



Desenvolvimento de um modelo baseado em Machine Learning para rastreamento precoce do câncer de boca

Development of a Machine Learning based model for early screening for oral cancer

SILVA, Ivisson Alexandre Pereira da⁽¹⁾; OLIVEIRA, Catarina Rodrigues Rosa de⁽²⁾; OLIVEIRA, José Marcos dos Santos⁽³⁾; FILHO, Carlos Alberto Correia Lessa⁽⁴⁾; FERREIRA, Sonia Maria Soares⁽⁵⁾

⁽¹⁾ 0000-0002-1682-3648; Centro Universitário CESMAC, discente, pesquisador e mestrando do Mestrado Profissional Pesquisa em Saúde, Brazil, E-mail: iapereira29@gmail.com.

⁽²⁾ 0000-0001-9178-8902; Centro Universitário CESMAC, docente, Mestre em Estomatologia e Radiologia pela São Leopoldo Mandic, docente na disciplina de Propedêutica Clínica, Brazil, E-mail: catarinarosaodonto@hotmail.com.

⁽³⁾ 0000-0002-4618-1500; Centro Universitário CESMAC e Universidade Federal de Alagoas (UFAL), docente, Doutor em Bioquímica e Biotecnologia, docente no Instituto de Química e Biotecnologia na UFAL e Farmácia no CESMAC, Brazil, E-mail: jose_marcos_cbjr@hotmail.com.

⁽⁴⁾ 0000-0002-4114-1235; Centro Universitário CESMAC, docente, pesquisador, Especialista em Desenvolvimento de softwares e docente da disciplina de Inteligência Artificial Brazil, E-mail: carlos.filho@cesmac.edu.br.

⁽⁵⁾ 0000-0002-4825-171X; Centro Universitário CESMAC, docente, pesquisadora, coordenadora do Mestrado Profissional Pesquisa em Saúde, Brazil, E-mail: sonia.ferreira@cesmac.edu.br.

ABSTRACT

Oral Squamous Cell Carcinoma (OSCC) is the most frequent type of oral cancer, accounting for about 40% of malignant head and neck lesions. It is known that a favorable prognosis is associated with early diagnosis, since the survival rate increases depending on the diagnosis in early stages of disease. The aim of this work was to implement and train a Machine Learning model that can help in the diagnosis of oral cancer. Through technologies such as artificial intelligence (AI) allows to use images in their analyses, the research improve the prognosis of oral cancer due its early detection. The employment of AI branch, Machine Learning and its Deep Learning subgroup, it becomes possible through the Convolutional Neural Network (CNN) to perform a screening of images from malignant and pre-malignant lesions, in order to identify the presence or absence of oral cancer. The RNC structure is based on the MobileNet structure, which separates the images into fragments, apply the identification of cancer in 91% and Leukoplakia in 84% of the examined images.

RESUME

O carcinoma espinocelular da cavidade bucal (CECCB) é o tipo de câncer de boca mais frequente, representando cerca de 40% das lesões malignas de cabeça e pescoço. Sabe-se que o prognóstico favorável está associado ao diagnóstico precoce, visto que a taxa de sobrevida aumenta em função do diagnóstico nas fases iniciais na doença. Desta forma, o objetivo deste trabalho foi implementar e treinar um modelo de Machine Learning que possa auxiliar no diagnóstico do câncer de boca. Através das tecnologias como inteligência artificial (IA) que podem utilizar imagens em suas análises, busca-se melhorar o prognóstico do câncer de boca por meio da detecção precoce do mesmo. Utilizando o ramo da IA, a Machine Learning e seu subgrupo Deep Learning, torna-se possível por intermédio de Rede Neural Convolutacional (RNC) realizar uma triagem de imagens de lesões malignas e pré-malignas, visando identificar a presença ou não do câncer de boca. A estrutura de RNC está baseada na estrutura de MobileNet, que separa as imagens em fragmentos e após treinamento, mostraram a identificação de câncer em 91% das imagens examinadas e de Leucoplasia em 84% das imagens analisadas.

ARTICLE INFORMATION

Article process:

Submitted: 03/12/2022

Approved: 14/04/2023

Published: 03/07/2023



Keywords:

Oral cancer, Artificial intelligence, Machine learning

Keywords:

Câncer de boca, Inteligência artificial, Machine learning.

Introduction

O câncer de cabeça e pescoço (CCP) refere-se a um grupo de cânceres biologicamente semelhantes, que afetam principalmente os lábios, cavidade oral (boca), cavidade nasal, faringe, laringe e seios paranasais. O câncer de boca é um dos mais frequentes, onde representa aproximadamente 40 % das lesões de cabeça e pescoço (SCUTT et al., 2016). De acordo com estimativas do Instituto Nacional do Câncer (INCA), o número de casos novos de câncer de boca esperados para o Brasil, para cada ano do triênio 2020-2022, será de 11.180 casos em homens e de 4.010 em mulheres. Em Alagoas, são esperados 190 novos casos, com um predomínio do sexo masculino e residentes fora da capital. Alagoas tem uma taxa de incidência estimada de 8,6/100 mil em Homens e 4,06/100 mil em mulheres (INCA, 2020). Estes dados refletem que os casos de câncer de boca não podem ser desprezados e que a patologia não deve ser considerada uma doença rara.

Um aliado importante para a detecção precoce do câncer de boca pode ser o uso de tecnologias que possam ser acessíveis para toda a equipe de saúde e que possa ser usada para suspeitar e ajudar no diagnóstico tanto do câncer de boca quanto das doenças potencialmente malignas (Al-Rawi et al., 2022; Mahmood et al., 2020). Desta forma, é possível dizer que através de dados passados e por meio de algoritmos estatístico a máquina poderá aprender como deve ser realizada essa associação. Este processo, segundo Hurwitz e Kirsch (2019), ocorre por meio de um treinamento. No treinamento, ainda de acordo com os autores, é informado dados anteriores de entradas, que podem ser históricos de compras, localizações, características de clientes e como esses dados foram classificados. Sem ser definido nenhuma regra de associação, o próprio algoritmo por meio de testes estatísticos irá aprender e definir as regras que definem como os dados de entrada possuem relação com as suas classificações (Lin et al., 2021; Uthoff et al., 2018; Welikala et al., 2020).

Devido a esse processo de aprender sozinho a relação dos dados de entrada com os dados das suas classificações, a *Machine Learning (ML)* começou a ser utilizado na área da saúde. Um exemplo que pode ser dado, ocorre ao coletar sintomas que pacientes tinham como dado de entrada e uma classificação se o paciente possuía ou não uma doença.

Através de vários testes, no treinamento, por meio de algoritmos estatísticos utilizando uma linguagem de programação, o algoritmo cria as regras que definem o modelo da *ML*. Por meio deste modelo, sempre que um novo paciente surgir, poderá ser utilizado o algoritmo para prever se um paciente possui ou não uma doença, caso o modelo já tenha sido treinado para reconhecer esses sintomas com a doença (Al-Rawi et al., 2022; Aubreville et al., 2017; Mahmood et al., 2020; Song et al., 2021; Uthoff et al., 2018; Welikala et al., 2020).

De acordo com Erickson *et al* (2017), ao utilizar *ML* para diagnóstico baseado em imagens, é utilizado imagens de Raio-X ou da região onde o sintoma se destacada de pacientes anteriores como dados de entrada do treinamento, assim como a informação de quais desses pacientes possuíam ou não a doença a ser analisada. Por fim, o algoritmo extrairia informações

de tonalidades de cores, texturas e formatos dos conteúdos das imagens que seriam convertidas para números para serem usadas no treinamento, gerando as regras que serão usadas para prever imagens de novos pacientes.

Um dos formatos mais utilizados atualmente para realizar esse treinamento, ainda segundo Erickson *et al* (2017), ocorre por meio de *Deep Learning (DL)*, ou aprendizagem profunda. O *DL* é um subgrupo de *ML*, que tem ganhado força graças ao melhoramento nos computadores atuais e ainda de acordo com Ravi *et al* (2016), e ainda que se baseia nos conceitos de redes neurais. Para realizar um treinamento baseado em Redes Neurais, segundo Marcus (2018), é necessário interligar vários nós, também chamados de neurônios, que estará separado por três camadas: Camada Entrada (Input Layer), que é a camada que recebe os dados de entrada do algoritmo; Camada Oculta (Hidden layers) que realizam mais operações matemáticas para melhorar as regras do treino; e Camada de Saída (Output Layer) que fornece o resultado esperado.

Uma vez que cada nó deverá realizar uma operação matemática e repassar para todos os nós da próxima camada, este processo exige um alto nível de processamento computacional, porém gera resultados mais precisos que outros algoritmos não baseados em redes neurais.

Diante desses conceitos, a pesquisa atual consistirá em utilizar algoritmo de *DL*, usando como base fotos de pacientes que possuem ou não câncer bucal, para gerar um modelo que seja capaz de prever se novos pacientes podem possuir essa enfermidade através de fotos, facilitando o processo de triagem. Desta forma, o objetivo geral foi o desenvolvimento, implementação e treinamento de um modelo de *ML* que possa auxiliar no diagnóstico precoce do câncer de boca através de imagens de lesões bucais malignas e não malignas.

Methodology

Imagens clínicas de lesões malignas e não malignas foram coletadas mediante fotografias de pacientes residentes no Estado de Alagoas usuários do Sistema Único de Saúde (SUS) e as imagens do Atlas digital de correlações clínico patológica do câncer de boca e imagens de livros de patologia oral. O modelo para auxiliar o diagnóstico precoce do câncer de boca foi desenvolvido a partir do reconhecimento dos padrões das imagens coletadas, como descrito anteriormente, com auxílio de inteligência artificial. Os padrões de lesões malignas e das lesões não malignas que fazem parte do diagnóstico diferencial de CECCB foram informados ao modelo por meio de algoritmos estatísticos que conferem atributos às imagens. O modelo foi treinado a reconhecer os padrões de lesões através da abordagem *DL*, utilizando redes neurais convolucionais, gerando um modelo capaz de prever se novos pacientes podem possuir a referida patologia somente através de fotos. Os programas utilizados para o desenvolvimento do aplicativo baseado em inteligência artificial (IA) foram: Keras (Python) e TensorFlow. O Keras é uma biblioteca do Python com suporte a Deep Learning que utiliza o TensorFlow no seu treinamento. O TensorFlow é uma biblioteca de código aberto destinada a desenvolvedores para a criação de modelos de será utilizado como ferramenta de *ML* baseado

na abordagem *DL*, onde a criação da rede neural convolucional foi realizada com utilização de múltiplos níveis de abstração, usando como base as camadas de *MobileNet*.

Development

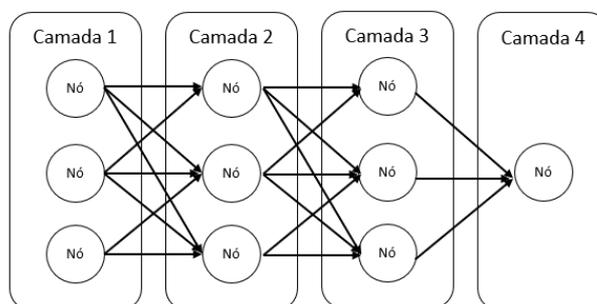
As imagens coletadas para o desenvolvimento do modelo de IA, foram provenientes das fotografias de pacientes residentes no Estado de Alagoas no período de 2001 até junho de 2022, onde foram utilizadas 4.785 imagens e através de uma triagem conseguiu-se selecionar 1.000 para que fossem aproveitadas no desenvolvimento do modelo de IA. No atlas e as imagens extraídas dos livros de patologia oral conseguimos aproveitar 100% das imagens visto que antes delas serem inseridas no mesmo, foi passado por um processo de triagem. Após a coleta e triagem das imagens que serviram para o treinamento, foi dado início a construção do modelo em *ML*.

A primeira etapa consistiu em utilizar o algoritmo denominado ImageDataGenerator, que como o próprio nome sugere, trata-se de um recurso capaz de aumentar o número de imagens usadas no treinamento, criando imagens baseadas nas antigas, utilizando-se de recursos como zoom, rotação ou espelhamento das imagens.

Após esta etapa foi dado início a criação do modelo de IA usado para triagem das fotos de câncer. O modelo foi construindo utilizando a estrutura de redes neurais convolucionais baseadas na estrutura de *MobileNet*, que consiste em separar as imagens em pequenos fragmentos, que serão convertidos para uma matriz numérica usada pela rede neural.

Uma rede neural consiste em vários nós, que realizam cálculos matemáticos em busca das respostas desejadas. Esses nós processam sua informação e enviam suas respostas para outros nós que estão interligados em uma camada seguinte, como pode ser visto na Figura 1.

Figura 1. Representação de uma Rede Neural



Fonte: Dados da pesquisa

A estrutura da rede neural criada para esse modelo contou com 4 camadas, no qual a primeira e segunda contém 1024 nós, a terceira 512, e a última apenas 2 nós, para identificar se é um valor positivo ou negativo para câncer (Figura 2).

Figura 2. Construção do modelo

```
1 #Modelo base, usando MobileNet
2 base_model=MobileNet(weights='imagenet',include_top=False)
3
4 #Estrutura da Rede Neural
5 x=base_model.output
6 x=GlobalAveragePooling2D()(x)
7 x=Dense(1024,activation='relu')(x)
8 x=Dense(1024,activation='relu')(x)
9 x=Dense(512,activation='relu')(x)
10 preds=Dense(2,activation='softmax')(x)
11
12 #Definição do modelo
13 model= Model(inputs=base_model.input,outputs=preds)
```

Fonte: Dados da pesquisa

Após todo o treinamento, o modelo foi salvo no formato HDF5, guardando todas as suas regras encontradas no treinamento, de modo a poder ser facilmente importada em outros algoritmos para realizar a predição de valores, sem precisar realizar todo treinamento novamente.

Como resultados parciais foi observado que quando o modelo de *ML* realizou o treinamento para diagnóstico de câncer de boca em contraponto aos seus respectivos diagnósticos diferenciais, houve uma precisão de 91 % de acertos para os casos de câncer de boca diagnosticados. Quando o modelo foi treinado para o diagnóstico de leucoplasia e as outras doenças potencialmente malignas, houve a precisão de 84 % de acertos.

Comparado com o estudo de Ilhan et al (2021), que mostrou uma precisão de identificação positiva do câncer de boca de 87%, e de Leucoplasia de 70%. E de Song et al (2018), que utilizando as RNC apresentou uma precisão no diagnóstico por imagem de 86,9% de casos de câncer de boca, os resultados do presente estudo pode indicar que o modelo construído é um produto que pode ser utilizado para auxiliar no diagnóstico do câncer de boca. Em trabalhos futuros pretende-se testar o modelo com diferentes tipos de imagens como fotos tiradas em câmera de celular com o objetivo de auxiliar no diagnóstico precoce do câncer de boca.

Final considerations

O presente estudo mostrou que o modelo desenvolvido para auxiliar no diagnóstico precoce do câncer de boca, pode ser utilizado para essa finalidade, visto que o modelo de *ML* apresentou durante o seu treinamento uma precisão de 91% de acertos para os casos de câncer de boca diagnosticados e para o treinamento do diagnóstico de leucoplasia e as outras doenças potencialmente malignas, houve a precisão de 84% de acertos. Abrindo assim outras oportunidades de modelos que tenham a finalidade de auxiliar no diagnóstico precoce do câncer de boca.

Funding agency

PPSUS - Nº:60030.0000000214/2021

Acknowledgments

Agradecimento a todos que fizeram parte desse trabalho, em especial aos meus orientadores e a toda equipe do Mestrado Profissional Pesquisa em Saúde – MPPS/ Cesmac.

REFERENCES

- Al-Rawi, N., Sultan, A., Rajai, B., Shuaeeb, H., Alnajjar, M., Alketbi, M., Mohammad, Y., Shetty, S. R., & Mashrah, M. A. (2022). The Effectiveness of Artificial Intelligence in Detection of Oral Cancer: AI AND ORAL CANCER DIAGNOSIS. In *International Dental Journal* (Vol. 72, pp. 436–447). Elsevier Inc. <https://doi.org/10.1016/j.identj.2022.03.001>
- Aubreville, M., Knipfer, C., Oetter, N., Jaremenko, C., Rodner, E., Denzler, J., Bohr, C., Neumann, H., Stelzle, F., & Maier, A. (2017). Automatic Classification of Cancerous Tissue in Laserendomicroscopy Images of the Oral Cavity using Deep Learning. *Scientific Reports*, 7(1). <https://doi.org/10.1038/s41598-017-12320-8>
- Erickson, B. J., Korfiatis, P., Akkus, Z., & Kline, T. L. (2017). Machine learning for medical imaging. *Radiographics*, 37(2), 505-515.
- Hurwitz, J., Morris, H., Sidner, C., & Kirsch, D. (2019). *Augmented intelligence: the business power of human-machine collaboration*. CRC Press.
- Ilhan, B., Guneri, P., & Wilder-Smith, P. (2021). The contribution of artificial intelligence to reducing the diagnostic delay in oral cancer. In *Oral Oncology* (Vol. 116). Elsevier Ltd. <https://doi.org/10.1016/j.oraloncology.2021.105254>
- Ilhan, B., Lin, K., Guneri, P., & Wilder-Smith, P. (2020). Improving Oral Cancer Outcomes with Imaging and Artificial Intelligence. *Journal of Dental Research*, 99(3), 241–248. <https://doi.org/10.1177/0022034520902128>
- Lin, H., Chen, H., Weng, L., Shao, J., & Lin, J. (2021). Automatic detection of oral cancer in smartphone-based images using deep learning for early diagnosis. *Journal of Biomedical Optics*, 26(08). <https://doi.org/10.1117/1.jbo.26.8.086007>
- Mahmood, H., Shaban, M., Indave, B. I., Santos-Silva, A. R., Rajpoot, N., & Khurram, S. A. (2020). Use of artificial intelligence in diagnosis of head and neck precancerous and cancerous lesions: A systematic review. In *Oral Oncology* (Vol. 110). Elsevier Ltd. <https://doi.org/10.1016/j.oraloncology.2020.104885>
- Marcus, R., & Papaemmanouil, O. (2018, June). Deep reinforcement learning for join order enumeration. In *Proceedings of the First International Workshop on Exploiting Artificial Intelligence Techniques for Data Management* (pp. 1-4).
- Ministério da Saúde. (2020). Instituto Nacional de Câncer José Alencar Gomes da Silva. *Estimativa 2020-2022: Incidência de Câncer no Brasil*. Rio de Janeiro.
- Ravi, D., Wong, C., Lo, B., & Yang, G.-Z. (2016). *Deep Learning for Human Activity Recognition: A Resource Efficient Implementation on Low-Power Devices*. IEEE Engineering in Medicine and Biology Society. <https://doi.org/10.1109/BSN.2016.7516235>
- Scutti, J. A. B., Pineda, M., Jr, E. E., & Ameida, E. R. de. (2016). *Carcinoma de células escamosas de cabeça e pescoço (HNSCC): desvendando os mistérios do microambiente tumoral*.
- Song, B., Sunny, S., Li, S., Gurushanth, K., Mendonca, P., Mukhia, N., Patrick, S., Gurudath, S., Raghavan, S., Tsusennaro, I., Leivon, S. T., Kolar, T., Shetty, V., Bushan, V. R., Ramesh, R., Peterson, T., Pillai, V., Wilder-Smith, P., Sigamani, A., ... Liang, R. (2021). Bayesian deep learning for reliable oral cancer image classification. *Biomedical Optics Express*, 12(10), 6422. <https://doi.org/10.1364/boe.432365>
- Uthoff, R. D., Song, B., Sunny, S., Patrick, S., Suresh, A., Kolar, T., Keerthi, G., Spires, O., Anbarani, A., Wilder-Smith, P., Kuriakose, M. A., Birur, P., & Liang, R. (2018). Point-of-care, smartphone-based, dual-modality, dual-view, oral cancer screening device with neural network classification for low-resource communities. *PLoS ONE*, 13(12). <https://doi.org/10.1371/journal.pone.0207493>
- Welikala, R. A., Remagnino, P., Lim, J. H., Chan, C. S., Rajendran, S., Kallarakkal, T. G., Zain, R. B., Jayasinghe, R. D., Rimal, J., Kerr, A. R., Amtha, R., Patil, K., Tilakaratne, W. M., Gibson, J., Cheong, S. C., & Barman, S. A. (2020). Automated Detection and Classification of Oral Lesions Using Deep Learning for Early Detection of Oral Cancer. *IEEE Access*, 8, 132677–132693. <https://doi.org/10.1109/ACCESS.2020.3010180>