

DEEP LEARNING PARA IDENTIFICAÇÃO E CLASSIFICAÇÃO EM IMAGENS DE MANGUEZAIS

IAGO NOGUEIRA MEDEIROS ¹; JONATHAN MARTINEZ TSEN ¹
JOÃO RICARDO FAVAN²

¹ Discente no curso Big Data no Agronegócio, FATEC Pompéia, Pompéia-SP.

² Docente do curso Big Data no Agronegócio, FATEC Pompéia, Pompéia-SP.

Resumo

As imagens de satélite podem fornecer muitas informações das superfícies terrestres em grande escala em um curto espaço de tempo. Com a evolução e o desenvolvimento de sensores que fornecem imagens de satélite, a resolução das imagens é aprimorada. Com isso, os manguezais estão entre os ecossistemas mais produtivos existentes, com muitos benefícios ecológicos. Portanto, o mapeamento preciso do desmatamento de ecossistemas de mangue é crucial para a proteção, conservação e planejamento de reflorestamento desses valiosos recursos naturais. O objetivo deste estudo foi identificar e classificar classes de manguezais em diferentes locais com a utilização do Deep Learning. Para tanto, foram coletadas 420 imagens divididas em três classes através do Google Maps de 5 países: Brasil, Índia, Austrália, África e os Estados Unidos. A abordagem proposta depende de um fluxo de trabalho direto, mas eficaz, para o mapeamento de ecossistemas de manguezais, com uma alta taxa de automação que pode ser facilmente implementada para o mapeamento frequente e preciso em outras partes do mundo. O modelo proposto apresentou o melhor desempenho de 92,50% de acuracidade no conjunto de dados selecionados. Nesse sentido, conclui-se que a abordagem proposta de identificar e classificar imagens de manguezais com a utilização de uma Deep Learning se mostrou eficiente para tal finalidade, podendo ser extensível para a classificação de outras sequências de imagens.

Palavra-chave: Deep Learning; Manguezal; Tensorflow; Satélite; Google Maps; Inteligência Artificial

Introdução

O mangue é uma vegetação típica de áreas de regiões tropicais e subtropicais, localizado entre a terra e o mar, são constituídos por diversas espécies vegetais e de árvores, há um progresso de florescimento das árvores do mangue que se dá nas marés por conta dos nutrientes que habitam o local.

No Brasil se encontram grandes áreas de manguezais no norte e nordeste, no estado do Amapá é um dos ambientes que mais se encontram manguezais no Brasil, o Brasil é o segundo país em extensão de mangues, com aproximadamente 14.000km² ao litoral brasileiro.(INSTITUTO CHICO MENDES DE CONSERVAÇÃO DA BIODIVERSIDADE , 2018)

O Brasil perdeu 20% de sua área de manguezais nos últimos 17 anos, em partes devastadas pela expansão urbana, esse dado faz parte da segunda edição de mapas do Projeto de Mapeamento Anual da Cobertura e Uso do Solo no Brasil (MAPBIOMAS, 2019). Nas últimas quatro décadas, 35% das florestas de mangue globais foram desmatadas.

Esta degradação dos manguezais afeta cadeias sobre algumas das espécies marinhas mais ameaçadas do Brasil, que dependem deles como 'habitat', como o peixe-boi e inúmeras espécies marinhas das quais 70 a 80% dos peixes, crustáceos e moluscos que a população consome precisam do bioma em alguma fase da vida. Tem diversos peixes que utilizam a área de reprodução e depois voltam para o mar, espécies economicamente importantes (SCHAEFFER NOVELLI, 1995).

Para realizar o experimento proposto foi utilizado a linguagem de programação Python e diversas bibliotecas como descritas a seguir:

NumPy é uma biblioteca python que é usada principalmente para realizar cálculos em arrays, arranjos e vetores de N dimensões, com isso tem a possibilidade de fazer cálculos algébricos e arranjos multidimensionais (SANTIAGO, 2019).

De acordo com o artigo de Introdução a Biblioteca Pandas (RIBEIRO, 2020), Pandas é uma biblioteca disponível para a linguagem *python*, está biblioteca ajuda na manipulação e análise de dados, dessa forma facilita-se a jornada de trabalho do programador tornando-a simples e eficiente

Matplotlib é uma biblioteca de linguagem python, para a criação de

visualizações de dados em forma de gráfico (COUTINHO, 2021) .

OpenCV 2, que tem por meio dar o acesso ao objeto da imagem que é uma matriz de 2 dimensões (Largura e Altura), no entanto essa matriz contém 3 camadas e em cada dimensão contém as cores RGB, e incluímos as variáveis de linha e coluna para serem as componentes de cor, as variáveis da cor devem assumir o valor entre 0 e 255 então utilizamos o Image Data Generator na qual dividirá os pixels de cada imagem por 255 para que normalize e todos os pixels fiquem entre 0 e 1 (GRANDO, 2019).

Keras é uma biblioteca de Redes Neurais, contendo uma interface mais simples e capaz de rodar com o Tensor Flow e que foi desenvolvida pensando em possibilitar uma fácil e rápida implementação (SANTANA 2020).

Tensor Flow é uma biblioteca de código aberto que pode ser usada para definir, treinar e executar modelos de aprendizado de máquina e pesquisa de redes neurais profundas, fazendo o uso somente de um navegador de internet(Google Collaboratory), através da linguagem python. O framework tem um conjunto abrangente e flexível de ferramentas, bibliotecas e recursos da comunidade que permitem criar modelos de machine learning de alta qualidade e eficiência.

O módulo OS em python fornece funções para interagir com o sistema operacional, fornecendo funções para criar e remover um diretório, buscar seu conteúdo, alterar e identificar o diretório atual (GEEKSFORGEEEKS, 2021).

Seaborn é uma biblioteca de visualização de dados em python baseada em matplotlib. Ele fornece uma interface de alto nível para desenhar gráficos estatísticos atraentes e informativos (SANTANA, 2020).

ResNet-50 é uma rede neural convolucional com 50 camadas de profundidade podendo carregar uma versão pré-treinada da rede treinada em mais de um milhão de imagens do banco de dados, o modelo apresentado teve uma especificação pois é dividido em 3 classes e conteve um resultado com parâmetros totais de 23.587.712 e para parâmetros treináveis com o resultado de 23.534.592 imagens (MATHWORKS, 2021).

O monitoramento eficaz é necessário para conservar os manguezais de novas perdas tanto no Brasil quanto no mundo. Nesse contexto, o sensoriamento remoto consegue fornecer informações sobre o estado e as mudanças dos

manguezais em grande extensão espacial e de forma contínua.

Neste estudo diferentemente de outros trabalhos que utilizam imagens em NDVI, tem como objetivo utilizar imagens de satélite do Google Maps em RGB para identificar e classificar regiões de manguezais, rios e margem dos rios, com técnicas de *Deep Learning* nas quais contém um conjunto de algoritmos modelados como inspiração para recriar o cérebro humano, e cada rede neural é como um neurônio que utilizamos para reconhecer e agrupar as imagens.

2 METODOLOGIA

O capítulo seguinte apresenta os passos realizados para o desenvolvimento do projeto. Desde a coleta dos dados, procedimentos experimentais, materiais usados e a utilização do modelo preditivo.

O projeto foi desenvolvido utilizando a linguagem de programação *Python* tanto para o processo da *coleta de dados*, *pré-processamento* e aplicação dos modelos de *Deep Learning*. As bibliotecas em Python que foram utilizadas para o desenvolvimento do projeto foram:

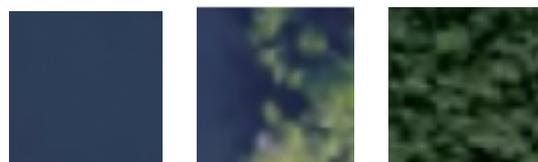
- Sklearn versão: 0.24.2 (SKLEARN, 2021)
- Numpy versão: 1.21.0 (NUMPY, 2021)
- Pandas versão: 1.3.1 (ROESCHKE et al, 2021)
- Matplotlib versão: 3.4.0 (HUNTER et al, 2021)
- OpenCV versão: 4.5.2 (OPENCV, 2021)
- Keras versão: 2.6.0 (KERAS, 2021)
- Tensorflow versão: 2.6.0 (TENSORFLOW, 2021)
- Python versão: 3.8.1 (PYTHON, 2021)
- Seaborn versão: 0.11.2 (SEABORN, 2021)

As tecnologias que foram utilizadas no processo todo do projeto foram:

- Jupyter Notebook;
- Google Maps;
- Google Collab;
- GitLab.

Este estudo se concentra em conseguir identificar e classificar classes em diferentes locais o qual coletamos imagens através do Google Maps de 5 diferentes países os quais são: Brasil, Índia, Austrália, África e os Estados Unidos. Conforme (Figura 1), as amostras de imagens coletadas contém um formato de 50x50 pixels, foram coletadas 420 imagens no total onde dividimos em três classes que são: rio, margem e manguezal (PURNAMASAYANGSUKASIH et al. 2016).

Figura 1: Exemplificação das classes



Rio

Margem

Manguezal

FONTE: GOOGLE MAPS (2021)

As amostras de referência das imagens foram divididas aleatoriamente em dois grupos de amostras de treinamento (80%) e teste (20%). A divisão aleatória leva a um baixo viés no desempenho dos resultados da classificação final (PAWLUSZEK; BORKOWSKI, 2020).

Para o desenvolvimento do modelo de Deep Learning foi utilizado Tensor Flow com Keras, Tensor Flow é uma biblioteca de código aberto que pode ser usada para definir, treinar e executar modelos de aprendizado de máquina e pesquisa de redes neurais profundas, fazendo o uso somente de um navegador de 'internet' (Google Collaboratory), através da linguagem Python.

Através da rede neural, foi utilizado para o input layer a camada Flatten pois ela nivelou e reformula o tensor para ter uma forma que seja igual ao número de elementos contidos no tensor.

Para a implementação do modelo utilizamos a função Relu pois contém camadas de neurônios ativos, já o modelo Softmax é usado para a camada de saída do classificador, pois é onde está sendo gerado probabilidades para definir as 3 classes de entrada.

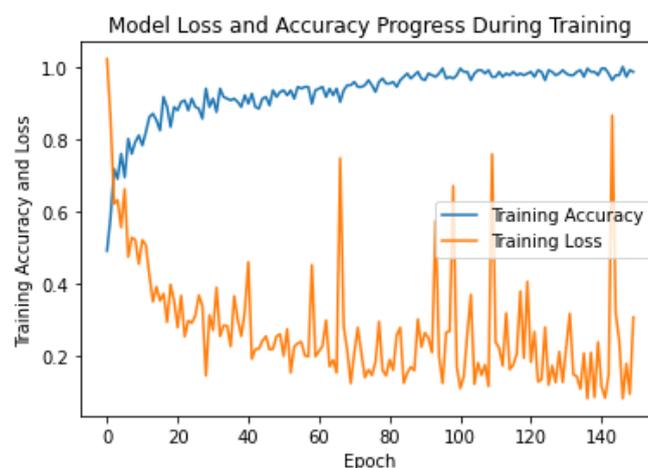
Resultados e Discussão

Implementamos um modelo de reconhecimento de manguezais, rios e margem foi alcançado 92,50% de acurácia. Ao final deste capítulo, compreenderemos o motivo da escolha do modelo proposto e sua função neste projeto. Podemos descobrir o melhor modelo com o melhor resultado preciso usando diferentes tipos de localidade de dados.

As métricas a seguir tanto de acurácia quanto a de perda são métricas muito utilizadas em aprendizado de máquinas pois com elas se pode ter uma demonstração visível dos resultados de acurácia e de perda do projeto proposto.

O gráfico conforme mostrado na Figura 3, percebe-se um aumento progressivo na acuracidade do modelo conforme as Épocas passam na qual atingimos uma acuracidade de 92.50%.

Figura 3: Demonstração do treinamento de acurácia e de perda do modelo

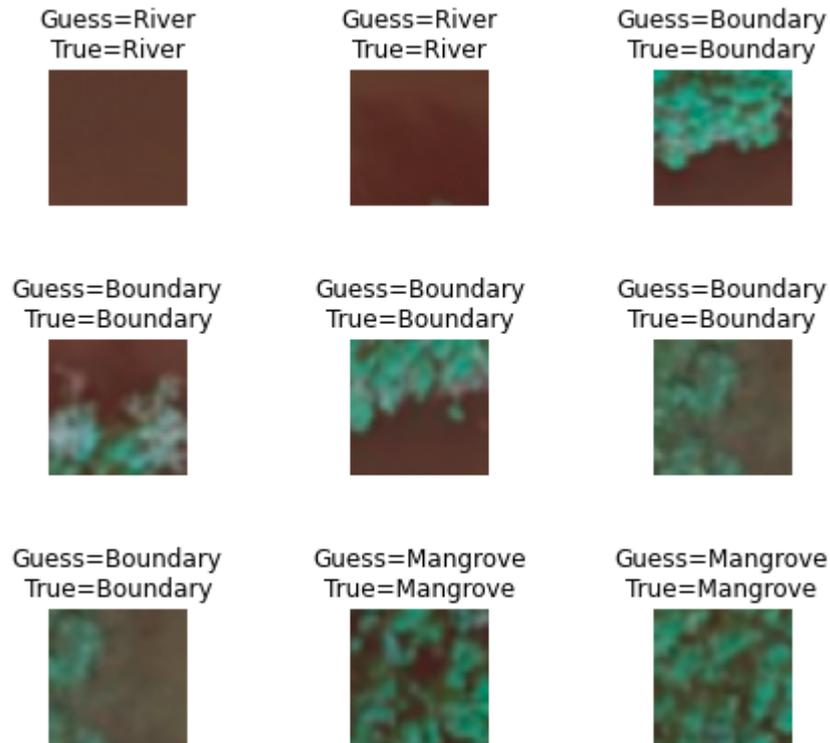


Fonte: Autores(2021)

Na Figura 4, pode ser observado o guess, que seria a validação da imagem se o algoritmo reconhece que a imagem apresentada for uma imagem de um rio, a mesma será considerada verdadeira, fazendo com que a validação

da imagem esteja correta.

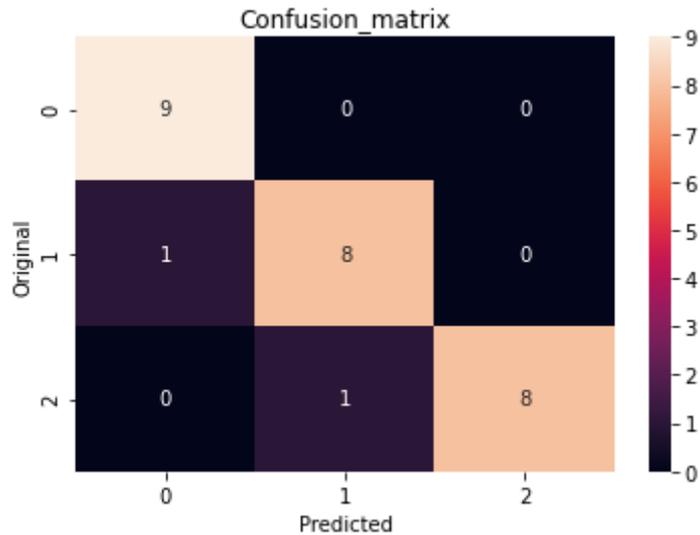
Figura 4: Validação das imagens



Fonte: Autores(2021)

A utilização do modelo de matriz de confusão é uma tabela específica que permite a visualização do desempenho de um algoritmo, e podemos perceber que na figura 5 que houve uma boa classificação da matriz, pois, a matriz de confusão do classificador possui a diagonal principal com valores positivos e a diagonal secundário com valores zero ou próximo a zero.

Figura 5: Matriz de Confusão



Fonte: Autores(2021)

Resultados semelhantes podem ser observados no artigo de Islam et al. (2019), o qual obteve uma acurácia de 92% a 95% de acurácia, resultado apresentado se obteve semelhança, pois foi atingida uma acurácia de 92%.

Além disso, notamos que o modelo apresentou um F1-score de 89% e um Precision e Recall de 88%. Com isso, ao final do experimento, podemos concluir que os objetivos do projeto foram alcançados pois a utilização de Deep Learning se mostrou eficiente para identificar manguezais, margem e rio, podendo ser extensível para a classificação de outras sequências de imagens.

Conclusões

Conclui-se que foi possível realizar a identificação e classificação das imagens de manguezais com a utilização de uma Deep Learning e se mostrou eficiente para tal finalidade. Com a utilização Deep Learning nas quais contém um conjunto de algoritmos modelados e se mostrou apto para realizar a identificação e classificação dos manguezais tanto no Brasil quanto no mundo. A necessidade de uma análise de imagens de satélite pode fornecer informações precisas para o planejamento de conservação e formulação de políticas, visto que as imagens de satélites estão atualmente em estágios avançados. Este trabalho de pesquisa ajudará alunos e pesquisadores que desejam seguir e pesquisar mais a fundo sobre esse tópico.

Agradecimentos

Queremos agradecer primeiramente a Deus por mais uma etapa em nossas vidas, em seguida nosso professor João Ricardo Favani que nos instruiu e nos apoiou nessa jornada em nossas vidas nos dando todo conhecimento e suporte.

Referências

BORKOWSKI, Andrzej; FILIPIAK, Kamila. **Sobre a importância da proporção de divisão de teste-treino de conjuntos de dados na detecção automática de deslizamento de terra por classificação supervisionada.** Polônia. 15 set. 2020

BROWNLEE, Jason. **Use Early Stopping to Halt the Training of Neural Networks At the Right Time.** Machine Learning Mastery. Disponível em <<https://machinelearningmastery.com/how-to-stop-training-deep-neural-networks-at-the-right-time-using-early-stopping/>>, 25 ago. 2020. Acesso em 6 set. 2021.

COUTINHO, Thiago. **O que é python matplotlib: Veja como o python matplotlib é uma tendência para os programadores e quais são as razões pelas quais essa modalidade pode ser considerada uma biblioteca de gráficos.** Blog Voitto, 11 jun. 2021. Disponível em <<https://www.voitto.com.br/blog/artigo/o-que-e-python-matplotlib/amp>>. Acesso em 18 ago. 2021

GEEKSFORGEES. **Os module in Python with Examples.** 19 aug, 2021. Disponível em: <<https://www.geeksforgeeks.org/os-module-python-examples/>>. Acesso em: 27 out, 2021.

HAO; LIYANG. et al. **TensorD: A Tensor Decomposition Library in TensorFlow.** China. 21 aug. 2018.

HUNTER, John. et al. **What's new?: What's new in Matplotlib.** In: HUNTER, John. What's new?: What's new in Matplotlib. 3.4.0. [S. l.], 25 jul. 2021. Disponível em: https://matplotlib.org/stable/users/whats_new.html. Acesso em: 1 nov. 2021.

ISLAM; MASUM. **Mangroves Tree Recognition Using Deep Learning.** Abr 2019. Disponível em:

<<http://dspace.daffodilvarsity.edu.bd:http://dspace.daffodilvarsity.edu.bd:8080/bitstream/handle/123456789/3610/P13335%20%2829%25%29.pdf?sequence=1&isAllowed=y8080/bitstream/handle/123456789/3610/P13335%20%2829%25%29.pdf?sequence=1&isAllowed=y>>.
Acesso em: 29 out, 2021.

JUNIOR, Nascimento; FILHO, Souza. **Mapa dos manguezais da região norte do Brasil**. 2008. Disponível em: <https://mapbiomas.org/mapas-de-referencia?cama_set_language=pt-BR> Acesso em: 27 out, 2021

KERAS. *In*: **Keras**. 2.6.0. [S. l.], 9 ago. 2021. Disponível em: <https://pypi.org/project/keras/>. Acesso em: 1 nov. 2021.

MINISTÉRIO DO MEIO AMBIENTE (Brasília). **Instituto Chico Mendes de Conservação da Biodiversidade**. Atlas dos Manguezais do Brasil. Brasília: [s. n.], 2018. 1 atlas.

MOREIRA Grando Benjamin. **Básico do OpenCV com Python-mostrar imagem/Galirows**. Disponível em <<https://www.galirows.com.br/meublog/blog/basico-opencv-python-mostrar-imagem/>>. Acesso em 6 set. 2021

NOVELLI, Schaeffer. **Manguezal ecossistema entre a terra e o mar**. [S. l.: s. n.], 1995.

NUMPY. 1.21.0. [S. l.], 22 jun. 2021. Disponível em: <https://numpy.org/doc/1.21/>. Acesso em: 1 nov. 2021.

OPENCV. *In*: **OpenCV: Releases**. 4.5.2. [S. l.], 19 jul. 2021. Disponível em: <https://opencv.org/releases/>. Acesso em: 1 nov. 2021.

PURNAMASAYANGSUKASIH; P. RYHMA et al. **Uma revisão dos usos de imagens de satélite no monitoramento de florestas de mangue**. Malásia. 14 abr, 2016.

PYTHON. *In*: **Python**. 3.8.1. [S. l.], 30 ago. 2021. Disponível em: <https://www.python.org/downloads/>. Acesso em: 1 nov. 2021.

RESNET50: **Rede neural convolucional ResNet-50**. MathWorks. Disponível em <<https://www.mathworks.com/help/deeplearning/ref/resnet50.html;jsessionid=291bb5d2c38d91b27caeb4f30b81>>. Acesso em 18 ago. 2021

RIBEIRO, Lucas. **Introdução a biblioteca Pandas/Medium**, 14 jul. 2020. Disponível em <<https://medium.com/tech-grupozap/introdu%C3%A7%C3%A3o-a-biblioteca-pandas-89fa8ed4fa38>>. Acesso em 23 ago 2021

ROESCHKE, Matthew. et al. **PANDAS**. 1.3.1. [S. l.], 25 jul. 2021. Disponível em: <https://pandas.pydata.org/pandas-docs/stable/whatsnew/v1.3.1.html>. Acesso em: 1 nov. 2021.

SANTANA, Sabrina. Keras: Biblioteca Python para Deep Learning. 17 jan, 2020. Disponível em: <<https://medium.com/@sabrinasantana0190/teste-e2abdbc38784>> Acesso em: 27 out, 2021.

SANTANA, Rodrigo. Tutorial Completo de Como Trabalhar com a Biblioteca Seaborn. 15 fev, 2020. Disponível em: <<https://minerandodados.com.br/tutorial-completo-de-como-trabalhar-com-a-biblioteca-seaborn>>. Acesso em: 27 out, 2021.

SANTIAGO, Junior. L. **Entendendo a biblioteca NumPy**. Medium, 30 set. 2018. Seção Ensina AI. Disponível em <<https://medium.com/ensina-ai/entendendo-a-biblioteca-numpy-4858fde63355>>. Acesso em 18 ago. 2021.

SEABORN. *In*: **Seaborn**. 0.11.2. [S. l.], 15 ago. 2021. Disponível em: <https://pypi.org/project/seaborn/>. Acesso em: 1 nov. 2021.

SKLEARN. 0.24.2. [S. l.], 1 abr. 2021. Disponível em: https://scikit-learn.org/stable/whats_new/v0.24.html. Acesso em: 1 nov. 2021.

SOARES Quimarães Samuel; RIBEIRO Maxwell Da Mata. **Redes Neurais Utilizando TensorFlow e Keras: Como facilitar o desenvolvimento de redes neurais com**

frameworks. TensorFlow e Keras, Alfenas, página inicial 1, página final 8, 20 dez. 2018
TENSORFLOW. *In:* **TensorFlow.** 2.6.0. [S. l.], 22 abr. 2021. Disponível em:
https://www.tensorflow.org/api_docs. Acesso em: 1 nov. 2021.

THECOMMONWEALTH. **Mangroves.**

Disponível em: <<https://thecommonwealth.org/mangroves>.> Acesso em: 27 out, 2021.