Redes e Segurança da Informação: Encom 2021*.
- Calazans, M. A. A., Ferreira, F. A. B. S., Alcoforado, M. d. L. M. G., Santos, A. d., Pontual, A. d. A., and Madeiro, F. (2022). Automatic classification system for periapical lesions in cone-beam computed tomography. *Sensors*, 22(17).
- Chan, T. and Vese, L. (2001). Active contours without edges. *IEEE Transactions on Image Processing*, 10(2):266–277.
- Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., and Fei-Fei, L. (2009). Imagenet: A large-scale hierarchical image database. In *2009 IEEE Conference on Computer Vision and Pattern Recognition*, pages 248–255.

- Goebel, P. M., Belbachir, A. N., and Truppe, M. (2005). Noise estimation in panoramic x-ray images: an application analysis approach. In *IEEE/SP 13th Workshop on Statistical Signal Processing*, pages 996–1001.
- Huang, G., Liu, Z., Maaten, L. V., and Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Khanagar, S. B., Al-ehaideb, A., Maganur, P. C., Vishwanathaiah, S., Patil, S., Baeshen, H. A., Sarode, S. C., and Bhandi, S. (2021). Developments, application, and performance of artificial intelligence in dentistry – A systematic review. *Journal of Dental Sciences*, 16(1):508–522.
- Lee, D., Baek, S., and Sung, K. (1997). Modified K-Means algorithm for vector quantizer design. *IEEE Signal Processing Letters*, 4(1):2–4.
- Linde, Y., Buzo, A., and Gray, R. (1980). An algorithm for vector quantizer design. *IEEE Transactions on Communications*, 28(1):84–95.
- Molander, B. (1996). Panoramic radiography in dental diagnostics. *Swedish Dental Journal. Supplement*, 119:1–26.
- Mozzo, P., Procacci, C., Tacconi, A., Martini, P. T., and Andreis, I. B. (1998). A new volumetric CT machine for dental imaging based on the cone-beam technique: Preliminary results. *European Radiology*, 8(9):1558–1564.
- Muresan, M. P., Barbura, A. R., and Nedevschi, S. (2020). Teeth detection and dental problem classification in panoramic X-ray images using deep learning and image processing techniques. In *2020 IEEE 16th International Conference on Intelligent Computer Communication and Processing (ICCP)*, pages 457–463.
- Nelson, S. J. (2014). *Wheeler’s Dental Anatomy, Physiology and Occlusion-e-book*. Elsevier Health Sciences.
- Scarfe, W. C., Farman, A. G., and Sukovic, P. (2006). Clinical applications of cone-beam computerized tomography in dental practice. *Journal Canadian Dental Association*, 72(1):75–80.
- Schwendicke, F., Golla, T., Dreher, M., and Krois, J. (2019). Convolutional neural networks for dental image diagnostics: A scoping review. *Journal of Dentistry*, 91:103226.
- Silva, G., Oliveira, L., and Pithon, M. (2018). Automatic segmenting teeth in X-ray images: trends, a novel data set, benchmarking and future perspectives. *Expert Systems with Applications*, 107:15–31.
- Silva, R. C. P., Bezerra, M. S., Gonzaga, G. L. P., Fonseca, A. B. M., Silva, M. K. A., Santos, I. A., and Lessa, S. V. (2022). Clinical applications of cone beam computed tomography in endodontics: Literature review. *Research, Society and Development*, 11(1).
- Simonyan, K. and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *ArXiv Preprint ArXiv:1409.1556*.