



Using Convolutional Neural Networks for segmentation of brain tumors

Kauã Gabriel Silva de Lima ¹ *
Vagner Alves Ferreira da Silva ²
João Victor Oliveira da Silva ³
Lucas Patrick Ramos de Oliveira ⁴
Diogo Lopes da Silva ⁵

^{1 2 3 4 5} Pernambuco Federal Institute of Education, Science, and Technology, Palmares, Brazil

Emails: ¹ kgs1@discente.edu.br; ² vafs@discente.ifpe.edu.br; ³ jvos2@discente.ifpe.edu.br;

⁴ lpro@discente.ifpe.edu.br; ⁵ diogo.lopes@palmares.ifpe.edu.br

*Corresponding Author

How to cite this paper: de Lima, K. G. S., da Silva, V. A. F., da Silva, J. V. O., G., de Oliveira, L. P. R., da Silva, D. L. (2024). Using Convolutional Neural Networks for segmentation of brain tumors. *Socioeconomic Analytics*, 2(1), 114-120. <https://doi.org/10.51359/2965-4661.2024.265072>

RESEARCH ARTICLE

Socioeconomic Analytics

<https://periodicos.ufpe.br/revistas/SECAN/>

ISSN Online: 2965-4661

Submitted on: 11.11.2024.

Accepted on: 15.12.2024.

Published on: 27.12.2024.

Copyright © 2024 by author(s).

This work is licensed under the Creative Commons Attribution International License CC BY-NC-ND 4.0

<http://creativecommons.org/licenses/by-nc-nd/4.0/deed.en>



Abstract

This paper presents a brain tumor segmentation system for MRI images using Convolutional Neural Networks (CNNs). The goal is to assist in automated medical analysis by providing accurate segmentations of tumor areas to support diagnosis and treatment planning. The CNN model was trained on MRI images and accurately detected tumor boundaries. The proposed approach utilizes transfer learning to optimize the model's performance on high-resolution images, reducing processing time. The system stands out for its efficiency in segmenting tumors of various sizes and shapes, offering a promising tool for clinical neuroscience.

Keywords

Machine Learning, Neural Networks, healthcare, tumors

1. Introdução

A segmentação de tumores cerebrais em imagens de ressonância magnética (MRI) é um passo crucial no diagnóstico e na elaboração do plano terapêutico, tendo um papel crucial na detecção de áreas tumorais. Contudo, esse desafio é acentuado pela vasta variação na forma, dimensão e localização dos tumores, além da complexidade das imagens produzidas. Normalmente, essa avaliação requer a participação de especialistas, sendo um procedimento trabalhoso e propenso a falhas.

Os progressos na inteligência artificial, particularmente no aprendizado profundo, têm transformado a segmentação de imagens médicas. Modelos como o YOLOv11 (You Only Look Once, versão 11) são notáveis pela sua habilidade de identificar objetos de maneira precisa e ágil, mesmo em situações complexas. Este estudo descreve um método de segmentação de tumores cerebrais que utiliza o YOLO, melhorado através de métodos de aprendizado por transferência para manusear imagens de alta definição de maneira eficaz.

O propósito central desta pesquisa é criar um instrumento exato e rápido que ajuda profissionais de saúde a detectar tumores cerebrais, aprimorando o diagnóstico e auxiliando no planejamento do tratamento. O objetivo da proposta é diminuir a duração da análise manual, aprimorar a consistência dos resultados e, possivelmente, aprimorar os resultados clínicos.

2. Material e Métodos

Para o desenvolvimento do modelo de segmentação de tumores cerebrais, empregamos a framework Ultralytics, construída com base em PyTorch. Essa biblioteca foi escolhida pela sua flexibilidade e adaptabilidade a modelos pré-treinados, como YOLO (Redmon, 2015), ResNet (He, 2016), DDRNet (Hong, 2021), entre outros. A Ultralytics permite configurações de hiperparâmetros simplificados e oferece ampla compatibilidade com outras bibliotecas, facilitando a integração e tornando o processo de configuração mais direto e eficiente. A aplicação de métodos como o aprendizado por transferência é frequente em modelos de detecção e segmentação, conforme ressaltado por (da Silva, 2017) em sua pesquisa sobre otimização de características e escolha de modelos. Sua efetividade na aceleração do treinamento e aprimoramento da performance é amplamente reconhecida.

Optamos pelo modelo YOLOv11 devido à sua alta performance em detecção de objetos e sua velocidade de processamento, características fundamentais para alcançar uma segmentação precisa e eficiente. Além disso, modelos como o U-Net, amplamente utilizado em segmentação de imagens médicas (Ronneberger, Fischer, & Brox, 2015), também demonstraram grande eficácia em tarefas semelhantes, embora o YOLOv11 tenha se destacado por sua rapidez e acurácia em tempo real. A Figura 1 apresenta uma imagem da arquitetura do YOLO, evidenciando sua estrutura e componentes-chave. O sistema foi treinado em um ambiente local, utilizando um processador Ryzen 7 5700U com 32GB de memória RAM, o que garantiu capacidade para lidar com grandes volumes de dados e processar imagens de alta resolução.

Para otimizar o desempenho, empregamos um modelo pré-treinado, aplicando aprendizado por transferência para acelerar o processo e reduzir o tempo de processamento das imagens. Essa abordagem é amplamente utilizada em redes de detecção, conforme discutido por (Silva e Candido, 2016) em sua metodologia para extração de conhecimento em redes de computadores, que enfatiza a importância da integração de tecnologias avançadas para otimizar o uso de redes neurais em contextos complexos como o diagnóstico médico.

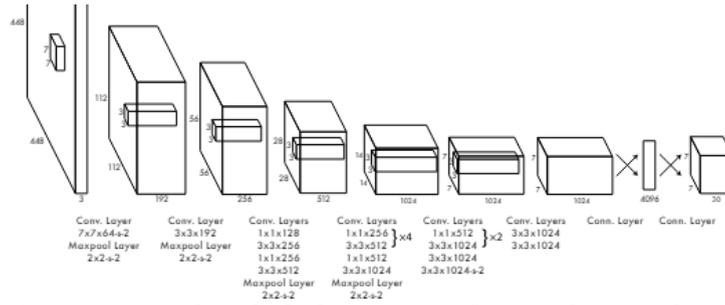


Figura 1. Arquitetura da rede de detecção com 24 camadas convolucionais e 2 conectadas.

O conjunto de dados (Brain MRI Tumor Segmentation Dataset open Source Dataset, 2024), composto por 1.937 imagens, foi dividido em três subconjuntos: 70% para treinamento, 20% para validação e 10% para teste. Essa divisão garantiu uma avaliação robusta do modelo, permitindo analisar sua capacidade de generalização. A análise do rendimento deste modelo foi feita com base em métricas comuns no campo da detecção de objetos, proporcionando uma perspectiva completa de sua capacidade preditiva e da qualidade geral das previsões (da Silva, 2017).

As principais métricas de desempenho utilizadas incluem a Acurácia na equação (1), que mede a proporção de predições corretas em relação ao total de amostras analisadas; o Recall na equação (2), que avalia a proporção de detecções corretas em relação ao total de objetos reais presentes; a Precisão na equação (3), que mede a proporção de detecções corretas em relação ao total de detecções realizadas; e o F1-score na equação (4), que representa a média harmônica entre a Precisão e o Recall. Juntas, essas métricas fornecem uma avaliação abrangente do desempenho do modelo, equilibrando a capacidade de detectar corretamente os objetos, a qualidade das detecções realizadas e o percentual geral de acertos.

$$Acurácia = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

- TP: Verdadeiro Positivo.
 - Tumores corretamente detectados pelo modelo. Representa os casos em que o modelo marcou uma área como tumor e essa predição estava correta.
- TN: Verdadeiro Negativo.
 - Áreas corretamente identificadas como não tumor. Representa os casos em que o modelo indicou ausência de tumor em uma área, e isso estava correto.
- FP: Falso Positivo.
 - Detecções incorretas de tumor. Representa os casos em que o modelo marcou uma área como tumor, mas na verdade não havia tumor
- FN: Falso Negativo.
 - Tumores não detectados pelo modelo. Representa os casos em que o modelo não conseguiu identificar a presença de um tumor que realmente existia.

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

- TP: Verdadeiro Positivo.
 - Mesmo conceito usado no *Acurácia*.
- FN: Falso Negativo.
 - Mesmo conceito usado na *Acurácia*

$$\text{Precisão} = \frac{TP}{TP+FP} \quad (3)$$

- TP: Verdadeiro Positivo.
 - Mesmo conceito usado no *Acurácia*.
- FP: Falso Positivo.
 - Mesmo conceito usado no *Acurácia*.

$$F1 = 2 \cdot \frac{\text{Precisão} \cdot \text{Recall}}{\text{Precisão} + \text{Recall}} \quad (4)$$

3. Resultados e Discussão

O tempo total de treinamento foi de 24 horas, utilizando as configurações detalhadas na seção de Materiais e Métodos. O modelo foi treinado por 100 épocas, e a 35ª época apresentou os melhores resultados, conforme destacado na Tabela 1. Esses resultados demonstram a eficácia e o potencial do sistema de segmentação de tumores cerebrais, evidenciando sua capacidade de gerar segmentações precisas e de alta qualidade.

A avaliação detalhada do modelo é apresentada pela Figura 2, que exibe a matriz de confusão gerada durante os testes. O modelo identificou corretamente 121 tumores (Verdadeiros Positivos – TP), com apenas 2 casos de tumores não detectados (Falsos Negativos – FN). Além disso, não foram registrados Falsos Positivos – FP, enquanto 70 regiões foram corretamente classificadas como áreas saudáveis (Verdadeiros Negativos – TN).

Os valores de precisão, recall e F1 Score apresentados na Tabela 1 reforçam o alto desempenho do modelo:

Tabela 1. Métricas de desempenho do modelo para segmentação de tumores cerebrais, incluindo precisão, recall e F1 Score para máscaras e caixas delimitadoras.

Métricas	Descrição	Valor
<i>Accuracy</i>	Mede a proporção de predições corretas em relação ao total de amostras.	98%
<i>Precision</i>	Precisão das previsões na máscara de segmentação	98%
<i>Recall</i>	Capacidade de identificar corretamente as segmentações	100%
<i>F1 Score</i>	Média harmônica entre a precisão e o <i>recall</i> .	99%

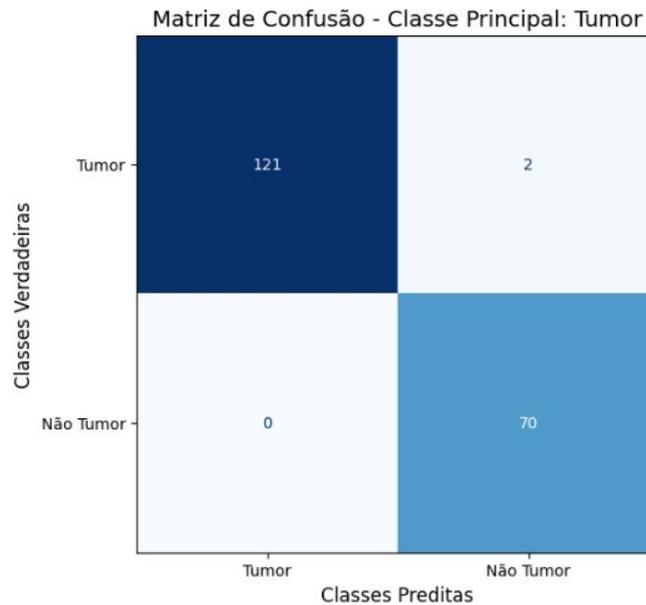


Figura 2. Matriz de confusão gerada durante a avaliação do modelo de segmentação de tumores cerebrais.

Esses resultados destacam a robustez do modelo, com alto desempenho nas principais métricas avaliadas. A combinação de precisão e recall elevados indica que o sistema é capaz de identificar e segmentar de forma confiável as áreas tumorais em imagens de ressonância magnética. Para ilustrar a eficácia do modelo, as Figuras 3, 4 e 5 apresentam duas imagens de ressonância magnética cerebral: a original e a processada pelo sistema, destacando a segmentação da região do tumor. Essa visualização reforça o potencial do modelo para aplicação prática em diagnósticos médicos, contribuindo para o auxílio clínico e a tomada de decisão.

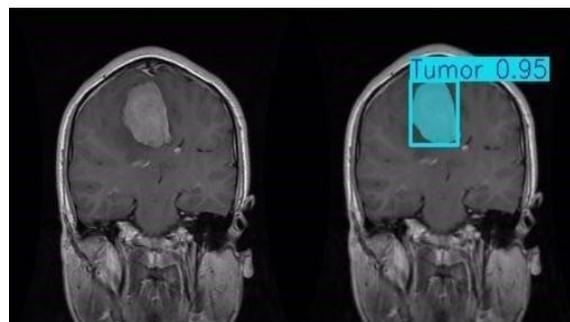


Figura 3. Detecção e Segmentação de Tumor com Caixa Delimitadora:

A Figura 3 mostra a detecção do tumor cerebral realizada pelo sistema, com a caixa delimitadora destacando a área identificada como tumor. À esquerda, é apresentada a ressonância magnética original, enquanto à direita, a imagem processada pelo sistema exibe a caixa delimitadora sobre a região do tumor, com a segmentação da área tumoral visível na parte posterior do crânio. A segmentação é realizada de forma precisa, separando claramente a região tumoral da parte saudável do tecido cerebral. Esta visualização evidencia a eficácia do modelo em identificar e destacar as áreas tumorais na imagem.

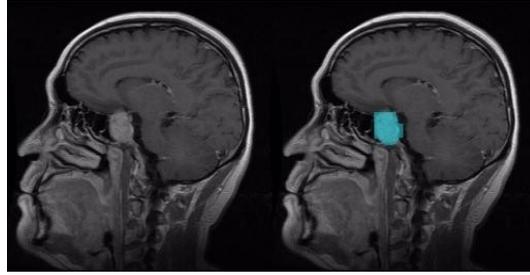


Figura 4. Segmentação sem Caixa Delimitadora – Vista Lateral do Crânio

Na Figura 4, a caixa delimitadora foi removida, mostrando apenas a segmentação do tumor cerebral. À esquerda, a imagem original e, à direita, a imagem processada pelo sistema, destacando a região lateral do crânio e oferecendo uma visualização mais clara da segmentação do tumor, sem distrações.

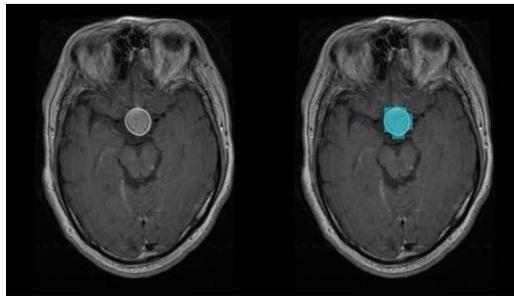


Figura 5. Segmentação sem Caixa Delimitadora – Vista Superior do Crânio

A Figura 5 também apresenta a segmentação do tumor cerebral, mas agora visualizada a partir da perspectiva superior do crânio. Como nas figuras anteriores, à esquerda vemos a original e, à direita, a imagem processada, com a segmentação do tumor claramente destacada na região do cérebro. A remoção da caixa delimitadora e a mudança de perspectiva proporcionam uma visão detalhada e precisa da localização e extensão do tumor na parte superior do crânio. Esta visualização oferece uma avaliação mais detalhada da segmentação em diferentes perspectivas anatômicas do cérebro.

4. Conclusão

A identificação de tumores cerebrais em imagens de ressonância magnética utilizando redes neurais convolucionais (CNNs) mostrou-se uma estratégia altamente eficaz para apoiar no diagnóstico e no planejamento de tratamentos. O modelo desenvolvido, baseado na arquitetura YOLOv11 e otimizado por aprendizado por transferência, obteve excelentes resultados nas métricas de Acurácia, Precisão, Recall e F1-Score, tanto para a segmentação das máscaras quanto para a identificação das regiões tumorais. Os resultados experimentais indicam que o sistema é capaz de identificar e segmentar com alta precisão as regiões tumorais, posicionando-se como uma ferramenta promissora para a análise automatizada de imagens médicas. A elevada performance do modelo, juntamente com a redução significativa no tempo de processamento, torna essa abordagem vantajosa para uso clínico, permitindo diagnósticos mais

rápidos e precisos de tumores cerebrais. Contudo, para otimizar ainda mais os resultados, estudos futuros podem explorar a ampliação do conjunto de dados e ajustes finos nos parâmetros do modelo, visando aprimorar a generalização para diferentes tipos de tumores. Tais avanços poderão fortalecer ainda mais a aplicação dessa tecnologia em cenários clínicos, oferecendo uma ferramenta robusta e confiável para os profissionais da saúde.

Referências

1. Brain MRI Tumor Segmentation Dataset. (2024). *Brain MRI Tumor Segmentation* [Dataset]. Roboflow Universe. <https://universe.roboflow.com/brain-mri-tumor-segmentation/brain-mri-tumor-segmentation-1d0nw>. Visitado em 11-10-2024.
2. da Silva, D. L., Seijas, L. M., & Bastos-Filho, C. J. (2017). Otimização por colônia artificial de abelhas para seleção de características no reconhecimento de sinais de trânsito. *International Journal of Swarm Intelligence Research (IJSIR)*, 8(2), 50–66.ion for feature selection of traffic sign recognition. *Int J Swarm Intell Res (IJSIR)* 8(2):50–66
3. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770-778.
4. Hong, Y., Gao, L., Chen, J., & Shi, M. (2021). Deep dual-resolution networks for real-time and accurate semantic segmentation of road scenes. *arXiv preprint arXiv:2101.06085*.
5. Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2015). You Only Look Once: Unified, real-time object detection. *University of Washington, Allen Institute for AI, Facebook AI Research*.
6. Silva, D. L., & Candido, E. A. (2016). Metodologia para extração de conhecimento em redes de computadores. *XI Congresso Norte Nordeste de Pesquisa e Inovação*, Maceió, AL, Brasil.
7. Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical Image Computing and Computer-Assisted Intervention* (pp. 234-241). Springer, Cham. https://doi.org/10.1007/978-3-319-24574-4_28