

Técnicas de Inteligência Computacional Aplicadas à Segmentação e ao Diagnóstico de Imagens Odontológicas

Maria Alice Andrade Calazans Maria de Lourdes Melo Guedes Alcoforado Francisco Madeiro
PPGES* PPGES* PPGES*
Universidade de Pernambuco (UPE) Universidade de Pernambuco (UPE) Universidade de Pernambuco (UPE)
Recife, Brasil Recife, Brasil Recife, Brasil
maac@poli.br mlmg@poli.br madeiro@poli.br

Resumo—Os exames de imagem são fundamentais no auxílio ao diagnóstico e planejamentos de tratamentos, uma vez que fornecem informações de regiões e tecidos inacessíveis na rotina clínica odontológica. Diante desse contexto, é proposto um sistema de classificação automática para apoio ao diagnóstico endodôntico, em tomografias computadorizadas de feixe cônico, oferecendo suporte aos profissionais da área. Além disso, é avaliado o uso de uma versão modificada do *K-Means* na segmentação de radiografias panorâmicas.

Palavras-chaves—Exames odontológicos, sistema de classificação automática, segmentação de imagens, *K-Means* modificado, Rede Siamesa Concatenada.

I. INTRODUÇÃO

As técnicas de imageamento são de grande valia nas ciências da saúde. Podem ser entendidas como ferramentas de auxílio na identificação de doenças e condições médicas e, conseqüentemente, como norteadoras para o planejamento de tratamentos [1].

No caso específico da odontologia, os exames de imagens são indispensáveis. Desempenham importante papel no provimento de informações ao dentista sobre os ossos faciais e tecidos dentários, o que não é possível de verificar no exame clínico rotineiro [2]. Nesse âmbito, as classes de exames mais frequentemente solicitadas são: a radiografia panorâmica [3], [4] e a tomografia computadorizada de feixe cônico. Esta é bastante requerida pelas especialidades de bucomaxilofacial e endodontia [5]–[8].

Com o avanço tecnológico em processamento digital de imagens e com a fundamental função dos exames de imagem no apoio ao diagnóstico, tais técnicas apresentam uma crescente demanda, o que provoca uma maior necessidade de análise dos exames solicitados. No entanto, esta é considerada uma atividade de alta complexidade, e exige uma vasta experiência do especialista para a correta interpretação das imagens [9]. Nesse sentido, sistemas inteligentes têm se apresentado como uma alternativa para auxílio ao diagnóstico [10], [11].

Neste trabalho são propostas duas metodologias distintas. A primeira diz respeito à segmentação de radiografias panorâmicas, que corresponde a uma importante etapa prévia para sistemas de detecção e classificação automática. Para tanto, utiliza-se o algoritmo *K-Means* modificado [12], o qual é comparado com as técnicas *K-Means* [13], *Fuzzy K-Means* [14] e *Morphological Chan Vese* [15]. A segunda consiste no desenvolvimento de um sistema de classificação automática com técnicas de aprendizado profundo para auxílio ao diagnóstico endodôntico de dentes na região posterior da maxila.

II. OBJETIVOS

Os objetivos deste trabalho são:

- Avaliar técnicas de aprendizado não supervisionado para segmentação de radiografias panorâmicas;
- Desenvolver um novo sistema de classificação automática para tomografias computadorizadas de feixe cônico para auxílio ao diagnóstico endodôntico.

III. MATERIAIS E MÉTODOS

Apresenta-se, inicialmente, nesta secção, a metodologia concernente à segmentação. Em seguida, a metodologia referente à classificação de imagens de tomografia.

A. Segmentação de Radiografia Panorâmica

A segmentação de imagens corresponde ao processo de subdividir uma imagem até que sejam detectados os objetos ou regiões de interesse. Para a realização da segmentação de imagens odontológicas, neste trabalho utilizou-se a base de dados da UFBA-UESC [16], a qual possui 1.500 imagens de radiografias panorâmicas, com dimensões de 1991×1127 pixels, que estão distribuídas em dez categorias, divididas a partir de variações de características como: número de dentes, presença ou ausência de aparelho ortodôntico, presença ou ausência de restauração odontológica e presença de implante dentário.

*Programa de Pós-Graduação em Engenharia de Sistemas (PPGES)

As radiografias foram segmentadas com o objetivo de separar os dentes e implantes, que eram os objetos de interesse, das demais informações presentes na imagem, como ossos faciais, coluna vertebral e gengiva. Nesse caso, ao segmentar as imagens, foram considerados dois *clusters*, um com os objetos de interesse, que idealmente deve ser segmentado na cor branca, e um segundo *cluster* que deve conter todas as informações secundárias e deve ser segmentado na cor preta.

Com relação as técnicas utilizadas, foi avaliado o desempenho da técnica *K-Means* modificado, que não havia sido utilizado na segmentação de imagens odontológicas anteriormente, em relação às técnicas *K-Means*, *Fuzzy K-Means*, que já apresentam resultados na literatura para a base de dados utilizada neste trabalho, e *Morphological Chan Vese*, uma técnica mais recente que também não havia sido utilizada para esse fim anteriormente.

O *K-Means* modificado foi simulado para os fatores de escala $s = 1,1$ até $s = 2,0$, variando 0,1 a cada simulação. Para fins comparativos com as outras técnicas foi considerado $s = 1,1$, pois foi o fator de escala que apresentou melhores resultados.

B. Sistema de Classificação Automática para Tomografias Computadorizadas de Feixe Cônico

Para o desenvolvimento do sistema de classificação automática, após a aprovação de projeto submetido ao Comitê de Ética em Pesquisa da UPE, sob o parecer de número 4.881.124, foi construída uma nova base de dados em parceria com o Departamento de Clínica de Radiologia Odontológica da Universidade Federal de Pernambuco (UFPE). A base de dados consiste em 1.000 dentes de exames de tomografias computadorizadas de feixe cônico, com dimensões de 115×186 pixels, selecionadas a partir da avaliação de especialistas em radiologia dos exames de pacientes atendidos entre 2015 a 2017, no Departamento de Odontologia Preventiva da UFPE. Como critério de inclusão das imagens foram considerados dentes posteriores da maxila com tratamento endodôntico anterior. Com isso, os dentes dos exames selecionados foram classificados de duas formas, inicialmente:

- Ausência de lesão periapical;
- Presença de lesão periapical em ao menos uma raiz.

Após isso, os dentes com presença de lesão foram avaliados quanto ao tamanho da lesão, e classificados como:

- Lesão pequena: 0,5 a 1,9 mm;
- Lesão grande: maiores ou iguais a 2,0 mm.

Como foram considerados exames de tomografias nesta etapa do trabalho, a avaliação das imagens é feita a partir de cortes. Foram considerados dois cortes, o sagital e o coronal. A importância da análise de mais de um corte tomográfico reside no fato de que, a depender da localização e do tamanho da lesão, esta pode ficar melhor evidenciada em um dos cortes.

Nesse sentido, o sistema de classificação automática foi proposto para ter um par de imagens como entrada e fornecer duas opções de saídas: "0", dente sem lesão, e "1", dente com lesão. Para ser possível processar simultaneamente um par de

imagens, foi proposta uma nova abordagem de rede baseada na Rede Siamesa [17], a qual foi nomeada de Rede Siamesa Concatenada. Assim como na versão original, são implementadas duas sub-redes idênticas para processar duas imagens como entradas, no entanto, na proposta tradicional o objetivo era de verificação de assinaturas, o que foi implementado por meio da correspondência entre imagens, ou seja, da comparação entre elas. Na estratégia apresentada neste trabalho, a perspectiva de uso está na compilação ou concatenação do par de imagens para que sejam processadas em conjunto com a finalidade de obter uma visão mais completa do dente e um diagnóstico mais assertivo.

Ainda foram utilizadas técnicas de aprendizado por transferência, com a finalidade de reduzir a complexidade computacional [18], [19]. Então, foram simuladas preliminarmente todas as redes disponíveis com o pacote Keras, todas treinadas com a base ImageNet [20], e foram selecionadas as redes VGG-16 [21] e DenseNet-121 [22] para a continuidade das implementações, uma vez que foram as que obtiveram os melhores resultados em comparação com as demais redes testadas. Também foram consideradas três técnicas de aumento de dados: inversão horizontal, rotação (com fator de 0,1) e zoom (com fator de 0,1).

Nas implementações a base utilizada foi dividida entre conjuntos de treino (60%), teste (20%) e validação (20%). O número de iterações definido foi de 150, com *batch size* de 32, com o otimizador RMSprop e a uma taxa de aprendizagem de 0,001. Foi adotado um *dropout* de 0,2, e em relação à função de ativação, foi considerada a sigmoide [23].

As simulações foram realizadas para comparação entre três cenários distintos: base de dados na íntegra, base de dados apenas com dentes sem lesão e com lesão grande e, por fim, base de dados com dentes sem lesão e com lesão pequena.

IV. RESULTADOS

Para a obtenção dos resultados, foram levados em conta verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN) [24]. A partir disso, foram calculadas cinco métricas:

- Acurácia: $(VP + VN)/(VP + VN + FP + FN)$;
- Recall: $VP/(VP + FN)$;
- Especificidade: $VN/(VN + FP)$
- Precisão: $VP/(VP + FP)$;
- F1-score: $(2 \times recall \times precisao)/(recall + precisao)$.

Os resultados de segmentação foram obtidos a partir de uma sequência de três etapas. Inicialmente, a radiografia panorâmica foi segmentada com a técnica definida, em seguida, a imagem segmentada foi multiplicada pela sua respectiva máscara com a delimitação da região de interesse e, por fim, na última etapa a imagem resultante da multiplicação da etapa anterior foi comparada com a imagem da segmentação de referência do especialista, conforme apresentado na Figura 1. Os resultados da segmentação foram calculados por meio da média ponderada do resultado por categoria e seu número de imagens.




Figura 1: Procedimento para a obtenção dos resultados da segmentação.

Na Tabela I, são apresentados os resultados das métricas avaliadas para as quatro técnicas distintas de segmentação. Os melhores desempenhos são os destacados em negrito. No caso do *K-Means* modificado, foi considerado o fator de escala de 1,1 para as comparações com as outras técnicas. Os resultados das técnicas se assemelham, porém o *K-Means* modificado pode ser considerado superior, ainda que sutilmente, pois foi o que atingiu os melhores valores em três das cinco medidas: acurácia, especificidade e precisão.

Tabela I: Resultados por métrica para os quatro métodos de segmentação para imagens odontológicas.

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

Os resultados do sistema de classificação são exibidos nas Tabelas II, III e IV para as métricas avaliadas com as redes DenseNet-121 e VGG-16. Na Tabela II, o cenário com a base de dados completa é avaliado, sendo possível inferir que a DenseNet-121 foi superior em quatro das cinco medidas, empatando com a VGG-16 apenas no *recall*. Neste caso, foi atingida uma acurácia máxima de 70%.

Tabela II: Resultado do sistema de classificação automática para o cenário com a base de dados completa.

Rede	Métricas				
	Acurácia	<i>F1-score</i>	Precisão	Espec.	<i>Recall</i>
DenseNet-121	0,7000	0,6970	0,7582	0,7634	0,6449
VGG-16	0,6800	0,6832	0,7263	0,7204	0,6449

Com relação ao cenário com dentes sem lesão e com lesão grande, os resultados são apresentados na Tabela III. Neste caso, a DenseNet-121 foi superior em três métricas, e a VGG-16 foi melhor no *recall* e na acurácia, alcançando nesta medida o valor de 81,25%, um valor maior do que no cenário anterior.

Tabela III: Resultados do sistema de classificação automática para o cenário considerando apenas com dentes sem lesão e com lesão grande.

Rede	Métricas				
	Acurácia	<i>F1-score</i>	Precisão	Espec.	<i>Recall</i>
DenseNet-121	0,7917	0,6591	0,8055	0,9239	0,5577
VGG-16	0,8125	0,6582	0,7429	0,9100	0,5910

Por fim, o último cenário avaliado verificou o desempenho das redes pré-treinadas para os dentes sem lesão e com lesão de 0,5 a 1,9 mm, como apresentado na Tabela IV. Mais uma vez, a DenseNet-121 foi superior na maioria das métricas, em quatro das cinco consideradas. A acurácia máxima foi de 66,67%, a menor dos três cenários apresentados. Esse resultado pode indicar uma dificuldade do sistema automático em diferenciar um dente com lesão pequena de um dente sem lesão.

Tabela IV: Resultados do sistema de classificação automática para o cenário considerando apenas com dentes sem lesão e com lesão grande.

Rede	Métricas				
	Acurácia	<i>F1-score</i>	Precisão	Espec.	<i>Recall</i>
DenseNet-121	0,6667	0,4494	0,6060	0,8571	0,3571
VGG-16	0,6599	0,4318	0,5000	0,8041	0,3800

V. CONCLUSÃO

Este trabalho tem o indetismo e viabilidade nas propostas avaliadas. O algoritmo *K-Means* modificado foi aplicado à segmentação de imagens odontológicas. Não foram encontrados relatos anteriores de seu uso para esse fim na literatura. Além disso, foi proposto um novo sistema de classificação automática para diagnóstico endodôntico, em que, a partir do processamento de um par de cortes tomográficos, um dente é classificado como com ausência ou presença de lesão periapical, o que é de grande valia para a odontologia, uma vez que o diagnóstico de lesão periapical é considerado de alta complexidade pelos especialistas. Uma outra novidade é que o sistema apresentado utilizou técnicas de aprendizado profundo para a classificação de imagens de dentes posteriores da maxila, que corresponde a uma região com elevado grau de dificuldade de análise, e que também não possui relatos anteriores na literatura.

Pode-se destacar, ainda, a proposta de uma nova abordagem baseada na Rede Siamesa, a qual foi chamada de Rede Siamesa Concatenada, que consiste na concatenação dos cortes sagitais e coronais da tomografia.

AGRADECIMENTOS

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

REFERÊNCIAS

- [1] P. Kora, C. P. Ooi, O. Faust, U. Raghavendra, A. Gudigar, W. Y. Chan, K. Meenakshi, K. Swaraja, P. Plawiak, e U. Rajendra Acharya, "Transfer learning techniques for medical image analysis: a review," *Biocybernetics and Biomedical Engineering*, vol. 42, pp. 79–107, 2021.
- [2] S. J. Nelson, *Wheeler's dental anatomy, physiology and occlusion-e-book*. Elsevier Health Sciences, 2014.
- [3] B. Molander, "Panoramic radiography in dental diagnostics." *Swedish Dental Journal. Supplement*, vol. 119, pp. 1–26, 1996.
- [4] M. P. Muresan, A. R. Barbura, e S. Nedeveschi, "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)*, 2020, pp. 457–463.
- [5] W. C. Scarfe, A. G. Farman, e P. Sukovic, "Clinical applications of cone-beam computerized tomography in dental practice," *Journal of the Canadian Dental Association*, vol. 72, n.º. 1, pp. 75–80, 2006.
- [6] P. Mozzo, C. Procacci, A. Tacconi, P. T. Martini, e I. B. Andreis, "A new volumetric CT machine for dental imaging based on the cone-beam technique: Preliminary results," *European Radiology*, vol. 8, n.º. 9, pp. 1558–1564, 1998.
- [7] J. B. Ludlow e M. Ivanovic, "Comparative dosimetry of dental CBCT devices and 64-slice CT for oral and maxillofacial radiology," *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, and Endodontology*, vol. 106, n.º. 1, pp. 106–114, 2008.
- [8] R. C. P. Silva, M. S. Bezerra, G. L. P. Gonzaga, A. B. M. Fonseca, M. K. A. Silva, I. A. Santos, e S. V. Lessa, "Clinical applications of cone beam computed tomography in endodontics: Literature review," *Research, Society and Development*, vol. 11, n.º. 1, 2022.
- [9] S. B. Khanagar, A. Al-haideb, P. C. Maganur, S. Vishwanathaiah, S. Patil, H. A. Baeshen, S. C. Sarode, e S. Bhandi, "Developments, application, and performance of artificial intelligence in dentistry – A systematic review," *Journal of Dental Sciences*, vol. 16, n.º. 1, pp. 508–522, 2021.
- [10] F. Schwendicke, T. Golla, M. Dreher, e J. Krois, "Convolutional neural networks for dental image diagnostics: A scoping review," *Journal of Dentistry*, vol. 91, p. 103226, 2019.
- [11] L. H. Son, T. M. Tuan, H. Fujita, N. Dey, A. S. Ashour, V. T. N. Ngoc, L. Q. Anh, e D.-T. Chu, "Dental diagnosis from x-ray images: An expert system based on fuzzy computing," *Biomedical Signal Processing and Control*, vol. 39, pp. 64–73, 2018.
- [12] D. Lee, S. Baek, e K. Sung, "Modified K-Means algorithm for vector quantizer design," *IEEE Signal Processing Letters*, vol. 4, n.º. 1, pp. 2–4, 1997.
- [13] Y. Linde, A. Buzo, e R. Gray, "An algorithm for vector quantizer design," *IEEE Transactions on Communications*, vol. 28, n.º. 1, pp. 84–95, 1980.
- [14] J. C. Bezdek, R. Ehrlich, e W. Full, "FCM: the Fuzzy C-Means clustering algorithm," *Computers & Geosciences*, vol. 10, n.º. 2-3, pp. 191–203, 1984.
- [15] P. Márquez-Neila, L. Baumela, e L. Alvarez, "A morphological approach to curvature-based evolution of curves and surfaces," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 36, n.º. 1, pp. 2–17, 2014.
- [16] G. Silva, L. Oliveira, e M. Pithon, "Automatic segmenting teeth in x-ray images: trends, a novel data set, benchmarking and future perspectives," *Expert Systems with Applications*, vol. 107, pp. 15–31, 2018.
- [17] J. Bromley, J. W. Bentz, L. Bottou, I. Guyon, Y. LeCun, C. Moore, E. Säckinger, e R. Shah, "Signature verification using a "siamese" time delay neural network," *International Journal of Pattern Recognition and Artificial Intelligence*, vol. 7, n.º. 04, pp. 669–688, 1993.
- [18] F. Zhuang, Z. Qi, K. Duan, D. Xi, Y. Zhu, H. Zhu, H. Xiong, e Q. He, "A comprehensive survey on transfer learning," *Proceedings of the IEEE*, vol. 109, n.º. 1, pp. 43–76, 2020.
- [19] S. J. Pan e Q. Yang, "A survey on transfer learning," *IEEE Transactions on Knowledge and Data Engineering*, vol. 22, n.º. 10, pp. 1345–1359, 2010.
- [20] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, e L. Fei-Fei, "Imagenet: A large-scale hierarchical image database," in *2009 IEEE Conference on Computer Vision and Pattern Recognition*, 2009, pp. 248–255.
- [21] K. Simonyan e A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *ArXiv Preprint ArXiv:1409.1556*, 2014.
- [22] G. Huang, Z. Liu, L. V. Maaten, e K. Q. Weinberger, "Densely connected convolutional networks," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, July 2017.
- [23] J. Han e C. Moraga, "The influence of the sigmoid function parameters on the speed of backpropagation learning," in *From Natural to Artificial Neural Computation*, J. Mira e F. Sandoval, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, 1995, pp. 195–201.
- [24] T. Fawcett, "An introduction to ROC analysis," *Pattern Recognition Letters*, vol. 27, n.º. 8, pp. 861–874, 2006.