



APRENDIZADO PROFUNDO DE MÁQUINAS PARA DIAGNÓSTICO DE TUMORES CEREBRAIS A PARTIR DA ANÁLISE DE EXAMES DE IMAGEM

DEEP MACHINE LEARNING FOR BRAIN TUMOR DIAGNOSIS THROUGH IMAGE ANALYSIS

Luisa de Souza Teixeira, Yesus Hadshimitra dos Santos, Luiz Antônio Ferraro Mathias

Universidade Santa Cecília, Faculdade de Engenharia, Curso de Sistemas de Informação
E-mail para contato: lusouza.alegre@gmail.com, yesushds123@gmail.com

RESUMO – A pesquisa aborda o aprendizado profundo de máquina, também conhecido como "deep learning", uma área da Inteligência Artificial que utiliza redes neurais artificiais para identificar tumores cerebrais a partir de exames de imagem. O estudo foca na aplicação destas redes para o reconhecimento de imagens nas quais fora detectada a presença de tumores cerebrais. Foi desenvolvida uma aplicação computacional utilizando técnicas e algoritmos de IA, especificamente a arquitetura VGG16, uma das Redes Neurais Convolucionais (RNCs) mais populares na visão computacional. Diversas ferramentas computacionais foram empregadas no desenvolvimento do projeto. O modelo concebido alcançou uma taxa de 70% de assertividade em imagens com e sem tumores cerebrais, com expectativas de melhoria contínua.

Palavras-chave: Aprendizado de máquina; Exames de Imagem; Inteligência Artificial; Rede Neural Convolucional; Tumor Cerebral.

ABSTRACT – The research addresses deep machine learning, also known as "deep learning", an area of Artificial Intelligence that uses artificial neural networks to identify brain tumors from image exams. The study focuses on the application of these networks to recognize images in which the presence of brain tumors has been detected. A computational application was developed using AI techniques and algorithms, specifically the VGG16 architecture, one of the most popular Convolutional Neural Networks (CNNs) in computer vision. Several computational tools were used in the development of the project. The designed model achieved a 70% accuracy rate in images with and without brain tumors, with expectations of continuous improvement.

Keywords: Machine Learning; Image Exams; Artificial Intelligence; Convolutional Neural Network; Brain Tumor.

Tipo do trabalho: () Iniciação científica (X) Iniciação tecnológica () Extensão

1 INTRODUÇÃO

Estudo de doenças oncológicas e Exames de imagem

O estudo das doenças oncológicas é essencial, pois o câncer é uma das principais causas de morbidade e mortalidade em todo o mundo. Nesse sentido, aprimorar a precisão dos exames diagnósticos torna-se uma meta cada vez mais relevante para a ciência.

Os exames de imagem consistem na principal forma para o diagnóstico de inúmeras doenças, inclusive o tumor cerebral. Eles fornecem informações e características detalhadas sobre os tumores cerebrais, permitindo um diagnóstico preciso e um plano de tratamento adequado.

Inteligência humana e Inteligência artificial

O conceito de inteligência proposto por (Zylberberg, 2018, p.2 apud Gardner 1994) [1], inicialmente, era a capacidade de resolver problemas ou elaborar produtos importantes em determinado ambiente ou comunidade cultural. Duas décadas após a publicação de sua teoria, ele reformulou este conceito substituindo o termo “capacidade” por potencial biopsicológico, querendo distanciar-se da concepção mais biológica.

A Inteligência Artificial (IA) é um campo de estudo da ciência da computação que se concentra na criação de sistemas capazes de realizar tarefas que normalmente requerem inteligência humana. Isso inclui a capacidade de aprender, raciocinar, adaptar-se e tomar decisões. A IA é frequentemente dividida em subcampos, incluindo aprendizado de máquina e processamento de linguagem natural, permitindo que máquinas realizem tarefas complexas de forma autônoma e aprendam com dados.

Machine Learning (ML) e suas aplicações

O ML é a ciência do desenvolvimento de algoritmos e modelos estatísticos que os sistemas de computador usam para realizar tarefas sem instruções explícitas, confiando em padrões e inferência, dando a capacidade de identificar padrões em dados massivos e fazer previsões. Essa aprendizagem permite que os computadores efetuem tarefas específicas de forma autônoma, sem necessidade de serem programados. Em resumo, a máquina aprende com os dados e melhora sua performance ao longo do tempo.



O ML vem revolucionando pelo campo da saúde e das ciências biológicas, fazendo com que os pesquisadores desenvolvam soluções capazes de detectar tumores e doenças, impactando significativamente o resultado da saúde humana.

Redes Neurais Artificiais e seus tipos

As Redes Neurais Artificiais (RNCs) são um subconjunto de ML e um dos tipos de redes neurais, seu nome e estrutura são inspirados no cérebro humano, imitando a maneira como os neurônios biológicos enviam sinais uns para os outros. As RNCs são utilizadas para processamento de linguagem natural, são classificadas de acordo com os seus propósitos onde cada uma tem suas características específicas, e além disso são capazes de simular a capacidade cognitiva humana, identificando rostos, indivíduos e outros elementos presentes em uma imagem.

O presente trabalho teve como objetivo desenvolver uma Rede Neural Convolucional, que utilizasse técnicas e algoritmos de IA para o reconhecimento de imagens, como sugestão para um potencial significativo de transformar o diagnóstico médico e promover avanços tecnológicos na área da saúde.

2 MATERIAIS E MÉTODOS

Foi conduzida uma pesquisa experimental utilizando imagens de ressonância magnética cerebral, com e sem tumor, extraídas do Kaggle (plataforma que hospeda diversos datasets), especificamente do dataset Br35H Brain Tumor Detection 2020. O conjunto de dados foi dividido em 70% para treinamento, 20% para validação e 10% para teste, com uma distribuição balanceada entre imagens com e sem tumor.

O modelo foi implementado utilizando as tecnologias Python (versão 3.10.12), Google Colab, Tensorflow (2.15.0), API Keras, NumPy (1.25.2) e Matplotlib (3.7.1), com suporte computacional avançado de GPUs e TPUs fornecido pelo Colab. A Rede Neural Convolucional (CNN) desenvolvida contava com 9 camadas, incluindo uma camada de pré-processamento para ajuste das dimensões das imagens, seguida por 5 camadas convolucionais (com 4, 32, 32, 64 e 128 nós computacionais, respectivamente, e função de ativação ReLU) e 2 camadas densas, sendo a primeira com 128 nós, e função de ativação Softmax, e a segunda com apenas 1 retorno lógico, e função Sigmoid, destinadas à submissão do valor variável entre presença ou ausência de tumor. Além disso, as imagens foram submetidas a um pré-processamento que aplicou filtros de zoom, alteração de largura e altura e cisalhamento para melhorar a performance do modelo.

3 CONCLUSÃO

O treinamento da rede neural foi realizado utilizando o método de otimização "adam" e a função de perda "binary_crossentropy", o treinamento foi feito com todo o dataset em 10 ciclos (epochs), mas as limitações de RAM impediram sua conclusão. Conforme registrado na tabela 1, várias tentativas foram realizadas com diferentes quantidades de imagens e ajustes nos ciclos de treino, porém o problema persistiu até a redução da resolução das imagens para 128x128, assim, possibilitando que o treinamento fosse concluído com sucesso, registrando uma leve redução na perda de 0,6515 para 0,6365 em 10 ciclos.

Conforme a figura 1, foi implementado o modelo VGG16, em uma tentativa de otimizar ainda mais o desempenho. De acordo com a figura 2, a configuração do VGG16 foi ajustada para incluir a função de parada antecipada ("EarlyStopping"), que interrompe o treino ao atingir o valor máximo da acurácia. Após o treinamento, a acurácia do VGG16 atingiu aproximadamente 60%, com 57% de acurácia de validação.

Figura 1: Configuração de compilação.

```
#VGG16
opt = tf.keras.optimizers.SGD(learning_rate=1e-6, momentum=0.9)
model.compile(loss='categorical_crossentropy', optimizer=opt, metrics=['accuracy'])
```

Figura 2: Modelagem do VGG16.

```
#VGG16
model.add(tf.keras.layers.Conv2D(input_shape=(224,224,3),filters=64,kernel_size=(3,3),padding='same', activation='relu'))
model.add(tf.keras.layers.Conv2D(filters=64,kernel_size=(3,3),padding='same', activation='relu'))
model.add(tf.keras.layers.MaxPool2D(pool_size=(2,2),strides=(2,2)))
model.add(tf.keras.layers.Conv2D(filters=128,kernel_size=(3,3), padding='same', activation='relu'))
model.add(tf.keras.layers.Conv2D(filters=128,kernel_size=(3,3), padding='same', activation='relu'))
model.add(tf.keras.layers.MaxPool2D(pool_size=(2,2),strides=(2,2)))
model.add(tf.keras.layers.Conv2D(filters=256,kernel_size=(3,3), padding='same', activation='relu'))
model.add(tf.keras.layers.Conv2D(filters=256,kernel_size=(3,3), padding='same', activation='relu'))
model.add(tf.keras.layers.MaxPool2D(pool_size=(2,2),strides=(2,2)))
model.add(tf.keras.layers.Conv2D(filters=512,kernel_size=(3,3), padding='same', activation='relu'))
model.add(tf.keras.layers.Conv2D(filters=512,kernel_size=(3,3), padding='same', activation='relu'))
model.add(tf.keras.layers.Conv2D(filters=512,kernel_size=(3,3), padding='same', activation='relu'))
model.add(tf.keras.layers.MaxPool2D(pool_size=(2,2),strides=(2,2),name='vgg16'))
model.add(tf.keras.layers.Flatten(name='flatten'))
model.add(tf.keras.layers.Dense(256, activation='relu', name='fc1'))
model.add(tf.keras.layers.Dense(128, activation='relu', name='fc2'))
model.add(tf.keras.layers.Dense(3, activation='softmax', name='output'))
```

Diante dos resultados insatisfatórios, a arquitetura do modelo foi revista, integrando camadas de pooling, conforme a figura 3, chegando a picos de até 76%, demonstrando uma melhora significativa, tendo os resultados registrados na tabela 1.

Figura 3: Modelo VGG16 Ajustado.



```
model.add(tf.keras.layers.Conv2D(input_shape=(224,224,3),filters=64,kernel_size=(3,3),padding='same', activation='relu'))
model.add(tf.keras.layers.Conv2D(filters=64,kernel_size=(3,3),padding='same', activation='relu'))
model.add(tf.keras.layers.MaxPool2D(pool_size=(2,2),strides=(2,2)))
model.add(tf.keras.layers.Flatten(name='flatten'))
model.add(tf.keras.layers.Dense(256, activation='relu', name='fc1'))
model.add(tf.keras.layers.Dense(128, activation='relu', name='fc2'))
model.add(tf.keras.layers.Dense(3, activation='softmax', name='output'))
```

Tabela 1: Resultados.

Modelo	Acurácia (%)
Modelo Inicial	66
VGG16	60
VGG16 Ajustado	70

4 CONSIDERAÇÕES FINAIS

O estudo desenvolveu uma Rede Neural Convolucional baseada na arquitetura VGG16 para detecção de tumores cerebrais, utilizando o dataset Br35H Tumor Detection 2020, e alcançou uma acurácia de 70% e um loss de 64,96%. Com o suporte de ferramentas como Python, TensorFlow, Keras, Numpy e Matplotlib no Google Colab, o modelo mostrou-se eficaz na análise de imagens médicas, destacando o impacto da Inteligência Artificial e do aprendizado profundo na área da saúde. Os resultados evidenciam a eficácia das redes neurais artificiais na detecção de tumores, sugerindo um potencial significativo para transformar o diagnóstico médico e promover avanços tecnológicos na área da saúde.

5 REFERÊNCIAS

1. NISTA-PICCOLO, Vilma Leni; ZYLBERBERG, Tatiana Passos. AS CONTRIBUIÇÕES DOS ESTUDOS SOBRE INTELIGÊNCIA HUMANA PARA A PEDAGOGIA DO ESPORTE. Revista UFG, v. 11, n. 1, p. 1-10, 2008.
2. ALVES, Gisely. Medium. Entendendo Redes Convolucionais (CNNs). 8 out. 2018.