

Aplicação de EfficientNet com Transfer Learning e Grad-CAM para Classificação de Tumores Cerebrais em Imagens de Ressonância Magnética

Autores: João Carlos de A. Carrett(UFPel) , Murilo Costa Salem(UFPel), Daniel Henrique da Silva Pontes Barretos(UFPel), Anderson Priebe Ferrugem (UFPel)

1 DESCRIÇÃO DA INOVAÇÃO

1.1 Detalhamento da Tecnologia

Sistema de inteligência artificial baseado em redes neurais convolucionais (CNN) para classificação automática de tumores cerebrais a partir de imagens de ressonância magnética (MRI). Utiliza a arquitetura EfficientNet, pré-treinada em ImageNet (transfer learning), adaptada para classificar quatro tipos de tumores cerebrais: glioma, sem tumor, meningioma e pituitário. A técnica Grad-CAM é aplicada para gerar mapas de calor que destacam as regiões da imagem que mais contribuíram para a decisão da rede, proporcionando interpretabilidade ao modelo.

1.2 Diferenciais

Eficiência: O EfficientNet atinge alta acurácia com menos parâmetros e operações em comparação a outras arquiteturas.

Interpretabilidade: A utilização do Grad-CAM permite visualizar as áreas de interesse na imagem, auxiliando médicos na compreensão do diagnóstico.

Transfer Learning: Aproveita o conhecimento prévio da rede treinada em ImageNet, permitindo treinamento eficaz mesmo com um conjunto menor de imagens médicas.

Classificação Multiclasse: Capaz de distinguir entre quatro classes de tumores cerebrais, incluindo a ausência de tumor

1.3 Como funciona na prática

1. Pré-processamento das imagens: redimensionamento para 150x150 pixels e normalização.
2. Carregamento do modelo EfficientNet pré-treinado, com remoção da camada superior e substituição por uma nova camada densa para classificação em 4 classes.
3. Treinamento do modelo com o conjunto de dados de imagens de tumores cerebrais, utilizando técnicas de aumento de dados.
4. Após o treinamento, o modelo classifica novas imagens de MRI.
5. Para interpretação, o Grad-CAM é aplicado sobre as imagens classificadas, gerando um mapa de calor sobreposto à imagem original.

2 ESTADO DA ARTE

2.1 Contextualização Técnica e Científica

A classificação automática de tumores cerebrais por meio de imagens de ressonância magnética (MRI) tem sido amplamente estudada com o uso de redes neurais convolucionais (CNNs). Arquiteturas como ResNet, Inception e VGG são frequentemente utilizadas, porém demandam grande capacidade computacional e grandes volumes de dados. A arquitetura EfficientNet surge como um avanço significativo, otimizando a relação entre profundidade, largura e resolução da rede, alcançando alta acurácia com menor número de parâmetros. Sua combinação com técnicas de *transfer learning* permite um treinamento eficiente mesmo em conjuntos de dados limitados, comum na área médica. Além da precisão, a interpretabilidade do modelo é essencial para aplicações clínicas. O Grad-CAM (Gradient-weighted Class Activation Mapping) destaca-se por fornecer mapas de calor que identificam as regiões da imagem mais relevantes para a decisão do modelo, aumentando a confiança dos profissionais de saúde.

2.2 Inovações Propostas

- Combinação inédita de EfficientNet e Grad-CAM aplicada especificamente à classificação de quatro tipos de tumores cerebrais: glioma, meningioma, pituitário e ausência de tumor; Uso de técnicas de aumento de dados (*data augmentation*) para melhorar a generalização do modelo em cenários com dados limitados; Desenvolvimento de um pipeline completo de pré-processamento, treinamento e interpretação, otimizado para imagens médicas.

2.3 Comparação com Trabalhos Correlatos

Enquanto a maioria das soluções existentes utiliza arquiteturas mais pesadas (ex: ResNet50, VGG19) e nem sempre incorporam mecanismos de interpretabilidade, a proposta aqui apresentada oferece: Menor custo computacional e maior eficiência; Explicabilidade visual através do Grad-CAM; Melhor desempenho em bases de dados reduzidas graças ao *transfer learning*.

2.4 Contribuições para a Área

- Disponibilização de um modelo leve, preciso e interpretável para auxílio ao diagnóstico de tumores cerebrais. Metodologia reprodutível que pode ser adaptada para outras modalidades de imagem médica. Base para futuras pesquisas em interpretabilidade e confiabilidade de modelos de IA na saúde.

3 ESTRATÉGIA DE DESENVOLVIMENTO E IMPLEMENTAÇÃO

3.1 Metodologia de Pesquisa e Desenvolvimento

O desenvolvimento do modelo seguiu uma abordagem baseada em metodologias de aprendizado de máquina aplicadas à área de saúde. Foram adotadas as seguintes etapas: Coleta e preparação dos dados: Utilizou-se um conjunto público

de imagens de ressonância magnética (MRI) contendo quatro classes: glioma, meningioma, tumor pituitário e ausência de tumor. Os dados foram divididos em conjuntos de treinamento, validação e teste. Pré-processamento: As imagens foram redimensionadas para 150x150 pixels e normalizadas. Técnicas de aumento de dados (*data augmentation*) foram aplicadas para melhorar a generalização do modelo. Arquitetura do modelo: Foi utilizada a arquitetura EfficientNet-B0, pré-treinada no conjunto ImageNet, com substituição da camada fully connected superior para adaptação à tarefa de classificação em quatro classes. Treinamento: O modelo foi treinado utilizando otimizador Adam e função de perda categórica *cross-entropy*. O treinamento foi monitorado com base na acurácia e perda no conjunto de validação. Interpretabilidade: A técnica Grad-CAM foi implementada para gerar mapas de ativação, permitindo a visualização das regiões da imagem que mais influenciaram a decisão do modelo.

3.2 Avaliação Experimental

O modelo foi avaliado por meio das métricas de desempenho padrão em classificação multiclasse: acurácia, precisão, recall e F1-score. A validação cruzada foi utilizada para assegurar a robustez dos resultados. Além disso, os mapas de calor do Grad-CAM foram qualitativamente analisados por especialistas em radiologia para verificar a relevância clínica das regiões destacadas.

3.3 Próximas Etapas de Pesquisa

Validação do modelo em conjuntos de dados independentes e multi-institucionais; Exploração de outras arquiteturas de redes neurais e técnicas de fine-tuning; Publicação dos resultados em periódicos científicos e repositórios públicos de código; Desenvolvimento de uma interface aberta para teste e validação pela comunidade científica.

4 RESULTADOS ESPERADOS E IMPACTO

4.1 Resultados Técnicos Esperados

- Alta acurácia na classificação de tumores cerebrais, comparável ou superior ao estado da arte; Redução do número de parâmetros e do custo computacional em relação a modelos baseados em ResNet ou VGG; Geração de mapas de calor clinicamente interpretáveis que corroboram as decisões do modelo; Publicação de artigos científicos detalhando a metodologia e os resultados obtidos.

4.2 Impacto Científico

Contribuição para a área de diagnóstico assistido por IA, com foco em interpretabilidade e confiabilidade; Disponibilização de um modelo eficiente e reprodutível que pode ser adaptado para outras tarefas de classificação de imagens médicas; Estímulo à pesquisa interdisciplinar entre ciência da computação e medicina.

4.3 Impacto Social e na Saúde

Potencial para auxiliar radiologistas no diagnóstico precoce e preciso de tumores cerebrais; Possibilidade de aplicação em regiões com escassez de especialistas, aumentando o acesso a diagnósticos de qualidade; Base para futuros desenvolvimentos em sistemas de apoio à decisão clínica.

5 CONCLUSÕES

5.1 Contribuições do Trabalho

Este trabalho propõe um pipeline completo para classificação de tumores cerebrais em imagens de MRI, combinando a eficiência da arquitetura EfficientNet com a transparência interpretativa do Grad-CAM. Os resultados preliminares indicam que a abordagem é viável e promissora, com potencial para se tornar uma ferramenta valiosa tanto para a pesquisa acadêmica quanto para aplicações clínicas futuras.

5.2 Limitações e Trabalhos Futuros

As principais limitações incluem a dependência de um conjunto de dados específico e a necessidade de validação externa. Como trabalhos futuros, planeja-se: Expandir a base de dados com imagens de múltiplas fontes; Realizar estudos clínicos em colaboração com instituições de saúde; Explorar a integração do modelo com sistemas de prontuário eletrônico e plataformas de telemedicina.

5.3 Considerações Finais

A combinação de redes neurais eficientes e técnicas de explicabilidade representa um avanço significativo para a adoção clínica de sistemas de IA. Este estudo demonstra que é possível desenvolver modelos precisos e interpretáveis, contribuindo para uma maior confiança e transparência no uso de inteligência artificial na medicina.

6 REFERÊNCIAS BIBLIOGRÁFICAS

6.1 Artigos

• TAN, M.; LE, Q. V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. International Conference on Machine Learning, 2019. • SELVARAJU, R. R. et al. Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization. International Conference on Computer Vision, 2017. • CHENG, J. et al. Brain Tumor Dataset. Figshare, 2017.

6.2 Livros

• GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Deep Learning. MIT Press, 2016. 6.3 Documentos eletrônicos WORLD HEALTH ORGANIZATION. Cancer. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/cancer>. Acesso em: 25 abr. 2023.